

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE  
MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA RECHERCHE SCIENTIFIQUE



Université des Frères Mentouri  
Constantine 1



Faculté des Sciences de la Technologie  
Département d'électrotechnique

## THESE

En vue de l'obtention du diplôme de

### Doctorat en Sciences en Electrotechnique

Spécialité: Modélisation et commande des machines électriques

Présentée par

**Bouguerne Abla**

Magistère en Electrotechnique de l'Université de Constantine 1

THEME

---

◇

## Classification automatique des défauts des moteurs asynchrones

---

◇

*Soutenu le : 02 / 02 / 2017*

*Devant le Jury :*

Bouzid aïssa	Président	Professeur	Univ. Constantine1
Lebaroud abdesslam	Rapporteur	Professeur	E.N.P_Constantine 3
Kaikaa mohamed yazid	Examineur	Maître de Conférences	Univ. Constantine 1
Medoued ammar	Examineur	Maître de Conférences	Univ. Skikda
Mordjaoui mourad	Examineur	Maître de Conférences	Univ. Skikda

# *Dédicaces*

*Je dédie ce travail à :*

*A ma mère et grand mère et Mon défunt père (Rahimhou Allah)*

*A mon mari et mes enfants*

*A mes sœurs et frères*

*A ma grande famille (Bouguerne et Boukadoum )*

*A mes collègues*

*A ceux qui m'éprouvent une véritable amitié.*

**Abla BOUGUERNE**

# REMERCIEMENTS

Qu'il me soit d'abord permis de remercier et d'exprimer ma gratitude envers le bon Dieu « Alah Azza wa Djella »

Je tiens à exprimer toute ma reconnaissance et ma gratitude à mon Directeur de thèse, Monsieur **LEBAROUD Abdesselam**, Professeur à l'école nationale polytechnique de Constantine, pour avoir dirigé le travail de cette thèse. Qu'il soit remercié pour ses qualités humaines et scientifiques. Je le remercie aussi pour ses encouragements incessants, ses précieux conseils et pour avoir su me prodiguer le savoir tout au long de la réalisation de cette thèse.

Je tiens à remercier Monsieur **BOUZID Aissa**, Professeur au département d'électrotechnique de l'université de Constantine 1, pour l'honneur qu'il m'a fait en acceptant la présidence du jury de cette thèse.

J'exprime toute ma reconnaissance à Monsieur **KAIKAA Mohamed Yazid**, maître de conférences au département d'électrotechnique de l'université de Constantine 1, d'avoir accepté d'examiner mon travail de thèse et d'être membre de mon jury de soutenance.

Je tiens à remercier aussi, Monsieur **MEDOUED Ammar**, maître de conférences au département de génie électrique de l'université de Skikda de m'avoir fait l'honneur d'examiner mon travail et d'être membre de jury de ma thèse de doctorat.

J'exprime également ma profonde reconnaissance et mes sincères remerciements à Monsieur **MORDJAOUI Mourad**, maître de conférences au département de génie électrique de l'université de Skikda d'avoir accepté d'examiner ce travail et à participer au jury de soutenance.

Enfin, mes remerciements s'adressent à toute personne ayant, de près ou de loin, aidé à l'aboutissement de ce travail.

.

.

## RESUME DE THESE

Titre: *Classification automatique des défauts des moteurs asynchrones*

Doctorante : **Mme BOUGUERNE Abla**

Directeur de Thèse: **Pr. LEBAROUD Abdesselam**

Le diagnostic des défauts de roulements à billes dans les machines électriques a connu des avancées très importantes ces dernières années. La plupart des études sont portés sur l'approche dite "signal" à savoir le diagnostic et la détection des défauts de roulements utilisant des mesures vibratoires issues de capteurs placés au plus près des éléments mécaniques à surveiller. Dans cette thèse, nous avons privilégié l'approche système à savoir la classification automatique des défauts de roulement de la machine asynchrone à cage d'écureuil.

L'approche proposée repose sur cinq étapes: La première étape utilise la décomposition du mode empirique pour séparer chaque signal vibratoire dans les différentes fonctions du mode intrinsèque, où chaque mode se trouve dans une bande de fréquence spécifique. La deuxième étape extrait l'amplitude de l'enveloppe et les fréquences instantanées pour chaque mode afin d'identifier sa bande de fréquence en calculant le spectre marginal Hilbert. La troisième étape, la phase d'extraction de caractéristique est réalisée par l'utilisation de l'opérateur d'énergie Teager- Kaiser (TKEO). Dans la quatrième étape, nous avons optimisé les vecteurs formes extraits à partir de l'optimisation par essaim de particules. Finalement, l'étape finale, concerne la classification automatique des vecteurs optimisés, par le biais de l'algorithme de modèle de mélange Gaussien. Ce dernier permet de rendre la pertinence des attributs et leur sélection complètement automatique.

UNIVERSITY OF CONSTANTINE 1-  
FACULTY OF TECHNOLOGY SCIENCES  
DEPARTMENT OF ELECTRICAL ENGINEERING

## **Abstract Thesis**

**Title:** « Automatic Classification of Asynchronous Motors Faults »

**Student:** Abla Bouguerne

**Supervisor:** Pr. Abdesselam Lebaroud

The diagnosis of bearings defects in electric machines has become an important area of research in recent years. Most studies on the detection of bearing faults using vibration measurements descended from sensors placed close to the mechanical elements to be monitored. For this reason, the work of this thesis focused on the automatic classification of bearing defects of the asynchronous machine with squirrel cage.

We proposed a clustering approach to bearing defects. This approach is based on five steps: The first step uses the decomposition of the empirical method to separate each vibration signal in the different intrinsic mode functions, where each mode is in a specific frequency band. The second step extracts amplitudes and instantaneous frequencies for each mode in order to identify its frequency band by calculating the Hilbert marginal spectrum. The third step, the feature extraction phase is carried out by using the energy operator Teager-Kaiser (TKEO) .In the fourth step, vectors forms extracted was optimized from optimization by particle swarm which is a stochastic optimization method developed, based on the reproduction of social behavior. Finally, the final step relates to the automatic classification of optimized vectors that can be achieved through the Gaussian mixture model algorithm. This will make the relevance of attributes and automatically selection and classification of bearings defects in asynchronous electric machines.

# جامعة قسنطينة 1

## كلية علوم التكنولوجيا

### قسم الالكتروتقني

## ملخص أطروحة الدكتوراه

عنوان المذكرة: التصنيف الآلي لأعطال المحركات اللاتزامنية

طالبة الدكتوراه: بوقرن عبلة

إشراف البروفيسور: لبارود عبد السلام

أصبح تشخيص أعطال المدحرجات بكرة في الآلات الكهربائية اللا تزامنية مجالاً هاماً من البحوث في السنوات الأخيرة. معظم الدراسات للكشف عن أعطال هذه المدحرجات تتضمن استخدام قياس الاهتزاز وذلك بوضع أجهزة الاستشعار (اللاقط) على مقربة من العناصر الميكانيكية التي يتعين مراقبتها. لهذا السبب، تركز عمل هذه الأطروحة على التصنيف الآلي لأعطال المدحرجات بكرة في الآلات الكهربائية.

اقترحنا لانجاز هذا العمل طريقة آلية لتصنيف أعطال المدحرجات بكرة. وترتكز طريقة هذا العمل على خمس خطوات: تستخدم الخطوة الأولى أسلوب التحلل الأميري لفصل مختلف الخواص الجوهرية لكل إشارة اهتزاز، حيث أن كل خاصية لها مجال ترددات محدد. الخطوة الثانية وتتضمن تعيين السعات السطحية والترددات لحظية لكل خاصية بعد تحديد المجال الترددي لكل منها من خلال تحليل الطيف بواسطة تحويل هيلبرت. الخطوة الثالثة، ويتم في هذه المرحلة استخراج الخواص المميزة من خلال استخدام العامل الطاقوي لتيفر و كايسر. ويتم في الخطوة الرابعة تحسين الأشعة الشكلية المستخرجة من خلال طريقة التحسين سرب الجسيمات التي هي طريقة عشوائية أساسها إعادة إنتاج السلوك الاجتماعي وتطويرها. الخطوة الأخيرة تتعلق بالتصنيف الآلي للأشعة الشكلية التي يمكن تحقيقها من خلال خوارزمية نموذج الخليط لغوس. وهذه الأخيرة تمكننا من استرجاع الخواص و آلية الاختيار والتصنيف لأعطال المدحرجات بكرة في الآلات الكهربائية اللا تزامنية.

## LISTE DES ACRONYMES

<b>Abréviation</b>	<b>Désignation</b>
TFD	Transformée de Fourier discrète
WT	Transformée en ondelettes
WVD	Distribution de Wigner-Ville
HHT	transformée de Hilbert Huang
THT	Transformation de Teager- Huang
IA	Intelligence artificielle
RdF	Reconnaissance des formes
CAH	Classification ascendante hiérarchique
KM	K-moyennes
<b>KNN</b>	k plus proches voisins
SC	Spectral Clustering
DBSCAN	density-based spatial clustering of applications with noise
FKM	K-moyennes floues
EM	Estimation/Maximisation
AFC	Analyse Factorielle des Correspondances
LSI	Latent Semantic Indexing
ACC	Analyse en composantes curvilignes
ACP	Analyse en composantes principales
TF	Transformée de Fourier
TFFG	Transformée de Fourier à fenêtre glissante
TKEO	Opérateur d'énergie Teager- Kaiser
BI	Bague intérieure
BE	Bague extérieure
SANC	Self Adaptative Noise Cancelation
RMS	Root Mean Square
IMF	Fonctions du mode intrinsèques
EMD	décomposition en mode empirique
AI	Amplitude instantanée
FI	fréquence instantanée

## **LISTE DES FIGURES**

### **CHAPITRE I**

Figure. 1.1	Structure générale d'un système de diagnostic [Tos 05]	07
Figure. 1.2	Différentes étapes du diagnostic [Tos 05]	10
Figure. 1.3	Classification des méthodes de diagnostic [Tos 05]	13
Figure. 1.4	Principe de technique d'estimation d'état	14
Figure. 1.5	Principe de technique de génération de résidus	14
Figure. 1.6	Principe des techniques d'identification	15
Figure. 1.7	Partition des outils de classification	20
Figure. 1.8	Différentes étapes du processus de classification automatique [Cle]	23
Figure. 1.9	Approches de classification automatique	29
Figure. 1.10	Schéma de la structure du processus de classification	38
Figure. 1.11	Principe de la sélection de variables	40
Figure. 1.12	Principe de l'extraction de caractéristiques	40

### **CHAPITRE II**

Figure. 2.1	Constitution d'un roulement à billes	44
Figure 2.2	Bases de calcul et déplacement radial et axial d'une bague par rapport à l'autre	45
Figure. 2.3	Bases de calcul	45
Figure. 2.4	Repères de référence du roulement à billes	48
Figure. 2.5	Centre de courbure et forces extérieures appliquées sur une bille	48
Figure. 2.6	Déplacement axiaux et radiaux du centre de courbure de la bague intérieure et du centre de la bille	50
Figure. 2.7	Basculement de la bague extérieure par rapport à la bague intérieure	51
Figure. 2.8	Répartition du taux de panne dans les machines asynchrones	53
Figure. 2.9	Structure d'un roulement à billes	58

Figure. 2.10	Spectrogramme d'un signal vibratoire $x(t)$	62
Figure. 2.11	Distribution de Wigner-Ville (DWV) pour un signal vibratoire $x(t)$	63
Figure. 2.12	Etude des interférences sur un signal vibratoire	64
Figure. 2.13	Ondelette de Morlet	65
Figure. 2.14	FFTs de dernière approximation on l'utilise l'ondelette Daubechies	67
Figure. 2.15	Signal vibratoire $x(t)$	69
Figure. 2.16	Processus de tamisage : Le signal original, l'enveloppe supérieure et inférieure, et l'enveloppe moyenne	70
Figure. 2.17	Première composante de $x(t)$	70
Figure. 2.18	Organigramme du processus de décomposition en mode empirique	72

### **CHAPITRE III**

Figure. 3.1	Montage expérimental pour la surveillance des vibrations	77
Figure. 3.2	Schéma de système expérimental	77
Figure. 3.3	Signaux temporels vibratoires de l'état sain	82
Figure. 3.4	Signaux temporels vibratoires des défauts de roulement coté accouplement avec 12.000 pts/s	83
Figure. 3.5	Signaux temporels vibratoires des défauts de roulement coté accouplement avec 48.000 pts/s	83
Figure. 3.6	Signaux temporels vibratoires des défauts de roulement coté ventilateur 12.000 pts/s	84
Figure. 3.7	Décomposition en mode empirique de roulement sain à vide	86
Figure. 3.8	Décomposition en mode empirique de roulement sain en charge	86
Figure. 3.9	Décomposition en mode empirique du défaut de bague intérieure à vide	87
Figure. 3.10	Décomposition en mode empirique du défaut de bague intérieure en charge	87
Figure. 3.11	Décomposition en mode empirique du défaut de bille à vide	88
Figure. 3.12	Décomposition en mode empirique du défaut de bille en charge	88
Figure. 3.13	Décomposition en mode empirique du défaut de bague extérieure à accéléromètre centré à vide	89

## Liste des figures

---

Figure.3.14	Décomposition en mode empirique du défaut de bague extérieure à accéléromètre centré en charge	89
Figure.3.15	Décomposition en mode empirique du défaut de bague extérieure à accéléromètre orthogonal à vide	90
Figure.3.16	Décomposition en mode empirique du défaut de bague extérieure à accéléromètre orthogonal en charge	90
Figure. 3.17	Décomposition en mode empirique du défaut de bague extérieure à accéléromètre opposé à vide	91
Figure. 3.18	Décomposition en mode empirique du défaut de bague extérieure à accéléromètre opposé en charge	91
Figure. 3.19	Analyse spectrale de Hilbert de roulement sain à vide: haut et moyenne fréquence	93
Figure. 3.20	Analyse spectrale de Hilbert de roulement sain en charge: haut et moyenne fréquence	94
Figure. 3.21	Analyse spectrale de Hilbert du défaut de bague intérieure à vide : haut et moyenne fréquence	95
Figure. 3.22	Analyse spectrale de Hilbert du défaut de bague intérieure en charge: haut et moyenne fréquence	95
Figure. 3.23	Analyse spectrale de Hilbert du défaut de bille à vide: haut et moyennes fréquence	97
Figure. 3.24	Analyse spectrale de Hilbert du défaut de bille en charge: haut et moyennes fréquence	97
Figure. 3.25	Analyse spectrale de Hilbert du défaut de bague extérieure à accéléromètre centré à vide: haut et moyenne fréquence	99
Figure. 3.26	Analyse spectrale de Hilbert du défaut de bague extérieure à accéléromètre centré en charge: haut et moyenne fréquence	99
Figure. 3.27	Analyse spectrale de Hilbert du défaut de bague extérieure à accéléromètre orthogonal à vide : haut et moyenne fréquence	101
Figure. 3.28	Analyse spectrale de Hilbert du défaut de bague extérieure à accéléromètre orthogonal en charge: haut et moyenne fréquence	101
Figure. 3.29	Analyse spectrale de Hilbert du défaut de bague extérieure à accéléromètre opposé à vide: haut et moyenne fréquence	103

## *Liste des figures*

---

Figure. 3.30	Analyse spectrale de Hilbert du défaut de bague extérieure à accéléromètre opposé en charge: haut et moyenne fréquence	103
Figure. 3.31	TKEO des signaux de roulement sain à vide	106
Figure. 3.32	TKEO des signaux de roulement sain en charge	106
Figure. 3.33	TKEO des signaux du défaut de bague intérieure à vide	107
Figure. 3.34	TKEO des signaux du défaut de bague intérieure en charge	107
Figure. 3.35	TKEO des signaux du défaut de bille à vide	108
Figure. 3.36	TKEO des signaux du défaut de bille en charge	108
Figure. 3.37	TKEO des signaux du défaut de bague extérieure à accéléromètre centré à vide	109
Figure. 3.38	TKEO des signaux du défaut de bague extérieure à accéléromètre centré en charge	109
Figure. 3.39	TKEO des signaux du défaut de bague extérieure à accéléromètre orthogonal à vide	110
Figure. 3.40	TKEO des signaux du défaut de bague extérieure à accéléromètre orthogonal en charge	110
Figure. 3.41	TKEO des signaux du défaut de bague extérieure à accéléromètre opposé à vide	111
Figure. 3.42	TKEO des signaux du défaut de bague extérieure à accéléromètre opposé en charge	111

## **CHAPITRE VI**

Figure. 4.1	Organigramme de la méthode des essais particuliers [Bom 11]	117
Figure. 4.2	Représentation des mises à jour de vitesse et de position par l'optimisation d'essai particulière	119
Figure. 4.3	vecteur forme de roulement sain (coté accouplement) : avant et après optimisation	121
Figure. 4.4	vecteur forme de roulement sain (coté ventilateur) : avant et après optimisation	121
Figure. 4.5	Vecteur forme par l'algorithme du défaut de bague intérieur (coté accouplement) : avant et après optimisation	122

## Liste des figures

---

Figure. 4.6	Vecteur forme par l’algorithme du défaut de bague intérieure (coté ventilateur) : avant et après optimisation	122
Figure. 4.7	Vecteur forme du défaut de la bille (coté accouplement): avant et après optimisation	123
Figure. 4.8	Vecteur forme du défaut de la bille (coté ventilateur) : avant et après optimisation	123
Figure. 4.9	Vecteur forme du défaut de bague extérieure à accéléromètre centré (coté accouplement) : avant et après optimisation	124
Figure 4.10	Vecteur forme du défaut de bague extérieure à accéléromètre centré (coté ventilateur) : avant et après optimisation	124
Figure 4.11	Vecteur forme du défaut de bague extérieure à accéléromètre orthogonal (coté accouplement) : avant et après optimisation	125
Figure 4.12	Vecteur forme du défaut de bague extérieure à accéléromètre orthogonal (coté ventilateur) : avant et après optimisation	125
Figure 4.13	Vecteur forme du défaut de bague extérieure à accéléromètre opposé (coté accouplement) : avant et après optimisation	126
Figure 4.14	Vecteur forme du défaut de bague extérieure à accéléromètre opposé (coté ventilateur) : avant et après optimisation	126
Figure.4.15	Représentation des vecteurs formes caractéristiques (coté accouplement)	141
Figure.4.16	Classification des vecteurs formes (Coté accouplement)	142
Figure.4.17	Représentation des vecteurs formes caractéristiques (coté ventilateur)	143
Figure.4.18	Classification des vecteurs formes (coté ventilateur)	143
Figure.4.19	Evolution des défauts de roulement suivant la sévérité (Coté accouplement à vide)	146
Figure.4.20	Evolution des défauts de roulement suivant la sévérité (Coté accouplement à charge)	146
Figure.4.21	Evolution des défauts de roulement suivant la sévérité (Coté ventilateur à vide)	147
Figure.4.22	Evolution des défauts de roulement suivant la sévérité (Coté ventilateur à charge)	147

## LISTE DES SYMBOLES

Symboles	Nomination
$\Omega$	Classe d'appartenance
$c_k$	k <sup>ième</sup> prototype
$J_m$	critère générique
$u_i$	degrés d'appartenance
$v_i$	centres d'appartenance
$L_c$	log-vraisemblance complétée
$\varphi_k$	densité de probabilité
$p_k$	proportions du mélange
$\theta$	vecteur des paramètres du mélange
$\delta_{axial}, \delta_{radial}$	déplacements axiaux et radiaux
$\delta_1, \delta_2$	déplacements partiels de chacune des bagues.
Fc	force centrifuge
$K_b$	rigidité axiale
$F_{axial}, F_{radial}$	efforts sur le roulement
$\gamma$	angle de basculement
$N_i, N_e$	déplacements des nœuds
$[R_\psi]$	matrice de rotation du modèle de De Mul
$\vec{u}_{B_0}$	matrice de raideur tangente
$f_c$	Fréquence de défaut de cage
$f_{er}$	Fréquence de défauts des éléments roulants
$f_{bi}$	Fréquence de défaut de la bague intérieure
$f_{be}$	Fréquence de défaut de la bague extérieure
f <sub>i</sub>	Fréquence de rotation de la bague intérieure
f <sub>e</sub>	Fréquence de rotation de la bague extérieure
d	Diamètre des éléments roulants
Z	Nombre des éléments roulants.
$E_x$	densité d'énergie
$\bar{\Psi}(t)$	ondelette mère
TOC	coefficients d'ondelettes
$\mathcal{G}(t)$	fonction d'échelle
$x_{up}(t)$	enveloppe supérieure du signal
$x_{low}(t)$	enveloppe inférieure du signal
$p_{10}$	première composante
$r_n$	résidu
$\tau$	coefficient de corrélation

$a_i(t)$	amplitude instantanée
$\theta_i(t)$	phase instantanée
Re	partie réelle
$H$	distribution temps-fréquence
$\Psi$	opérateur d'énergie Teager- Kaiser
$F(n)$	fréquence instantanée de l'enveloppe du signal
$A(n)$	amplitude instantanée de l'enveloppe du signal
$V_K, V_{K+1}$	vitesses de la particule aux itérations $K$ et $K + 1$ .
$best_{particule}$	meilleure position de la particule
$best_{voisin}$	meilleure position de son voisinage à l'itération $K$
$position_{particule}$	position de la particule à l'itération $K$
$c_1, c_2, c_3$	coefficients fixés
$h(\cdot \lambda_k)$	distribution gaussienne
$\mu_k$	moyenne de la distribution
$\Sigma_k$	matrice de covariance.
$p_k$	poids de la distribution

## **LISTE DES TABLEAUX**

Tableau.1.1	Différents types d'approches de classification	37
Tableau.3.1	Caractéristiques du roulement à billes à gorge profonde	78
Tableau.3.2	Fréquences de défauts du roulement	78
Tableau.3.3	Caractéristiques des défauts de roulements à billes à gorge profonde	79
Tableau.3.4	Base de données des signaux vibratoires du roulement	81
Tableau.3.5	IMFs sélectionné pour chaque mode d'entraînement	92
Tableau.3.6	Fréquences et amplitudes des signaux de roulement à l'état sain	94
Tableau.3.7	Fréquences et amplitudes du défaut de bague intérieure	96
Tableau.3.8	Fréquences et amplitudes du défaut de bille	98
Tableau.3.9	Fréquences et amplitudes du défaut de bague extérieure à accéléromètre centré	100
Tableau.3.10	Fréquences et amplitudes du défaut de bague extérieure à accéléromètre orthogonal	102
Tableau.3.11	Fréquences et Amplitudes du défaut de bague extérieure à accéléromètre opposé	104
Tableau.4.1	Variables initialisent de l'algorithme PSO	120
Tableau.4.2	Valeurs initiales et estimées des paramètres de modèle GMM ainsi que le taux de classification (Coté accouplement)	139
Tableau.4.3	Valeurs initiales et estimées des paramètres de modèle GMM ainsi que le taux de classification (coté ventilateur)	140
Tableau.4.4	Modes de fonctionnement	145

---

**TABLE DES MATIERES****Résumé****Liste des acronymes****Liste des figures****Liste des symboles****Liste des tableaux****Introduction générale** **01****CHAPITRE I*****ETAT DE L'ART : DETECTION, DIAGNOSTIC ET CLASSIFICATION DES DEFAUTS  
DES MOTEURS ASYNCHRONES***

<b>1.1 Introduction</b>	<b>5</b>
<b>1.2 Détection, diagnostic et classification</b>	<b>6</b>
<b>1.3 Principes de base du diagnostic</b>	<b>6</b>
<b>1.3.1 Notion de base du diagnostic</b>	<b>7</b>
<b>1.3.2 Définitions</b>	<b>8</b>
<b>1.3.3 Différentes étapes du diagnostic</b>	<b>10</b>
<b>1.3.3.1 Acquisition des données</b>	<b>10</b>
<b>1.3.3.2 Étape d'élaboration d'indicateurs de défauts</b>	<b>11</b>
<b>1.3.3.3 Étape de détection</b>	<b>11</b>
<b>1.3.3.4 Étape de localisation</b>	<b>11</b>
<b>1.3.3.5 Etape de prise de décision</b>	<b>12</b>
<b>1.3.4 Méthodes de diagnostic</b>	<b>12</b>
<b>1.3.4.1 Méthodes de diagnostic avec modèle analytique</b>	<b>13</b>
<b><i>1.3.4.1.1 Techniques d'estimation d'état</i></b>	<b>14</b>
<b><i>1.3.4.1.2 Techniques de génération de résidus</i></b>	<b>14</b>
<b><i>1.3.4.1.3 Techniques d'identification</i></b>	<b>15</b>
<b>1.3.4.2 Méthodes de diagnostic sans modèle analytique</b>	<b>16</b>
<b>1.3.4.2.1 Méthode par traitement de signal</b>	<b>16</b>
<b>1.3.4.2.2 Méthodes par intelligence artificielle (IA)</b>	<b>17</b>
<b>1.4 Classification</b>	<b>19</b>
<b>1.4.1 Définition</b>	<b>19</b>
<b>1.4.2 Objectif de la classification</b>	<b>19</b>

<b>1.4.3 outils de classification</b>	<b>20</b>
<b>1.4.3.1 Classification supervisée</b>	<b>21</b>
<b>1.4.3.2 Classification non supervisée</b>	<b>22</b>
<b>1.4.4 Etapes du Classification non supervisée (clustering)</b>	<b>23</b>
<b>1.4.4.1 Préparation des données</b>	<b>23</b>
<b>1.4.4.1.1 Variables et sélections</b>	<b>23</b>
<b>1.4.4.1.2 Distances et similarités</b>	<b>24</b>
<b>1.4.4.2 Choix de l'algorithme</b>	<b>25</b>
<b>1.4.4.2.1 Taille des données</b>	<b>25</b>
<b>1.4.4.2.2 Nature des données</b>	<b>26</b>
<b>1.4.4.2.3 Forme des clusters</b>	<b>26</b>
<b>1.4.4.2.4 Type de résultats attendus</b>	<b>27</b>
<b>1.4.4.3 Exploitation des clusters</b>	<b>27</b>
<b>1.4.5 Approches de classification</b>	<b>28</b>
<b>1.4.5.1 Approches hiérarchiques</b>	<b>29</b>
<b>1.4.5.2 Approches partitives</b>	<b>31</b>
<b>1.4.5.2.1 Approches basées sur les prototypes</b>	<b>31</b>
<b>1.4.5.2.2 Approches basées sur la densité ou voisinage</b>	<b>32</b>
<b>1.4.5.3 Approches floues et probabilistes</b>	<b>34</b>
<b>1.4.5.3.1 K-moyennes floues (FKM )</b>	<b>35</b>
<b>1.4.5.3.2 Modèle de mélange</b>	<b>36</b>
<b>1.5 Approche proposée : Reconnaissance des formes par THT</b>	<b>38</b>
<b>1.6 Conclusion</b>	<b>422</b>

## *CHAPITRE II*

### *LES ROULEMENTS A BILLES : CONSTITUTION, DEFAILLANCES*

#### *ET ANALYSE VIBRATOIRE*

<b>2.1 Introduction</b>	<b>43</b>
<b>2.2 Roulements à billes</b>	<b>44</b>
<b>2.2.1 Constitution de Roulements à billes</b>	<b>44</b>
<b>2.2.2 Modèles de roulement</b>	<b>45</b>
<b>2.2.2.1 Modèle de Palmgrem</b>	<b>45</b>
<b>2.2.2.2 Modèle de De Mul</b>	<b>47</b>

---

2.2.2.3 Modèle de Bourdon	51
2.3 Défauts de roulement et techniques de détection	53
2.3.1 Statistique	53
2.3.2 Défauts de roulement	53
2.3.2 Techniques de détection des défauts de roulement	54
2.4 Analyse vibratoire	55
2.4.1 Outils de l'analyse vibratoire	56
2.4.1.1 Capteur de vibrations	56
2.4.1.2 Conditionnement du signal	56
2.4.1.3 Matériel de traitement	57
2.4.2 Caractéristiques du signal engendré par le roulement	57
2.4.3 Prétraitements des signaux	59
2.4.4 Méthodes d'analyse vibratoire	59
2.4.4.1 Indicateurs temporels	60
2.4.4.2 Résolution temps-fréquence dans la TFFG	61
2.4.4.3 Distribution de Wigner-Ville	63
2.4.4.4 Transformée en ondelettes	65
2.4.4.5 Transformée de Hilbert-Huang	68
2.4.4.5.1 Décomposition en mode empirique (EMD)	68
2.4.4.5.2 Analyse spectrale de Hilbert	73
2.4.4.6 Extraction de caractéristique par TKEO	74
2.5 Conclusion	75

### *CHAPITRE III*

#### *APPLICATION AU SIGNAUX VIBRATOIRES DES MOTEURS ASYNCHRONES*

3.1 Introduction	76
3.2. Essais expérimentales	76
3.2.1 Description de bancs d'essais	77
3.2.2 Identification des roulements utilisés	78
3.2.3 Acquisition de données	80
3.2.4 Représentation des signaux temporels	81
3.2.5 Normalisation des données	84
3.3 Prétraitement des signaux vibratoires	85
3.3.1 Décompositions en mode empirique des signaux vibratoires	85

---

3.3.2 Sélection des IMFs	92
3.3.3 Analyse spectral de Hilbert des IMFs	93
3.3.3.1 Analyse spectral de Hilbert à l'état sain	93
3.3.3.2 Analyse spectral de Hilbert du défaut de bague intérieure	95
3.3.3.3 Analyse spectral de Hilbert du défaut de bille	97
3.3.3.4 Analyse spectral de Hilbert du défaut de bague extérieure	99
3.3.3.5 Interprétation des résultats	104
3.3.4 Extraction de caractéristique par TKEO	105
3.4 Conclusion	112
<i>CHAPITRE VI</i>	
<i>OPTIMISATION ET CLASSIFICATION AUTOMATIQUE</i>	
4.1 Introduction	113
4.2 Optimisation par essaim particulaire (PSO)	114
4.2.1 Eléments de la P.S.O	114
4.2.2 Principe fondamental	115
4.2.3 Algorithme de principe	116
4.2.4 Etapes de l'algorithme PSO	117
4.2.5 Applications de PSO pour l'optimisation des vecteurs formes	120
4.2.5.1 Optimisation par PSO du vecteur forme de roulement sain	120
4.2.5.2 Optimisation par PSO du vecteur forme des défauts de roulement	122
4.3 Classification automatique (non supervisée)	127
4.3.1 Eléments de classification automatique	128
4.3.2 Modèle de mélange gaussien	129
4.3.2.1 Décomposition de la matrice des variances	130
4.3.2.2 Estimation des paramètres	132
4.3.2.2.1 Étape estimation	134
4.3.2.2.2 Étape Maximisation	135
4.3.2.2.3 Étape classification	136
4.3.3 Application à la classification des vecteurs formes	137
4.4 Evolution des modes de fonctionnement	144
4.5 Conclusion	148
Conclusion générale	149
Bibliographie	151

## **INTRODUCTION GENERALE**

La machine asynchrone est largement utilisée dans le secteur industriel grâce à son faible coût, sa robustesse et ses performances statiques et dynamiques. Toutefois, il est important de développer des systèmes de diagnostic pour détecter de manière précoce les défauts éventuels qui peuvent être causés par cette machine. Ces défauts sont d'origines différentes, soient de nature mécanique, électrique ou magnétique. Cependant, statistiquement les défauts de roulements à billes sont les causes principales de ces défaillances car ils sont sensibles aux conditions environnementales et d'exploitation de la machine. Par ailleurs, des modes de fonctionnement dégradés peuvent apparaître durant la vie de la machine. Par conséquent un diagnostic de pannes est devenu incontournable. Afin d'améliorer la sûreté de fonctionnement et d'entraînement de la machine, des méthodes de surveillance peuvent être mise en place afin d'assurer une maintenance préventive.

Dans le diagnostic des machines rotatives, l'analyse des vibrations est largement utilisée. Les vibrations sont une caractéristique inhérente des machines rotatives et les différentes composantes de ce type de machines telles que les arbres, les roulements et les engrenages produisent de l'énergie vibratoire avec différentes caractéristiques. N'importe quelle détérioration de l'état de telles composantes peut affecter leurs propriétés vibratoires et se manifester par conséquent dans la signature de vibration. Ceci est valable pour le diagnostic des défauts en analysant la signature des vibrations du système.

De manière générale, Le diagnostic des systèmes peut être considéré comme une phase importante de classification supervisée. La supervision des systèmes correspond à établir l'état présent du système pour pouvoir prendre des décisions et pouvoir maintenir des critères de performance (qualité, rentabilité, sûreté, etc.) du système afin de vérifier que le système ne s'écarte pas leur point de fonctionnement. Il est donc, possible de considérer que la détection des défauts comme une classification supervisée. En effet, la détection peut être vue comme une classification en deux classes: fonctionnement normal de la machine, et respectivement fonctionnement anormal de la machine.

Le diagnostic peut être vu comme une extension de la détection pour le cas où le nombre de classes est supérieure à deux. Ainsi, dans le cas d'un fonctionnement anormal détecté, on peut s'intéresser à savoir quelle faute s'est produite. Cependant, les classifications pour le diagnostic se différencient en classification supervisée et non-supervisée.

- Dans le premier cas, les frontières de séparation des classes sont déduites sur la base d'un échantillon d'individus pour lesquels on connaît l'appartenance aux différentes classes.
- Dans le cas de la classification non-supervisée, les frontières de séparation sont obtenues suivant certains principes (tels que l'homogénéité des classes ou bien la distance aux différents voisins) à partir des données disponibles et sans aucune information concernant l'appartenance des individus aux différentes classes [Ver 07].

Le choix d'une méthode de diagnostic est basé sur la complexité du système ou bien sur la disponibilité de la connaissance acquérir sur lui. Pour surpasser ce problème, on convient de développer d'une approche de diagnostic à base des méthodes de classification non supervisée. La classification non supervisée, ou clustering, est un outil très performant pour la détection automatique de sous-groupes pertinents (ou clusters) dans un jeu de données, lorsqu'on n'a pas de connaissances à priori sur la structure interne de ces données. Les membres d'un même cluster doivent être similaires entre eux, contrairement aux membres de clusters différents (homogénéité interne et séparation externe). La classification non supervisée joue un rôle indispensable pour la compréhension de phénomènes variés décrits par des bases de données [Ver 07].

L'accroissement incessant de la complexité des systèmes automatiques a fait en sorte que la tâche de la surveillance devienne de plus en plus moins aisée. De ce fait, les systèmes peuvent fonctionner en plusieurs modes. Certains de ces modes correspondent à un fonctionnement normal et d'autres représentent des modes défectueux. En outre, nous pouvons être confronté à des modes inconnus qui n'ont jamais été observés sur le système auparavant (modes imprévisibles).

Le travail de cette thèse s'inscrit dans le domaine de la classification automatique des défauts éventuels d'une machines asynchrones triphasé, plus particulièrement la mise en œuvre d'une approche de classification non supervisée des défauts du roulement.

En effet, l'objectif principal de cette étude est le développement d'une nouvelle approche de diagnostic à base de reconnaissance de forme par la transformation de Huang-Teager et du modèle de mélange gaussien (GMM). Cette approche est fondée sur l'extraction des caractéristiques à partir de traitement des signaux mesurés. Dans notre cas nous nous intéressons aux signaux vibratoires issus du moteur asynchrone en l'occurrence le défaut du roulement. Ces signaux peuvent fournir des informations significatives sur l'état de fonctionnement du système.

Ce travail de thèse s'articule autour de quatre chapitres :

**Le premier chapitre** présente un état de l'art sur les approches de diagnostic et de la classification. A cet effet, une classification non exhaustive des méthodes de diagnostic a été présentée et détaillée. Dans un deuxième temps, il a été proposé une classification automatique simple, ainsi que certains algorithmes associés. Les différents algorithmes classiques de classification ont été organisés selon les approches hiérarchiques, partitives, génératives, floues et probabilistes. A la fin, de ce chapitre il a été proposé une approche automatique basée sur l'algorithme du modèle de mélange Gaussien (GMM) pour la classification des défauts des moteurs asynchrones plus particulièrement les défauts de roulements.

**Le deuxième chapitre** concerne l'étude des défauts de roulement et leurs influences sur la signature vibratoire. Dans un premier temps un rappel sur les principaux modèles de roulement proposés dans la littérature. Dans un second temps une investigation sur les outils de traitement de signal pour la surveillance vibratoire, à savoir la distribution de Wigner-ville, la transformation on ondelette et finalement l'outil privilégié à savoir la transformation de Hilbert Huang.

**Le troisième chapitre** propose une méthode de prétraitement des données vibratoires permettant d'augmenter significativement les valeurs des amplitudes pertinentes. Ceci afin d'avoir une bonne sélection des vecteurs formes caractéristiques à chaque type de défaut.

Cette méthode a été appliquée à des signaux vibratoires issus des roulements du moteur. Six états de roulement ont été traités à savoir l'état sain, défaut de bague intérieure, défaut de bille et de défaut de bague extérieure à accéléromètre centré, orthogonal ou opposé, selon la position de l'accéléromètre.

Dans le **quatrième et dernier chapitre**, l'optimisation par l'algorithme PSO des vecteurs formes a permis de réduire de quatre fois la taille initiale des ces vecteurs que ce soit coté accouplement ou coté ventilateur. Les vecteurs optimisés ont facilités le processus de la classification automatique par l'application de l'algorithme de modèle de mélange gaussien (GMM). Les modèles de mélange apparaissent encore comme une approche suffisamment flexible et rigoureuse pour apporter des réponses pertinentes. Cet algorithme a prouvé sa robustesse et son efficace lors de la classification non supervisée de six classes à savoir roulement sain, défaut de bague intérieure, défaut de la bille et défaut de bague extérieure à accéléromètre centré, orthogonal et opposé. L'algorithme GMM a permis de maximiser la séparabilité inter-classe et de minimiser la compacité intra-classe.

# **CHAPITRE I**

## **ETAT DE L'ART : DETECTION, DIAGNOSTIC ET CLASSIFICATION DES DEFAUTS DES MOTEURS ASYNCHRONES**



## **CHAPITRE I**

### **ETAT DE L'ART : DETECTION, DIAGNOSTIC ET CLASSIFICATION**

#### **DES DEFAUTS DES MOTEURS ASYNCHRONES**

##### **1.1 Introduction**

Aujourd'hui, le concept d'automatisation des processus inclue plusieurs aspects globaux. L'automatisation de nos jours ne s'attache pas seulement au maintien de quelques variables à des valeurs de référence, elle s'intéresse au procédé dans sa globalité et dans ses divers. L'automatisation s'effectue grâce à un système numérique de contrôle commande et peut avoir des objectifs divers. Une première catégorie d'objectifs concerne les performances du système de production, une deuxième catégorie qui prend de plus en plus d'importance, est la sûreté du fonctionnement [GEN07]. Les objectifs de sûreté de fonctionnement et de continuité de service des entraînements électriques ont motivé l'enjeu scientifique et économique de la surveillance et le diagnostic des machines électriques. De nombreuses approches et procédures de diagnostic sont développées par les différentes communautés de recherche en automatique, productique et intelligence artificielle, en vue de la détection des défaillances et du diagnostic.

Dans ce contexte, ce chapitre présente un état de l'art sur les approches de diagnostic et de la classification. A cet effet, on présente une classification non exhaustive des méthodes de diagnostic. Dans un deuxième temps, nous allons présenter la classification automatique simple, ainsi que certains algorithmes associés. Nous développerons les prémices de ces méthodes, et nous verrons son évolution jusqu'à la généralisation avec des modèles de mélange Gaussien. Donc, les différents algorithmes classiques de classification seront organisés selon les approches : hiérarchiques, partitives et génératives, floues et probabiliste. A la fin, de ce chapitre on propose une approche automatique basée sur les algorithmes avancés pour la classification des défauts des moteurs asynchrones plus particulièrement les défauts de roulements.

## 1.2 Détection, diagnostic et classification

Concernant les approches de surveillance basées sur les données, le diagnostic peut être considéré comme une tâche de classification supervisée. Il est également possible de considérer la phase de détection comme une classification supervisée. En effet, la détection peut être vue comme une classification en deux classes : fonctionnement normal du procédé, et respectivement fonctionnement anormal du procédé.

Le diagnostic peut être vu comme une extension de la détection pour le cas où le nombre de classes est supérieur à deux. Ainsi, dans le cas d'un fonctionnement anormal détecté, on peut s'intéresser à savoir quelle faute s'est produite [Ver 07].

Cependant, les classifications pour le diagnostic se différencient en classification supervisée et non-supervisée.

- Dans le premier cas, les frontières de séparation des classes sont déduites sur la base d'un échantillon d'individus pour lesquels on connaît l'appartenance aux différentes classes.
- Dans le cas de la classification non-supervisée, les frontières de séparation sont obtenues suivant certains principes (tels que l'homogénéité des classes ou bien la distance aux différents voisins) à partir des données disponibles et sans aucune information concernant l'appartenance des individus aux différentes classes [Ver 07].

## 1.3 Principes de base du diagnostic

Dans le domaine du diagnostic des entraînements électriques, la machine asynchrone occupe une place prépondérante. En effet, il est important de savoir la surveillance pour améliorer la qualité de service par l'utilisation de la maintenance prédictive.

De nombreux défauts peuvent être diagnostiqués comme :

- les défauts électriques au niveau du stator ou du rotor [Bac 02], [Cas 03a], [Did 04],...
- les défauts d'origine mécanique [Ben 03], [Blo 06],...

Ceci étant, on distingue alors plusieurs approches pour surveiller et diagnostiquer les machines asynchrones.

### 1.3.1 Notion de base du diagnostic

Les grandeurs surveillées peuvent être très diverses: un courant électrique, une température, une pression, un pourcentage de particule dans l'huile, un niveau de vibration et bien d'autres encore. Le suivi d'une grandeur donnée s'effectue en mesurant sa valeur régulièrement dans le temps et permet alors de vérifier qu'elle ne s'écarte pas, de façon significative, de sa valeur nominale. La grandeur surveillée subit, au cours du fonctionnement de l'installation deux types de variation [Isa 07].

- des fluctuations autour de sa valeur nominal qui sont dues aux diverses perturbation agissant sur le système considéré,
- une dérive qui peut être due à un phénomène d'usure, un phénomène de dégradation progressive ou à des conditions d'environnement anormales.

La mise en œuvre d'une telle approche (figure.1.1) nécessite de générer des indicateurs de défauts ou symptômes, puis à interpréter correctement ces symptômes afin de déterminer l'origine du défaut, c'est-à-dire l'élément présentant un fonctionnement anormal et enfin à prendre une décision pour un retour à un fonctionnement normal de l'installation [Tos 05].

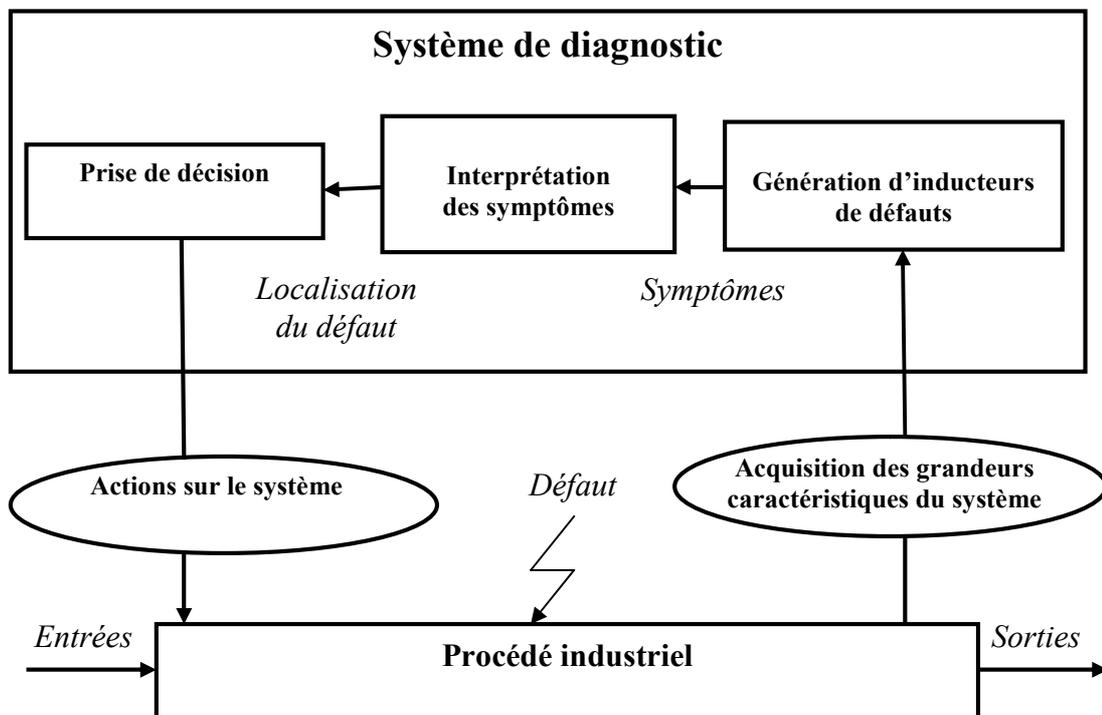


Figure.1.1 Structure générale d'un système de diagnostic [Tos 05]

Donc, Un système de diagnostic sera réalisé à l'aide des différentes étapes suivantes :

- Dans le cas d'une déviation jugée anormale (étape de détection d'un défaut) ;
- il s'agit de localiser l'origine de cette anomalie (étape de diagnostic du défaut) ;
- puis de prendre, en conséquence, les mesures qui s'imposent pour un retour à la normale du fonctionnement du système (étape de prise de décision).

### 1.3.2 Définitions [Lou 06], [Tos 05]

#### ❖ *Fonctionnement normal d'un système*

Un système est dit dans un état de fonctionnement normal lorsque les variables le caractérisant (variables d'état, variables de sortie, variables d'entrée, paramètres du système) demeurent au voisinage de leurs valeurs nominales. Le système est dit défaillant dans le cas contraire.

#### ❖ *Défaut*

Le concept de défaut est fondamental dans les opérations de surveillance pour la conduite et la maintenance des procédés industriels. On appelle défaut tout écart entre la caractéristique observée sur le dispositif et la caractéristique théorique cet écart est idéalement nul en l'absence de défaut. Les défauts peuvent apparaître au niveau des capteurs, des actionneurs ou au niveau du processus lui-même.

#### ❖ *Défaillance*

Une défaillance est l'altération ou la cessation de l'aptitude d'un ensemble à accomplir sa ou ses fonctions requises avec les performances définies dans les spécifications techniques. Une défaillance est un dysfonctionnement du système, le processus présente alors un fonctionnement inacceptable du point de vue des performances. Il est clair qu'une défaillance implique l'apparition d'un défaut puisqu'il existe un écart entre la caractéristique mesurée et théorique. Par contre, un défaut n'implique pas nécessairement une défaillance puisque le dispositif peut très bien continuer à assurer sa fonction principale.

**❖ Panne**

Une panne est l'inaptitude d'un dispositif à accomplir une fonction requise. Une panne résulte toujours d'une défaillance et donc d'un défaut :



Dans le cadre de la maintenance préventive conditionnelle, il est clair que le diagnostic doit permettre de détecter et de localiser un défaut avant que celui-ci ne conduise à une défaillance ou à une panne qui entraînerait l'arrêt du système.

**❖ Détection de défaut**

La détection d'un défaut consiste à décider si le système se trouve ou non dans un état de fonctionnement normal.

**❖ Localisation d'un défaut**

A l'issue de la détection d'un défaut, il s'agit de déterminer le ou les éléments à l'origine du défaut.

**❖ Diagnostic**

Détermination du type, de la taille, de la localisation et de l'instant d'occurrence d'un défaut. C'est une fonction qui suit la détection et inclut les fonctions de localisation et d'identification.

**❖ Surveillance**

Ensemble de fonctions s'exécutant en temps réel ayant pour but de reconstituer l'état réel du procédé au sein des modèles utilisés par le système de conduite du procédé. Elle consiste à l'enregistrement de l'information ainsi qu'à la reconnaissance et l'indication des comportements anormaux.

**❖ Supervision**

Représente la surveillance d'un système physique et la prise de décisions appropriées en vue de maintenir son opération face à des défaillances.

### 1.3.3 Différentes étapes du diagnostic

Un système de diagnostic nécessite un certain nombre d'étapes qui sont résumées dans la figure.1.2.

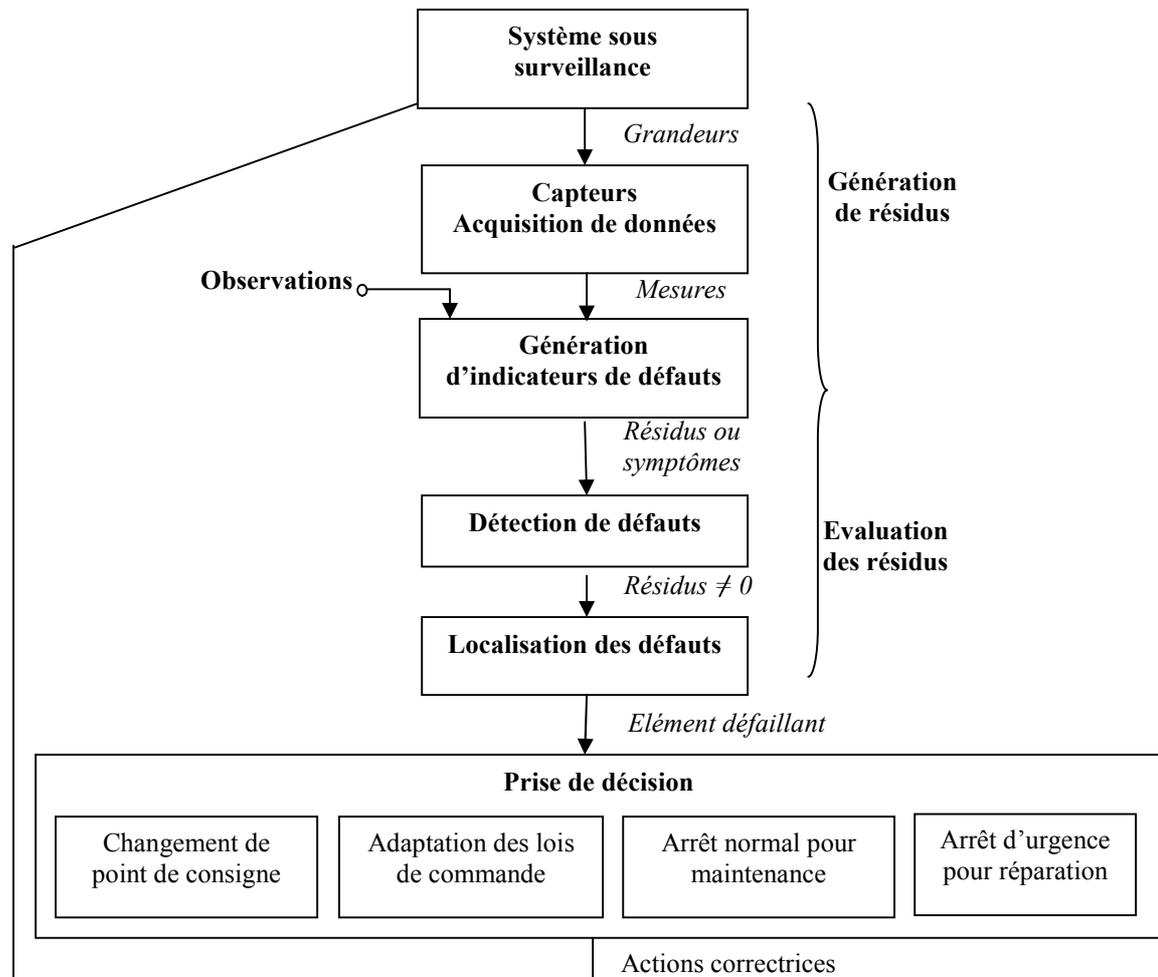


Figure.1.2 Différentes étapes du diagnostic [Tos 05]

#### 1.3.3.1 Acquisition des données

La procédure de diagnostic nécessite de disposer d'informations sur le fonctionnement du système à surveiller. Ces informations sont recueillies lors d'une phase d'acquisition de données suivie d'une validation. Cette étape implique donc l'utilisation de capteurs permettant de mesurer différentes variables du processus. L'instrumentation du système à surveiller n'entraîne pas obligatoirement de coût supplémentaire dans la mesure où celle-ci est de toute façon nécessaire pour réaliser la commande automatique du processus [Tos 05].

### 1.3.3.2 Étape d'élaboration d'indicateurs de défauts

A partir des mesures réalisées et des observations issues des opérateurs en charge de l'installation, il s'agit de construire des indicateurs permettant de mettre en évidence les éventuels défauts pouvant apparaître au sein du système.

Dans le domaine du diagnostic, les indicateurs de défauts sont couramment dénommés les résidus ou symptômes. Un résidu représente un écart entre les grandeurs estimées et mesurées [Isa 07], [Kwa 14].

### 1.3.3.3 Étape de détection

Cette étape doit permettre de décider si le système se trouve ou non dans un état de fonctionnement normal. On pourrait penser qu'il suffit de tester la non nullité des résidus pour décider de l'apparition d'un défaut [Lou 06].

### 1.3.3.4 Étape de localisation

Il s'agit, à partir des résidus détectés non nuls statistiquement, de localiser le défaut, c'est-à-dire de déterminer le ou les éléments défaillants. On appelle signature d'un défaut l'effet de celui-ci sur un ou plusieurs résidus. Si l'on dispose de la connaissance de la signature des défauts, il est possible, à partir de celle-ci, de remonter des effets (résidu non nul) aux causes (les éléments défaillants).

Donc, cette étape nécessite un modèle des défauts du système permettant la résolution du problème inverse. Ceci peut être réalisé à l'aide d'un arbre de défaillance, d'un classifieur construit, à l'aide d'un réseau de neurones, d'un système d'inférences floues, etc.

En résumé, quelle que soit la méthode employée, une procédure de diagnostic comprend deux étapes [Die 08]:

- une étape de génération de résidus
- une étape d'évaluation des résidus.

### 1.3.3.5 Etape de prise de décision

Le fonctionnement incorrect du système étant constaté, il s'agit de décider de la marche à suivre afin de conserver les performances souhaitées du système sous surveillance. Cette prise de décision doit permettre de générer, éventuellement sous le contrôle d'un opérateur humain, les actions correctrices nécessaires à un retour à la normale du fonctionnement de l'installation [Isa 07].

### 1.3.4 Méthodes de diagnostic

Le choix d'une méthode, techniquement et économiquement fiable, se fait en suivant ces étapes :

- Nature des causes de défaillance à localiser ;
- Connaissance des symptômes associés aux défaillances induites par les causes ;
- Maitrise des moyens des mesures des symptômes ;
- Maitrise des moyens de traitement des symptômes ;
- Connaissance des mécanismes physiques entre les causes et les effets ;
- Définition du niveau de confiance dans le diagnostic ;
- Identification des utilisateurs finaux du diagnostic ;

Globalement, On peut distinguer deux grandes familles dans les méthodes de diagnostic :

- Les méthodes basées sur une modélisation des systèmes ou des signaux, que nous dénommerons le diagnostic quantitatif.
- Les méthodes basées sur l'intelligence artificielle que nous appellerons diagnostic qualitatif.

Un panorama général des différentes méthodes de diagnostic est présenté à la figure.1.3 :

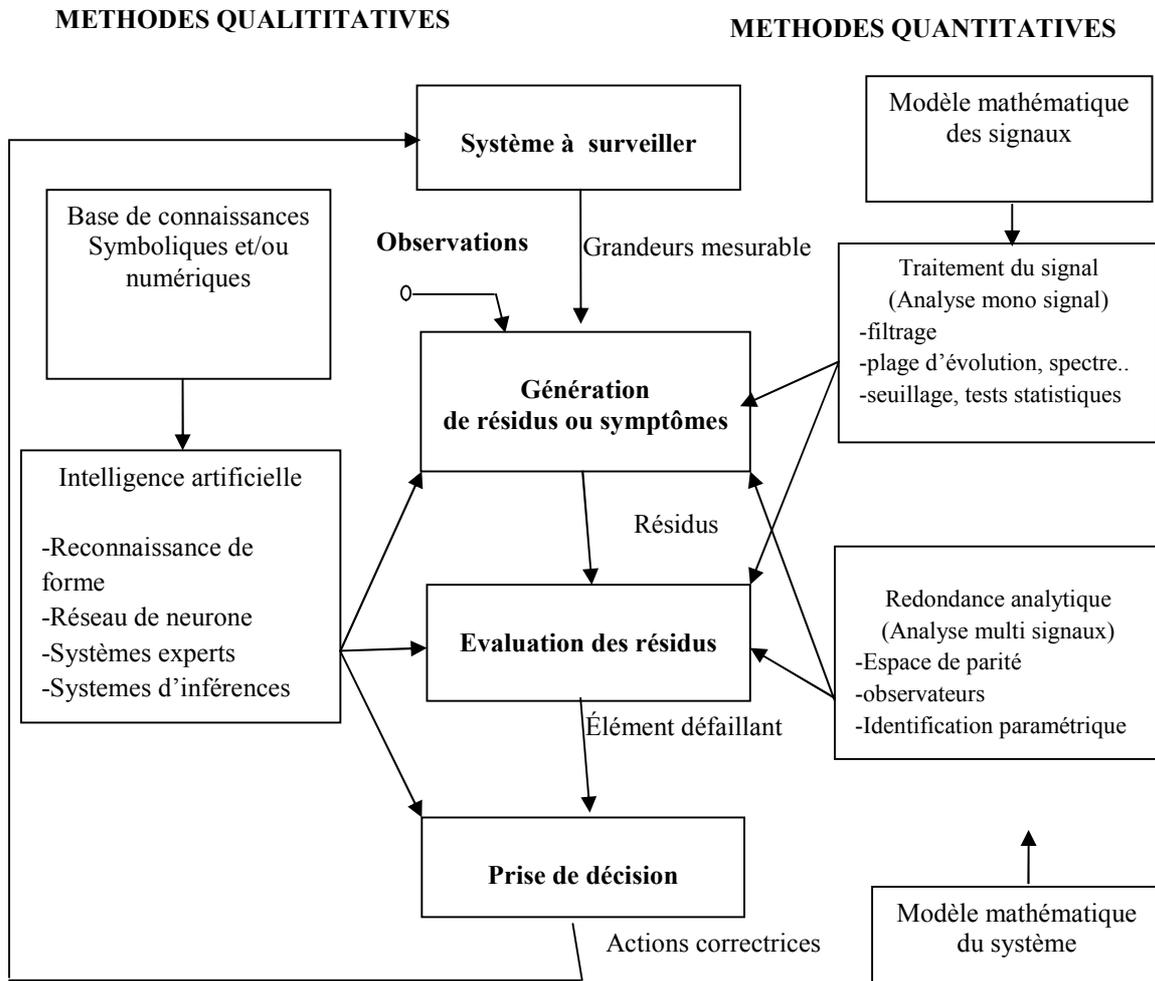


Figure.1.3 Classification des méthodes de diagnostic [Tos 05]

### 1.3.4.1 Méthodes de diagnostic avec modèle analytique

C'est des méthodes de détection basée sur la connaissance à priori du système, exigent la connaissance des modèles et des paramètres du processus physique du système. La comparaison des signaux relevés lors du fonctionnement du système et ceux générés par les modèles estimés.

Les méthodes de diagnostic avec modèle analytique peuvent classer en trois techniques supposant la connaissance de la plage de variation des modèles et des paramètres en fonction des conditions de fonctionnement du système [Cas 03b], [Baz 09a].

### 1.3.4.1.1 Techniques d'estimation d'état

Les modèles analytiques utilisent un nombre fini de variables internes, qui sont inaccessibles et pas mesurables, appelés aussi variables d'état. Puisque, ces dernières caractérisent l'évolution temporelle du système, il est souvent nécessaire de recourir à des techniques d'estimation (capteurs logiciels) pour suivre l'évolution des valeurs.

La figure.1.4 présente le schéma de principe de l'estimation d'état à partir des grandeurs mesurées (les signaux d'entrée et les signaux de sortie du système) [Baz 09b].

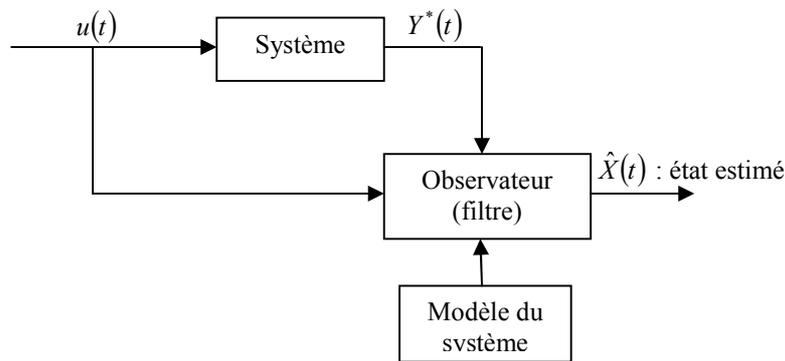


Figure.1.4 Principe de Technique d'estimation d'état

### 1.3.4.1.2 Technique de génération de résidus

Les résidus sont les signaux qui représentent l'écart entre les signaux déduit du modèle du système à surveiller, et ceux mesurés. Ces techniques d'extraction des résidus doivent fournir des signaux indicatifs et exploitables pour détecter la présence d'une défaillance spécifique. A cet effet, en mode sain (sans défauts) les résidus doivent s'approcher de zéro et prendre des valeurs indicatives indiquant la présence d'un défaut [BAZ 09b]. La figure .1.5 représente le schéma de principe de la génération de résidus.

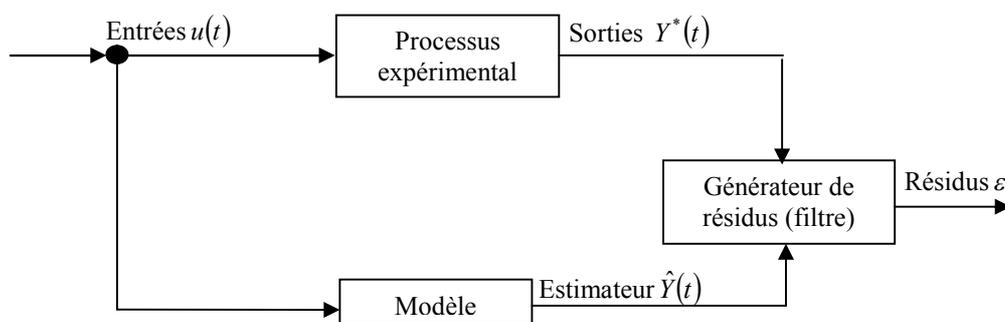


Figure.1.5 Principe de technique de génération de résidus

### 1.3.4.1.3 Techniques d'identification

Les techniques d'identification permettent de déterminer un modèle dynamique du système à surveiller à partir de mesures expérimentales, en entrée et en sortie. L'objectif est que les paramètres caractérisant le modèle identifié soient sensibles aux défauts et permettre par leurs variations de caractériser ces défauts [Ise 93]. L'estimation des paramètres du modèle est assurée par un algorithme de minimisation de l'erreur entre la sortie du modèle et celle du système à surveiller [Ric 71].

La figure.1.6 montre le schéma de principe d'une procédure d'identification.

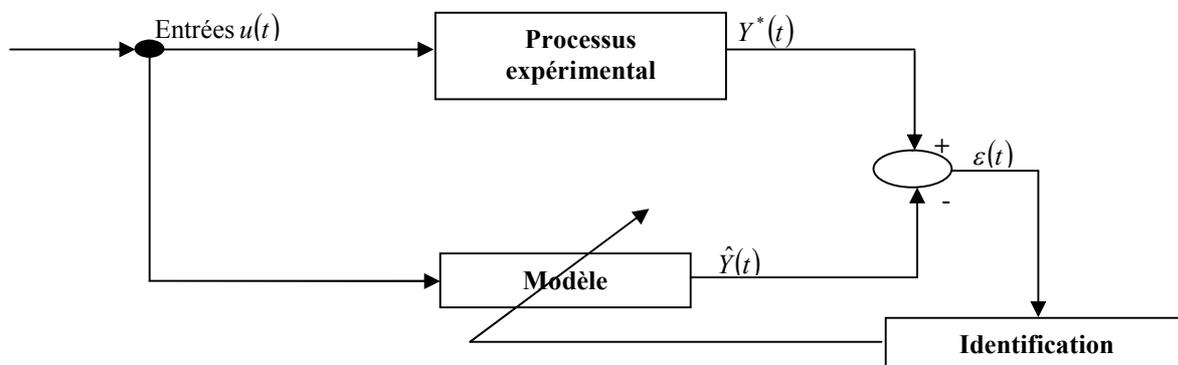


Figure.1.6 Principe des techniques d'identification

Parmi les techniques d'identification basées sur la minimisation d'un critère quadratique ; on peut citer ;

- ❖ Les techniques à erreur d'équation [Lju87] ;
- ❖ Les techniques à erreur de sortie [Tri 01] ;
- ❖ Le Filtre de Kalman étendu [Lor 98] ;

La principale limitation des techniques par identification est la nécessité d'une excitation persistante, c'est à dire d'une entrée qui perturbe suffisamment le système pour générer des signaux exploitables par l'algorithme d'identification.

Les techniques de diagnostic à base de modèle analytique ne permettent pas d'étudier tous les défauts de la machine, notamment, les défauts de roulements. Alors, nous nous sommes intéressés, pour le cas de notre travail aux techniques n'exigeant pas la connaissance du modèle d'un système, mais basées sur le suivi et l'analyse des grandeurs telles que les courants, flux, couple et les vibrations.

### 1.3.4.2 Méthodes de diagnostic sans modèle analytique

Ces méthodes ne nécessitent pas forcément de modèle précis du système mais reposent plutôt sur une reconnaissance de signatures. Les signatures de défauts, obtenues par modélisation ou par mesure sur maquette, sont généralement classées dans une base de données. L'analyse est réalisée par une interprétation du type signal ou par système expert . . . Les défauts étudiés par ces méthodes de diagnostic sont :

- ❖ Les ruptures de barres ou de portions d'anneaux au rotor,
- ❖ L'excentricité statique et dynamique,
- ❖ La défaillance des paliers,
- ❖ Le court-circuit entre spires au stator.

#### 1.3.4.2.1 Méthode par traitement de signal

L'approche dite "signal" est très utilisée en diagnostic grâce à sa simplicité et son efficacité. Elle se base sur la comparaison du spectre correspondant au comportement du système sain, avec celui des signaux mesurés. Les méthodes courantes d'analyse des signaux de diagnostic en régime transitoire et en régime permanent sont [And94]:

##### ❖ *Approches spectrales*

Les approches spectrales sont les plus couramment rencontrées pour détecter la présence d'une anomalie. Le principal inconvénient de l'analyse spectrale est qu'elle est très sensible à la qualité de la mesure, ainsi qu'à la fréquence d'échantillonnage et au nombre d'échantillons. C'est pourquoi, pour le cas de diagnostic des machines électriques les procédures de surveillance sont généralement orientées vers des défaillances spécifiques intervenant sur l'une des trois parties de la machine : le stator, le rotor ou les paliers. Cette technique est généralement utilisée durant le régime permanent de la machine [DID 04].

##### ❖ *Technique de spectrogramme*

Les Technique de spectrogramme permettent d'effectuer des analyses fréquentielles des signaux en régime dynamique de fonctionnement du système [Fla 93]. Cette technique consiste à effectuer un calcul répétitif de la FFT sur une fenêtre temporelle glissante, ce qui rend cette technique sensible à la longueur de la fenêtre, au type de fenêtrage, à la durée totale de supervision et au pas de glissement de la fenêtre.

Bien que cette technique permette d'analyser des signaux en régime dynamique, la rapidité du régime dynamique des machines asynchrones de l'ordre de 150 ms réduit significativement la précision de cette technique.

#### ❖ *Analyse temporelle*

L'Analyse temporelle consiste à comparer les signaux temporels issus d'un fonctionnement sain du système aux signaux temporels du fonctionnement courant [Cas 03b, Kra 04]. Le déphasage introduit par les instruments de mesure rend la comparaison directe de ces signaux non significative [Ond 06]. A cet effet, il est coutume d'effectuer des transformations sur les signaux avant de les comparer. Malgré cette transformation, cette méthode ne permet pas d'identifier efficacement les défaillances pouvant affecter les machines électriques.

#### ❖ *Méthodes temps-fréquence*

Les méthodes temps-fréquence, basées sur l'analyse de Wigner-Ville, combinent l'analyse temporelle et l'analyse fréquentielle. cette technique permet d'extraire des informations du régime dynamique d'un système, et que ce régime est plus riche que le régime stationnaire du processus [And 94]. Il existe diverses méthodes temps-fréquence appliquées pour identifier les défauts de machines tournantes telles que la Transformée de Fourier discrète, Transformée en ondelettes (WT), distribution de Wigner-Ville (WVD), Hilbert Huang transformer (HHT) et Teager- Huang transformation (THT) qui nous allons détaillée on deuxième chapitre.

#### **1.3.4.2.2 Méthodes par l'intelligence artificielle**

L'intelligence artificielle (IA) est de plus en plus utilisée dans le domaine de la supervision et du diagnostic. Particulièrement, dans le domaine de la supervision des machines électriques, les industriels et les chercheurs ont de plus en plus recours aux techniques pour augmenter l'efficacité et la fiabilité du système [Alt 99, Awa 03]. Ces techniques, nécessitent une phase d'apprentissage nécessaire pour un fonctionnement optimal. A l'issue de la phase d'apprentissage les techniques intelligentes s'adoptent avec succès et efficacement pour le diagnostic de défauts des machines électriques.

En effet, elles, contribuent à accélérer le processus de décision avec une intervention humaine réduite. Le terme Intelligence Artificielle comprend diverses techniques telles que :

❖ **Les réseaux de neurones artificiels**

Imitent la structure neuronale d'un cerveau humain ; ils sont formés par un réseau complexe de blocs arithmétiques simples [Sal 00], [Awa03]. Ils peuvent facilement représenter les systèmes non linéaires multi-entrées/multi-sorties. Cette technique a largement été utilisée dans le domaine du diagnostic des machines électriques.

❖ **La logique floue**

Les systèmes flous sont capables de traiter des variables naturelles via des conditions floues « si- alors » [Alt 99]. Les systèmes flous adaptatifs exploitent les facultés d'apprentissage des réseaux de neurones ou la robustesse des algorithmes génétiques dans le domaine de l'optimisation des paramètres du système à étudier, afin de prendre en considération les connaissances à priori et l'expertise humaine dans le domaine. Plusieurs travaux ont utilisé ces techniques pour le diagnostic et la surveillance des machines électriques [Bal 07], [Zid 08].

❖ **La technique neuro-floue**

C'est la combinaison de la technique des réseaux de neurones artificiels et celle de la logique floue. Cette technique est très intéressante pour le diagnostic et la surveillance de machines asynchrones [Bal 07]. En effet, les réseaux de neurones adaptatifs peuvent générer le système ou correspondant d'une manière autonome. Cette génération des règles est faite à partir des exemples d'apprentissage, en minimisant ainsi l'intervention de l'expert lors de la formulation des règles conditionnelles.

❖ **La reconnaissance des formes (RdF)**

Cette approche peut être employée lorsque les observations sont de type numérique. De nombreux travaux ont permis de montrer l'intérêt de ce type d'approche. Dans le domaine du diagnostic des machines électriques, la technique RdF, quoique plus rarement utilisée, a été mise en œuvre avec succès par [Cas 03b]. Pour anticiper l'apparition d'un dysfonctionnement, soit pour les éviter, soit pour en limiter les conséquences, quelques études ont utilisées l'association de la RdF et la théorie des ensembles flous. Il est parfois important de détecter l'évolution du système à diagnostiquer, notamment pour détecter la transition entre les modes de fonctionnement normal et anormal.

## 1.4 Classification

### 1.4.1 Définition

La classification est un procédé algorithmique visant à diviser l'ensemble des éléments  $\{P_i, i \in \{1, \dots, N\}\}$  d'une population  $P$  en un nombre  $C$  de partitions, selon un critère de similarité dépendant du contexte et du résultat désiré.

La qualité des résultats obtenus dépendant grandement de la robustesse des classes, ces dernières doivent satisfaire aux trois exigences suivantes :

- **Exhaustivité** : toutes populations doivent pouvoir être associés à une classe.
- **Séparabilité** : les classes doivent être suffisamment différenciables.
- **Pertinence** : l'ensemble des classes doit refléter l'information.

Ces exigences doivent être vérifiées simultanément, les deux premières étant liées aux données tandis que la dernière dépend de l'utilisateur.

### 1.4.2 Objectif de la classification

L'objectif est d'identifier les classes contenant des objets à partir de traits descriptifs (attributs, caractéristiques, etc.). Toutefois, il arrive que des classes soient oubliées ou que l'étiquetage ait été réalisé dans de conditions qui ne permettant pas la distinction de classes intéressantes [Sub 12], [Cle 04]. On distingue les classifications supervisée et non-supervisée.

L'objectif des approches de les classifications non-supervisée est de produire une structure permettant d'organiser les données. Celle-ci peut être un dendrogramme, ou une partition de taille fixée éventuellement représentée par un ensemble d'éléments représentatifs appelés prototypes.

La forme et la manière d'obtenir une telle structure sera explicitée en temps voulu lors de la présentation des différentes familles d'algorithmes [Sub 12] [Cle 04]. En effet, il peut arriver que des classes soient oubliées, ou encore que l'étiquetage ait été réalisé dans de mauvaises conditions ne permettant pas la distinction de classes intéressantes.

La classification non-supervisée ne se positionne pas sur ce type de problème, puisqu'elle détermine les classes, peut venir en aide à une classification supervisée, pour confirmer ou infirmer le choix des classes initiales, et proposer une classification avec des classes ayant plus de sens [Cle 04], [Gué 06].

Une solution envisagée est alors de fusionner les résultats donnés par la classification supervisée et non-supervisée en vue de tirer profit des deux types de méthodes et répondre à un tel problème.

Les résultats des deux types de classification peuvent ainsi être vus dans un système de fusion comme des données hétérogènes, imprécises et incertaines. La combinaison offre par conséquent à l'utilisateur un compromis entre les deux méthodes [Cle 04], [Gué 06].

### 1.4.3 Outils de classification

Les algorithmes de classification peuvent être répertoriés de plusieurs manières comme l'illustre la figure 1.7.

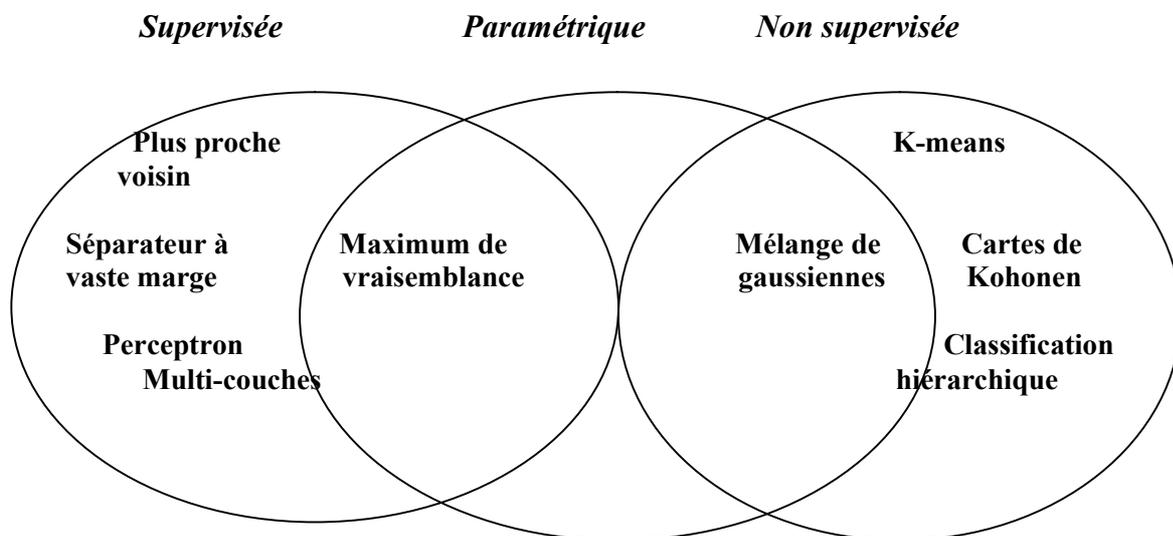


Figure. 1.7 Partition des outils de classification

Un premier critère est le niveau de la supervision, c'est-à-dire l'importance de l'intervention de l'utilisateur dans le processus de classification [Rou 04].

Quelque soit le type de la classification, on est confronté à différents problèmes.

- ❖ Dans le cas supervisé, un problème important peut être le manque de données pour réaliser l'apprentissage ou la disponibilité de données inadéquates.
- ❖ Pour la classification non-supervisée, la délimitation des frontières entre les classes n'est pas toujours franche et reconnaissable. La recherche d'une partition des données revient à regrouper celles-ci selon une certaine mesure de similarité ou de dissimilarité [Hay 99], [Kil 96]. La métrique employée peut être de nature géométrique ou probabiliste.

Ainsi, on distingue:

- ❖ Les méthodes paramétriques, qui modélisent les données par un ensemble de paramètres à estimer (associés à un modèle probabiliste).
- ❖ Les méthodes non paramétriques, qui ne font pas d'hypothèse sur la distribution de ces données [Dre 02], [Kil 96].

#### 1.4.3.1 Classification supervisée

Dans le contexte supervisé on dispose déjà d'exemples dont la classe est connue et étiquetée. Les données sont donc associées à des labels des classes notés  $\Theta = \{q_1, q_2, \dots, q_N\}$

L'objectif est alors d'apprendre à l'aide d'un modèle d'apprentissage des règles qui permettent de prédire la classe des nouvelles observations, ce qui revient à déterminer une fonction  $C_1$  qui à partir des descripteurs ( $D$ ) de l'objet associe une classe  $q_i$  et de pouvoir aussi affecter toute nouvelle observation à une classe parmi les classes disponibles. Ceci revient à la fin à trouver une fonction qu'on note  $Y_S$  qui associe chaque élément de  $X$  un élément de  $Q$ . On construit alors un modèle en vue de classer les nouvelles données.

Parmi les méthodes supervisées, on cite [Bou 05] :

- Les k-plus proches voisins ;
- Les arbres de décision ;
- Les réseaux de neurones ;
- Les machines à support de vecteurs (SVM) ;
- Les classificateurs de Bayes

### 1.4.3.2 Classification non supervisée

Cette classification est aussi appelée "classification automatique", "clustering" ou encore "regroupement". Dans ce type de classification, on est amené à identifier les populations d'un ensemble de données.

On suppose qu'on dispose d'un ensemble d'objets que l'on note par  $X = \{x_1, x_2, \dots, x_N\}$  caractérisé par un ensemble de descripteurs  $D$ , l'objectif de la classification automatique est de trouver les groupes auxquels appartiennent chaque objet  $x$  qu'on note par  $C = \{C_1, C_2, \dots, C_N\}$ . Ce qui revient à déterminer une fonction notée  $Y_S$  qui associe à chaque élément de  $X$  un ou plusieurs éléments de  $C$ .

Concernant la classification non supervisée l'image est partitionnée sans utiliser de connaissance a priori (nombre de classes, ensembles d'échantillons déjà étiquetés). Ces outils sont très prisés, principalement parce que l'acquisition de vérités terrain précises (un processus long et délicat) n'est pas systématiquement possible [Gué 06].

Les deux difficultés essentielles que rencontre la classification non supervisée sont.

- ❖ S'il est naturel de reconnaître comme "appartenant à une même classe" des observations regroupées dans une même zone de forte densité, il n'en est pas de même dans des zones de faible densité.
- ❖ L'œil humain est un extraordinaire outil de classification non supervisée. Malheureusement, il n'est opérationnel que pour des données bidimensionnelles, alors que les données que rencontre l'analyste sont couramment décrites par des dizaines de variables ou plus.

Il s'avère que reproduire les performances de l'œil humain dans des espaces de grande dimension est un exploit aujourd'hui hors d'atteinte des machines.

### 1.4.4 Etapes du Classification non supervisée (classification automatique)

Le processus de classification automatique se divise en trois étapes majeures, comme le montre la Figure 1.8.

- ❖ Préparation des données ;
- ❖ Algorithme de classification automatique ;
- ❖ Exploitation des résultats de l'algorithme.

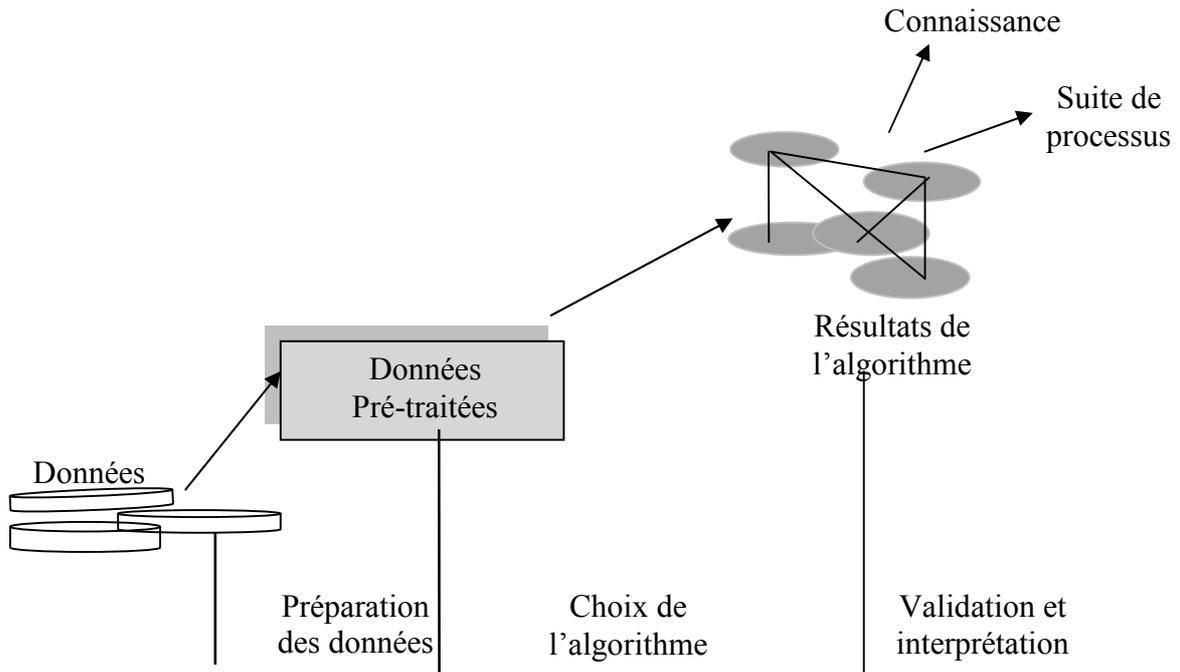


Figure. 1.8 Différentes étapes du processus de classification automatique [Cle 04]

#### 1.4.4.1 Préparation des données

##### 1.4.4.1.1 Variables et sélections

Les objets sont décrits par des variables  $\{v_j\}_{j=1\dots p}$ , aussi appelées attributs, descripteurs ou traits. Ces variables sont de différentes natures :

- ❖ **variables quantitatives** : continues, discrètes ou sous forme d'intervalles ;
- ❖ **variables qualitatives** : non-ordonnées ou ordonnées ;
- ❖ **variables structurées** : la forme d'un objet.

L'étape de préparation consiste à sélectionner et/ou pondérer ces variables, voire à créer de nouvelles variables, afin de mieux discriminer entre eux les objets à traiter. En effet les variables ne sont pas nécessairement toutes pertinentes : certaines peuvent être redondantes et d'autres non-pertinentes pour la tâche ciblée. Ce problème de sélection de variables a été largement étudié en classification supervisée mais reste très ouvert pour une approche non-supervisée [Cle 04], [Bau 09].

Dans un cadre supervisé, chaque variable peut-être évaluée relativement à son pouvoir discriminant par rapport aux classes prédéfinies. On distingue deux(2) types:

- **les méthodes *filtrent*** qui consiste à enlever les variables non pertinentes avant la phase d'apprentissage.
- **les méthodes *enveloppent*** qui utilisent de manière explicite le classifieur pour choisir un sous-ensemble de variables réellement discriminantes [Liu 96].

En revanche, peu de travaux concernent la sélection de variables dans une perspective non-supervisée, principalement parce que, sans les étiquettes de classe, il est difficile d'évaluer la pertinence d'une variable. Cette difficulté peut être contournée en effectuant une première étape de clustering à partir de l'ensemble des variables, puis de considérer chaque cluster comme une classe et de réitérer ce processus [Law 02]. Récemment, des approches "filtre" ont été envisagées dans ce contexte non-supervisé [Mit 02], [Das 02].

#### 1.4.4.1.2 Distances et similarités

La plupart des algorithmes de classification automatique utilisent une mesure de proximité entre les objets à traiter. Cette notion de proximité est formalisée à l'aide d'une mesure (ou indice) de similarité, dissimilarité ou encore par une distance. Le choix ou la construction de cette mesure est déterminant pour la suite du processus.

En effet, deux mesures différentes peuvent induire deux schémas de classification différents. Finalement, chaque domaine d'application possédant ses propres données, il possède également sa propre notion de proximité; il faut concevoir alors une mesure différente pour chaque domaine d'application, permettant de retranscrire au mieux les différences qui semblent importantes pour un problème donné.

#### 1.4.4.2 Choix de l'algorithme

Le choix de l'algorithme de classification automatique doit donner lieu à une analyse globale du problème :

Quelle est la nature (qualitative et quantitative) des données ?

Quelle est la nature des clusters attendus (nombre, forme, densité, etc.) ?

L'algorithme doit alors être choisi de manière à ce que ses caractéristiques répondent convenablement à ces deux dernières questions.

Les critères de décision peuvent être :

- la quantité de données à traiter ;
- la nature de ces données ;
- la forme des clusters souhaitée ;
- le type de schéma attendu (pseudo-partition, partition stricte, dendrogramme, etc).

##### 1.4.4.2.1 Taille des données

La quantité d'objets à traiter est un premier facteur de décision.

- En effet, pour des données de très grande taille (par exemple en traitement d'images), les algorithmes de complexité plus que linéaires sont quasiment prohibés. Ainsi des méthodes telles que l'algorithme des k-moyennes ou plus généralement la méthode des nuées dynamiques [Gen 90], étant de complexité linéaire, sont très souvent utilisés.
- En revanche, lorsque l'on souhaite organiser quelques milliers, voire quelques centaines d'objets, il est possible d'avoir recours à des méthodes plus complexes et nécessitant un temps de traitement plus important (méthodes hiérarchiques ou de partitionnement plus élaborées).

#### 1.4.4.2.2 Nature des données

Comme nous l'avons précisé, beaucoup d'algorithmes de classification automatique s'appuient sur une matrice de similarité ou dissimilarité [Cle 04].

- cette matrice est obtenue à partir des descriptions des données c'est le cas le plus souvent,. Quand bien même une matrice de similarité existe, certaines méthodes de classification automatique s'appuient sur la notion d'espace métrique.
- Dans le cas où un tel espace n'est pas présent, le processus de classification automatique se base uniquement sur la mesure de similarité.

#### 1.4.4.2.3 Forme des clusters

Des méthodes de classification automatique aboutissent à des clusters de formes spécifiques.

- les méthodes qui consistent déterminer des centroïdes / Médoïdes aboutissent le plus souvent à des clusters de forme convexe, par exemple les méthodes hiérarchiques ou de partitionnement.
- Les algorithmes agglomératif hiérarchiques du simple lien, construisent des clusters de formes variées.

La question est alors de savoir s'il est raisonnable de formuler à priori, une hypothèse sur la forme des clusters. Les variations de taille et densité ainsi que la gestion des outliers sont également à prendre en compte dans le choix de l'algorithme de classification automatique:

- ❖ la variation de taille, la capacité d'un algorithme à obtenir à la fois des clusters contenant beaucoup d'objets, et des clusters contenant peu voire très peu d'objets.
- ❖ la prise en compte de la densité permet ou non d'obtenir des clusters contenant des objets plus ou moins proches, au sens de la mesure de similarité établie.

Enfin, la méthode de classification automatique peut être ou non sensible à la présence d'outliers [Cle 04].

#### 1.4.4.2.4 Type de résultats attendus

La sortie d'un algorithme de classification automatique peut être, par exemple, une partition (ou pseudo-partition), une fonction ou encore un dendrogramme (arbre hiérarchique). De même, chaque cluster obtenu peut être défini soit par l'ensemble des objets qui le composent, soit par une description relative aux variables initiales. On parle d'une définition en extension, dans le premier cas, et en intension, dans le second [Azé 03].

- Précisons que la plupart des approches proposent une classification à partir d'une définition en extension des clusters.
- Une nouvelle fois, le choix de la méthode de classification automatique devra être faite en fonction du type de résultat souhaité et donc de l'exploitation envisagée du résultat.

#### 1.4.4.3 Exploitation des clusters

Il est utile de distinguer les classes pertinentes obtenues, des autres en termes de disposition relative, dispersion, orientation, séparation, densité ou stabilité. Cette tâche permet, même de recourir à une autre approche de classification automatique plus adaptée. Deux situations sont possibles [Gna 90],[Azé 03]:

- ❖ Soit la tâche de classification automatique s'inscrit dans un traitement global d'apprentissage, Dans ce premier cas, l'analyse des clusters obtenus (mesures statistiques de qualité) peut aider à orienter le traitement suivant. Une description des clusters n'est pas nécessaire dans cette situation. Lorsque les objets se présentent sous la forme d'une matrice de (dis) similarité, il existe peu de méthodes pour décrire les classes (Médoides,  $k$  objets représentatifs et mesures de cohésion).
- ❖ Soit les clusters générés par classification automatique constituent un résultat final. dans ce cas où le clustering constitue à lui seul un processus global de découverte de classes, l'exploitation des clusters pour une application donnée passe par une description de ces derniers. Lorsque les objets sont décrits par un ensemble de variables, on peut avoir recours à des méthodes de description des classes (descriptions conceptuelles).

### 1.4.5 Approches de classification

La présentation de ces approches de classification suit une trame classique en fonction du résultat obtenu. Aussi, Il existe plusieurs critères pour les différencier et les présenter en une typologie cohérente :

- ❖ Discriminative, c'est à dire que l'approche vise à déterminer géométriquement des frontières de décision en séparant les individus dans un espace donné. Elles se présentent sous la forme d'un programme d'optimisation d'un critère objectif, éventuellement avec contraintes. La solution est ainsi caractérisée par l'optimum global de ce critère objectif, qui est en général approché par un algorithme directement dérivé du critère.
- ❖ Générative, lorsqu'elle est basée sur un modèle probabiliste. L'approche permet ainsi de définir à la fois la solution optimale après émission d'une hypothèse sur la nature des lois censées régir l'ensemble d'individus, et en même temps propose une explication sur la façon dont a été généré cet ensemble. Cette dernière information offre l'intérêt notamment de pouvoir régénérer automatiquement un nouvel ensemble d'individus, semblable à celui d'origine;
- ❖ Purement algorithmique, si elle n'est fondée sur aucun critère objectif, mais les groupes sont obtenus par pure recherche heuristique durant l'application de l'algorithme.

Les différents algorithmes classiques seront organisés comme montré l'organigramme de la figure 1. 9 selon les approches suivantes:

- Hiérarchiques produisant un ensemble de partitions imbriquées appelé dendrogramme;
- Partitives, dont le résultat est une partition en un nombre de groupes fixés, donné, ou découvert par l'algorithme;
- Génératives ou floues, permettant d'obtenir une partition floue des individus, ou d'attribuer des valeurs de probabilités d'appartenance des individus à chaque groupe.

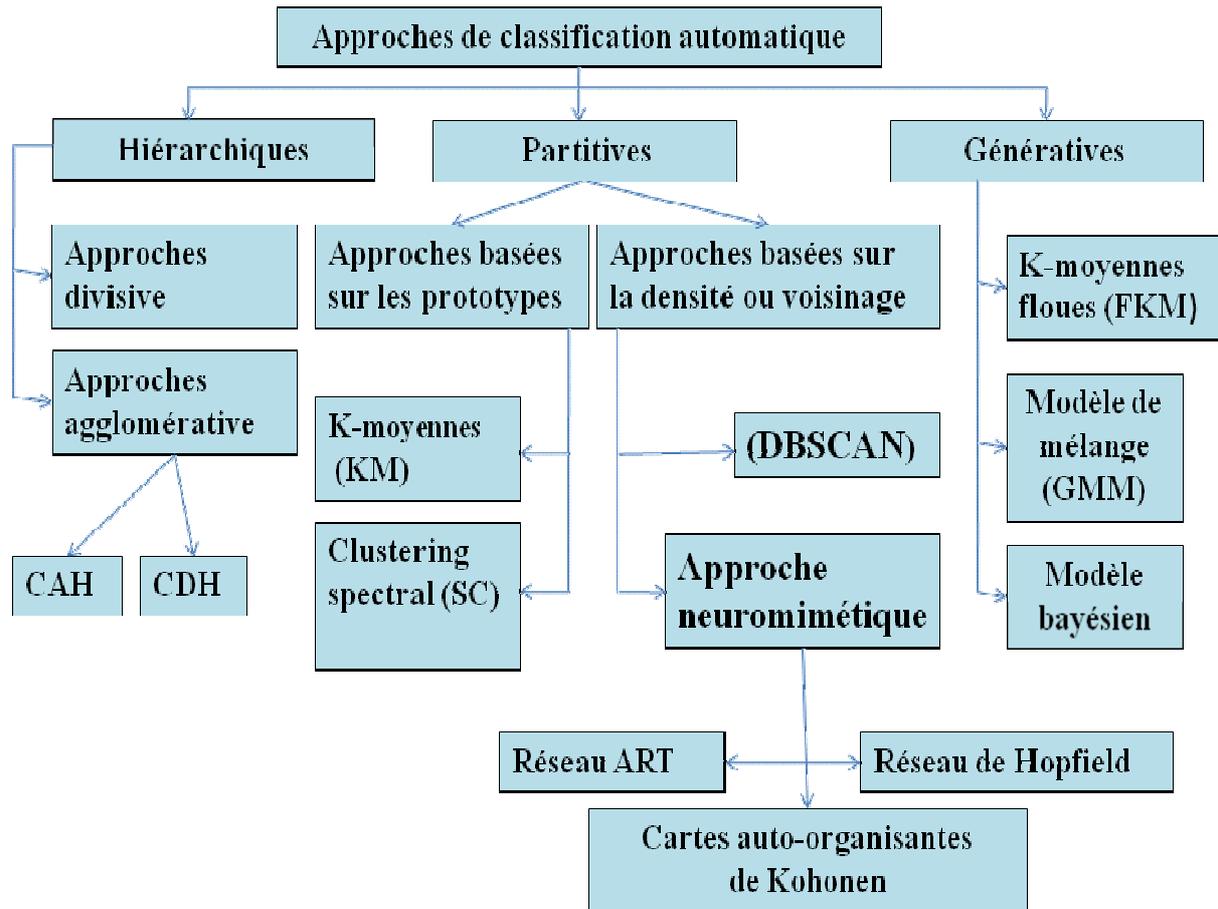


Figure. 1.9 Approches de classification automatique

#### 1.4.5.1 Approches hiérarchiques

Les approches de clustering hiérarchiques sont des approches non paramétriques et purement algorithmiques qui proposent de construire une structure hiérarchique appelée dendrogramme.

Ces approches consistent à calculer une matrice exprimant les distances mutuelles entre les points à classer, puis, en fonction de celle-ci, regrouper entre eux les points les plus proches. Cette méthode permet la construction d'un arbre hiérarchique, qui révèle plusieurs partitions possibles, où chaque point est attribué à l'un des groupes d'une partition donnée.

Le choix de la meilleure partition s'effectue une fois la classification hiérarchique terminée ; elle peut être fondée sur différents critères. Les critères plus couramment utilisés sont : critère du lien minimum, critère du lien maximum, critère du lien moyen et le critère de Ward [Sub 12].

Nous décrivons les principales étapes de l'algorithme de classification ascendante hiérarchique (CAH) [Kar 99]:

- Au début, l'algorithme de classification considère chaque observation comme une classe, la phase d'initialisation est définie par la variable :

$$\Omega_i^\ell = \{X_i\} \quad \forall i \text{ et } \ell = 0 \quad (1.1)$$

Où, la variable  $\Omega_i^\ell$  dénote la classe d'appartenance de l'observation  $X_i$  à la  $\ell^{\text{ième}}$  itération, avec  $\ell = 0$  pour la phase d'initialisation.

- La similarité entre deux classes est définie par un critère de liaison qui évalue deux classes à l'aide d'une mesure de similarité qui à son tour évalue la similarité entre deux classes. La similarité « Sim » entre deux classes est définie par :

$$Sim(\Omega_l^\ell, \Omega_h^\ell) = \beta(\Omega_l^\ell, \Omega_h^\ell) \quad (1.2)$$

- Sélectionner les paires de classes qui ont une très grande similarité  $Sim(\Omega_l^\ell, \Omega_h^\ell)$

$$\left[ \Omega_{l^*}^\ell, \Omega_{h^*}^\ell \right] = \underset{l, h \in [1-M], l \neq h}{\text{arg max}} Sim(\Omega_l^\ell, \Omega_h^\ell) \quad (1.3)$$

- Fusionner les deux classes avec un indice  $l^*$  et  $h^*$

$$\Omega_{l^*}^{\ell+1} = \left( \Omega_{l^*}^\ell \cup \Omega_{h^*}^\ell \right) \quad (1.4)$$

$$\Omega_{h^*}^{\ell+1} = \{ \} \quad (1.5)$$

On répète les étapes 2 à 4 jusqu'à n'avoir plus qu'une seule classe.

Ces approches permettant de construire un dendrogramme de ce type se décomposent en deux familles :

- **Approches agglomérative** : construisent le dendrogramme par la base, en regroupant à chaque étape les amas d'individus les plus similaires;
- **Approches divisive** : construisent le dendrogramme par le haut, en partitionnant à chaque étape un amas en sous amas.

L'avantage de cette méthode est qu'elle n'est soumise à aucune initialisation particulière de paramètre(s) ce qui la rend déterministe, et en outre, que le nombre de classe n'a pas à être fixé a priori. Cependant, ce type de méthode impose le calcul de la matrice des distances de tous les points d'observation avec tous les autres, et cette masse de calcul est beaucoup trop importante compte tenu du temps que nous voulons consacrer à cette étape.

### 1.4.5.2 Approches partitives

Ces approches sont désormais plus courantes dans les communautés dédiées au développement de nouveaux algorithmes de clustering. Cette section détaille les algorithmes de partitionnement selon deux familles d'approches [Sub 11]:

#### 1.4.5.2 .1 Approches basées sur les prototypes

Ces approche consistent à définir un ensemble de centres ou moyennes de départ qui caractériseront chacun un groupe d'individus.

##### ❖ *K-moyennes (KM)*

La méthode discriminative des K-moyennes (KM) [Mac 67], consiste à choisir aléatoirement des centres initiaux et améliorer la partition obtenue de manière itérative en alternant les deux (2) étapes ci-dessous jusqu'à stabilisation :

- **Etape d'affectation** : chaque objet  $x \in \Omega$  est affecté au centre le plus proche, noté  $\phi(x)$  ;
- **Etape d'optimisation** : chaque centre est remplacé par le barycentre de l'ensemble des objets qu'il représente.

Le principe est étant données la distribution des individus de  $X$  dans l'espace de description et un nombre  $n_k$  de groupes fixé, l'objectif est de minimiser la dispersion des individus relativement à un ensemble de prototypes représentatifs de ces groupes. Il consiste à minimiser le critère suivant [Lel 08]:

$$W(z, g) = \sum_{k=1}^s \sum_{i \in z_k} d^2(x_i, g_k) \quad (1.6)$$

Où :  $g = (g_1, \dots, g_s)$ ,  $g_k$  est le centre de la classe  $z_k$ ,  $s$  nombre de classes.

Cet algorithme se déroule de la façon suivante :

- Initialisation : les points tirés au hasard pour les centres de gravité de chaque classe,
- Affectation : On affecte les points à la classe la plus proche,
- Représentation : On recalcule les nouveaux centres de gravité,
- On répète les étapes d'affectation et de représentation jusqu'à la convergence de l'algorithme.

### ❖ Clustering spectral (SC)

Le clustering spectral (SC) [Lux 07] est une autre approche discriminative de partitionnement, qui aurait pu être traitée parmi les approches basées sur le voisinage, car elle permet de prendre en compte la topologie naturelle des données.

En réalité, il s'agit d'un KM appliqué à l'ensemble des individus projetés dans un sous espace particulier. Cet espace de projection de dimensions  $n_k$  est construit de telle sorte que des paquets d'individus proches se forment naturellement dans chaque dimension [Dhi 05].

Cet algorithme repose sur une représentation des données sous formes d'un graphe de similarité  $G$  traduisant la notion de proximité entre individus. Il existe plusieurs façons de construire un tel graphe à partir des données:

- dans le graphe de voisinage  $\varepsilon$ , une arête existe entre deux individus  $x_i \in X$  et  $x_j \in X$  si

$$d(x_i, x_j) \leq \varepsilon \quad (1.7)$$

- dans le graphe des  $k$  plus proches voisins  $KNN$ , une arête existe entre les individus  $x_i \in X$  et  $x_j \in X$  si  $x_j \in KNN(x_i)$ , donc  $x_j$  est parmi les  $k$  individus les plus proches de  $x_i$  ;

- le graphe complet, une arête existe pour toutes les paires d'individus.

Le clustering spectral peut donc être vu comme un K-moyennes où les individus sont projetés en paquets d'individus similaires relativement au graphe de similarité construit à partir des données. Elle permet de retrouver naturellement les zones de fortes densités correspondant à un nombre important d'individus proches. Cette notion de densité est centrale dans le développement des approches basées sur le voisinage.

#### 1.4.5.2.2 Approches basées sur la densité ou voisinage

Sont les approches qui émettent des hypothèses topologiques sur la distribution de l'ensemble d'individus  $X$ .

❖ **Clustering basé sur la densité (DBSCAN)**

C'est une approche exclusivement algorithmique fondée sur la modélisation du concept de zone dense, et qui parcourt l'ensemble des individus afin de déterminer s'ils appartiennent ou non à une telle zone [Est 96].

Elle nécessite pour être applicable deux paramètres globaux :  $\varepsilon$  et *MinPts* qui fixent la manière de trouver les groupes en définissant une topologie, puis proposer une approche constructive basée sur celle-ci.

On distingue à partir de ces paramètres deux familles d'individus, des individus cœur, et frontières. Un individu  $x_i$  est qualifié de cœur s'il contient dans son voisinage de longueur  $\varepsilon$  au moins *MinPts* points, sinon il s'agit d'un individu frontière [Sub 12]. Le voisinage d'un individu  $x_i$  est défini par :

$$N_{\varepsilon}(x_i) = \left\{ x_j \in X \mid d(x_i, x_j) \leq \varepsilon \right\} \quad (1.8)$$

Alors :  $x_i$  est cœur si  $|N_{\varepsilon}(x_i)| \geq \text{MinPts}$  et frontière sinon.

Nous désignons deux cas:

- Atteignabilité directe :  $x_j$  est directement atteignable en densité à partir de  $x_i$  si  $x_j \in |N_{\varepsilon}(x_i)|$  et  $x_i$  est un individu cœur ;
- Atteignabilité en densité:  $x_j$  est atteignable en densité à partir de  $x_i$  si  $x_j$  est directement atteignable en densité à partir de  $x_i$  ou si  $\exists x_k \in X$  et  $x_k$  est un individu cœur tel que  $x_j$  est directement atteignable en densité à partir de  $x_k$  et  $x_k$  est atteignable en densité à partir de  $x_i$ .

On notera alors :

$$A(x_i) = \left\{ x_j \in X \mid x_j \text{ est atteignable par } x_i \right\} \quad (1.9)$$

Par ailleurs, l'approche DBSCAN permet de capturer des groupes de formes variées.

### ❖ *Approche neuromimétique : les cartes auto-organisées de Kohonen*

Les cartes auto-organisatrices [Koh 88] constituent une famille d'algorithmes d'apprentissage réalisant un clustering des individus en tenant compte de la topologie présente dans les données. Le principe est de faire évoluer un ensemble de prototypes (appelés aussi neurones) liés entre eux au moyen d'un graphe  $G$  qui représente une hypothèse topologique (souvent une grille) sur ces derniers. Le nombre de prototypes, prédéfini, doit être plus grand que le nombre de groupes supposé, ainsi le surnombre de prototypes permet de capturer la forme des groupes [Sub 12].

L'objectif visé est que l'ensemble des prototypes approxime la distribution naturelle des individus dans l'espace. La stabilité de la carte topologique est obtenue comme l'optimum du critère objectif suivant [Koh 01]:

$$\min_c Q_{soM}(c) = \min_c \sum_{k=1}^{n_k} \sum_{x_i \in X} K(c_k, f^*(x_i)) \|x_i - c_k\|_2^2 \quad (1.10)$$

Où  $c_k$  est le  $k$ -ième prototype. L'idée est alors proche, dans l'esprit, de KM où l'on va chercher à déplacer les prototypes, de sorte à minimiser l'inertie des individus autour de ceux-ci. L'inertie est pondérée par une fonction  $K$  quantifiant, pour un terme de l'inertie donné, une similarité entre le prototype concerné  $c_k$  et le prototype le plus représentatif de l'individu concerné  $f^*(x_i)$ .

#### 1.4.5.3 Approches floues et probabilistes

L'incertitude en classification lors du clustering peut être modélisée en utilisant la théorie des ensembles flous ou celle des probabilités [Sub 11]

- Dans le cadre des ensembles flous [Zad 65], on considère en général que chaque individu appartient simultanément à tous les groupes mais avec un certain degré d'appartenance.
- En ce qui concerne les approches probabilistes [Dem 77], nous considérons qu'un individu appartient à un seul groupe, qui correspond au groupe le plus probable, mais une probabilité non nulle existe concernant l'évènement d'appartenance à chacun des autres groupes.

### 1.4.5.3.1 K-moyennes floues (FKM)

L'approche discriminative des K-moyennes floues (FKM) est une généralisation de K-moyennes se basant sur des éléments de la théorie des ensemble flous [Bez 81] dont le principe est de minimiser la dispersion des individus relativement aux prototypes, mais pondérée cette fois par le degré d'appartenance de l'individu au groupe.

Généralement le nombre de groupes est désormais désigné par  $c_k$ . Tout simplement, un paramètre  $m$  est introduit, qui prend des valeurs strictement plus grandes que 1, et qui module le degré de flou de la partition obtenue à l'aide des c-moyennes floues. La forme générale du critère générique,  $J_m$ , paramétré par  $m$ , est :

$$J_m(u(\cdot), v) = \sum_{i=1}^c \sum_{x \in X} u_i^m(x) \|x - v_i\|^2 \quad (1.11)$$

Les centres et les degrés d'appartenance sont, pour une valeur de  $m$  donnée, calculés à l'aide des deux formules suivantes :

$$v_i = \frac{\sum_{x \in X} (u_i(x))^m x}{\sum_{x \in X} (u_i(x))^m} \quad (1.12)$$

$$u_i = \frac{1}{\|x - v_i\|^{2/(m-1)}} \frac{1}{\sum_{j=1}^c \frac{1}{\|x - v_j\|^{2/(m-1)}}} \quad (1.13)$$

La généralisation de KM est formulée comme étant un problème d'optimisation non convexe selon l'ensemble des variables correspondant aux centres et aux degrés. Ainsi, aucune garantie n'existe concernant l'optimalité globale de la solution, et il convient également dans ce cadre de relancer plusieurs fois l'algorithme. Cependant, empiriquement, FKM est beaucoup plus stable que son analogue strict [Sub 11].

### 1.4.5.3.2 Modèle de mélange

On suppose que l'ensemble de la population est une distribution de probabilité présentant un mélange de  $s$  distributions de probabilités associées aux classes dont l'intérêt est d'identifier les  $s$  distributions en estimant leurs paramètres [Day 69], [Wol 65].

Dans un contexte de classification, chaque  $x_i$  est supposé provenir d'une seule des  $s$  classes du mélange. Pour chaque objet, nous aurons donc un vecteur  $z_i$  de dimension  $s$ , avec  $z_{ik} = 1$  ou 0 selon que l'objet appartient à la classe  $z_k$  ou non. Les données complétées seront représentées par  $(x_1, z_1), \dots, (x_n, z_n)$ . A partir de cette formulation, nous obtenons la log-vraisemblance des données complétées ou log-vraisemblance complétée qui s'écrit :

$$L_C(x_1, \dots, x_n; \theta) = \sum_{i=1}^n \sum_{k=1}^s z_{ik} \log(p_k \varphi_k(x_i; \alpha_k)) \quad (1.14)$$

Où :  $\varphi_k(x_i; \alpha_k)$  est une densité de probabilité appartenant à une famille de densités de probabilités.

$p_k$  est la probabilité qu'un élément de l'échantillon suive la loi  $\varphi$ . On appellera ces  $p_k$  les proportions du mélange.

$\theta = (p_1, \dots, p_s; \alpha_1, \dots, \alpha_s)$  Désigne le paramètre du modèle de mélange, qui est inconnu.

Dans notre travail, on prend le modèle de mélange Gaussien. Dans ce cas, chaque objet  $x_i$  est supposé provenir indépendamment des autres, d'un mélange de densités

$$\varphi(x_i; \theta) = \sum_{k=1}^s p_k \varphi_k(x_i; g_k; \Sigma_k) \quad (1.15)$$

Où  $\varphi_k$  représente la densité Gaussienne de dimension  $d$ , de moyenne  $g_k$  et de variance  $\Sigma_k$

$$\varphi_k(x_i; g_k; \Sigma_k) = (2\pi)^{-d/2} |\Sigma_k|^{-1/2} \exp\left(-\frac{1}{2}(x_i - g_k)' \Sigma_k^{-1} (x_i - g_k)\right) \quad (1.16)$$

Et  $\theta = (p_1, \dots, p_{s-1}; g_1, \dots, g_s; \Sigma_1, \dots, \Sigma_s)$  est le vecteur des paramètres du mélange.

Ainsi, les classes associées aux composants du mélange sont ellipsoïdales, centrées sur la moyenne  $g_k$  et la matrice de variance  $\Sigma_k$  détermine les caractéristiques géométriques.

Les différents algorithmes classiques de classifications seront organisés dans le tableau 1.1 :

Le tableau 1.1 Différents méthodes de classification [Tur 01]

Famille	Variantes	Type
Méthodes probabilistes	Modèle bayésien, Modèle de l'information syntaxique, approche EM (estimation/maximisation)	hiérarchie ou partition
Méthodes des plus proches voisins (k-moyennes)	méthodes avec simple passe , Méthode de réallocation , Méthode des nuées dynamiques et des centres mobiles	partition
Méthodes factorielles	Analyse Factorielle des Correspondances (AFC), Latent Semantic Indexing (LSI)	partition
Méthodes agglomératives	ascendante ou descendante: Méthode du simple lien ou saut minimum, Algorithme de l'arbre de couverture minimum, Méthode du diamètre ou lien complet , Méthode du lien moyen , Méthode de Ward ou de la variance minimum , Méthode du plus proche voisin	hiérarchie
Méthodes d'extraction de graphes	Treillis de Galois, Graphe connexe, Motifs de graphe	partition
Méthodes de sériation	Analyse relationnelle, Méthode par permutation, Méthode des mots associés	partition
Méthodes neuronales	Cartes auto-organisantes de Kohonen, Réseau de Hopfield, Réseau ART	hiérarchie ou partition
Méthodes symboliques	Approche des plus proches voisins, Approche descendante, Approche ascendante	hiérarchie ou partition

Le classification automatique consiste à chercher quelles sont les paramètres des lois permettant d'expliquer, au mieux, la génération de l'échantillon d'individus  $X$ . Le modèle de mélange et l'algorithme EM est avantageux, comparativement aux méthodes cités et présentées avant. Il est générique du point de vue des l'hypothèse considérées sur la nature des distributions du mélange expliquant la génération de l'échantillon  $x$ . Ainsi nous pouvons utiliser différents type de lois pour modéliser les groupes (lois gaussiennes, multinomiales, poisson, etc.), l'algorithme reste le même, seul change le calcul explicite de la mise à jour des paramètres du modèle [Ver 07].

### 1.5 Approche proposée : Reconnaissance des formes par THT

L'objectif de notre travail consiste à la classification automatique des défauts de roulements à billes dans les entraînements électrique par les moteurs asynchrones. Nous proposons une méthodologie de reconnaissance de forme non supervisée intégrant la Transformation de Huang-Teager (**THT**) comme étape initiale d'analyse des données.

Enfin, la figure (1.10) présente la structure générale du processus de classification avec leurs étapes.

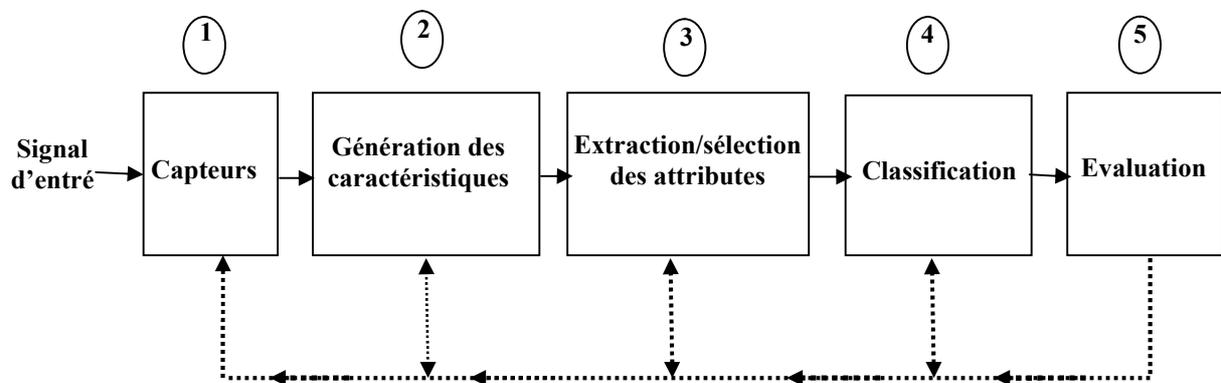


Figure .1.10 Schéma de la structure du processus de classification

De l'acquisition des données à la classification, la qualité de reconnaissance dépend grandement de chacune des étapes intermédiaires [Cex 06]

L'approche proposée est articulée autour de cinq (5) étapes :

**❖ Première Étape**

Elle consiste à l'acquisition des données. Concernant, notre cas, Dans cette étape, on utilise les données des signaux vibratoires [<http://www.eecs.case.edu/laboratory/bearing>] de roulement à billes sain et défectueux.

**❖ Deuxième Étape**

La mise en œuvre de cette étape est complexe [Dre 02], [Kil 96]. Elle consiste à l'analyse de données en collaboration avec des experts du domaine. Dans notre cas, la description des caractéristiques est réalisée par l'intermédiaire de la THT. Lorsque l'étape d'analyse semble satisfaisante par rapport aux objectifs, le nombre de caractéristiques est probablement important et peut être alors réduit.

**❖ Troisième Étape**

L'extraction/sélection des attributs, permet de réaliser une sélection parmi les caractéristiques et/ou d'en extraire de nouvelles soit par combinaison, soit par d'autres transformations. Ce faisant, la dimension des données est réduite. La réduction de la dimension est un problème complexe qui permet de réduire le volume d'informations à traiter et faciliter le processus de l'apprentissage. Pour deux raisons principales [Cor 02], [Dre 02] :

- La première repose sur la pertinence des caractéristiques. on acquiert un nombre maximal d'attributs que l'on réduit pour obtenir un espace de dimension inférieure dans lequel la discrimination est optimale.
- La deuxième repose sur ce que l'on appelle couramment la malédiction de la dimension) lors de l'apprentissage. En effet, paradoxalement l'augmentation du nombre de caractéristiques n'amélioré pas systématiquement la qualité de l'apprentissage et la capacité de généralisation de la RdF.

Les principaux objectifs de la réduction de dimension sont [Bau 09]:

- faciliter la visualisation et la compréhension des données ;
- réduire l'espace de stockage nécessaire ;
- réduire le temps d'apprentissage et d'utilisation ;
- identifier les facteurs pertinents.

On peut classer toutes les techniques mathématiques de réduction des dimensions en deux (2) catégories importantes [Gué 06] :

- la sélection des variables : elle consiste à choisir des caractéristiques dans l'espace de mesure, (Figure 1.11), Les méthodes de sélection visent à réduire la dimension de l'ensemble initial en recherchant un sous-ensemble d'attributs tout en maximisant un critère donné, en générale, sur une distance comme par exemple celle de Bhattacharya ou de Kullback-Leibler.

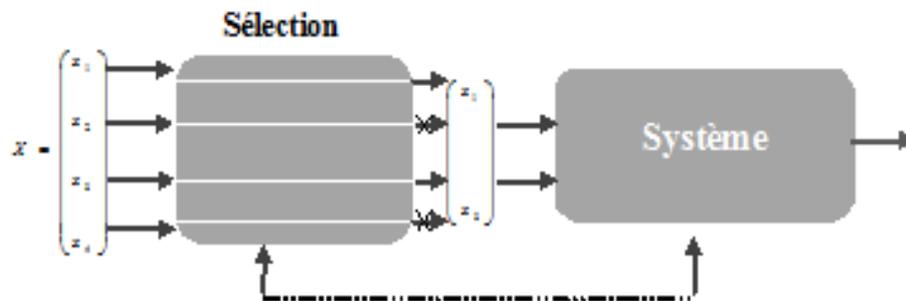


Figure .1.11 Principe de la sélection de variables

- l'extraction de traits : qui vise à sélectionner des caractéristiques dans un espace transformé dans un espace de projection (Figure 1.12), Parmi les méthodes d'extraction les plus couramment employées citons l'analyse en composantes principales (ACP), l'analyse en composantes curvilignes (ACC), ou encore la projection de Sammon

Dans ce contexte, on choisit la méthode d'opérateur d'énergie Teager- kaiser pour l'extraction des points pertinents et donc les vecteurs formes de tous les modes de fonctionnement afin de mieux classifier les défauts de roulement.

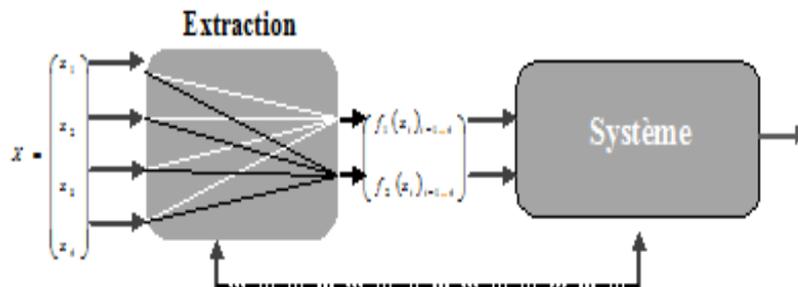


Figure .1.12 Principe de l'extraction de caractéristiques

### ❖ *Quatrième Étape*

Le type de méthodes de classification, se décline généralement en deux grandes familles : le mode supervisé et le mode non supervisé [Cor 02].

- Si l'on dispose d'un ensemble de points étiquetés, on parlera de classification supervisée. Dans ce cas, les classes d'appartenance des données sont connues.
- Dans le cas contraire, qu'il s'agit de notre objet de travail, on effectue une classification non supervisée appelée également classification automatique, dans ce cas, la recherche d'une partition des données revient à regrouper celles-ci selon une certaine mesure de similarité ou de dissimilarité. La métrique employée peut être de nature géométrique ou probabiliste.

On distinguera ainsi :

- Méthodes paramétriques, qui modélisent les données par un ensemble de paramètres à estimer,
- Méthodes non paramétriques, qui ne font pas d'hypothèse sur la distribution de ces données.

Les algorithmes de classification étant nombreux dans la littérature, notre étude sera consacrée aux modèles de mélange plus particulièrement le modèle de mélange gaussien avec estimation par l'algorithme expectation-minimisation (EM).

### ❖ *Cinquième Étape 5*

L'évaluation du système : le système doit être validé par une phase de test : c'est l'évaluation du système de RdF. La phase de généralisation consiste à appliquer les différentes étapes de 1 à 4 sur un signal inconnu et en déduire sa classe d'appartenance. L'évaluation des résultats d'un clustering est un problème majeur, qui renvoie à la question première : qu'est-ce qu'un bon schéma de clustering ? Cette problématique est plutôt bien synthétisée dans les récents travaux de M. Halkidi [Fla 93], [Fla 04].

Trois cheminements sont alors envisagés pour évaluer ou comparer entre eux des schémas de classification automatique :

- **L'évaluation externe** : il s'agit de confronter un schéma avec une classification prédéfinie. L'évaluation porte donc sur l'adéquation entre le schéma obtenu et une connaissance externe sur les données (schéma attendu).
- **L'évaluation interne** : Elle n'utilise que les données d'entrées comme référence. Concernant, le meilleur schéma c'est celui qui conserve un maximum d'informations relativement à l'information contenue dans la matrice de (dis) similarité.
- **L'évaluation relative** : elle porte sur les deux principaux critères de dispersions intra-clusters (à minimiser) et inter-clusters (à maximiser).

## 1.6 Conclusion

Le diagnostic des machines électriques a été (et il est encore) un thème de recherche très important depuis plusieurs décennies. En fait, ce terme se réfère à un suivi du système permettant de diagnostiquer les défauts des machines afin de déterminer les types de défaillances et leur gravité. Pour cette raison, on a essayé de présenter la relation entre le diagnostic et d'autres tâches de surveillance telle que la détection et la classification, en vue de donner un aperçu sur les méthodes et les techniques de surveillance et de diagnostic des machines électriques. Aussi, nous nous sommes intéressés à des approches heuristiques en expliquant la phase de classification (types, étapes, approches) après avoir choisi les modèles de mélanges et particulièrement le modèle de mélange gaussien. Nous avons mis l'accent sur ce dernier dans le but de l'appliquer à la classification des données des défauts de roulement dans les machines asynchrones. Finalement, Nous avons proposé et adapté une approche basée essentiellement sur les méthodes de RdF. Une méthodologie de reconnaissance de forme non supervisée intégrant la Transformation de Huang-Teager comme étape d'analyse des données. Cette approche repose sur cinq étapes: L'acquisition des données, génération des caractéristiques, l'extraction/sélection des attributs, la classification automatique et l'évaluation du système.

Le chapitre suivant sera consacré à l'étude de roulement à billes de la machine asynchrone, leurs défaillances et leurs méthodes de surveillance vibratoire.

## **CHAPITRE II**

# **LES ROULEMENTS A BILLES : CONSTITUTION, DEFAILLANCES ET ANALYSE VIBRATOIRE**

## **CHAPITRE II**

### **ROULEMENTS A BILLES : CONSTITUTION, DEFAILLANCES ET**

### **ANALYSE VIBRATOIRE**

#### **2.1 Introduction**

Les défaillances inhérentes aux machines tournantes sont très nombreuses parmi lesquels les défauts de roulement. Les roulements sont des composants mécaniques utilisés dans différents équipements industriels. Ils peuvent être considérées comme des éléments clés, car leurs défaillances réduisent la fiabilité et la disponibilité des équipements, et augmentent le risque d'accidents humains. En outre, leurs défaillances génèrent des coûts supplémentaires de maintenance et produit un impact négatif sur l'environnement. Beaucoup de ces défaillances entraînent des vibrations de la machine défaillante. Les vibrations peuvent alors être vues comme des symptômes de défaillances qui permettraient de traduire l'état mécanique d'une machine tournante.

Dans ce chapitre, on va d'abord rappeler les principaux modèles de roulements proposés dans la littérature ainsi que l'étude des roulements par analyse vibratoire. Les défauts de roulements, type écaillage, ont la propriété de générer un signal périodique qui a servi pour le développement de nombreuses méthodes de détection. Parmi les méthodes susceptibles de répondre à nos attentes, seules les plus utilisées vont retenir notre attention comme TFFG, distribution de Wigner-ville, transformation en ondelette et finalement l'outil le plus privilégié transformation de Hilbert Huang.

## 2.2 Roulements à billes

Le roulement est un organe de base qui assure une liaison mobile entre deux éléments d'un mécanisme en rotation l'un par rapport à l'autre. Sa fonction est de permettre la rotation relative de ces éléments, sous charge, avec précision et avec un frottement minimal. Toute machine tournante comporte des roulements à billes ou à rouleaux. Ils constituent la partie la plus sollicitée de la machine et causent des pannes fréquentes [Bou 03]. La plus part de mauvais fonctionnement se répercutent directement sur leurs états, donc il est recommandable de connaître parfaitement leurs architectures et leurs dynamiques de fonctionnement [Oum 12]. Le roulement à billes présente un vieillissement relativement rapide [Sch 95] qui peut être diagnostiqué grâce à l'analyse du spectre d'une mesure acoustique ou vibratoire [Liu 13].

### 2.2.1 Constitution de Roulements à billes

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

- ❖ un organe externe/ bague extérieure ;
- ❖ un organe interne/bague intérieure ;
- ❖ des organes roulants / rangée de billes ;
- ❖ un organe de lubrification/ cage.

Cependant, les organes de roulement peuvent être des billes, des rouleaux ou des aiguilles ayant des caractéristiques spécifiques en termes de charges radiales et axiales supportées, de vitesse limite ou encore de défaut d'alignement admissible [Bou 03]. Par ailleurs, les roulements à billes se distinguent selon la forme de leur bague : roulements à billes à gorge profonde, à contact oblique, à rotule sur billes et butées à billes [Fen 11].

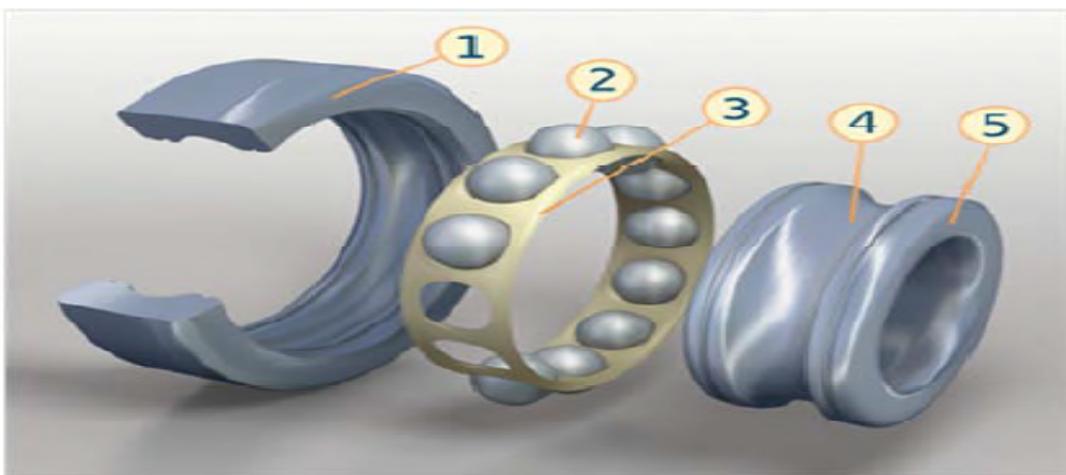


Figure. 2.1 Constitution d'un roulement à billes [Nia 00]

**2.2.2 Modèles de roulement**

En générale, il y en a trois :

**2.2.2.1 Modèle de Palmgrem**

En tenant compte des hypothèses suivantes : déformations structurales des bagues et bâti négligés , petits déplacements , forces d’inertie négligées , pas de rotation de la bague intérieure par rapport à la bague extérieure , les travaux [Aub 92] [Her 82] montre qu’avec l’estimation les déflexions radiales et axiales ( voir la figure 2.2), on obtient des modèles analytiques du comportement d’un point de vue force-déplacement [Pal 59] .

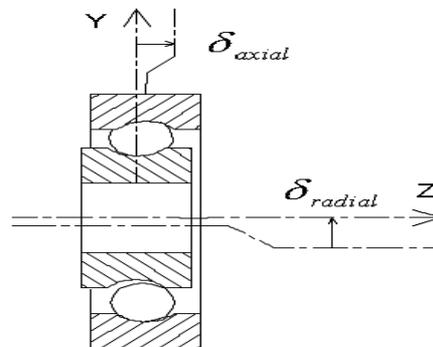


Figure.2.2 Bases de calcul et déplacement radial et axial d’une bague par rapport à l’autre.

Le roulement est soumis à un déplacement tel que :

$$\vec{\delta} = \delta_{radial} \vec{Y} + \delta_{axial} \vec{Z} \tag{2.1}$$

Où  $\delta_{radial}$  et  $\delta_{axial}$  sont les déplacements radiaux et axiaux d’une bague par rapport à l’autre.

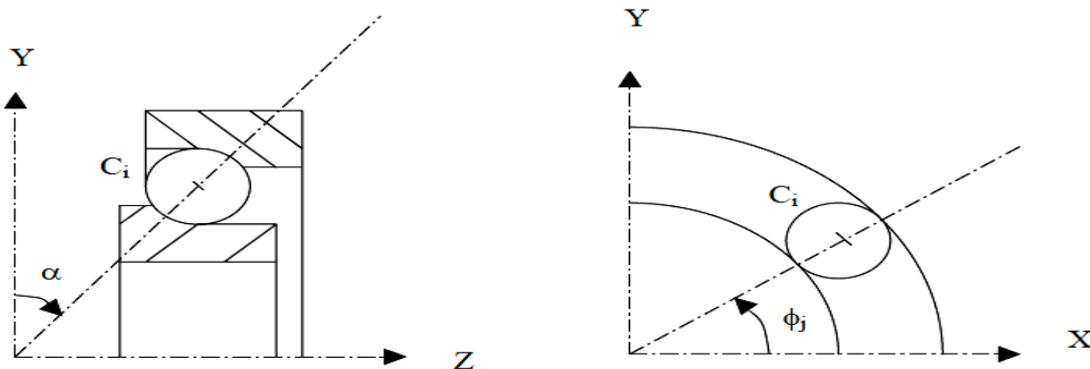


Figure.2.3 Bases de calcul

La figure (2.3) montre le déplacement local au niveau de la bille, qui s'exprime par :

$$\delta_j = \delta_{axial} \sin(\alpha) + \delta_{radial} \cos(\alpha) \cos(\phi_j) \quad (2.2)$$

La relation entre la force et le déplacement au niveau du contact bille et bague permet de l'établir par la théorie de Hertz :

$$F_j = K \delta_j^{3/2} \quad (2.3)$$

Où,

$K$  : constante liée à la géométrie du roulement ;

$F$  : effort appliqué à la  $j^{\text{ème}}$  bille.

Cette relation permet d'étudier l'équilibre global de la bague intérieure du roulement. En sommant sur l'ensemble des billes, les efforts sur le roulement s'écrivent :

$$\begin{cases} F_{axial} = \sum_{j=1}^z F_j \sin(\alpha) \\ F_{radial} = \sum_{j=1}^z F_j \cos(\alpha) \cos(\phi_j) \end{cases} \quad (2.4)$$

Où :

$z$  : nombre de billes ;

$\alpha$  : angle de contact ;

$\phi_j$  : angle que fait la bille avec l'axe de référence.

Une force de compression ( $F_j$ ) sollicite les bagues extérieure et intérieure de chacune des billes ayant rigidité radiale du contact exprimée par les relations suivantes:

$$\begin{cases} F_j = K_{b1} \delta_1^{3/2} \\ F_j = K_{b2} \delta_2^{3/2} \end{cases} \quad (2.5)$$

Avec,

$\delta_1$  et  $\delta_2$  : déplacements partiels de chacune des bagues.

L'écrasement total sur la bille ( $j$ ) peut s'exprimer par la somme des déplacements, tel que:  $\delta_j = \delta_1 + \delta_2$ . De ce fait,  $\delta_j$  peut s'écrire :

$$\delta_j = \left( \frac{1}{K_{b1}^{2/3}} + \frac{1}{K_{b2}^{2/3}} \right) F_j^{2/3} \quad (2.6)$$

Ainsi, on déduit que :

$$F_j = \frac{1}{\left( \frac{1}{K_{b1}^{2/3}} + \frac{1}{K_{b2}^{2/3}} \right)} F_j^{2/3} \quad (2.7)$$

La rigidité axiale de chaque bille s'écrit :

$$K_b = \frac{K_{b1} \cdot K_{b2}}{\left( K_{b1}^{2/3} + K_{b2}^{2/3} \right)^{3/2}} \quad (2.8)$$

La variation de la rigidité est surtout le désalignement des arbres sont les causes principaux de l'apparition des vibrations des roulements à billes [Bri 99]

### 2.2.2.2 Modèle de De Mul

Ce modèle est une approche basée sur une description vectorielle et un formalisme matriciel [Mul 89]. Il considère que les forces sollicitant les billes sont provoquées par les charges extérieures appliquées sur l'arbre. Par ailleurs, Il permet de déterminer la répartition des charges, les déplacements et les angles de contact des éléments roulants [Deb 04] en tenant compte des hypothèses simplificatrices suivantes :

- la bague extérieure est fixe dans l'espace ;
- les bagues sont supposées indéformables ;
- les effets hydrodynamiques sont négligés (absence de lubrification) ;
- les interactions dues à la cage ne sont pas prises en compte ;
- les effets gyroscopiques sont négligés (la vitesse de rotation de l'arbre est faible).

Le modèle utilise un repère cartésien B0 (X, Y, Z) et d'un repère cylindrique B1 (r, t, Z). Comme le montre la figure (2.4).

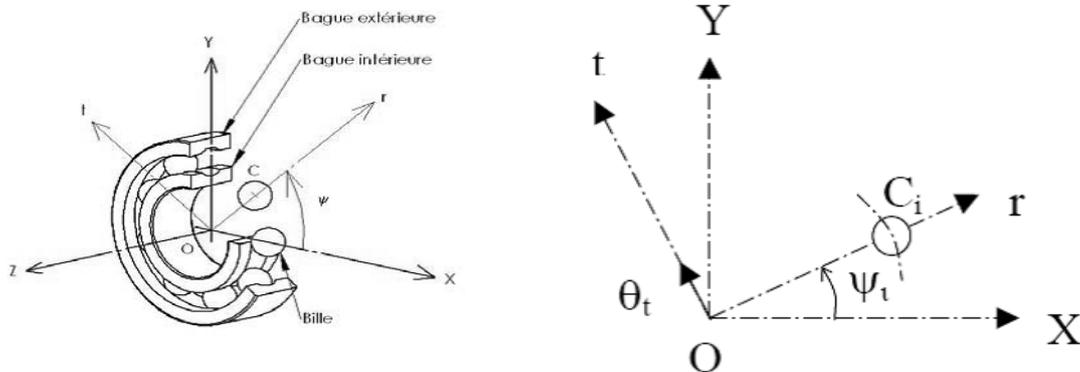


Figure.2.4 Repères de référence du roulement à billes

Avec,  $C_i$  est le centre de la bille  $i$  ;  $I$  est de la bague intérieure et  $E$  est le centre de courbure de la bague extérieure dans le plan radial.

La charge sur l'arbre développe des forces sur chacune des billes causant un déplacement relatif de la bague intérieure (BI) par rapport à la bague extérieure (BE), Comme le montre la figure 2.5.

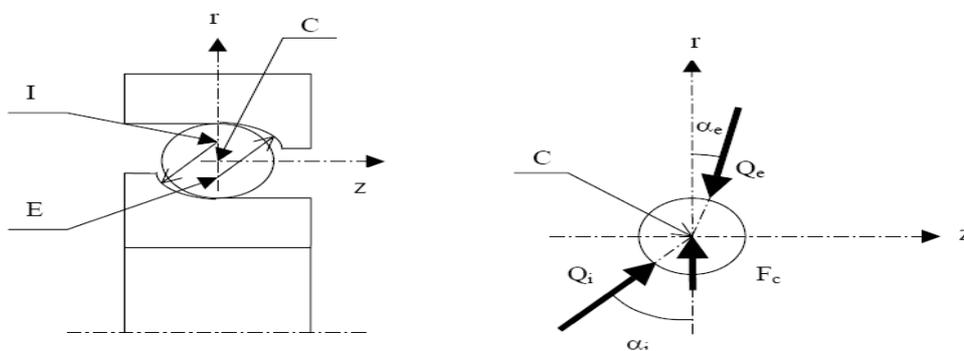


Figure.2.5 Centre de courbure et forces extérieures appliquées sur une bille

Le déplacement peut s'écrire sous la forme d'un torseur au point O dans la base B0 (X, Y, Z):

$$\bar{\delta}_{BI/BE} = \left\{ \begin{matrix} \beta_x & \delta_x \\ \beta_y & \delta_y \\ 0 & \delta_z \end{matrix} \right\}_{O, B_0} \tag{2.9}$$

En le projetant dans la base cylindrique B1, il s'écrit pour la  $i^{\text{ème}}$  bille

$$\bar{\delta}_{BI/BE} = \left\{ \begin{array}{cc} \beta_x \cdot \cos(\psi_i) + \beta_y \cdot \sin(\psi_i) & \delta_x \cdot \cos(\psi_i) + \delta_y \cdot \sin(\psi_i) \\ -\beta_x \cdot \cos(\psi_i) + \beta_y \cdot \sin(\psi_i) & -\delta_x \cdot \cos(\psi_i) + \delta_y \cdot \sin(\psi_i) \\ 0 & \delta_z \end{array} \right\}_{O, B_1} \quad (2.10)$$

Ce déplacement peut facilement être transporté au point I (centre de courbure de la BI pour la  $i^{\text{ème}}$  bille) dans la base B1 :

$$\bar{\delta}_{BI/BE}^{I, B_1} = \bar{\delta}_{BI/BE}^{O, B_1} + \overrightarrow{IO} \wedge \theta_{BI/BE}^{O, B_1} \quad (2.11)$$

Où :  $R_I$  et  $Z_I$  sont les coordonnées radiale et axiale dans la base (r, t, z).

Les déplacements obtenus dans le repère cylindrique B1 sont :

$$\left\{ \begin{array}{l} \delta_r = \delta_x \cdot \cos(\psi_i) + \delta_y \cdot \sin(\psi_i) - Z_I \cdot \beta_x \cdot \sin(\psi_i) + Z_I \cdot \beta_y \cdot \cos(\psi_i) \\ \delta_a = \delta_z + R_I \beta_x \cdot \sin(\psi_i) - R_I \cdot \beta_y \cdot \cos(\psi_i) \\ \theta_t = -\beta_x \cdot \sin(\psi_i) + \beta_y \cdot \cos(\psi_i) \end{array} \right. \quad (2.12)$$

Les autres termes étant identiquement nuls. Ce système peut s'écrire sous forme matricielle, en posant que :

$$\bar{d}_{BI/BE}^{I, B_1} = \begin{bmatrix} T \\ \psi \end{bmatrix} \cdot \bar{d}_{BI/BE}^{I, B_0} \quad (2.13)$$

Avec:

$$\begin{bmatrix} T \\ \psi \end{bmatrix} = \begin{bmatrix} \cos(\psi_i) & \sin(\psi_i) & 0 & -Z_i \sin(\psi_i) & Z_i \cos(\psi_i) \\ 0 & 0 & 1 & R_i \sin(\psi_i) & -R_i \cos(\psi_i) \\ 0 & 0 & 0 & -\sin(\psi_i) & +\cos(\psi_i) \end{bmatrix} \quad (2.14)$$

Le principe fondamental de la dynamique est appliqué à chaque bille, en considérant la figure (2.4), permet d'écrire dans la base cylindrique  $B_1$  :

$$\left\{ \begin{array}{l} \Phi_i \cdot \cos(\alpha_i) + \Phi_e \cdot \cos(\alpha_e) + F_c = 0 \\ \Phi_i \cdot \sin(\alpha_i) - \Phi_e \cdot \cos(\alpha_e) = 0 \end{array} \right. \quad (2.15)$$

Avec  $Q_i$  la force de la bague intérieure sur la bille,  $Q_e$  la force de la bague extérieure sur la bille et  $F_c$  la force centrifuge. Les angles  $\alpha_i$  et  $\alpha_e$  peuvent s'écrire (figure 2.6) :

$$\tan(\alpha_i) = \frac{CI \cdot \sin(\alpha_0) - \delta_a^C + \delta_a^I}{CI \cdot \cos(\alpha_0) - \delta_r^C + \delta_r^I} \quad (2.16)$$

$$\tan(\alpha_e) = \frac{EC \cdot \sin(\alpha_0) + \delta_a^C}{EC \cdot \cos(\alpha_0) + \delta_r^C} \quad (2.17)$$

Où ,  $\alpha_0$  est l'angle de contact initial,  $\delta_r^C$  et  $\delta_a^C$  les déplacements radial et axial du centre de la bille,  $\delta_r^I$  et  $\delta_a^I$  les déplacements radial et axial du centre de courbure de la bague .

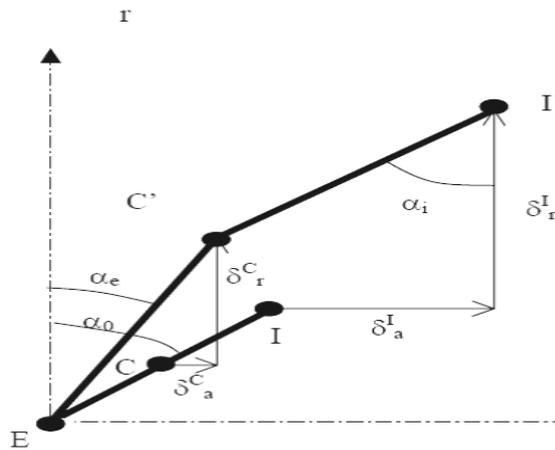


Figure.2.6 Déplacement axial et radiaux du centre de courbure

La théorie d'Hertz permet d'établir la relation force-déplacement pour chaque bille :

$$\begin{cases} \Phi_i = K \cdot \delta_i^n, & \text{pour } \delta_i \geq 0 \\ \Phi_i = 0, & \text{pour } \delta_i < 0 \end{cases} \quad (2.18)$$

$$\begin{cases} \Phi_e = K \cdot \delta_e^n, & \text{pour } \delta_e \geq 0 \\ \Phi_e = 0, & \text{pour } \delta_e < 0 \end{cases} \quad (2.19)$$

Où : K est le coefficient de rigidité au contact,

n dépend de la nature du contact et vaut 3/2 pour un roulement à billes,

$\delta_i$  et  $\delta_e$  le rapprochement des centres de courbure des bagues intérieure et extérieure vers le centre de la bille :

$$\begin{cases} \delta_i = \overline{C'I} - \overline{CI} - r_i = \sqrt{\left(\overline{CI} \cdot \sin(\alpha_0) - \delta_a^C + \delta_a^I\right)^2 + \left(\overline{CI} \cdot \cos(\alpha_0) - \delta_r^C + \delta_r^I\right)^2} - \overline{CI} - r_i \\ \delta_e = \overline{EC} - \overline{EC} - r_e = \sqrt{\left(\overline{EC} \cdot \sin(\alpha_0) + \delta_a^C\right)^2 + \left(\overline{EC} \cdot \cos(\alpha_0) + \delta_r^C\right)^2} - \overline{CI} - r_i \end{cases} \quad (2.20)$$

Où :  $r_i$  et  $r_e$  sont les jeux radiaux entre la bille et les bagues intérieure et extérieure.

L'équilibre de la bague intérieure s'obtient en résolvant les équations suivantes :

$$\vec{F} + \sum_{j=1}^n [R_{\psi}]_j^t \cdot \vec{\Phi}_i^j \approx \vec{0} \quad (2.21)$$

Où :  $\vec{F}$  le vecteur force de la bille  $j$  sur la bague intérieure exprimé dans le repère  $R_{\psi}$ .

La méthode de Newton- Raphson permet de résoudre ce système d'équations non linéaire de calculer la matrice de raideur tangente globale du roulement:

$$[k_t^e] = \begin{bmatrix} [k_t] & [-k_t] \\ [-k_t] & [k_t] \end{bmatrix}_{10*10} \quad (2.22)$$

Avec:

$$[k_t] = [R_{\psi}]_{5*3}^t \left[ \frac{\partial \vec{\Phi}_i}{\partial x_j} \right]_{3*3} [R_{\psi}]_{3*5} \quad (2.23)$$

### 2.2.2.3 Modèle de Bourdon

Ce modèle tient compte d'un éventuel angle de basculement ( $\gamma$ ) entre la bague extérieure et intérieure [Bou 99], voir la figure 2.7. Deux nœuds ( $N_i$  et  $N_e$ ) sont arbitrairement choisis pour chaque bille sur la bague intérieure et extérieure.

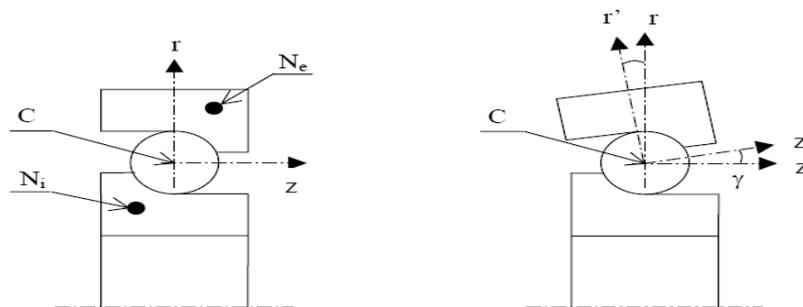


Figure.2.7 Basculement de la bague extérieure par rapport à la bague intérieure

L'angle de basculement  $\gamma$  se décompose dans la base fixe  $B_0$  :

$$\gamma = -\theta_x^{Ne} \cdot \sin(\psi_j) + \theta_y^{Ne} \cdot \cos(\psi_j) \quad (2.24)$$

Les déplacements relatifs entre les bagues intérieure et extérieure pour le centre C de la bille sont déduits des déplacements des nœuds  $N_i$  et  $N_e$  :

$$\vec{d}_{R_0}^{N_i} = \vec{\delta}_{R_0}^{N_i} - \vec{\delta}_{R_0}^{N_e} \quad (2.25)$$

Dans le système cylindrique  $B_2$  ( $C_2, r', t, z'$ ), ces déplacements et rotations peuvent s'exprimer considéré fixe par rapport à la bague extérieure, en utilisant la matrice de rotation :

$$\begin{bmatrix} R_{\psi\varphi} \end{bmatrix} = \begin{bmatrix} R_{\psi} \end{bmatrix} \cdot \begin{bmatrix} R_{\varphi} \end{bmatrix} \quad (2.26)$$

Où :  $\begin{bmatrix} R_{\psi} \end{bmatrix}$  est la matrice de rotation du modèle de De Mul et  $\begin{bmatrix} R_{\varphi} \end{bmatrix}$ , celle qui caractérise la rotation de la base  $B_1$  par rapport à la base  $B_2$ . Le déplacement du point  $N_i$   $\vec{d}_{R_0}^{N_i}$  peut s'exprimer alors dans la base  $B_2$  (2.27) et la base  $B_0$  (2.28):

$$\vec{\delta}_{BI/BE}^{C, B_2} = \vec{\delta}_{BI/BE}^{N_i, B_2} + \overrightarrow{CN_i} \wedge \theta_{BI/BE}^{B_2} \quad (2.27)$$

$$\vec{\delta}_{BI/BE}^{C, B_2} = \begin{bmatrix} R_{\psi\varphi} \end{bmatrix} \cdot \vec{\delta}_{BI/BE}^{N_i, B_2} + \overrightarrow{CN_i} \wedge \begin{bmatrix} R_{\psi\varphi} \end{bmatrix} \cdot \theta_{BI/BE}^{B_2} \quad (2.28)$$

La connaissance des déplacements de  $N_i$  et  $N_e$  pour chaque bille permet de résoudre le problème statique du roulement en utilisant aussi la méthode De Mul.:

$$\begin{bmatrix} k_t^e \end{bmatrix} = \begin{bmatrix} \frac{\partial \overrightarrow{\Phi}_i}{\partial x_j} \end{bmatrix}_{10*10} \quad (2.29)$$

Pour chaque bille, la matrice de raideur tangente est associée aux degrés de liberté suivants :

$$\overrightarrow{u}_{B_0} = \left[ \delta_x^{N_i} \quad \delta_y^{N_i} \quad \delta_z^{N_i} \quad \beta_x^{N_i} \quad \beta_y^{N_i} \quad \delta_x^{N_e} \quad \delta_y^{N_e} \quad \delta_z^{N_e} \quad \beta_x^{N_e} \quad \beta_y^{N_e} \right]^t \quad (2.30)$$

## 2.3 Défauts de roulement et techniques de détection

### 2.3.1 Statistique

Statistiquement les défauts des roulements à billes s'estiment entre 40 et 50% des pannes totales d'une machine électrique [IEEE 85a], [IEEE 85b], [EPR 82]. La figure 2.8 donne une idée sur la répartition des pannes selon les sources IEEE et EPRI.

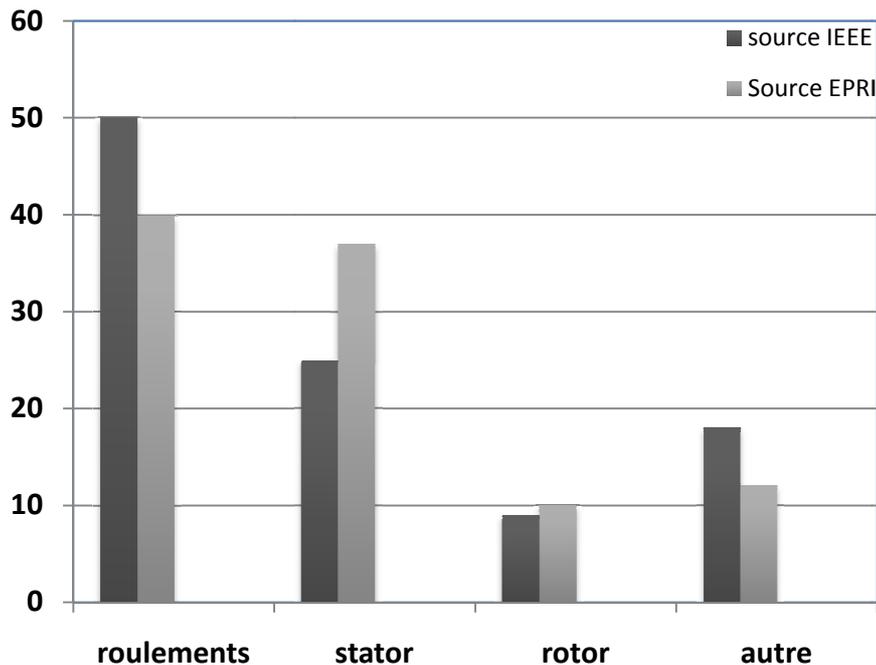


Figure.2.8 Répartition du taux de panne dans les machines asynchrones

Ceci a orienté notre contribution vers la détection et diagnostic de défauts roulements à billes de la machine asynchrone. En effets plusieurs mécanismes sont la cause de ces défauts et nombreuses méthodes existent [McI 03], [Li 06] pour détecter et les localiser.

### 2.3.2 Défauts de roulement

On peut noter deux types d'avaries caractéristiques de la détérioration des roulements ;

- les avaries dites naturelles dues à la fatigue des roulements
- les avaries dues à un mauvais montage ou une mauvaise utilisation du roulement.

On qualifie les principaux défauts :

- Le grippage, dû à l'absence de lubrification, à une vitesse excessive ou un mauvais choix du type de roulement. Les empreintes par déformation, dues à des traces de coups, des fissures ou des cassures.
- 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, surtout quand les roulements viennent d'être nettoyés et sont contaminés par la transpiration des mains.
- La corrosion de contact, due au mauvais choix d'ajustements entre les bagues et les logements ou les arbres.
- 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. L'usure par abrasion donne aux roulements un aspect gris, givré.

### **2.3.3 Techniques de détection des défauts de roulement**

Comparé à d'autres pannes de la machine asynchrone, les défauts de roulement ont suscité relativement peu d'attention. Ceci est certainement lié à la difficulté de les détecter par la surveillance du courant statorique [Ibr 09].

Un premier travail sur l'incidence des défauts localisés de roulement sur le courant statorique a été publié dans [Sch 95], les défauts de roulement entraînent une excentricité qui varie avec la position du rotor et qui se manifeste par des fréquences supplémentaires dans le spectre du courant statorique [Ibr 09].

Lebaroud et Clerc [Leb 08] proposent des outils de classification des défauts, en l'occurrence la Représentation Temps-Fréquence (RTF) associé à un critère de décision basé sur la distance Mahalanobis. La RTF sert à l'extraction des points pertinents qui séparent au maximum, selon le critère de Fisher, deux états : l'un sain et l'autre en défaut.

Toutefois le choix des points est expertisé, ce qui rend cette méthode semi automatique. L'association RTF - HMM (Modèle de Markov Caché) permet l'automatisation complète de la procédure de diagnostic des défauts depuis l'acquisition et le traitement des données jusqu'à la prise de décision. Cette méthode, testée en présence des défauts (stator, rotor et roulement), semble donner des bons résultats [Ibr 09].

La détection des défauts de roulement par analyse du courant électrique est pertinente, mais le problème majeur de l'analyse du courant est que les défauts mécaniques sont souvent noyés dans le bruit ou masqués par la forte contribution électrique, ce qui ne permet pas un bon diagnostic à partir du courant électrique. Certaines méthodes, dites à haute résolution (HR) fréquentielle, ont été appliquées [Kia 07], pour aider à la détection des défauts et au diagnostic des machines qui ne sont pas l'objectif de notre étude.

La détection de défaut de roulement à partir des signaux de vibration est affectée par la vitesse de la machine [Sta 03], en particulier quand l'état de roulement se dégrade. Les vibrations de la machine peuvent diminuer même si la panne soit imminente et la durée de vie du roulement est également influencée par les fluctuations de vitesse de la machine.

L'avantage de l'analyse d'enveloppe sur l'analyse traditionnelle du spectre est montré dans [Ran 01], [Mcl 03], [Ant 05]. Le travail [Mcl 03] présente également les principes fondamentaux des techniques de détection de défaut de roulement d'une façon très simplifiée.

## **2.4 Analyse vibratoire**

L'analyse des vibrations permet de détecter les dysfonctionnements et d'estimer leur effet et par conséquent de planifier ou reporter une intervention mécanique [Bou 99], [Est 04]

Il existe deux technologies permettant de réaliser une surveillance vibratoire :

- par mesure directe du déplacement des parties tournantes (arbres de machines). Réalisée à l'aide de capteurs à courants de Foucault, la technologie mise en œuvre est lourde. Cette surveillance est presque toujours réalisée on line c'est-à-dire en temps réel. Les capteurs mesurent en permanence les déplacements des arbres et autorisent ainsi le déclenchement immédiat d'alarmes en cas de dysfonctionnement;

- par mesure de l'accélération subie par les parties fixes de la machine (carters). Les moyens mis en œuvre sont, dans ce cas, beaucoup plus accessibles. À l'aide d'un accéléromètre relié à un collecteur de données, on recueille les vibrations subies par les carters des machines. Cette technique se prête aussi bien à la surveillance on line qu'à la surveillance périodique effectuée lors de rondes selon un calendrier préétabli.

### 2.4.1 Outils de l'analyse vibratoire

On peut distinguer trois grandes étapes pour réaliser l'acquisition :

- les vibrations mécaniques sont transformées en signaux électriques grâce aux capteurs de vibrations,
- les signaux électriques sont conditionnés pour rendre exploitable les signaux par les appareils d'analyses,
- les signaux sont enregistrés par différents matériels tels que les analyseurs de spectre, les collecteurs de données ou les cartes d'acquisition associés à des logiciels de traitement.

#### 2.4.1.1 Capteur de vibrations

Le capteur le plus utilisé est l'accéléromètre. Son principe est de générer un signal électrique proportionnel au niveau de vibration. [Est 04].

#### 2.4.1.2 Conditionnement du signal

Le signal électrique doit être conditionné, par les différents points ci dessous, pour être traité par les appareils d'analyse.

- L'amplification du signal de sortie du capteur pour le rendre exploitable, réalisée par le préamplificateur ;
- L'intégration du signal pour passer à la vitesse ou au déplacement, réalisée par l'intégrateur ;
- La limitation de la plage de fréquences du signal, réalisée par les filtres passe-haut et passe bas;
- l'amplification du signal pour le transmettre à l'appareil d'analyse, réalisée par l'amplificateur.

### 2.4.1.3 Matériel de traitement

Les signaux issus du conditionnement sont obtenus grâce à des analyseurs de spectre, les collecteurs de données ou les cartes d'acquisition associés à des logiciels de traitement. Cependant, le choix de la fréquence d'échantillonnage, conditionne la qualité du signal enregistré

### 2.4.2 Caractéristiques du signal engendré par le roulement

À l'interface entre le rotor et le stator, le roulement à billes présente aussi un vieillissement relativement rapide. Classiquement ce type de défaut est diagnostiqué à partir du spectre d'une mesure acoustique ou vibratoire. En partant du principe que l'entrefer n'est plus constant lors d'une défectuosité du roulement, R. Schoen et al. [Sch 95] ont montré que cette information était aussi présente dans le spectre du courant, puisque n'importe quelle excentricité produit des anomalies dans la distribution du champ dans l'entrefer. Il a explicité l'expression analytique des fréquences liées aux défauts du roulement en fonction de ses paramètres mécaniques (nombre de billes de roulement, vitesse mécanique du rotor, l'angle de contact des billes avec les bagues ...), et donne la relation suivante [Oum 12] :

$$f_{bng} = |f_s \pm mf_v| \quad (2.31)$$

où  $m = 1, 2, 3, \dots, m$  et  $f_v$  est une fréquence caractéristique de vibration.

Blödt, [40] suggère les expressions pour les trois types de défaut comme suit :

$$\text{Défaut de bague extérieure : } f_{bng} = |f_s \pm mf_o| \quad (2.32)$$

$$\text{Défaut de bague intérieure : } f_{bng} = |f_s \pm f_r \pm mf_i| \quad (2.33)$$

$$\text{Défaut de bague extérieure : } f_{bng} = |f_s \pm f_{cage} \pm mf_b| \quad (2.34)$$

Les défauts les plus rencontrés sur les roulements sont l'écaillage, le grippage. Ces défauts se traduisent par des vibrations à des fréquences caractéristiques. Les fréquences de défaut de roulement incluent la fréquence de la bague extérieure  $f_o$ , la fréquence de la bague intérieure  $f_i$ , la fréquence des billes  $f_b$ , ainsi que la fréquence de la cage  $f_{cage}$  peuvent être estimées par les expressions suivantes:

- Fréquence de défaut de cage :

$$f_{cage} = \frac{f_r}{2} \left( 1 - \frac{d}{D_m} \cos \alpha \right) \quad (2.35)$$

- Fréquence de défauts des éléments roulants

$$f_b = \frac{D_m}{d} f_r \left( 1 - \left( \frac{d}{D_m} \cos \alpha \right)^2 \right) \quad (2.36)$$

- Fréquence de défaut de la bague intérieure

$$f_i = \frac{Nb}{2} f_r \left( 1 + \frac{d}{D_m} \cos \alpha \right) \quad (2.37)$$

- Fréquence de défaut de la bague extérieure

$$f_e = \frac{Nb}{2} f_r \left( 1 - \frac{d}{D_m} \cos \alpha \right) \quad (2.38)$$

La figure (2.9) présente les dimensionnements d'un roulement à bille, dont les paramètres caractéristiques sont les suivantes :

Nb : Nombre des éléments roulants.

Dm : diamètre moyen du roulement,

d : diamètre moyen de la bille,

$\alpha$ : angle de contact de la bille avec les bagues

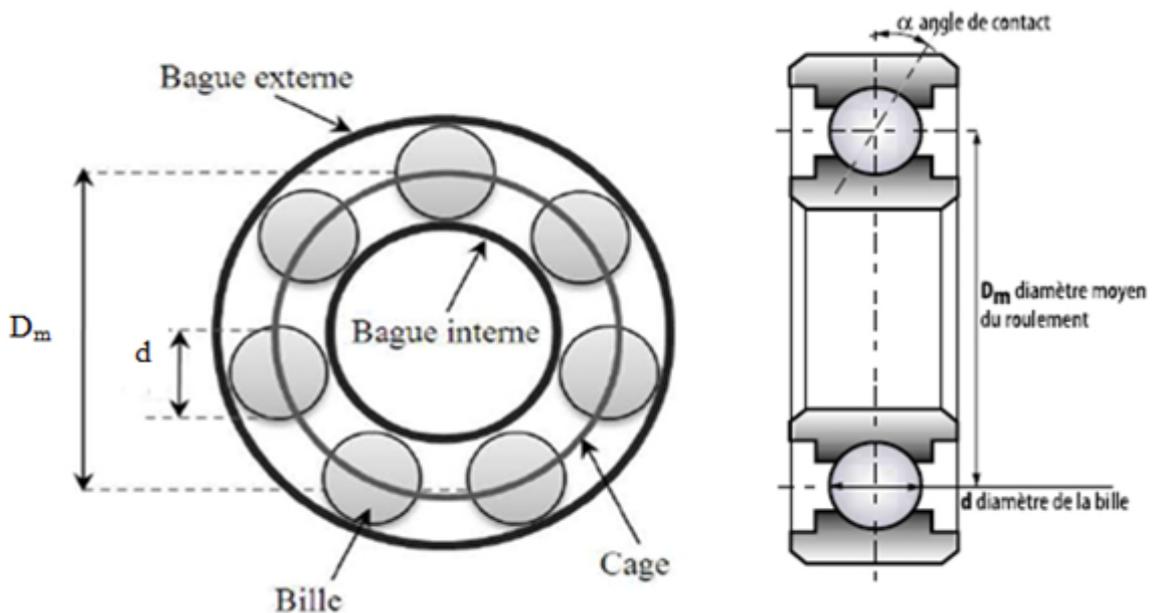


Figure.2.9 Structure d'un roulement à billes

### 2.4.3 Prétraitements des signaux

La qualité d'un enregistrement nécessite quelquefois un prétraitement. Il s'agit essentiellement de méthodes de débruitage et de filtrage. Le débruitage permet en supprimant le bruit de conserver juste le signal utile. Plusieurs techniques existent [Chi 07]:

- La soustraction spectrale [Bol 79]. Le signal est découpé en M blocs, tous traités par la transformée de Fourier et sont moyennés. Cette moyenne fait enfin l'objet d'une transformée de Fourier inverse supprimant ainsi le bruit.
- Le Moyennage synchrone [Mcf 87]. Il consiste à faire l'acquisition de plusieurs signaux à partir d'un "top tour" ou d'un front montant (lors d'un choc par exemple) et de réaliser la moyenne de l'ensemble des signaux.
- La méthode SANC, Self Adaptive Noise Cancelation [Cha 81]. Cette méthode consiste à déterminer un filtre adaptatif permettant d'estimer le bruit perturbateur afin de le supprimer du signal.
- Le seuillage en ondelettes [Don 95]. Ce seuillage est conçu pour traiter du bruit stationnaire gaussien. Cette technique peut être utilisée pour extraire les défauts vibratoires d'un signal fortement bruité.
- La méthode de séparation de sources [Has 96]. Elle permet de séparer des signaux statistiquement indépendants. On peut citer l'exemple de la parole mélangée au bruit du véhicule.

### 2.4.4 Méthodes d'analyse vibratoire

La Transformée de Fourier (TF) convient pour des signaux stationnaires dont les propriétés statistiques sont invariantes dans le temps. Donc, il s'est avéré qu'elle n'est pas adéquate les signaux non-stationnaires. Alors, pour l'analyse ces dernier signaux, on utilise la représentation temps-fréquence [Est 04] afin d'avoir une description détaillée et pertinente des signatures temps-fréquence composant le signal. Parmi ces méthodes, on distingue particulièrement :

### 2.4.4.1 Indicateurs temporels

Ceux sont des méthodes temporelles dédiées pour la surveillance des systèmes car elles ne permettent pas de localiser les défauts [Tan 99], [Jar 05]. Elles sont basées sur l'analyse statistique du signal à travers des indicateurs dits "globaux" qui prédisent l'état de fonctionnement global du système.

L'indicateur scalaire le plus couramment utilisé est la valeur efficace du signal ou valeur RMS (Root Mean Square). Ils sont utilisés pour signaux de type accélérations sur une bande de fréquences allant de 0 à 20 kHz ou de fréquences de structure pour augmenter la sensibilité leur sensibilité [Est 04].

$$V_{efficace} = V_{RMS} = \sqrt{\frac{1}{T} \int_t^{t+T} x^2(t) dt} \quad (2.39)$$

Cet indicateur est traditionnellement utilisé pour des signaux de type accélérations et sur une large bande de fréquences entre 0 et 20 kHz. Cependant, il n'est pas rare de voir des valeurs RMS calculées sur des bandes de fréquences correspondant à des résonances de structure pour augmenter la sensibilité de l'indicateur [Est 04].

Par ailleurs, on distingue les indicateurs crêtes et le kurtosis dont les plus utilisés sont les facteurs (K) crêtes [Miy 86], déterminés comme étant le rapport entre la valeur crête et la valeur efficace (Eq 2.36)  $i=4$ . Par ailleurs, le kurtosis est basé sur les moments d'ordre 4 [Mar 95]. Il est exprimé par la relation (2.38) et il permet une détection précoce d'un défaut de roulement.

$$Facteur_{crete} = \frac{valeur_{crete}}{valeur_{efficace}} = \frac{\sup|x(t)|}{\sqrt{\frac{1}{T} \int_t^{t+T} x^2(t) dt}} \quad (2.40)$$

$$Facteur K = valeur_{crete} \cdot valeur_{efficace} = \sqrt{\frac{1}{T} \int_t^{t+T} x^2(t) dt} \quad (2.41)$$

$$Kurtosis = \frac{\mu_4(X)}{\mu_2(X)} = \frac{E[(X - \bar{X})^4]}{E[(X - \bar{X})^2]^2} \quad (2.42)$$

$\mu_4$  : est le moment statistique d'ordre 4 ;

$\mu_2$  : est le moment statistique d'ordre 2 ;

$X$  : est la distribution de signal temporel  $x(t)$ .

$E[X]$  : est l'espérance mathématique définie par la relation :

$$E[X] = \int_{-\infty}^{+\infty} t x(t) dt \quad (2.43)$$

Ces indicateurs sont souvent utilisés simultanément pour bénéficier des avantages de chacun d'eux. Cependant, ils ne permettent pas de localiser le défaut donc il est nécessaire de d'effectuer le diagnostic pour définir la cause des changements vibratoires.

#### 2.4.4.2 Résolution temps-fréquence dans la TFFG

La résolution temps-fréquence dans la TFFG appliquée sur le signal  $x(t)$  fournit une représentation à deux dimensions dépendant du temps et de la fréquence [Gab 46]. Elle est définie par la représentation mathématique suivante :

$$F_x(t, \nu) = \langle x, h_{t, \nu} \rangle = \int_{-\infty}^{+\infty} x(s) h(s-t) e^{-j2\pi \nu s} ds \quad (2.44)$$

Où, la fonction qui associe  $h(s-t)$  à  $t$  est la fenêtre qui sélectionne la durée  $T_h$  autour de l'instant  $t$ .

Cette intégrale de Fourier peut être exprimée en une intégrale en fréquence grâce à l'identité de Parseval.

$$F_x(t, \nu) = e^{-j2\pi \nu t} \int_{-\infty}^{+\infty} X(\xi) H^*(\xi - \nu) e^{j2\pi \xi t} d\xi \quad (2.45)$$

La densité d'énergie  $E_x$ , notée  $|F_x(t, \nu)|^2$ , est appelée spectrogramme. Elle mesure l'énergie de  $x(t)$  dans le voisinage temps-fréquence de  $(t, \nu)$  défini par la boîte d'Heisenberg de  $h_{t, \nu}$  centrée en  $(t, \nu)$  et de dimension  $(T_h, B_h)$ . La taille de cette boîte ne dépend pas de  $(t, \nu)$ , cela veut dire que les dimensions de la fenêtre d'analyse sont constantes dans tout le plan temps-fréquence.

Le passage d'un axe unique de temps (de fréquence) à un plan temps-fréquence (spectrogramme) fournit une meilleure structuration de l'information du signal analysé [Dav 00]. La figure 2.10 donne une illustration de ceci :

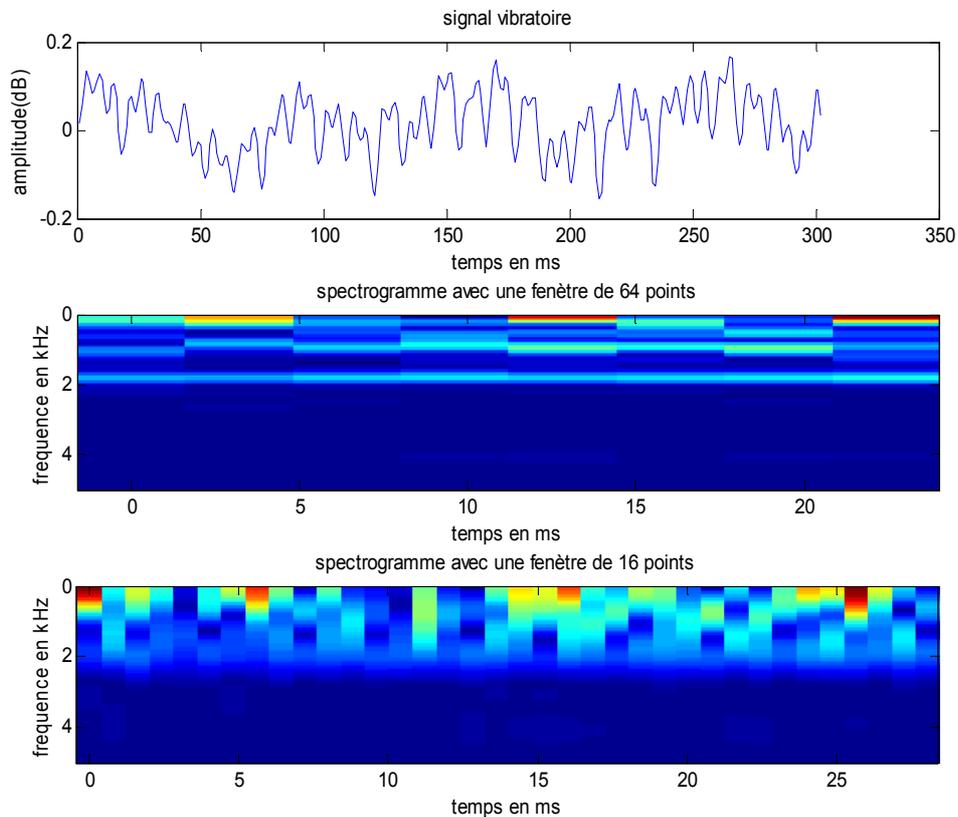


Figure.2.10 Spectrogramme d'un signal vibratoire  $x(t)$

L'inconvénient réside que la taille de la fenêtre d'analyse fixe ne correspond pas nécessairement à la nature variable des signaux [Alt 91]. Donc, il est difficile de déterminer, à ce stade, la sévérité du défaut pour trois raisons principales [Aya 03], [Bas 93]

- ❖ Très sensible aux artefacts dus aux mouvements du sujet et aux clignements des yeux.
- ❖ L'évolution spectrale de la densité dépend largement du sujet.
- ❖ La taille minimale de la fenêtre, permettant d'assurer une précision suffisante de la FT, n'est pas compatible avec l'objectif de détection.

Afin de surmonter ces limites, nous avons évalué d'autres techniques d'analyse temps fréquence, comme la transformée en ondelettes et la transformée de Hilbert Huang.

### 2.4.4.3 Distribution de Wigner-Ville

La distribution de Wigner-Ville (DWV) est déterminée en le corrélant avec une translation en temps et en fréquence de lui-même. Par ailleurs, la fenêtre d'analyse est le même signal mais inversé et ni le choix de la fenêtre d'analyse ni sa largeur ne sont imposées, or le temps et la fréquence jouent des rôles symétriques (figure 2.11). La formule de la DWV est :

$$W_x(t, \nu) = \int_{-\infty}^{+\infty} x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi \nu \tau} d\tau \quad (2.46)$$

La distribution de Wigner-Ville est réelle et représente la transformée de Fourier de  $x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right)$  qui possède une symétrie hermitienne en  $t$ .

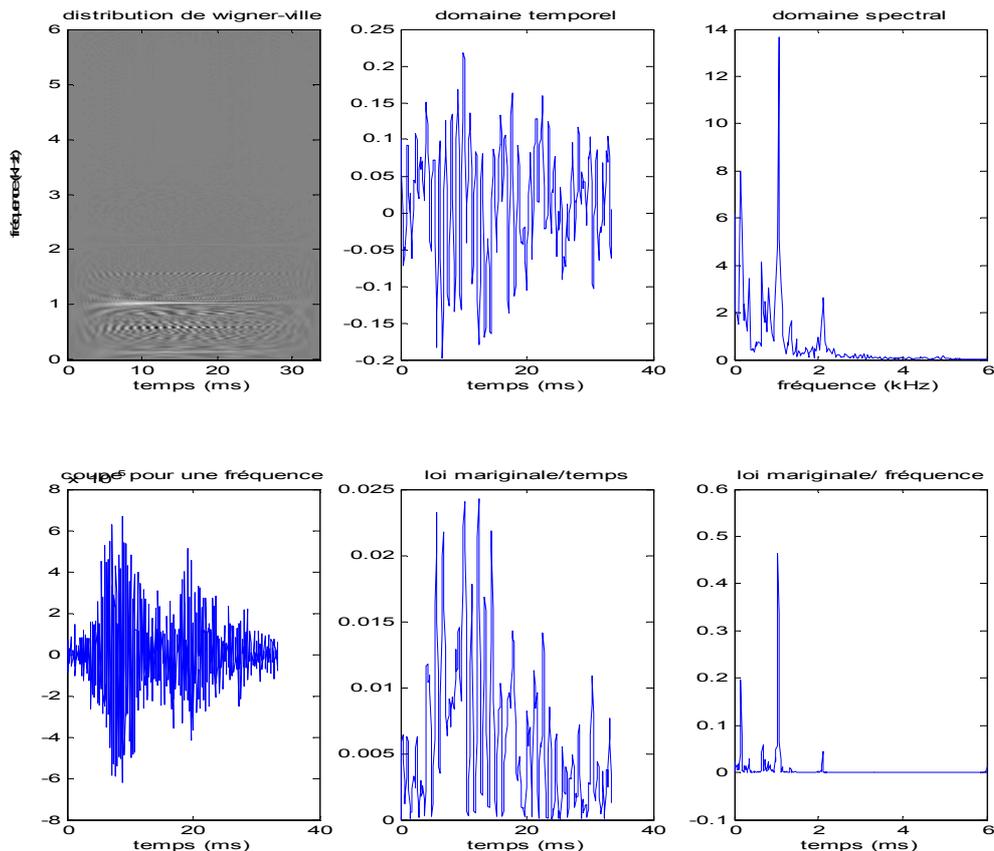


Figure.2.11 Distribution de Wigner-Ville (DWV) pour un signal vibratoire  $x(t)$

La représentation d'une classe de Cohen entraîne l'apparition de termes d'interférences externes en présence de signaux multi-composantes et de termes d'interférences interne en présence d'une composante dont la fréquence instantanée est non linéaire en fonction du temps [Rou 03].

Les termes interférentiels sont porteurs d'une information sur le signal analysé en particulier de phase, donc utiles pour la détection et la classification des signaux [Fla 98], [Hla 92]. Au fait, l'intérêt en nombre et en amplitude perturbe l'analyse des signaux à composantes multiples ou à modulation de fréquence non-linéaire (figure 2.12). Alors, il s'agit un lissage pour éliminer les interférences.

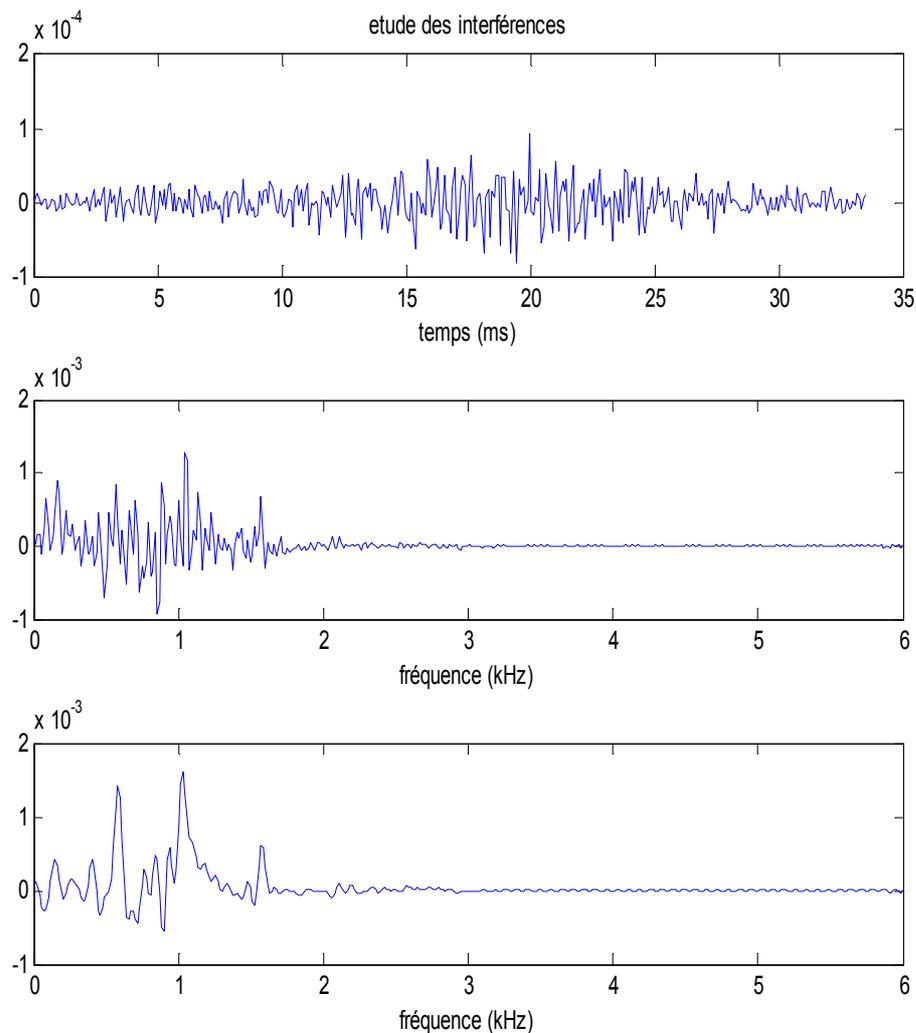


Figure.2.12 Etude des interférences sur un signal vibratoire  $x(t)$

#### 2.4.4.4 La transformée en ondelettes (Wavelet Transform WT)

L'analyse par transformée en ondelettes est réalisée au moyen d'une fonction  $\Psi$  appelée ondelette de base (ou ondelette mère) qui permet de spécifier les caractéristiques du signal que l'on souhaite détecter dont le but de positionner, dans le domaine temporel, l'ondelette mère en regard de la partie du signal à traiter, on parlera alors de translation.

Par ce changement d'échelle (contraction - dilatation), la transformée en ondelettes amène à une décomposition temporelle du signal [Ber 10]. Dans ce cas, on utilise l'expression suivante :

$$C(b,a) = |a|^{-1/2} \int_{-\infty}^{+\infty} S(t) \bar{\Psi} \left( \frac{t-b}{a} \right) dt \quad (2.47)$$

Où :  $\bar{\Psi}(t)$  Représentent l'ondelette mère,

$b$  Le paramètre de translation,

$a$  Le paramètre d'échelle  $a \neq 0$ .

Un exemple empirique et pratique d'ondelette mère est l'ondelette de Morlet [Gou 85] (figure 2.13).

$$\psi(t) = e^{-t^2 + j2\pi f_0 t} \text{ Avec } f_0 = 1/\sqrt{\ln 2} \quad (2.48)$$

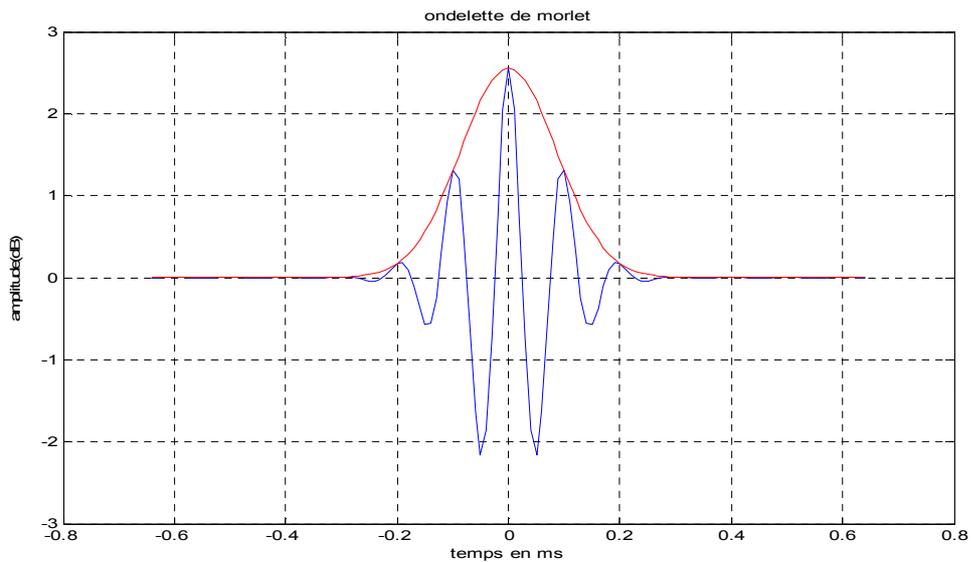


Figure.2.13 Ondelette de Morlet

Les conditions qui gouvernent le choix des ondelettes mères sont les deux conditions d'admissibilité suivantes :

1. une ondelette mère doit être localisée et à décroissance rapide ;
2. ses  $m$  premiers moments doivent être nuls c'est-à-dire

$$\int_{-\infty}^{+\infty} \psi(t) dt = \int_{-\infty}^{+\infty} t \psi dt = \dots = \int_{-\infty}^{+\infty} t^{m-1} \psi dt = 0 \quad (2.49)$$

3. D'autres conditions d'admissibilités peuvent se résumer au fait que l'ondelette mère doit être passe-bande et de densité spectrale d'énergie finie.

### ***Propriétés multi-échelle ou multiresolution de l'analyse en ondelettes***

En considérant une échelle  $a_0$ , le signal  $x_{a_0}(t)$  correspondant à (2.43) est :

$$x_{a_0}(t) = \int_{-\infty}^{+\infty} dt' \int_{a_0}^{+\infty} TOC_x^\psi(t', a) \psi_{(t', a)}(t) \frac{da}{a^2} \quad (2.50)$$

Est une approximation basse fréquence du signal  $x(t)$ . La transformée de Fourier de  $x_{a_0}(t)$  est :

$$\begin{aligned} \hat{x}_{a_0}(f) &= \int_{a_0}^{+\infty} \hat{\psi}(af) \frac{da}{a^{3/2}} \int_{-\infty}^{+\infty} TOC_x^\psi(t', a) e^{-j2\pi f t'} dt' \\ &= \hat{x}(f) \int_{a_0}^{+\infty} \hat{\psi}(af) \hat{\psi}^*(af) \frac{da}{a} \end{aligned} \quad (2.51)$$

$$\text{Où } \int_{-\infty}^{+\infty} TOC_x^\psi(t', a) e^{-j2\pi f t'} dt' = \sqrt{a} \hat{x}(f) \hat{\psi}^*(af) \quad (2.52)$$

Ainsi  $x_{a_0}(t)$  ne serait qu'une version filtrée de  $x(t)$  à l'échelle  $a_0$ . Les coefficients d'ondelettes  $\left\{ TOC_x^\psi(t', a) \right\}_{a_0 \leq a \leq a_1}$  représentent l'information manquante faisant passer d'une version lissée de  $x(t)$  à l'échelle grossière  $a_1$ , à la version lissée plus fine à l'échelle.

Et s'il existe un instant  $t'$  tel que  $TOC_x^\psi(t', a) = 0$  alors les deux versions  $x_{a_0}(t)$  et  $x_{a_1}(t)$  coïncident (figure 2.14).

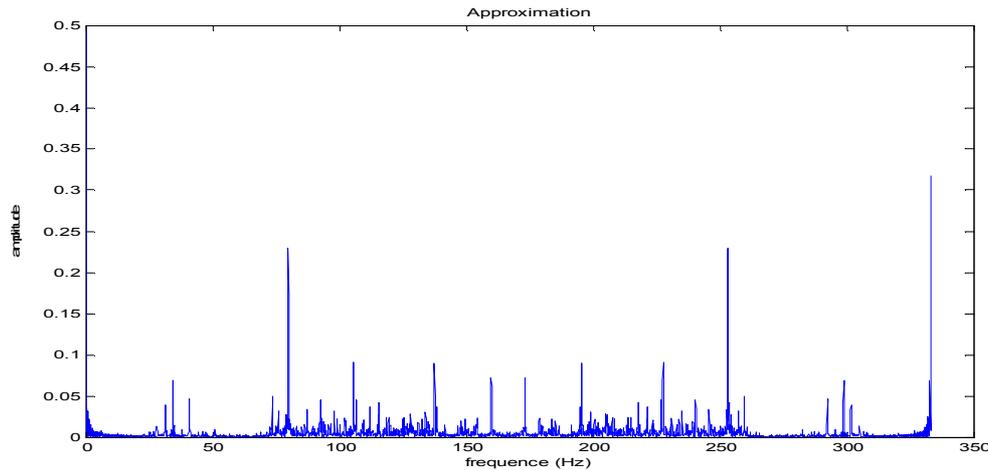


Figure. 2.14 FFTs de dernière approximation on l'utilise l'ondelette Daubchies

Plus généralement la reconstruction partielle  $x_{a0}(t)$  du signal  $x(t)$  peut s'écrire :

$$x_{a0}(t') = \int_{-\infty}^{+\infty} x(t') \frac{1}{a0} \mathcal{G}\left(\frac{t-t'}{a0}\right) dt' \quad (2.53)$$

Où,  $\mathcal{G}$  est une fonction d'échelle ou ondelette mère vérifiant :

$$\mathcal{G}(t) = \begin{cases} \int_0^{+\infty} \hat{\psi}(f') \hat{\psi}^*(f') \frac{df'}{f'} & \text{si } f \geq 0, \\ \int_{-\infty}^0 \hat{\psi}(f') \hat{\psi}^*(f') \frac{df'}{|f'|} & \text{si } f \leq 0. \end{cases} \quad (2.54)$$

Ainsi, la transformation en ondelettes (WT) favorise la résolution temporelle lors de l'analyse des composantes hautes fréquences et privilégie la résolution fréquentielle lors de l'analyse des composantes basses fréquences [Ber 10].

La transformée en ondelettes est une représentation temps - échelle qui permet de décrire l'évolution temporelle d'un signal. La transformée en ondelettes dilatée est plus diffuse dans le temps donc elle a un spectre plus concentré autour de sa fréquence centrale, contrairement à transformée en ondelettes contractée.

Les quelques applications de l'analyse en temps-fréquence évoquées ci-dessus augurent pour l'EMD (qui est une opération pré-analyse temps-fréquence) couplée avec la transformée de Hilbert en particulier, de bonne opportunité d'utilisation.

#### 2.4.4.5 Transformée de Hilbert-Huang

La transformée de Hilbert Huang (THH) est une méthode d'analyse temps-fréquence [Cex 05]. Cette méthode consiste à décomposer, de façon adaptative, le signal en une somme de composantes oscillantes qui possède une seule fréquence à chaque échantillon, pour ensuite calculer la fréquence et l'amplitude instantanée de chacune de ces composantes en utilisant la transformée de Hilbert. [Hua 99], [Hua 98] [Dat 04] [Nun 04] [Lou 04], [Li 04][Mon 04], etc. La THH est réalisée en deux étapes.

- La première étape concerne l'EMD [Wei 12], [Gan 14], qui décompose le signal pour obtenir les fonctions du mode intrinsèques (IMFs) représentant la tendance moyenne du signal. Chacun de ces IMFs se trouve dans une bande de fréquence spécifique.
- La deuxième étape traite de la transformée de Hilbert, qui est appliqué à la IMF afin d'en extraire des fréquences instantanées et amplitudes instantanées du signal. Ces deux étapes, EMD et transformée de Hilbert, permettent d'obtenir trois dimensions (temps, fréquence et amplitude) représentation du signal.

Les deux étapes de la transformée de Hilbert-Huang seront expliquer plus en détails dans la suite.

##### 2.4.4.5.1 Décomposition en mode empirique (EMD)

La méthode de décomposition en mode empirique (EMD) a proposé, en 1998 [Hua 98], est un auto-adaptatif méthode de données entraîné, qui décompose un signal complexe dans un certain nombre de simples oscillatoire modes appelés fonctions du mode intrinsèques (IMFs). L'EMD décompose un signal en un ensemble d'IMFs représentant les modes oscillants simples.

En règle générale, le composant avec la période la plus courte (haute fréquence) est identifié et décomposé dans le premier IMF. Les composantes de longues périodes (faible fréquences) sont ensuite identifiées et décomposés par ordre dans les IMFs suivants. Donc, Tout signal peut être reconstruit en additionnant ses différentes IMFs. Pour chacun d'eux, le même nombre d'extrema et passages à zéro est affecté. Il n'y a qu'un extremum entre deux passages à zéro successifs. Chaque IMF doit être indépendamment des autres.

De cette façon, il est possible d'isoler les bandes de fréquences d'intérêt dans le signal en sélectionnant les IMFs qui composent les fréquences souhaitées. Pour illustrer la décomposition, nous considérons le signal vibratoire  $x(t)$  qui présentée sur la Figure 2.14.

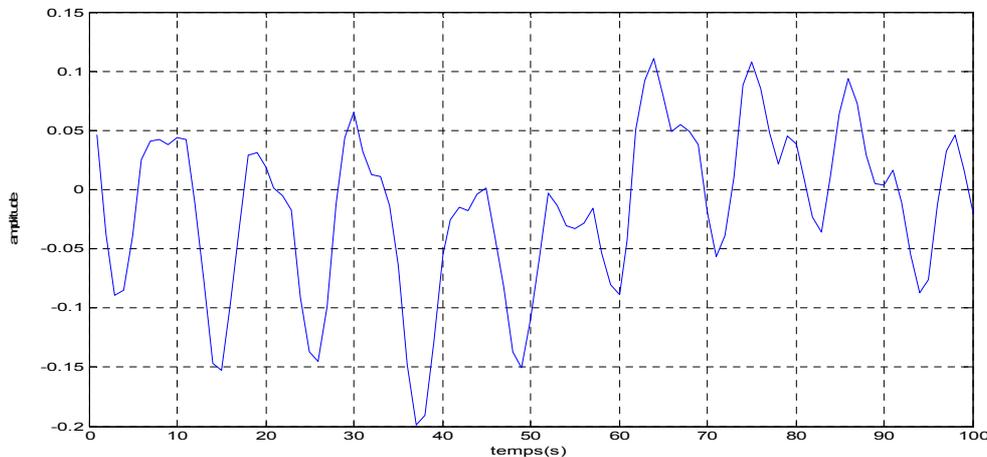


Figure.2.15 Signal vibratoire  $x(t)$

Chaque IMF doit satisfaire les contraintes suivantes:

- Dans l'ensemble des données, le nombre d'extrema et le nombre de passages à zéro doivent égaux ou diffèrent au maximum de un;
- A chaque instant  $t$ , la valeur moyenne de l'enveloppe définie par les maxima locaux et de l'enveloppe définie par la section locale minima est proche de zéro.

EMD décompose un signal  $x(t)$  en quatre étapes:

- 1- Identification de tous les extrema locaux, puis de raccorder tous les maxima locaux par une spline cubique pour former la partie supérieure enveloppe.
- 2- En répétant la même procédure pour les minima locaux afin de produire l'enveloppe inférieure. La partie supérieure et enveloppes inférieures doivent couvrir l'ensemble des données entre eux.
- 3- La valeur moyenne de l'enveloppe supérieure et inférieure est désignée comme  $m_{10}$  et est donnée comme suit:

$$m_{10}(t) = \left( x_{up}(t) + x_{low}(t) \right) / 2 \quad (2.55)$$

Où :  $x_{up}(t)$  et  $x_{low}(t)$  sont respectivement, les enveloppes supérieure et inférieure du signal.

La différence entre le signal  $x(t)$  et  $m_{10}$  fournit une première composante notée  $p_{10}$ , (voir les figures 2.16 et 2.17):

$$x(t) - m_{10}(t) = p_{10}(t) \tag{2.56}$$

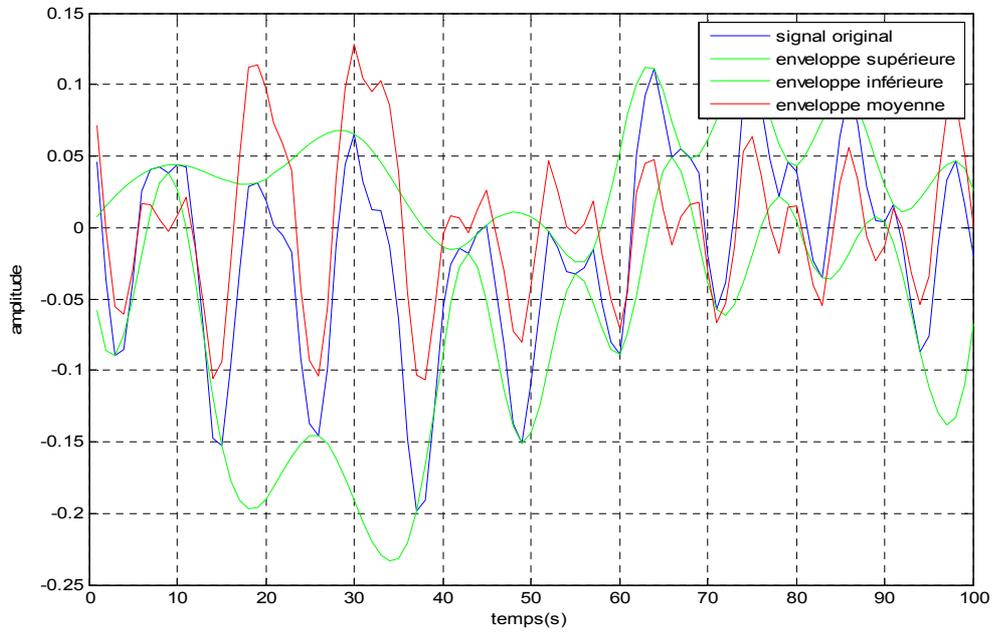


Figure.2.16 Processus de tamisage

Le signal original, l'enveloppe supérieure et inférieure, et l'enveloppe moyenne.

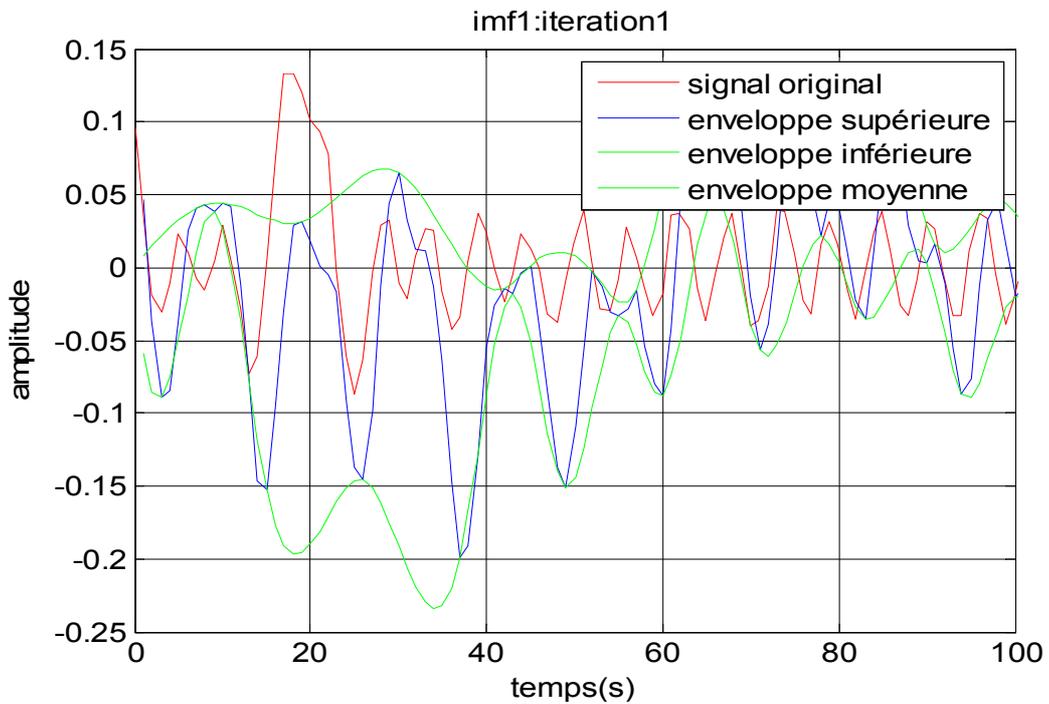


Figure.2.17 Première composante de  $x(t)$ .

4- Si  $p_{10}$  est pas un FMI, alors il sera considéré comme le signal original et les étapes 1 à 3 sont répétés. La deuxième composante notée  $p_{11}$  peut être obtenu:

$$p_{11}(t) = p_{10}(t) - m_{10}(t) \quad (2.57)$$

Ce processus est appelé processus de tamisage et il est répété successivement jusqu'à ce que le temps  $k$  sur  $p_{ik}$ , jusqu'à ce que la ligne médiane entre la enveloppe supérieure et inférieure est proche de zéro à chaque point.

$$p_{1k}(t) = p_{1(k-1)}(t) - m_{1k}(t) \quad (2.58)$$

où :  $m_{1k}$  est la moyenne de l'enveloppe supérieure et inférieure de  $p_{1(k-1)}$ .

La première composante du IMF,  $c_1$  noté avec  $c_1 = p_{1k}$  représente échelle la plus fine ou de la composante de la plus courte période du signal  $x(t)$ .

L'extraction de  $c_{1k}$  à partir  $x(t)$  fournit un premier résiduel dénoté  $r_2$  :

$$r_2(t) = r_1(t) - c_1(t) \quad (2.59)$$

Avec:  $r_1(t) = x(t)$

L'ensemble du processus de tamisage est répété sur le signal  $r_1$  pour  $n$  fois pour obtenir des composants successifs de durée croissante.

Ceci permet d'obtenir les  $n$  IMF du signal  $x(t)$  en utilisant l'expression suivante:

$$r_n(t) = r_{n-1}(t) - c_{n-1}(t) \quad (2.60)$$

Lorsque le signal  $r_n$  devient une fonction monotone à laquelle aucun IMF peut être extrait, le processus de décomposition peut être arrêté. A partir de l'équation (2.60) et l'équation. (2.56), on peut reconstruire le signal  $x(t)$  par la formule suivante:

$$x(t) = \sum_{j=1}^{n-1} c_j(t) + r_n(t) \quad (2.61)$$

où :  $r_n$  est le dernier composant, considéré comme un résidu, est la tendance moyenne de  $x(t)$ .

Les IMFs  $c_1, c_2, \dots, c_n$  comprennent différentes bandes de fréquences allant du haut vers le bas. La bande de fréquences contenue dans chaque composant est différent d'un composant à une autre, et ces fréquences changent en fonction du signal  $x(t)$ .

Le processus d'extraction des IMFs est résumée dans l'organigramme du processus de décomposition en mode empirique sur la figure 2.18.

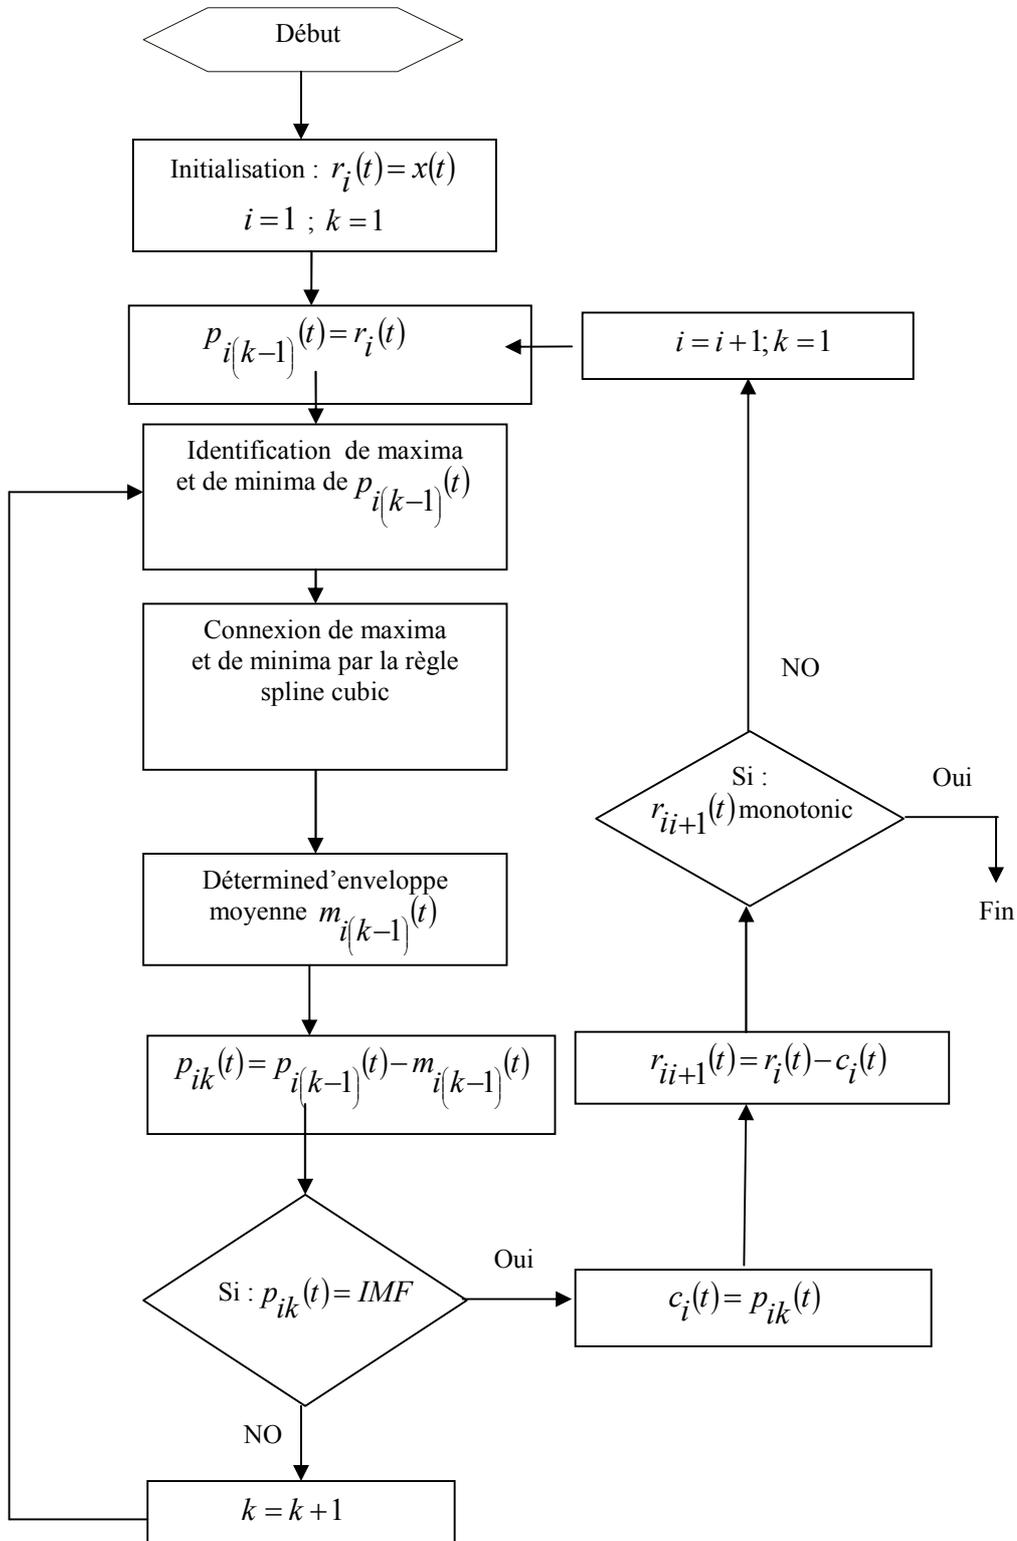


Figure.2.18 Organigramme du processus de décomposition en mode empirique.

### 2.4.4.5.2 Analyse spectral de Hilbert

Le signal  $x(t)$  étant décomposé en IMFs alors l'analyse du spectre de Hilbert peut être réalisé sur chacune des composantes modales :

$$c_i^H(t) = \frac{1}{\pi} \int \frac{c_i(t')}{t-t'} dt' \quad (2.62)$$

La combinaison  $c_i(t)$  et  $c_i^H(t)$  permet la construction d'un signal analytique notée  $c_i^A(t)$  :

$$c_i^A(t) = c_i(t) + jc_i^H(t) = a_i(t) e^{j\theta_i(t)} \quad (2.63)$$

Où :  $a_i(t)$  et  $\theta_i(t)$  représentent respectivement l'amplitude instantanée et la phase, ils sont donnés comme suit:

$$\begin{cases} a_i(t) = \sqrt{c_i^2 + c_i^{H2}} \\ \theta_i(t) = \tan^{-1} \left( \frac{c_i^H}{c_i} \right) \end{cases} \quad (2.64)$$

La fréquence instantanée  $f_i(t)$  peut être calculée ainsi:

$$f_i(t) = \frac{1}{2\pi} \frac{d\theta_i(t)}{dt} \quad (2.65)$$

Et, la série temporelle du signal d'origine  $x(t)$  peut être exprimée par la relation ci-dessous :

$$x(t) = \text{Re} \sum_{i=1}^n a_i(t) \exp \left[ j2\pi \int_0^T f_{inst}(i) \right] \quad (2.66)$$

Où, le Re moyen partie réelle et T est la longueur du signal  $x(t)$ .

Le signal  $x(t)$  est donc représenté par une distribution temps-fréquence et sa transformée Hilbert-Huang est donnée par:

$$H(f, t) = \sum_{i=1}^n H_i(f, t) = a_i(f_i, t) \quad (2.67)$$

Où,  $H(f, t)$  représente une distribution temps-fréquence obtenu du  $i^{\text{ème}}$  IMF du signal  $x(t)$

$a_i(f_i, t)$  Combine l'amplitude  $a_i(t)$  et la fréquence instantanée  $f_i(t)$  du signal.

### 2.4.4.6 Extraction de caractéristique par TKEO

L'opérateur d'énergie Teager- Kaiser (TKEO) a été proposé par Teager et plus étudié par Kaiser [Tea 83], [Tea 89], qui est un opérateur différentiel non linéaire peut estimer l'énergie nécessaire pour générer un signal.

En temps continu, l'opérateur TKEO est défini pour un signal  $x(t)$ , par:

$$\Psi [x(t)] = [\dot{x}(t)]^2 - x(t)\ddot{x}(t) \quad (2.68)$$

où :  $\dot{x}(t)$  correspondent à la dérivée première de  $x(t)$

$\ddot{x}(t)$  Correspondent à la dérivée secondaire de  $x(t)$

Dans le cas discret, et en fonction de la forme de discrétisation choisie pour l'opérateur de dérivation, différentes formules de TKEO peuvent être obtenues:

$$\Psi(x[n]) = x^2[n] - x[n+1] \cdot x[n-1] \quad (2.69)$$

À tout instant, trois échantillons consécutifs sont nécessaires pour estimer de TKEO instantané, il est adaptable aux changements instantanés de signaux et tout à fait pour résoudre événements transitoires. Par conséquent, il est une bonne adaptabilité aux variations instantanées de signaux et une excellente capacité à résoudre les événements transitoires.

C'est une méthode adaptative et efficace pour l'estimation de la fréquence instantanée et l'enveloppe d'amplitude des signaux non stationnaires [Cex 06].

La fréquence et l'amplitude instantanée de l'enveloppe du signal  $x(t)$  à tout instant sont définis par:

$$F(n) \approx \frac{1}{2\pi} \sqrt{\frac{\dot{\Psi}[x(t)]}{\Psi[x(t)]}} \quad (2.70)$$

$$|A(n)| \approx \frac{\Psi[x(t)]}{\sqrt{\Psi[x(t)]}} \quad (2.71)$$

Nous pouvons écrire :

$$F(n) = \frac{1}{2} \arccos \left( 1 - \frac{\Psi[x(n+1) - x(n-1)]}{2\Psi[x(n)]} \right), \quad (2.72)$$

$$A(n) \approx \frac{2\Psi[x(n)]}{\sqrt{\Psi[x(n+1) - x(n-1)]}} \quad (2.73)$$

Dans cette méthode, le signal est décomposé en quelques IMFs par l'algorithme EMD. Puis l'estimation de l'amplitude et la fréquence instantanée des IMFs sont obtenus en utilisant la méthode de TKEO [Tab 13].

## 2.5 Conclusion

Contrairement à la transformée de Fourier ou en ondelettes, la base de décomposition de l'EMD est propre au signal. Une des motivations du développement de l'EMD est la recherche d'une estimation de la fréquence instantanée du signal. En effet, l'approche classique d'estimation de la fréquence instantanée basée sur la transformée de Hilbert est strictement limitée aux signaux mono-composante. Cette méthode est la combinaison d'un algorithme de décomposition temporelle d'un signal en composantes de base, appelée décomposition modale empirique (EMD pour Empirical mode decomposition) et de la transformation de Hilbert pour l'estimation des AI et FI.

A cause de sa robustesse et son efficacité de traitement des données vibratoires en termes de la taille, qualité et quantité du signal, nous retenons cette méthode pour le traitement des données vibratoires. Pour ces avantages, nous allons appliquer, dans le chapitre suivant, plus en détails les deux étapes de la transformée de Hilbert-Huang.

# **CHAPITRE III**

## **APPLICATION AUX SIGNAUX VIBRATOIRES DES MOTEURS ASYNCHRONES**

## **CHAPITRE III**

### **APPLICATION AUX SIGNAUX VIBRATOIRES**

#### **DES MOTEURS ASYNCHRONES**

##### **3.1 Introduction**

Le fonctionnement des roulements se traduit généralement par un comportement dynamique qui génère des signaux acoustiques et vibratoires fixes et / ou non-stationnaires en mélange avec une quantité de bruit de fond. Les vibrations peuvent alors être vues comme des symptômes de défaillances qui permettraient de traduire l'état mécanique d'une machine tournante. Pour cela, ces vibrations doivent être traitées au travers d'outils d'aide à la détection au bien au diagnostic de défaillances. Le but de ce chapitre est d'introduire des nouvelles approches pour effectuer efficacement la surveillance de l'état du roulement. Cette approche est réalisée à partir des signaux de vibration fixes et / ou non-stationnaires brutes en suivant trois étapes. La première étape utilise la décomposition du mode empirique pour séparer chaque signal vibratoire dans les différentes fonctions du mode intrinsèque, où chaque mode se trouve dans une bande de fréquence spécifique. La deuxième étape consiste à extraire les amplitudes instantanées et les fréquences pour chaque mode afin d'identifier sa bande de fréquence en calculant le spectre marginal de Hilbert. Dans la troisième étape, la phase d'extraction de caractéristique est réalisée par l'utilisation de l'opérateur d'énergie Teager-kaiser (TKEO).

##### **3.2. Essais expérimentaux**

La base de donnée utilisée dans cette thèse est un ensemble des signaux vibratoires de roulement provient de " Case Western Reserve University Bearing Data Center " voir le site : (<http://csegroups.case.edu/bearingdatacenter/home>). La base de données des roulements à billes normaux ou défectueux, sont recueillis sur un banc d'essai, composé d'un moteur, d'un accouplement et d'une génératrice. Des défauts sous forme de points de différents diamètres et profondeurs ont été créés sur les différentes parties des roulements [San 13].

### 3.2.1 Description du banc d'essai

Les données issues des accéléromètres ont été mesurées à des endroits près et éloigné des paliers du moteur. Comme on le voit sur les figures 3.1 et 3.2, le banc d'essai se compose principalement de:

- un moteur à induction 1.491 kW (2 HP) à gauche ;
- un transducteur de couple / encodeur (centre) ;
- un dynamomètre (à droite) ;
- une commande électronique (non représentés).

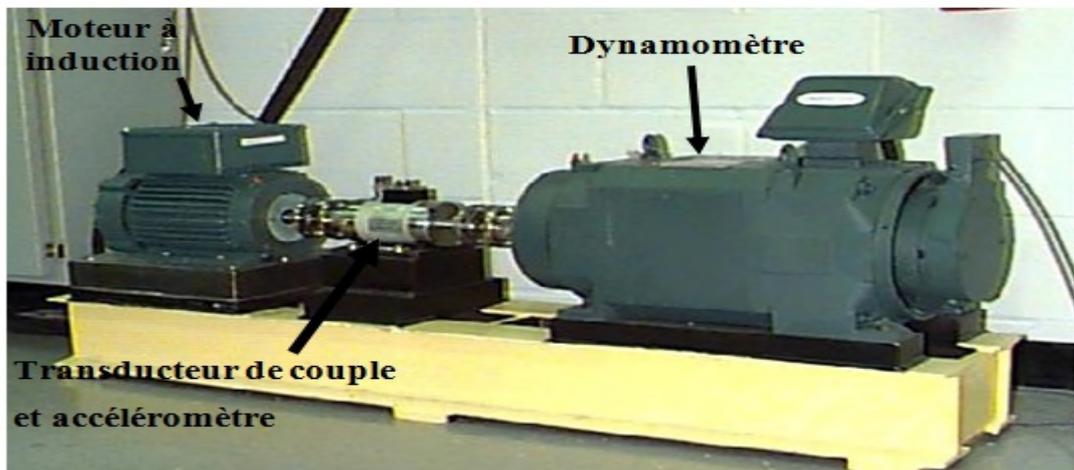


Figure.3.1 Montage expérimental pour la surveillance des vibrations

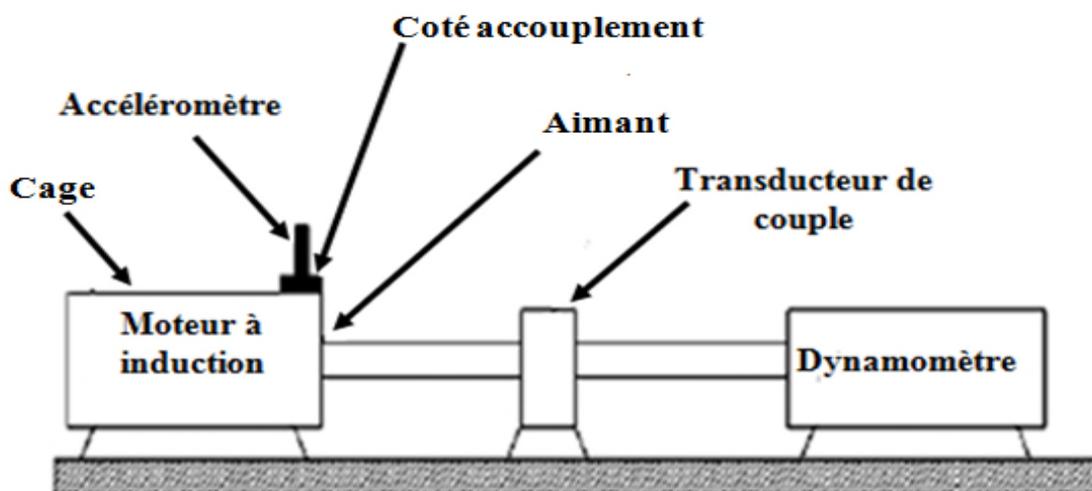


Figure.3.2 Schéma de système expérimental

### 3.2.2 Identification des roulements utilisés

Les roulements testés soutiennent l'arbre du moteur des deux cotés (coté entraînement et coté ventilateur). Des simples défauts sous forme de points ont été créés sur les roulements d'essai, en utilisant l'usinage électro-décharge.

Les défauts allant de 0,007 pouces à 0.040 pouces de diamètre ont été introduits séparément dans:

- la bague intérieure ;
- l'élément roulant (la bille) ;
- la bague extérieure de roulement.

Les roulements défectueux ont été réinstallés dans le moteur de l'essai et les données de vibration ont été enregistrées pour ce moteur chargé de 0 à 3 HP (vitesse du moteur varier de 1797 à 1720 t/mn). Les caractéristiques de roulements de deux cotés (accouplement et ventilateurs) y compris les fréquences des défauts et la géométrie du roulement sont énumérées ci-dessous :

Tableau 3.1 : Caractéristique du roulement à billes à gorge profonde utilisée

	Diamètre intérieur (mm)	Diamètre extérieur (mm)	Epaisseur (mm)	Diamètre de Bille (mm)	Diamètre primitif (mm)
Coté accouplement	0.9843	2.0472	0.5906	0.3126	1.537
Coté ventilateur	0.6693	1.5748	0.4724	0.2656	1.122

Tableau 3.2 : Fréquences de défauts du roulement

	Bague intérieure	Bague extérieure	Cage	Elément roulant (bille)
Coté accouplement	5.4152	3.5848	0.39828	4.7135
Coté ventilateur	4.9469	3.0530	0.3817	3.9874

Des roulements SKF ont été utilisés pour les défauts de diamètres 7, 14 et 21 [mil], et des roulements équivalents NTN ont été utilisés pour les défauts de diamètres 28 et 40 [mil].

Le tableau 3.3 représente les diamètres des défauts, leurs profondeurs et les marques de roulements utilisés.

Tableau 3.3 : Caractéristiques des défauts de roulements à billes à gorge profonde

Position du roulement	Emplacement de défaut	Diamètres	Profondeur	Marque du roulement
Coté entraînement	Bague intérieure	0.007	0.011	SKF
Coté entraînement	Bague intérieure	0.014	0.011	SKF
Coté entraînement	Bague intérieure	0.021	0.011	SKF
Coté entraînement	Bague intérieure	0.028	0.050	NTN
Coté entraînement	Bague extérieure	0.007	0.011	SKF
Coté entraînement	Bague extérieure	0.014	0.011	SKF
Coté entraînement	Bague extérieure	0.021	0.011	SKF
Coté entraînement	Bague extérieure	0.040	0.050	NTN
Coté entraînement	bille	0.007	0.011	SKF
Coté entraînement	bille	0.014	0.011	SKF
Coté entraînement	bille	0.021	0.011	SKF
Coté entraînement	bille	0.028	0.150	NTN
Coté ventilateur	Bague intérieure	0.007	0.011	SKF
Coté ventilateur	Bague intérieure	0.014	0.011	SKF
Coté ventilateur	Bague intérieure	0.021	0.011	SKF
Coté ventilateur	Bague extérieure	.007	.011	SKF
Coté ventilateur	Bague extérieure	.014	.011	SKF
Coté ventilateur	Bague extérieure	.021	.011	SKF
Coté ventilateur	bille	.007	.011	SKF
Coté ventilateur	bille	.014	.011	SKF
Coté ventilateur	bille	.021	.011	SKF

1 mil=0.001 inches

Inches = pouces=25.4mm, 1 HP=745.69 Watt

### 3.2.3 Acquisition des données

Les vibrations ont été mesurées à l'aide d'accéléromètres fixés à la cage du moteur par un aimant dans les positions suivantes:

- Un accéléromètre est placé à la position verticale (12heures), des deux cotés "accouplement et ventilateur" de la cage du moteur ;
- Un accéléromètre est fixé verticalement à la cage du moteur.

Les défauts de la bague externe de roulement sont des défauts stationnaires, donc le placement du défaut relativement à la zone de charge du roulement a un impact direct sur la réponse vibratoire du système "moteur / roulement". Afin de mesurer cet effet, des essais ont été effectuées pour les deux cotés "accouplement et ventilateur", avec des défauts de bagues extérieures situés:

- à 3 heures (directement dans la zone de charge) ;
- à 6 heures (orthogonale à la zone de charge) ;
- à 12 heures.

Les données ont été enregistrées pour :

1. les roulements normaux (sans défauts) ;
2. les défauts uniques du coté accouplement: Les données ont été enregistrées à 12.000 et 48.000 points/seconde) ;
3. les défauts uniques du coté ventilateur : Les données ont été enregistrées à 12.000 points/seconde).

La vitesse (tr/min) et la puissance (HP) pour chaque essai ont été enregistrées manuellement en utilisant le transducteur/encodeur. Tous les fichiers de données sont en format Matlab (\*.mat). Chaque fichier contient trois données : signaux de vibration des deux cotés accouplement et ventilateur ainsi que la vitesse de rotation du moteur. Pour tous les fichiers, le nom des variables utilisés:

- DE - données de coté accouplement de l'accéléromètre ;
- FE - données de coté ventilateur de l'accéléromètre ;
- BA- les données de base de l'accéléromètre ;
- Temps - les données de séries chronologiques.

### 3.2.4 Représentation des signaux temporels

La base de données contient six états des défauts de roulements [Bou 13], à savoir :

1. l'état sain (sans défauts) ;
2. défaut de bague intérieure ;
3. défaut de bille ;
4. défaut de bague extérieure à accéléromètre centré ;
5. défaut de bague extérieure à accéléromètre orthogonal ;
6. défaut de bague extérieure à accéléromètre opposé.

Avec deux niveaux de charge (0, 3HP) correspondant à l'entraînement à vide et en charge pour les trois (3) cas suivants:

- entraînement coté accouplement 12.000 points/seconde ;
- entraînement coté accouplement 48.000 points/seconde ;
- entraînement coté ventilateur 12.000 points/seconde.

Les données utilisées sont consignées dans le tableau 3.4 :

Tableau 3.4 : Base de données des signaux vibratoires du roulement utilisé

	Mode de fonctionnement	Niveau de charge
Cas sain		0%,33%,66% ,100%
Défaut de Bague intérieure	<ul style="list-style-type: none"> <li>➤ Coté accouplement 12.000 pts/s (CA _12.000 pts/s )</li> <li>➤ Coté accouplement 48.000 pts/s (CA _48.000 pts/s )</li> <li>➤ Coté ventilateur 12.000 pts/s (CV_12.000 pts/s )</li> </ul>	0%,33%,66% ,100%
Défaut de bille	<ul style="list-style-type: none"> <li>➤ Coté accouplement 12.000 pts/s (CA _12.000 pts/s)</li> <li>➤ Coté accouplement 48k (CA _48.000 pts/s )</li> <li>➤ Coté ventilateur 12.000 pts/s (CV_12.000 pts/s)</li> </ul>	0%,33%,66% ,100%
Défaut de Bague extérieure	<ul style="list-style-type: none"> <li>➤ Coté accouplement 12.000 pts/s (CA _12.000 pts/s )</li> <li>➤ Coté accouplement 48.000 pts/s (CA_48.000 pts/s )</li> <li>➤ Coté ventilateur 12.000 pts/s (CV_12.000 pts/s)</li> </ul>	0%,33%,66% ,100%

Les figures ci-dessous montrent les signaux vibratoires temporels enregistrés pour un l'état sain (le roulement sans défauts), les défauts du coté accouplement (12.000 pts/s, 48.000 pts/s) et le défaut du coté ventilateur.

#### ❖ *Etat sain*

La figure 3.3 présente les signaux vibratoires pour différents niveaux de charges (0%, 33%,66% et 100%) lorsque le roulement est à l'état sain.

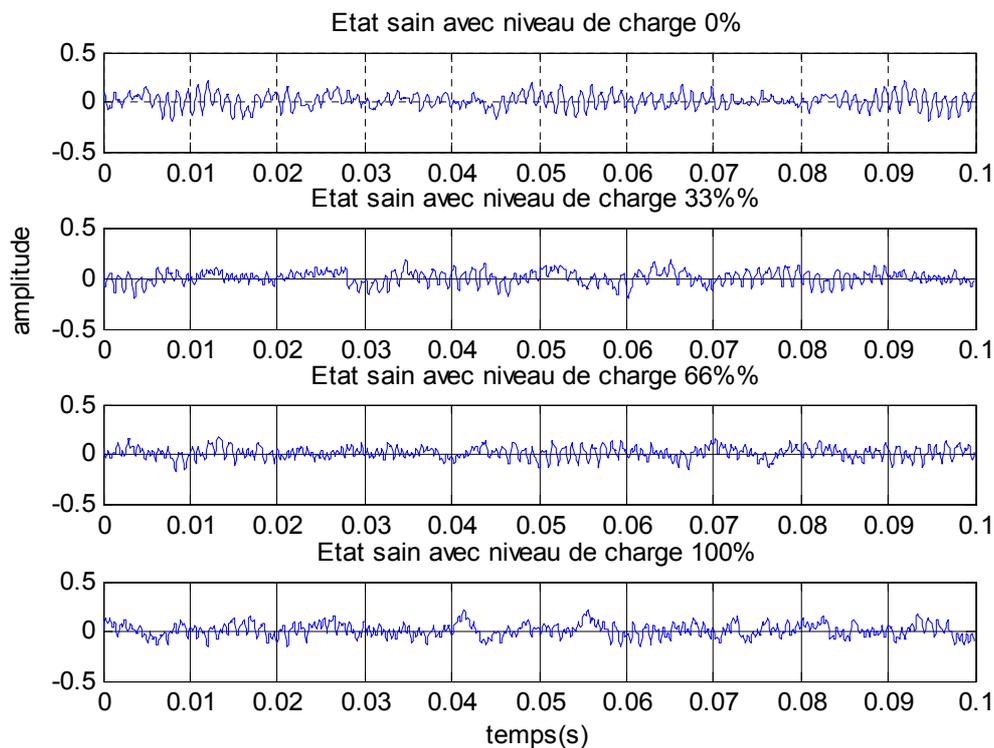


Figure.3.3 Signaux temporels vibratoires de l'état sain

#### ❖ *Défauts de roulement coté accouplement*

Les figures 3.4 et 3.5 montrent les signaux vibratoires temporels lors de défauts de roulement coté accouplement avec respectivement 12.000 pts/s et 48.000 pts/s pour cinq(5) types de défauts: défaut de bague intérieure, défaut de bille, défaut de bague extérieure centrée, défaut de bague extérieure orthogonale et défaut de bague extérieure opposée.

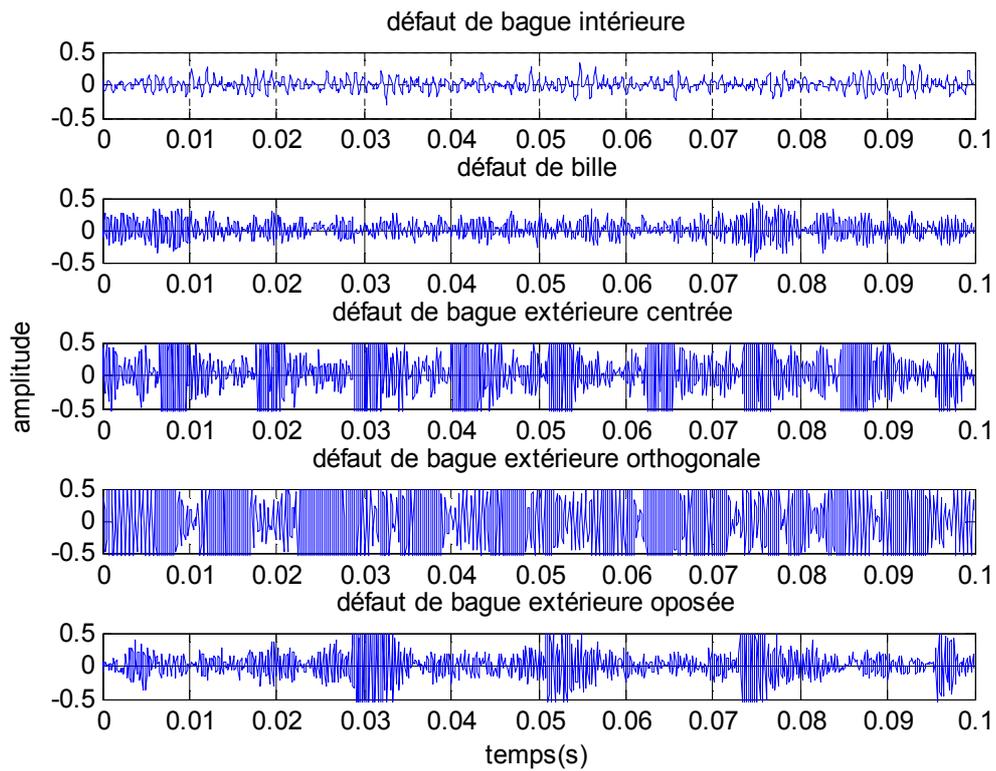


Figure.3.4 Signaux temporels vibratoires des défauts de roulement coté accouplement avec 12.000 pts/s

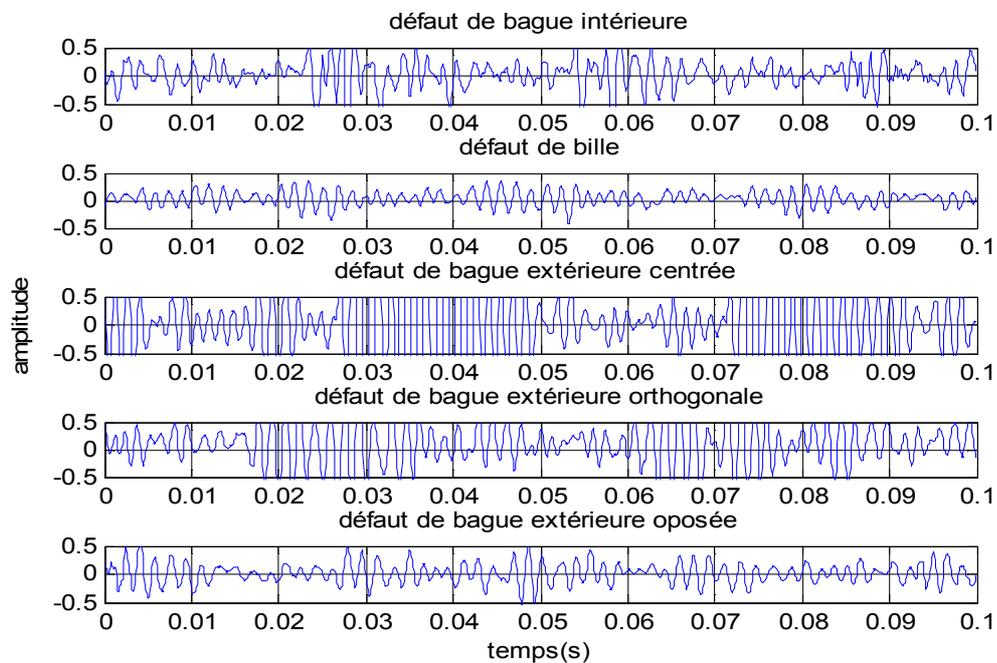


Figure.3.5 Signaux temporels vibratoires des défauts de roulement coté accouplement avec 48.000 pts/s

### ❖ Défauts de roulement coté ventilateur

La figure 3.6 présente des signaux vibratoires temporels pour des défauts de roulement coté ventilateur 12.000 pts/s pour cinq(5) types de défauts: défaut de bague intérieure, défaut de bille, défaut de bague extérieure centrée, défaut de bague extérieure orthogonale et défaut de bague extérieure opposée.

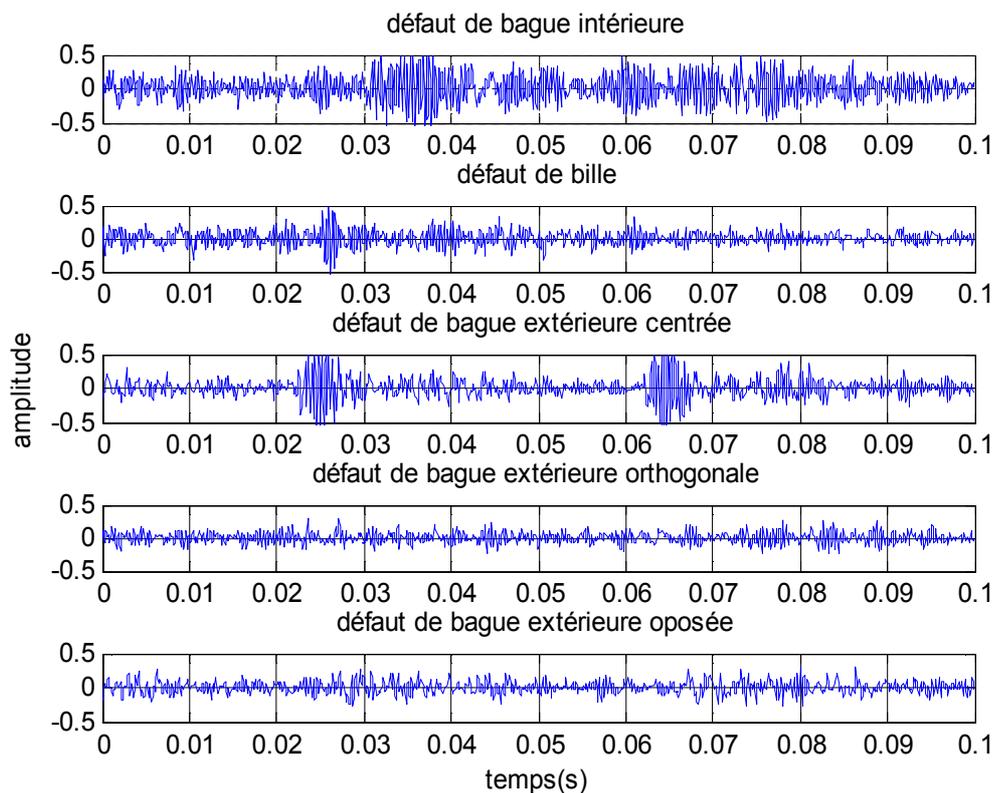


Figure.3.6 Signaux temporels des défauts coté ventilateur

Les représentations temporelles des signaux vibratoires pour tous les cas montrent que les amplitudes ( $m/s^2$ ) des signaux ont des valeurs trop faibles, donc, il faut faire une normalisation de données par rapport aux valeurs moyennes en décible (db).

#### 3.2.5 Normalisation des données

Cette étape de normalisation des données initiales [Ond 06] consiste à ce que les données soient normalisées à partir de la valeur moyenne de l'amplitude de chaque signal vibratoire mesuré pour chaque défaut en vue d'améliorer la classification, et ce, en utilisant la relation suivante :

$$V_n = \frac{V_i}{V_m} \quad (3.1)$$

Où :  $V_i$  est le signal vibratoire initial ;

$V_m$  est la valeur moyenne de l'amplitude de signal  $V_i$ .

Cependant, on a proposé une méthode de prétraitement pour amplifier les amplitudes afin d'avoir une bonne sélection des vecteurs formes caractéristiques.

### 3.3 Prétraitement des signaux vibratoires

La phase de prétraitement se déroule en trois étapes :

1. La première étape utilise la décomposition du mode empirique pour séparer chaque signal vibratoire dans les différentes fonctions du mode intrinsèque, où chaque mode se trouve dans une bande de fréquence spécifique.
2. La deuxième étape consiste à extraire les amplitudes instantanées et les fréquences pour chaque mode afin d'identifier sa bande de fréquence en calculant le spectre marginal d'Hilbert.
3. La troisième étape, notamment, la phase d'extraction de caractéristique est réalisée par l'utilisation de l'opérateur d'énergie Teager- kaiser (TKEO).

#### 3.3.1 Décompositions en mode empirique des signaux vibratoires

La décomposition en mode empirique (EMD) ne demande aucune connaissance à priori sur le signal à décomposer. Couplée avec la transformée d'Hilbert, pour la détermination de la fréquence instantanée des modes, l'EMD tend à devenir l'une des outils le plus utilisés en sciences appliquées, parmi les techniques d'analyse temps-fréquence.

L'EMD a été appliquée aux signaux vibratoires à différents niveaux de charge à vide et en charge (0-100%). Les figures 3.7 à 3.18 présentent les résultats de la décomposition en mode empirique des signaux vibratoires de roulement sain et respectivement les différents cas des défauts du roulement : défaut de bague intérieure, défaut de bille, défaut de bague extérieure centrée, défaut de bague extérieure orthogonale et défaut de bague extérieure opposée. Cette décomposition a permis l'obtention pour chaque signal plusieurs IMFs. Pour tout les cas, chaque signal se décompose en sept IMFs plus un résidu ( $rn(t)$ ) correspondant au nombre de passage (transition) entre chacun des deux bandes de fréquences.

➤ Etat sain des roulements

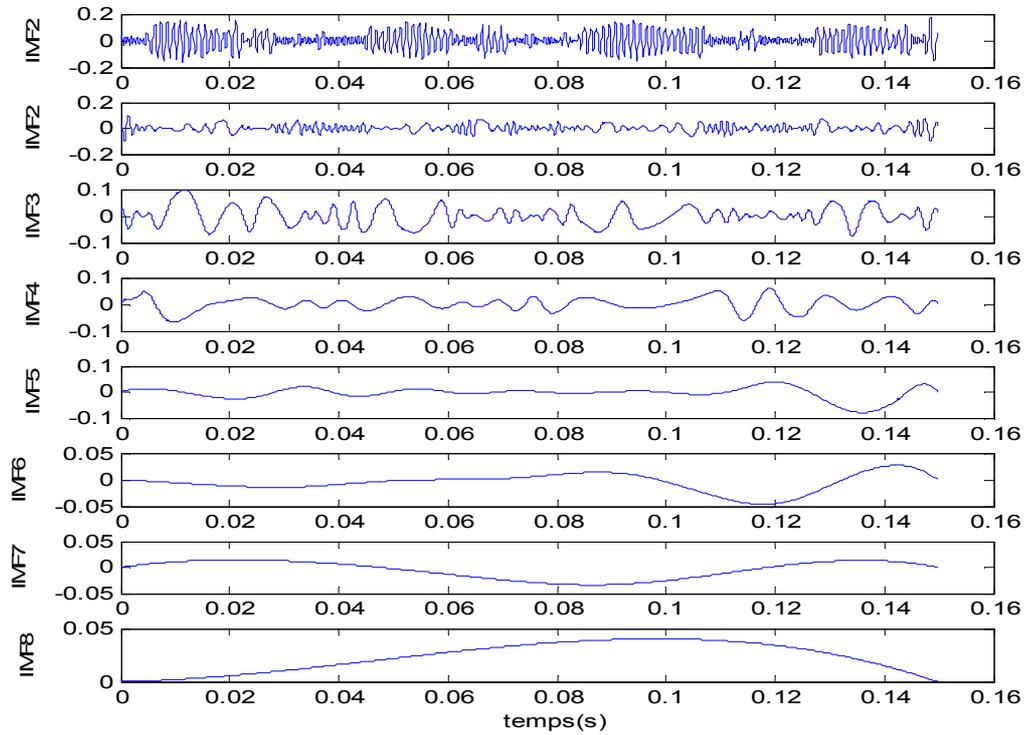


Figure.3.7 Décomposition en mode empirique de roulement sain à vide

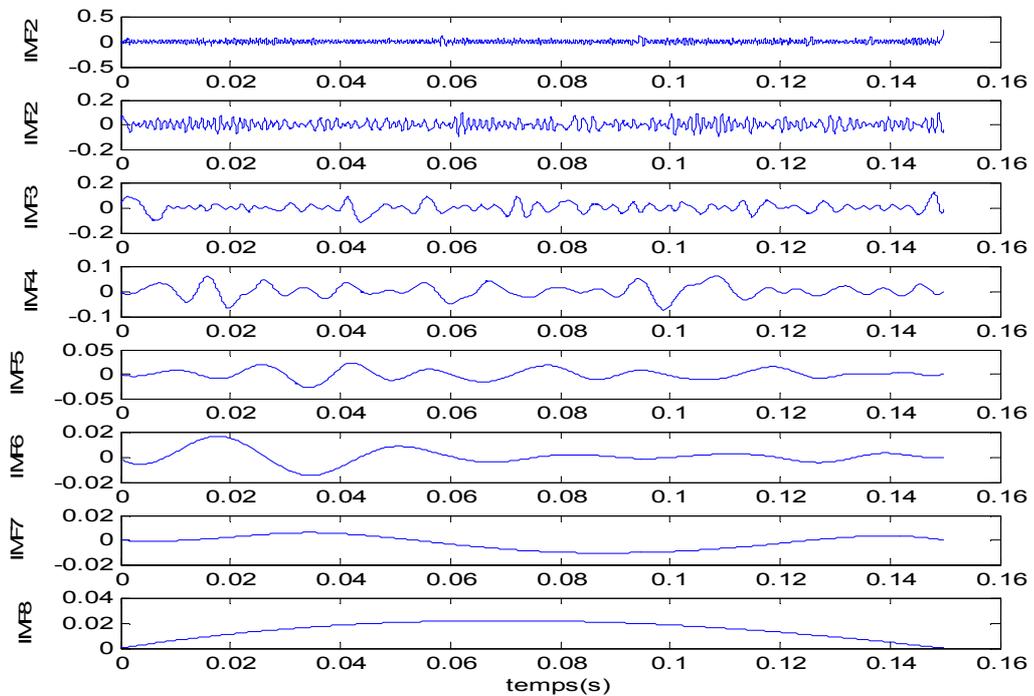


Figure.3.8 Décomposition en mode empirique de roulement sain en charge

➤ Défaut de bague intérieure

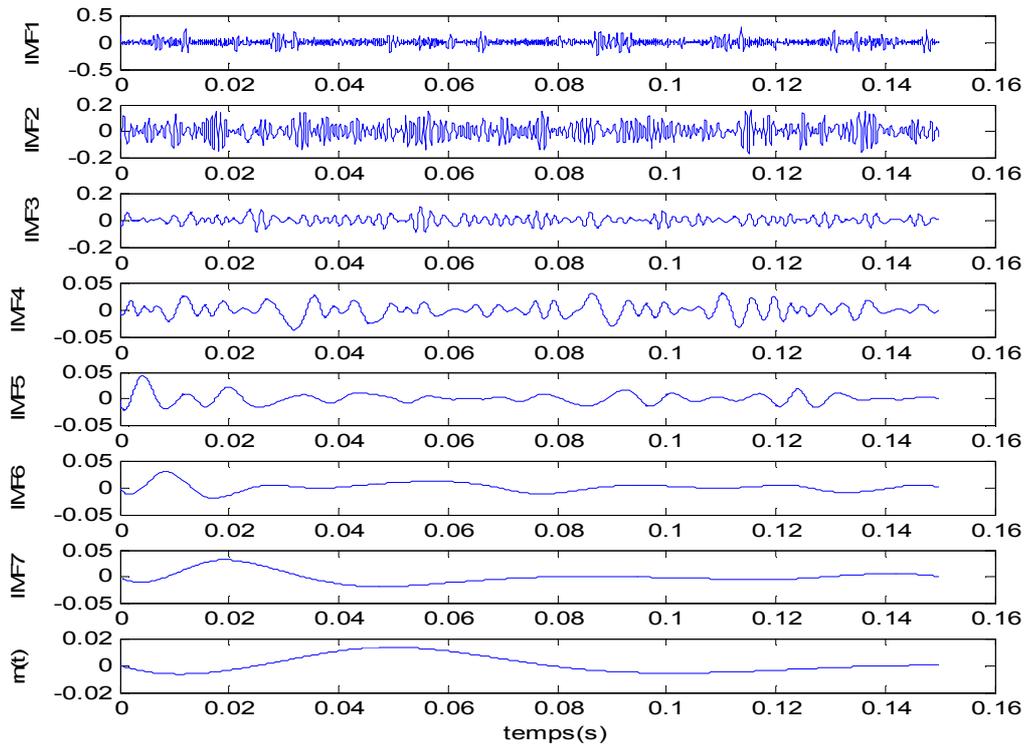


Figure.3.9 Décomposition en mode empirique du défaut de bague intérieure à vide

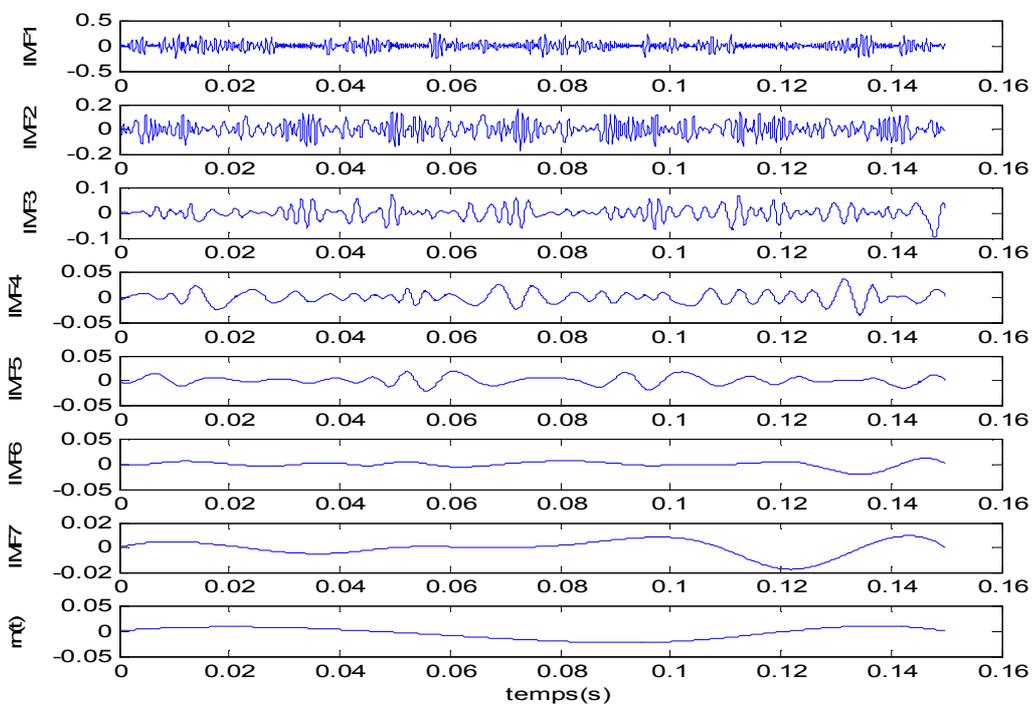


Figure.3.10 Décomposition en mode empirique du défaut de bague intérieure en charge

➤ Défaut de billes

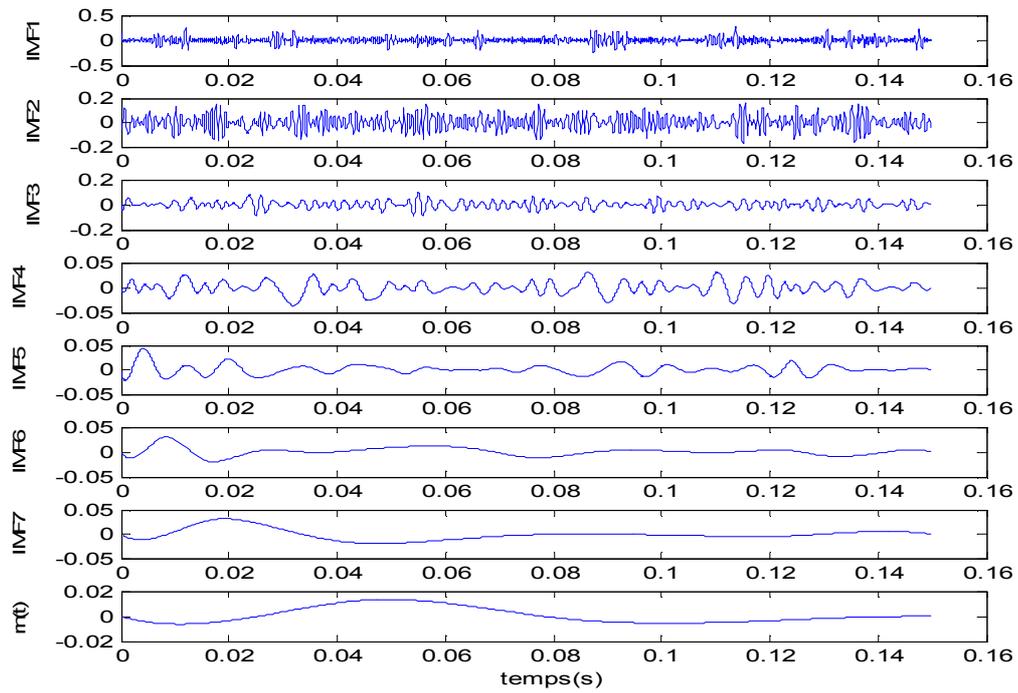


Figure.3.11 Décomposition en mode empirique du défaut de billes à vide

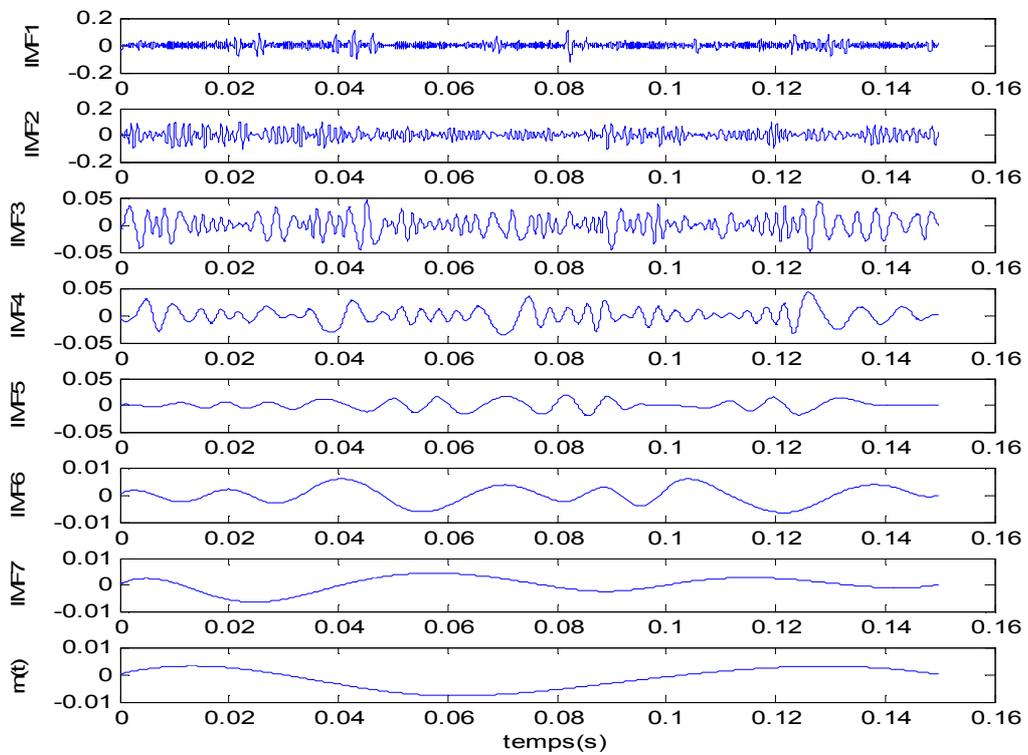


Figure.3.12 Décomposition en mode empirique du défaut de billes on charge

➤ Défaut de bague extérieure à accéléromètre centré

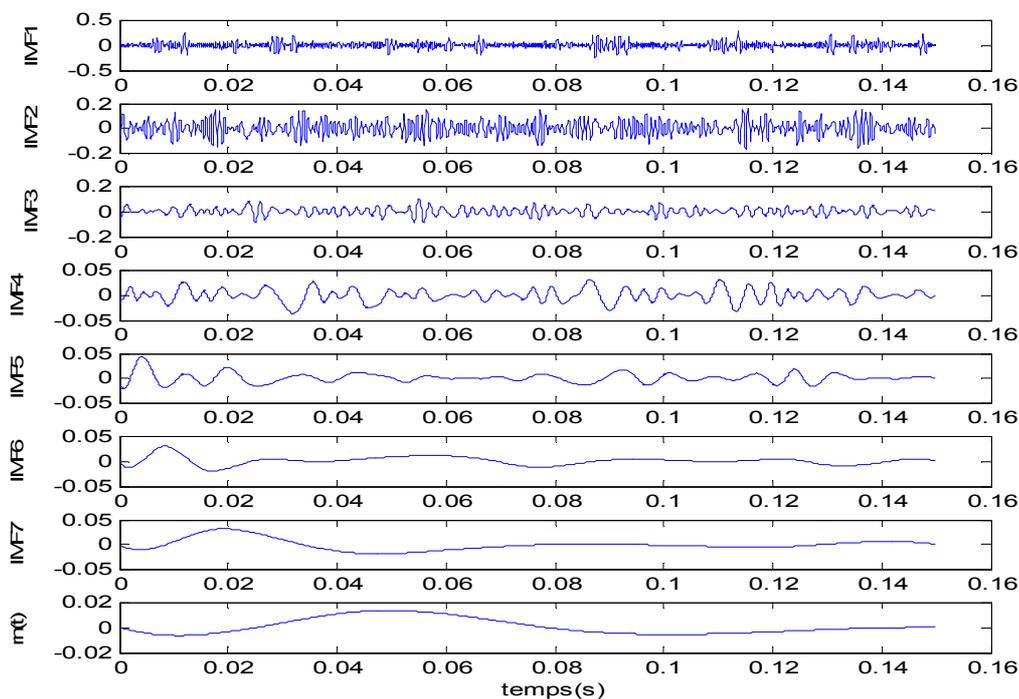


Figure.3.13 Décomposition en mode empirique du défaut de bague extérieure à accéléromètre centré à vide

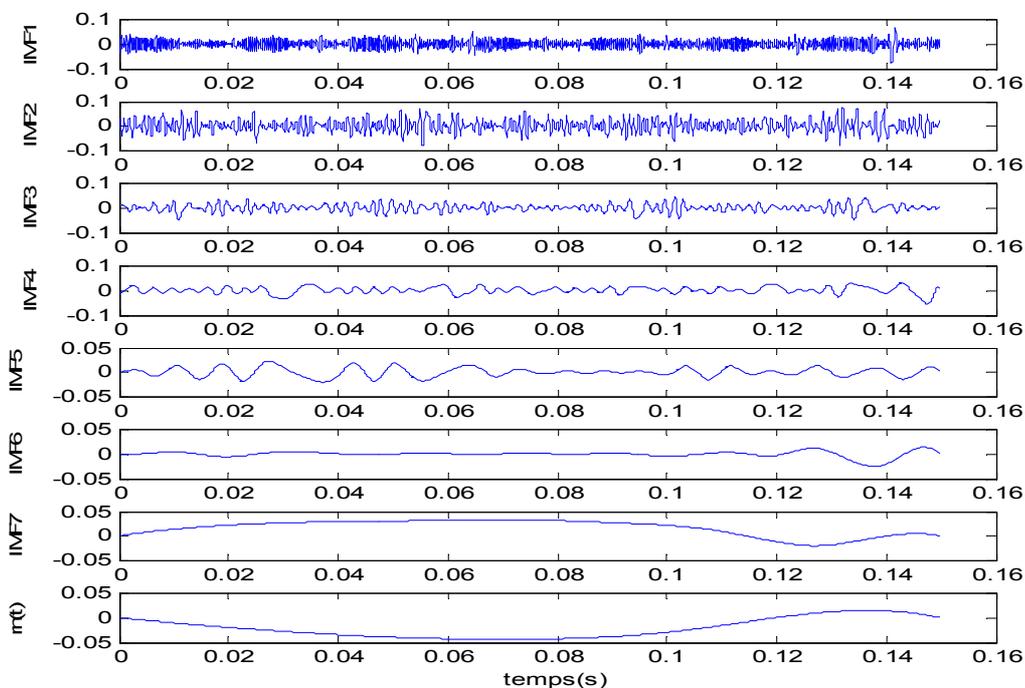


Figure.3.14 Décomposition en mode empirique du défaut de bague extérieure à accéléromètre centré en charge

➤ Défaut de bague extérieure à accéléromètre orthogonal

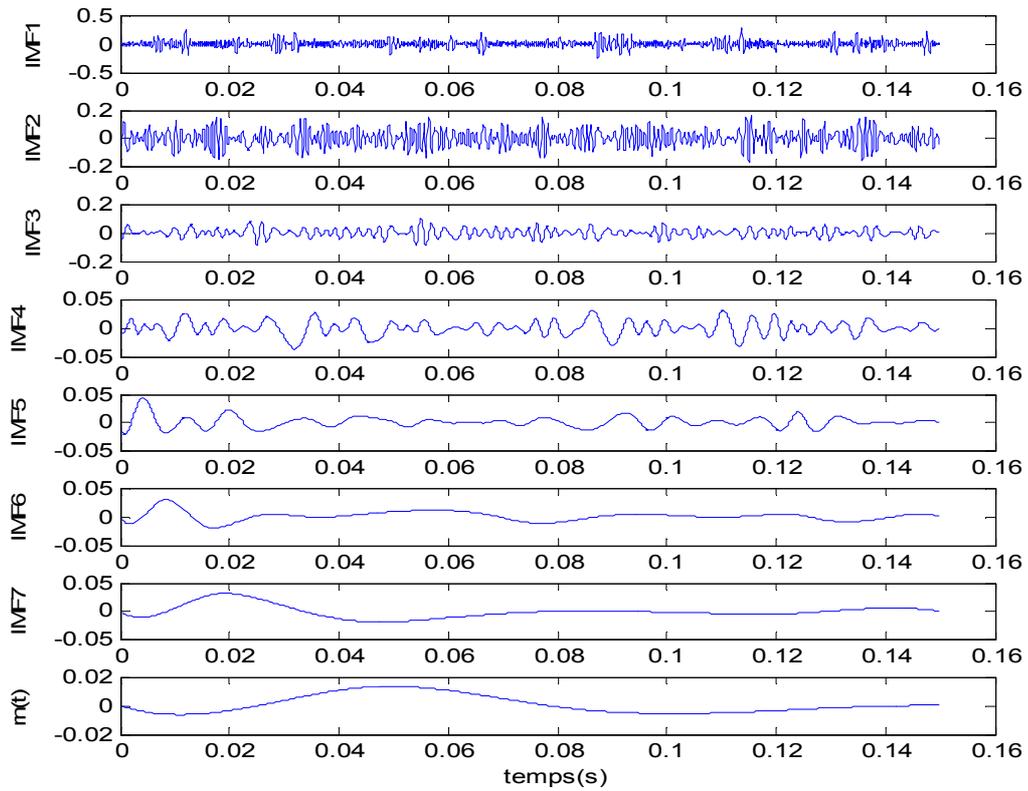


Figure.3.15 Décomposition en mode empirique du défaut de bague extérieure à accéléromètre orthogonal à vide

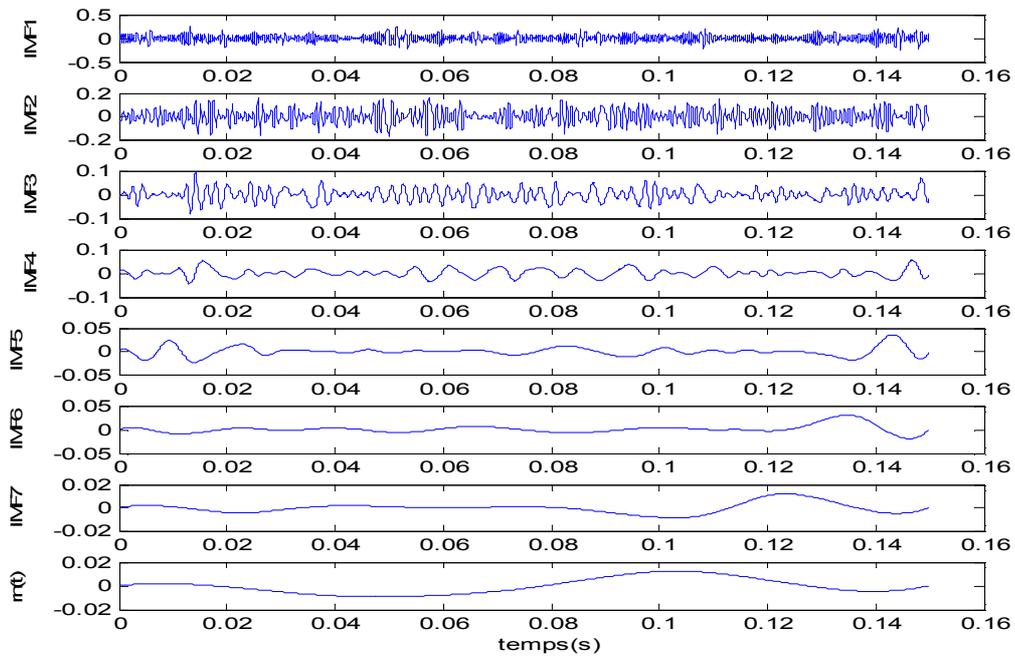


Figure.3.16 Décomposition en mode empirique du défaut de bague extérieure à accéléromètre orthogonal en charge

➤ Défaut de bague extérieure à accéléromètre opposé

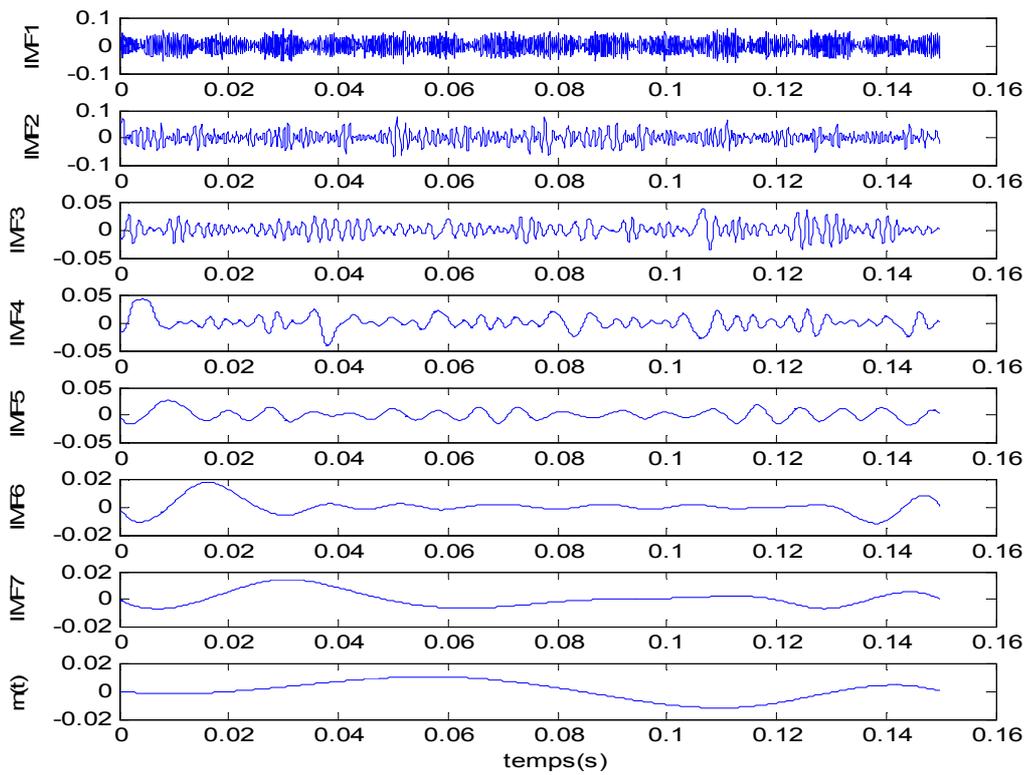


Figure.3.17 Décomposition en mode empirique du défaut de bague extérieure à accéléromètre opposé à vide

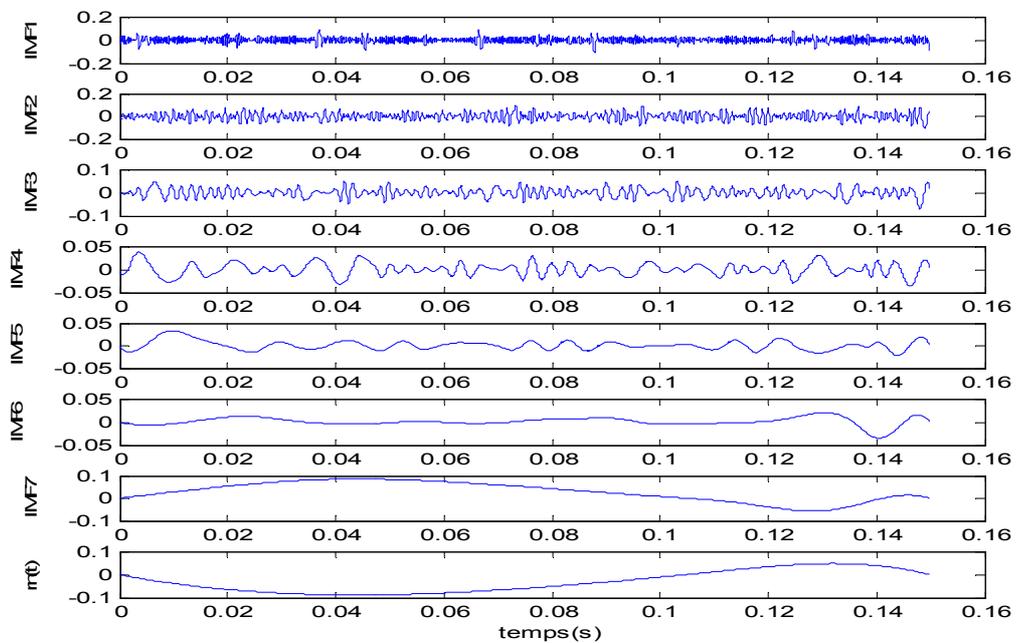


Figure.3.18 Décomposition en mode empirique du défaut de bague extérieure à accéléromètre opposé en charge

### 3.3.2 Sélection des IMFs

Après l'application de EMD sur chaque signal des défauts de roulement, nous allons obtenir une série de IMFs, chaque IMFs donne des informations peut être redondantes. Puisque ces IMFs peuvent être corrélées et ne sont pas tous pertinents. Donc, On doit sélectionner les IMFs les plus discriminantes pour chaque mode de défaillance à chaque cas d'entraînement de roulement. La sélection des IMFs pertinentes est réalisée à base d'analyse auto-corrélation. Les IMFs sélectionnées sont les plus performants ayant le plus grand coefficient de corrélation avec le signal original. Le coefficient de corrélation défini par :

$$\tau = \frac{\sum_{t=1}^T (x(t) - \bar{x})(IMF_i(t) - \overline{IMF_i})}{\left[ \sum_{t=1}^T (x(t) - \bar{x})^2 \sum_{t=1}^T (IMF_i(t) - \overline{IMF_i})^2 \right]^{1/2}} \quad (2.58)$$

Avec :  $\bar{x}$  et  $\overline{IMF_i}$  sont les moyennes des  $x(t)$  et  $\overline{IMF_i}$  respectivement

Les résultats obtenus de la sélection des IMFs correspondent aux valeurs supérieures des coefficients de corrélation pour différents niveaux de charge. Les résultats sont illustrés dans le tableau ci dessous:

Tableau 3.5: IMFs sélectionné pour chaque niveau de charge.

	niveau de charge 0%,33%,66% ,100%			
	Coté accouplement 1 (CA_12.000 pt/s)	Coté accouplement (CA_48.000 pt/s)	Coté ventilateur (CV_12.000 pt/s)	Cas sain
Défaut de la Bague intérieure	IMF 3	IMF 4	IMF 3	IMF 3
Défaut de bille	IMF 3	IMF 5	IMF4	
Défaut de la Bague extérieure	IMF 4	IMF 5	IMF 4	

Chaque IMF doit être prise indépendamment des autres. De cette façon, il est possible d'isoler les bandes de fréquences pertinentes dans le signal en sélectionnant les IMFs qui composent les fréquences désirées. Ces bandes de fréquences sont identifiées grâce à l'analyse spectral d'Hilbert.

### 3.3.3 Analyse spectral d'Hilbert des IMFs

L'analyse du spectre d'Hilbert est réalisée en tenant compte, de chaque IMFs de manière individuelle. La transformée d'Hilbert peut se résumer au calcul de la série discrète de Fourier (DFS) du signal, puis l'annulation des coefficients des fréquences négatives, ainsi que la multiplication des coefficients des fréquences positives par deux, puis en calcul la transformée inverse de Fourier du signal défini. A la fin de ce processus, nous obtenons un signal complexe, le signal final représente la partie réelle et la transformée de Hilbert représente la partie imaginaire.

Comme mentionné dans le paragraphe précédent, chaque IMF est indépendante aux autres. De cette façon, il est possible d'isoler les bandes de fréquences d'intérêt dans le signal en sélectionnant les IMFs qui composent ces fréquences souhaitées. Ces bandes de fréquences sont identifiées grâce au spectre marginal d'Hilbert. Ce dernier calcule la densité d'énergie au niveau de chaque fréquence. Une fois que les bandes de fréquences sont identifiées, il est possible de sélectionner les IMFs regroupant les fréquences caractéristiques d'un défaut donné.

#### 3.3.3.1 Analyse spectral d'Hilbert à l'état sain

Les figures 3.19 et 3.20 montre le spectre d'Hilbert des signaux vibratoires dans le cas sain (vide et charge). Elles situent la haute et la moyenne fréquence de chaque signal que la fréquence dans le cas où le roulement est sain est insensible à la charge.

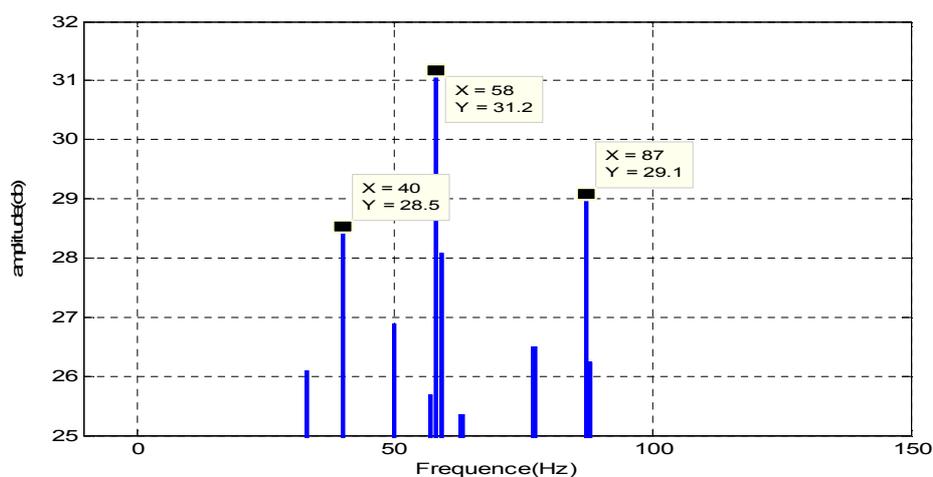


Figure.3.19 Analyse spectrale de Hilbert de roulement sain à vide: haute et moyenne fréquence

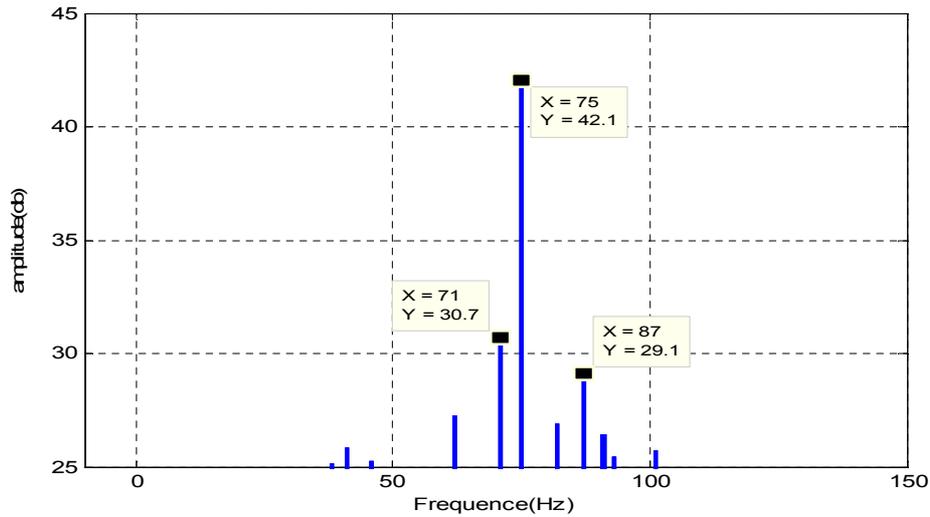


Figure.3.20 Analyse spectrale de Hilbert de roulement sain en charge:  
haute et moyenne fréquence

A partir de spectre de Hilbert on peut relever les amplitudes et les fréquences des signaux de l'état sain. Les résultats sont portés dans le tableau suivant :

Tableau3.6 : Fréquences et Amplitudes des signaux de roulements dans le cas du défaut de bague intérieure

Charge du moteur	Vitesse approximée du moteur	Fréquence (Hz)	Fréquence caractéristique	Amplitude (db)
0%	1797	58	75	31.2
33%	1772	75	75	39.4
66%	1750	75	75	38.7
100%	1730	75	75	42.1

Dans ce tableau, on remarque que les fréquences des signaux vibratoires à l'état sain sont presque constantes quelque soit la variation de la charge, par contre l'amplitude augmente légèrement avec l'augmentation de la charge.

### 3.3.3.2 Analyse spectrale de Hilbert du défaut de bague intérieure

Les figures 3.21 et 3.22 présentent le spectre de Hilbert des signaux vibratoires dans le cas de défaut de bague intérieure à différents niveaux de charge, ces figures représentent le haut et la moyenne fréquence pour chaque signal. Dans ce cas, on observe que la fréquence de défaut de bague intérieure diminuée légèrement avec l'augmentation du niveau de charge.

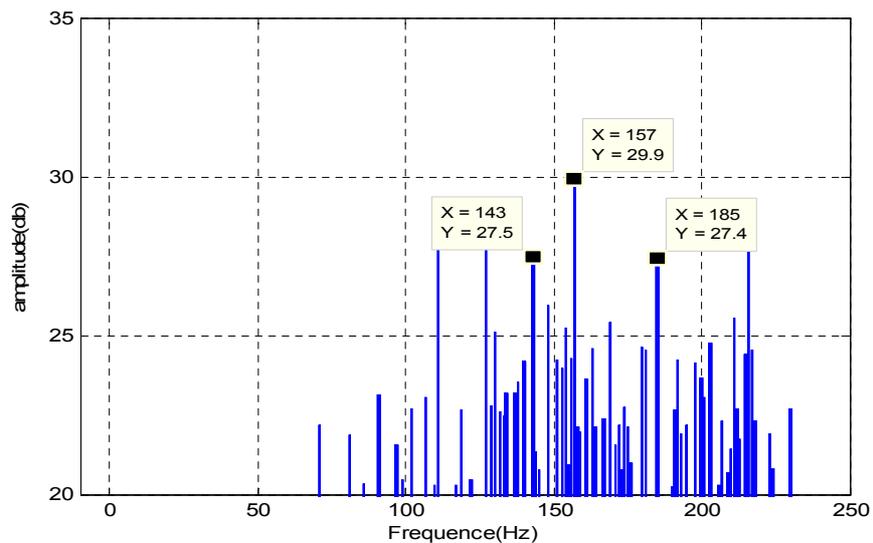


Figure.3.21 Analyse spectrale de Hilbert du défaut de bague intérieure à vide :  
haute et moyenne fréquence

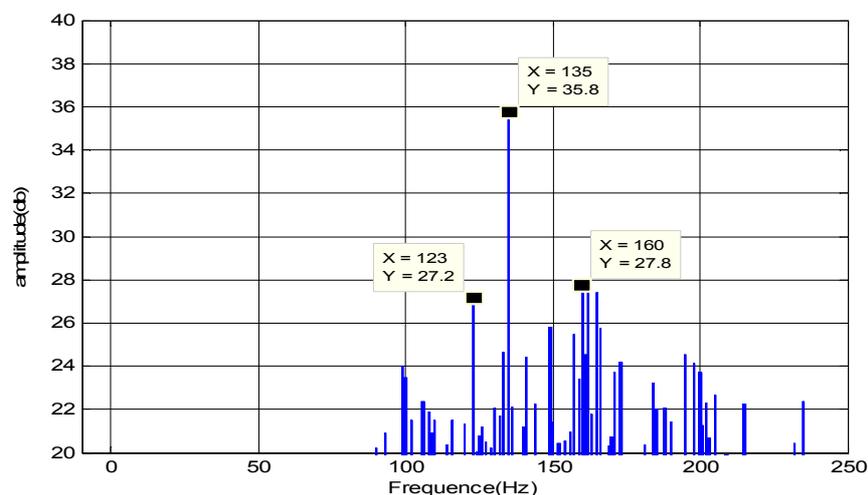


Figure.3.22 Analyse spectrale de Hilbert du défaut de bague intérieure en charge :  
haute et moyenne fréquence

Avec les valeurs requises spécifiques pour le palier étant énumérées dans le tableau 3.1, la fréquence caractéristique du défaut de bague intérieure c'est 162.19 Hz.

A partir de spectre de Hilbert, on peut relever les amplitudes et les fréquences des signaux du défaut de bague intérieure et dresser le tableau suivant :

Tableau3.7 : Fréquences et amplitudes du défaut de bague intérieure

diamètre de défaut (mm)	Charge du moteur	Vitesse du moteur	Fréquence (Hz) (CA_12) pt/s	Fréquence (Hz) (CA_48k) pt/s	Fréquence (Hz) (CV_48k) pt/s	Amplitude (db) (CA_12k) pt/s	Amplitude (db) (CA_48k) pt/s	Amplitude (db) (CV_48k) pt/s
0.007	0%	1797	160	160	156	46.5	48.6	30.3
	33%	1772	158	160	158	46.2	56.2	28.1
	66%	1750	155	158	161	44.1	48.4	27.4
	100%	1730	153	158	156	44.5	52.8	43.8
0.014	0%	1797	160	165	153	46.4	34	35.5
	33%	1772	158	158	158	32.9	34.7	31.8
	66%	1750	158	158	156	47	34.5	29.5
	100%	1730	156	152	156	48.2	34.1	44.2
0.021	0%	1797	160	165	158	47.5	41.8	34.9
	33%	1772	156	158	156	46.3	45.5	35.7
	66%	1750	156	156	154	45.1	45.4	47.1
	100%	1730	154	150	155	44.6	49.5	26.4
0.028	0%	1797	160	*	*	46.5	*	*
	33%	1772	158	*	*	43.4	*	*
	66%	1750	155	*	*	52	*	*
	100%	1730	153	*	*	44.5	*	*

### 3.3.3.3 Analyse spectrale de Hilbert du défaut de bille

Les figures 3.13 et 3.24 présentent le spectre de Hilbert des signaux vibratoires à l'entraînement dans le cas de roulement à défaut de bille pour chaque niveau de charge, ces figures représentent le haut et la moyenne fréquence pour chaque signal. Dans ce cas, on observe que la fréquence augmente légèrement avec l'augmentation du niveau de charge.

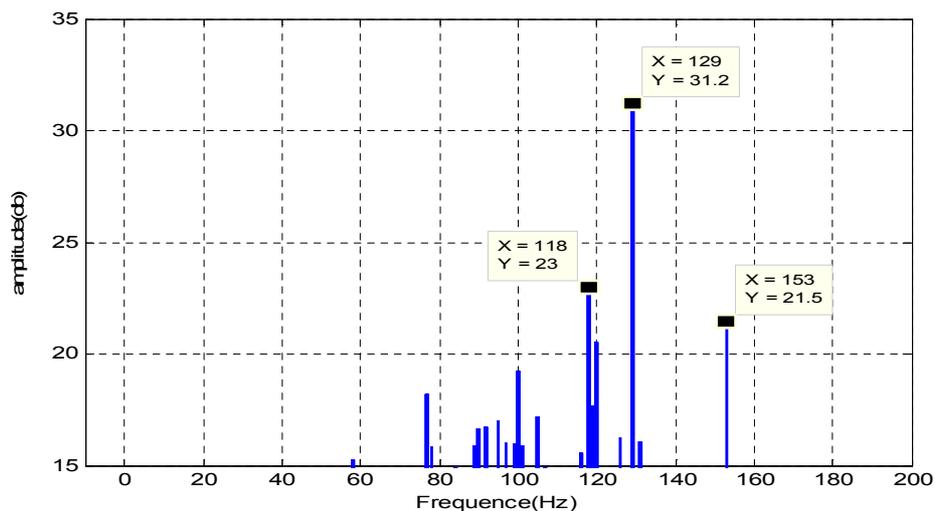


Figure.3.23 Analyse spectral de Hilbert du défaut de bille à vide:  
haut et moyennes fréquence

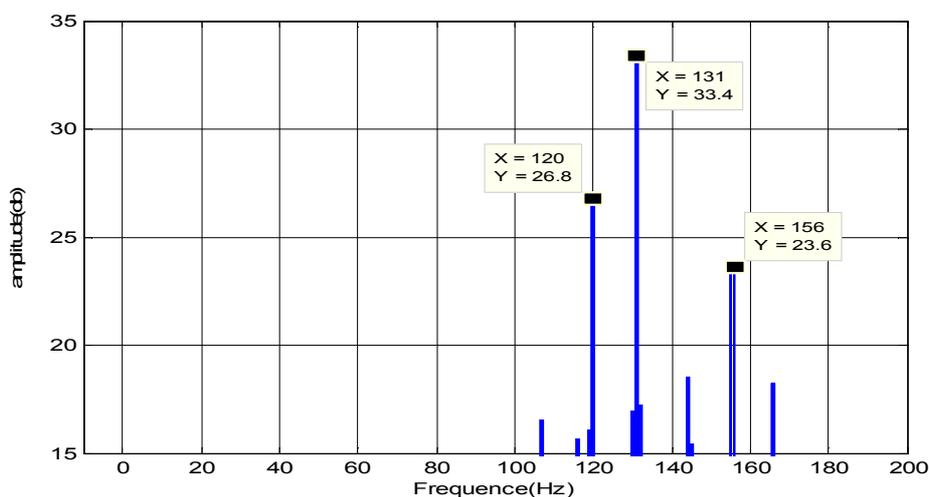


Figure.3.24 Analyse spectral de Hilbert du défaut de bille en charge:  
haut et moyennes fréquence

Avec les valeurs requises spécifiques pour le palier étant énumérées dans le tableau 3.1, la fréquence caractéristique du défaut de bille est 141,17 Hz.

A partir de spectre de Hilbert nous avons relevé les amplitudes et les fréquences des signaux du défaut de bague extérieure à accéléromètre centré. Les valeurs obtenues sont portées dans le tableau ci-dessous.

Tableau 3.8 : Fréquences et amplitudes de roulement avec défaut de bille

diamètre de défaut (mm)	Charge du moteur	Vitesse du moteur	Fréquence (Hz) (CA_12000) pt/s	Fréquence (Hz) (CA_4800) pt/s	Fréquence (Hz) (CV_1200) pt/s	Amplitude (db) (CA_1200) pt/s	Amplitude (db) (CA_4800) pt/s	Amplitude (db) (CV_1200) pt/s
0.007	0%	1797	135	137	135	51.2	49.8	61.1
	33%	1772	133	134	133	53.1	40.9	54.5
	66%	1750	131	131	130	48.8	38.6	52.6
	100%	1730	129	131	130	49.8	50.3	61.3
0.014	0%	1797	135	137	133	48.6	44.3	46
	33%	1772	133	131	132	48.3	44.8	48.3
	66%	1750	131	132	131	49.5	43	48.4
	100%	1730	129	130	130	50.6	45.2	48.3
0.021	0%	1797	135	137	135	50.3	40.9	49.4
	33%	1772	133	143	133	52.4	40.8	39.5
	66%	1750	131	150	132	53	39.9	45.3
	100%	1730	130	131	130	53	45.1	39.8
0.028	0%	1797	135	*	*	49.5	*	*
	33%	1772	133	*	*	50	*	*
	66%	1750	131	*	*	53.5	*	*
	100%	1730	129	*	*	49.8	*	*

### 3.3.2.4 Analyse spectrale de Hilbert du défaut de bague extérieure

Avec les valeurs requises spécifiques pour le palier étant énumérées dans le tableau 3.1, la fréquence caractéristique du défaut de bague extérieure est 107,36 Hz. Selon la position de l'accéléromètre, le défaut de bague extérieure se décline en trois versions.

#### ➤ Analyse spectrale de Hilbert du défaut de bague extérieure à accéléromètre centré

Les figures 3.25 et 3.26 présentent le spectre de Hilbert des signaux vibratoires dans le cas de défaut de bague extérieure à accéléromètre centré pour chaque niveau de charge. Ces figures présentent l'haute et la moyenne fréquence pour chaque signal. Dans ce cas on observe que la fréquence est augmentée légèrement avec l'augmentation du niveau de charge.

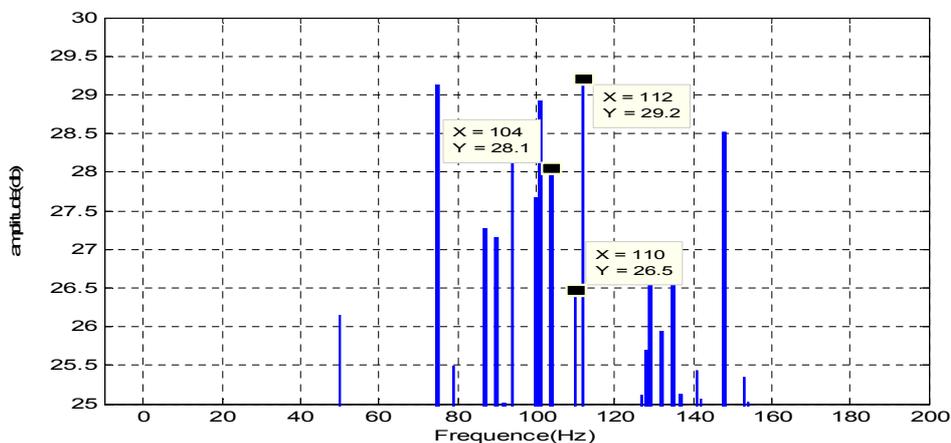


Figure.3.25 Analyse spectrale de Hilbert du défaut de bague extérieure à accéléromètre centré à vide : haute et moyenne fréquence

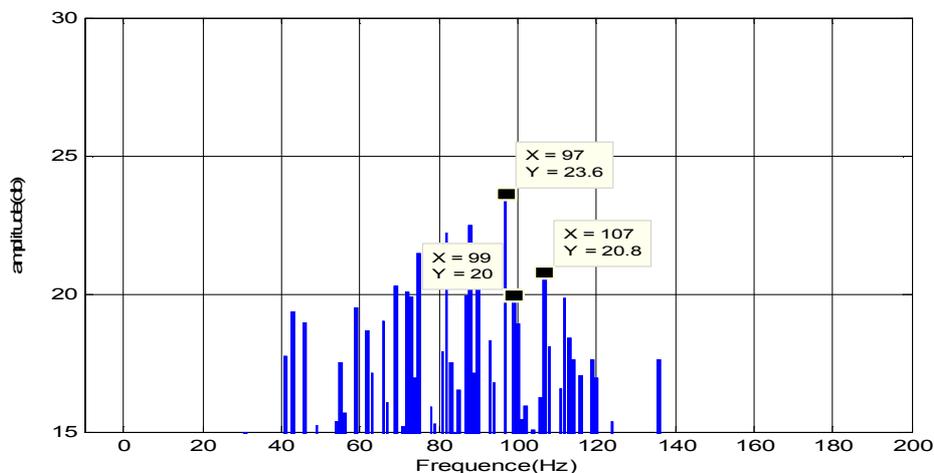


Figure.3.26 Analyse spectrale de Hilbert du défaut de bague extérieure à accéléromètre centré en charge: haute et moyenne fréquence

A partir de spectre de Hilbert nous avons relevé les amplitudes et les fréquences des signaux du défaut de bague extérieure à accéléromètre centré. Les valeurs obtenues sont portées dans le tableau ci-dessous.

Tableau 3.9 : Fréquences et amplitudes de roulement à défaut de bague extérieure à accéléromètre centré

diamètre de défaut (mm)	Charge du moteur	Vitesse du moteur (tr/min)	Fréquence (Hz) (CA_12000) pt/s	Fréquence (Hz) (CA_4800) pt/s	Fréquence (Hz) (CV_1200) pt/s	Amplitude (db) (CA_1200) pt/s	Amplitud (db) (CA_4800) pt/s	Amplitude (db) (CV_1200) pt/s
0.007	0%	1797	99.8	110	107	41.3	31.1	34.5
	33%	1772	110	109	105	39.4	39.2	34.2
	66%	1750	111	107	111	37.7	32	38.2
	100%	1730	112	100	107	40.3	38	37.7
0.014	0%	1797	115	102	111	34.1	33.5	47.4
	33%	1772	121	*	106	34	*	34.9
	66%	1750	105	*	105	29.3	*	42.2
	100%	1730	118	*	104	39.8	*	35.3
0.021	0%	1797	110	108	110	34.5	34.4	48.1
	33%	1772	111	*	106	36	*	42.2
	66%	1750	115	*	104	40.3	*	41.2
	100%	1730	118	*	103	42.9	*	39.9

➤ *Analyse spectrale de Hilbert du défaut de bague extérieure à accéléromètre orthogonal*

Les figure.3.27 et 3.28 présentent le spectre de Hilbert des signaux vibratoires du défaut de bague extérieure à accéléromètre orthogonal de chaque niveau de charge. Elle montre l'haute et la moyenne fréquence pour chaque signal. On note les mêmes observations que les cas précédents, avec une faible diminution de la fréquence quand la charge augmente.

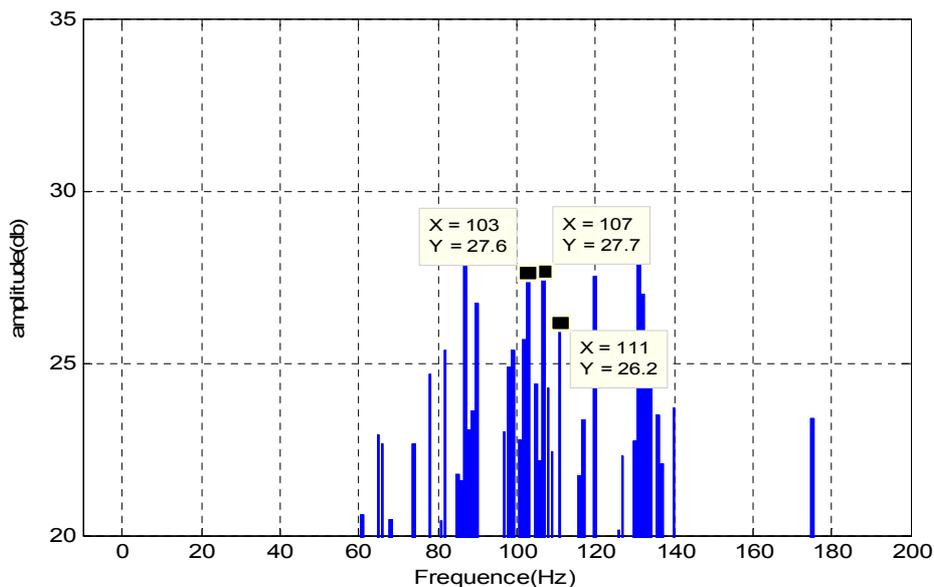


Figure.3.27 Analyse spectrale de Hilbert du défaut de bague extérieure à accéléromètre orthogonal à vide: haute et moyenne fréquence

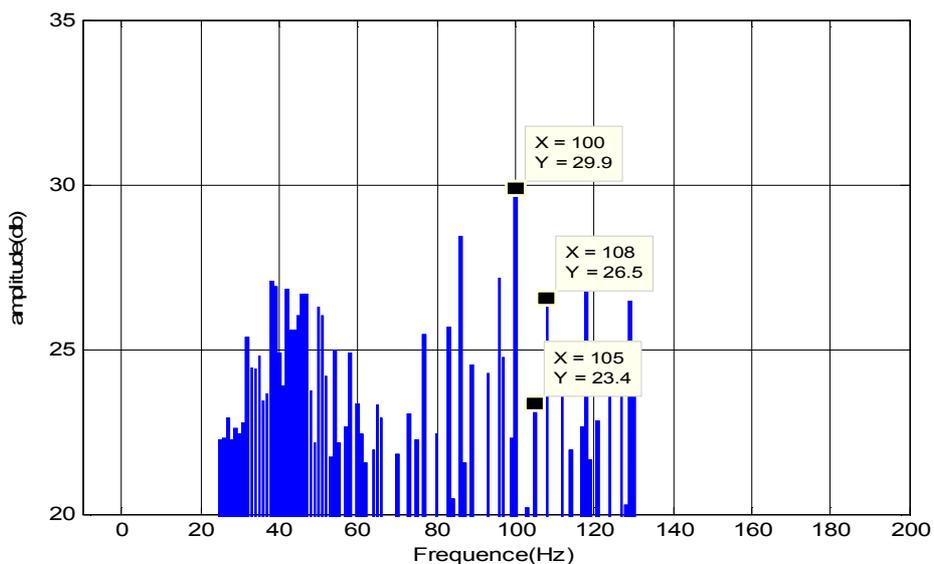


Figure.3.28 Analyse spectrale de Hilbert du défaut de la bague extérieure à accéléromètre orthogonal en charge: haute et moyenne fréquence

A partir de spectre de Hilbert nous avons relevé les amplitudes et les fréquences des signaux du défaut de bague extérieure à accéléromètre orthogonal. Les valeurs obtenues sont portées dans le tableau ci-dessous.

Tableau 3.10 : Fréquences et amplitudes du défaut de bague extérieure à accéléromètre orthogonal

Diamètre de défaut (mm)	Charge du moteur	Vitesse du moteur Tr/min	Fréquence (Hz) (CA_12000) Pt/s	Fréquence (Hz) (CA_12000) Pt/s	Fréquence (Hz) (CV_12000) Pt/s	Amplitude (db) (CA_12000) Pt/s	Amplitude (db) (CA_48000) Pt/s	Amplitude (db) (CV_12000) Pt/s
0.007	0%	1797	106	111	105	30.1	28.6	40.9
	33%	1772	102	108	105	34.1	31.8	42.1
	66%	1750	109	105	107	34	33.2	37.7
	100%	1730	118	109	108	47.6	31.2	43.4
0.014	0%	1797	*	108	*	*	34.1	*
	33%	1772	*	106	*	*	29.3	*
	66%	1750	*	107	*	*	29	*
	100%	1730	*	102	*	*	36.8	*
0.021	0%	1797	110	*	102	36.8	*	53.3
	33%	1772	108	107	103	24	34.3	37.2
	66%	1750	107	107	107	35.6	31.5	54.8
	100%	1730	105	103	109	34	34.8	56.5

➤ *Analyse spectrale de Hilbert du défaut de bague extérieure à accéléromètre opposé*

Les figures 3.29 et 3.30 présentent le spectre de Hilbert des signaux vibratoires pour le défaut de bague extérieure à accéléromètre opposé de chaque niveau de charge. Ces figures présentent la haute et la moyenne fréquence de chaque signal. On constate une faible diminution de la fréquence quand la charge augmente.

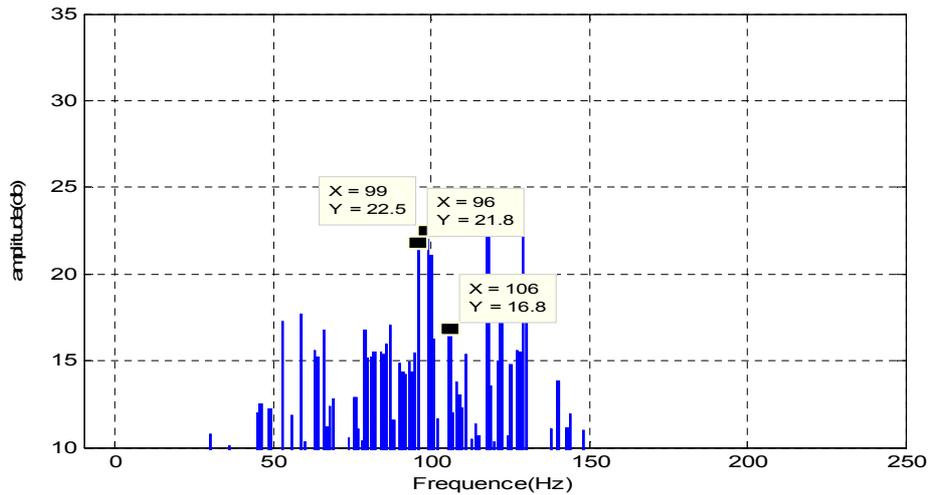


Figure.3.29 Analyse spectrale de Hilbert du défaut de bague extérieure à accéléromètre opposé à vide: haute et moyenne fréquence

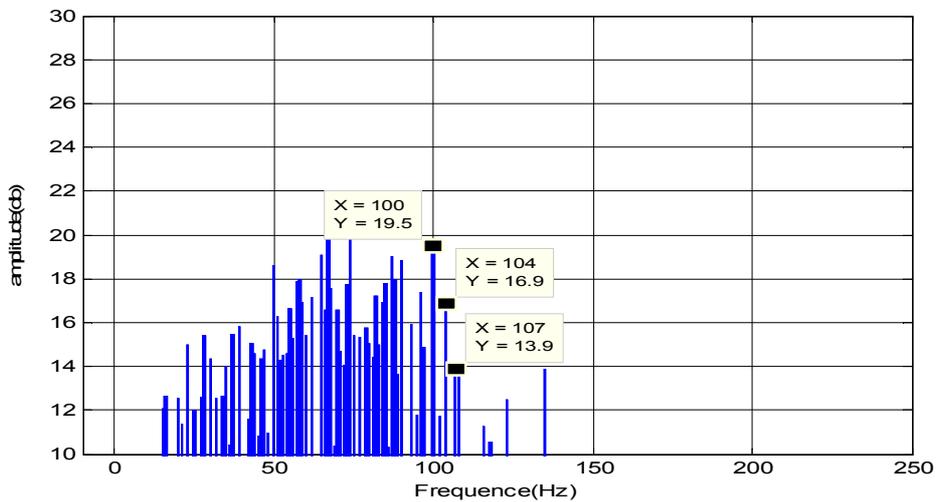


Figure.3.30 Analyse spectrale de Hilbert du défaut de bague extérieure à accéléromètre opposé en charge: haute et moyenne fréquence

A partir de spectre de Hilbert nous avons relevé les amplitudes et les fréquences des signaux du défaut de bague extérieure à accéléromètre opposé. Les valeurs obtenues sont portées dans le tableau ci-dessous.

Tableau 3.11 : Fréquences et Amplitudes du défaut de bague extérieure à accéléromètre opposé

diamètre de défaut (mm)	Charge du moteur	Vitesse du moteur tr/min	Fréquence (Hz) (CA_12000) pt/s	Fréquence (Hz) (CA_48000) pt/s	Fréquence (Hz) (CV_12000) pt/s	Amplitude (db) (CA_12000) pt/s	Amplitude (db) (CA_48000) pt/s	Amplitude (db) (CV_1200) pt/s
0.007	0%	1797	102	110	102	29.9	34.9	42.4
	33%	1772	100	109	105	39.1	31.1	37.8
	66%	1750	114	107	107	31.6	34.4	36.8
	100%	1730	118	106	108	48	28.7	41.2
0.014	0%	1797	*	*	*	*	*	*
	33%	1772	*	*	*	*	*	*
	66%	1750	*	*	*	*	*	*
	100%	1730	*	*	*	*	*	*
0.021	0%	1797	108	*	102	26.3	*	50
	33%	1772	114	*	101	28.7	*	51.2
	66%	1750	106	*	103	31	*	46.9
	100%	1730	107	*	104	34.1	*	40.2

### 3.3.2.5 Interprétation des résultats

L'analyse des résultats obtenus dans les tableaux précédents montrent que l'augmentation du diamètre de défaut a entraîné les effets suivant:

- une faible variation de la vitesse qui ne dépassant pas les 3%
- les fréquences des défauts présent sur les signaux expérimentaux sont très proches des fréquences théoriques de l'ordre de 2 à 9 Hz
- l'augmentation du niveau de charge entre (0-3) HP a entraînée une faible diminution de l'amplitude et de la fréquence caractéristique (44-46 dB) cela peut s'expliquer par l'augmentation de l'inertie de l'entraînement (moteur +charge)

### 3.3.3 Extraction de caractéristique par TKEO

Comme le TKEO détecte un changement instantané d'énergie sans connaissance a priori de la structure de données, il peut être utilisé pour connaître l'état sur la base de surveillance vibratoire.

Dans cette étape, nous avons présenté l'effet d'applications de l'opérateur d'énergie de Teager-Kaiser (TKEO). Cet opérateur ne calcule pas l'énergie d'un signal mais l'énergie du système qui génère le signal. Cette énergie qui est égale au carré du produit de la fréquence et de l'amplitude du signal est destinée à la démodulation en amplitude et/ou en fréquence du signal [Rod 13].

Pour appliquer cet opérateur la fréquence d'échantillonnage doit être environ de huit fois supérieure à la fréquence la plus élevée du signal. Comme mentionné dans les étapes précédents, nous avons utilisé la transformé de Hilbert-Huang pour décomposer le signal  $x(t)$  en plusieurs IMFs. Ces IMFs représentent le signal d'entrée dans des bandes de fréquences spécifiques données par la fréquence instantanée  $f_i(t)$ . Ces bandes de fréquences sont identifiées grâce à l'analyse spectrale de Hilbert, qui calcule la densité d'énergie au niveau de chaque fréquence. Une fois que les bandes de fréquences sont identifiées, il est possible de sélectionner les IMFs regroupant les fréquences caractéristiques d'un défaut donné.

Dans notre cas, nous avons appliqué le TKEO à chaque IMFs décomposées par l'EMD pour extraire les amplitudes et les fréquences instantanées. Ensuite, le TKEO extrait les spectres des enveloppes obtenus en utilisant l'analyse spectrale pour rechercher des fréquences caractéristiques correspond à la densité d'énergie le plus élevée pour chacun des défauts de roulements. Pour créer un vecteur caractéristique (vecteur forme) il faut appliquer le TKEO à chacun des vecteurs communs obtenus à partir des IMFs, puis calculer la somme des TKEOs obtenus pour chaque état. Cette opération, nous a permis d'extraire quatre vingt (80) points pertinents pour chaque vecteur correspondant au chaque état considéré.

Les figures 3.31 à 3.42 présentent les amplitudes estimées par l'opérateur d'énergie TKEO pour des signaux vibratoires qui sont respectivement : le cas sain, défaut de bague intérieure, défaut de bille et défaut de bague extérieure à accéléromètre centré, orthogonal ou opposé. Ces amplitudes ont été estimées pour les deux cas : machine à vide et en charge.

➤ Extraction de caractéristique par TKEO de l'état sain

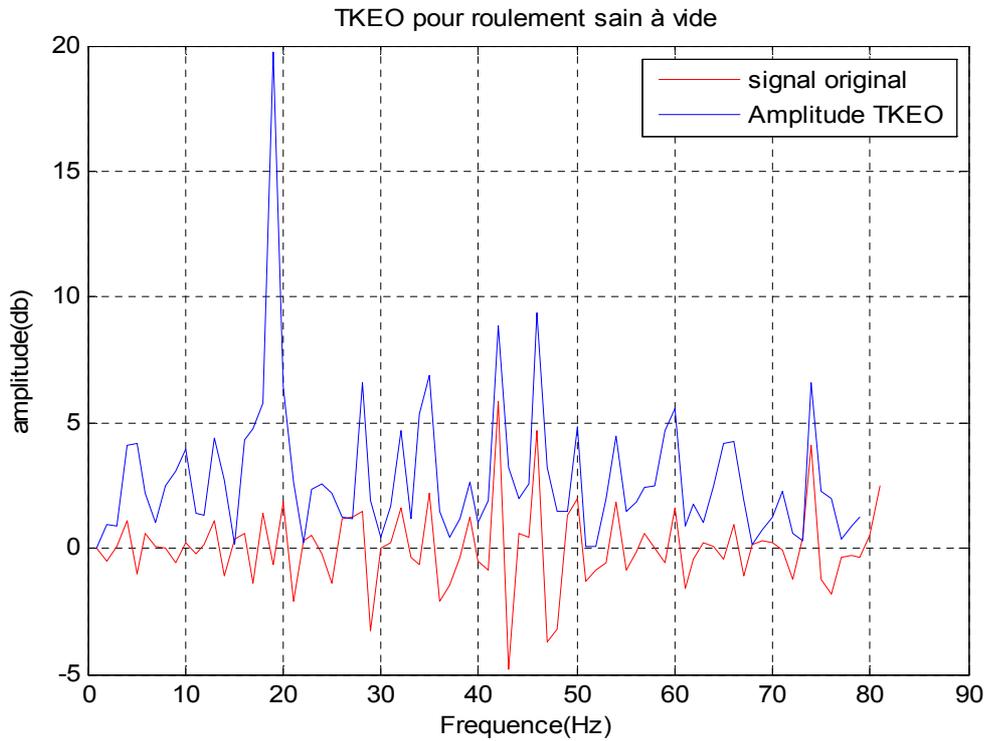


Figure.3.31 TKEO des signaux du roulement sain à vide

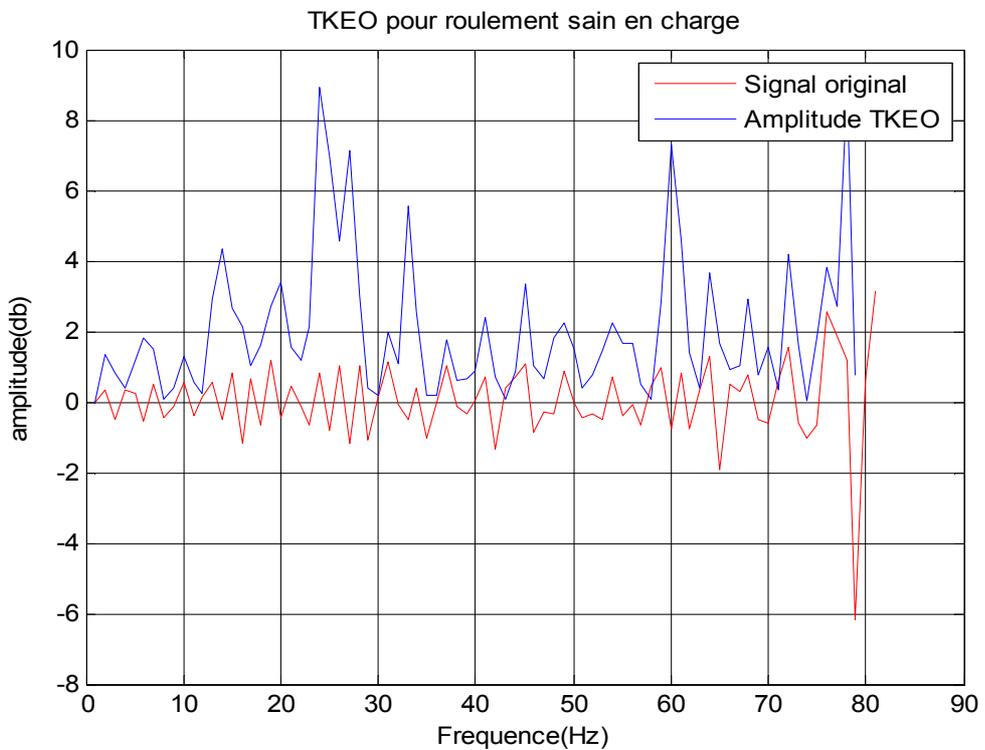


Figure.3.32 TKEO des signaux de roulement sain en charge

➤ Extraction de caractéristique par TKEO du défaut de bague intérieure

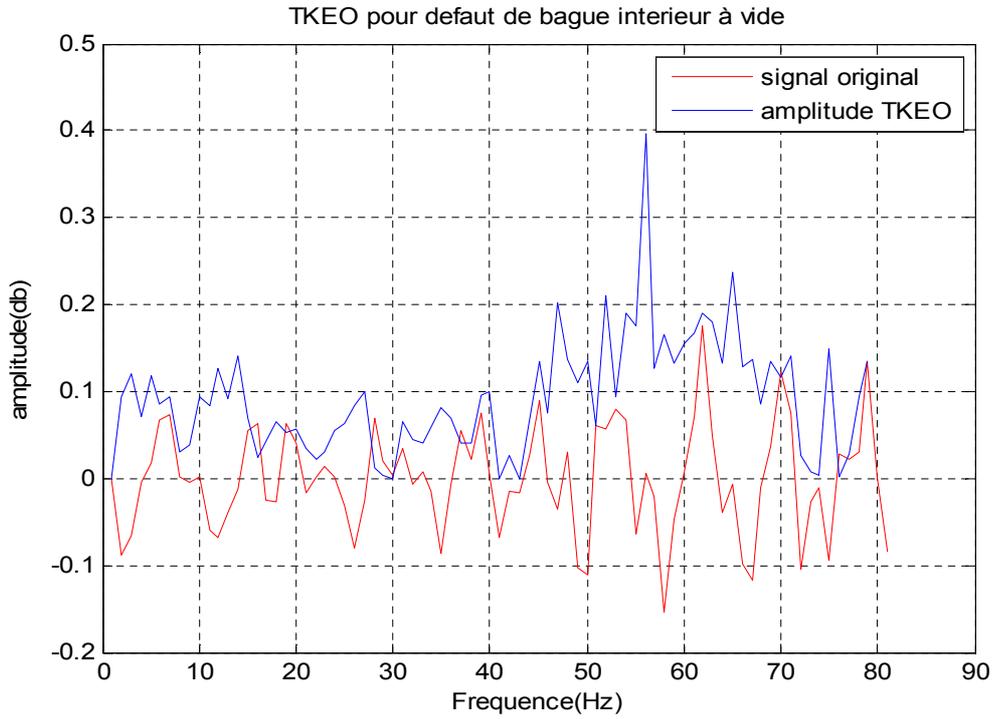


Figure.3.33 TKEO des signaux du défaut de bague intérieure à vide

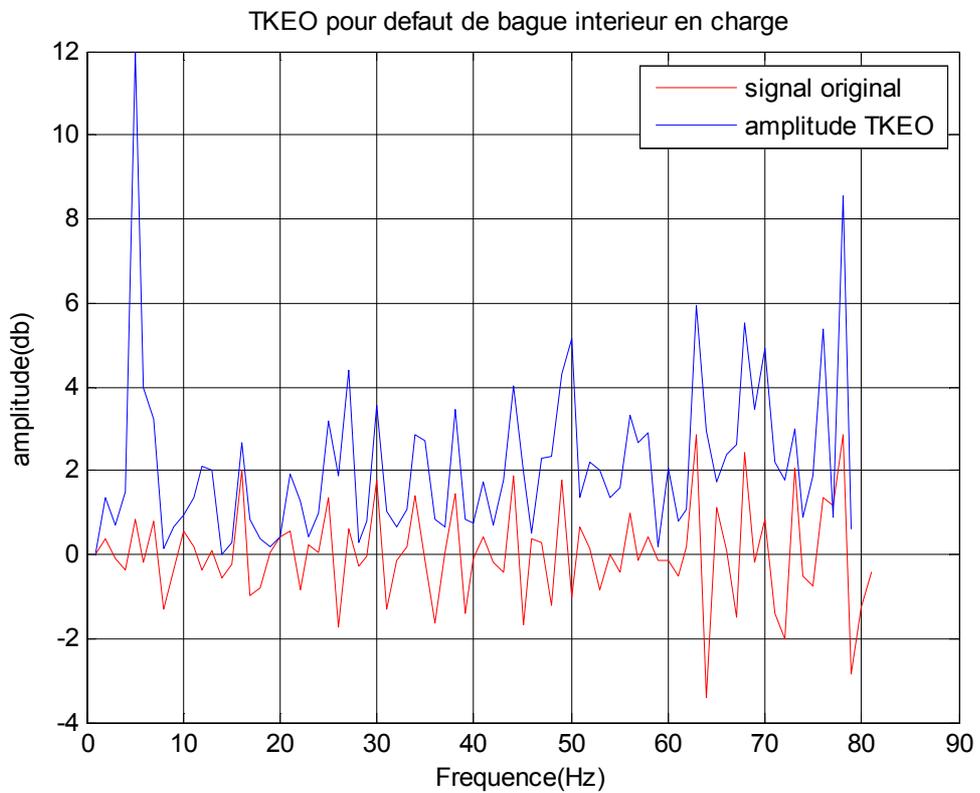


Figure.3.34 TKEO des signaux du défaut de bague intérieure en charge

➤ Extraction des caractéristiques par TKEO du défaut de bille

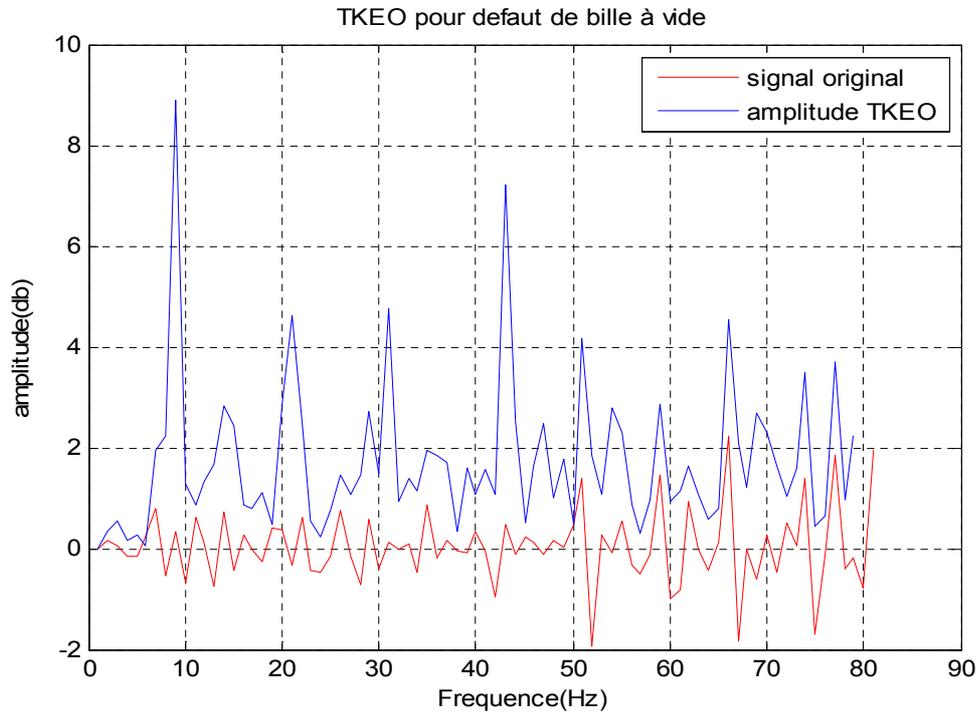


Figure.3.35 TKEO des signaux du défaut de bille à vide

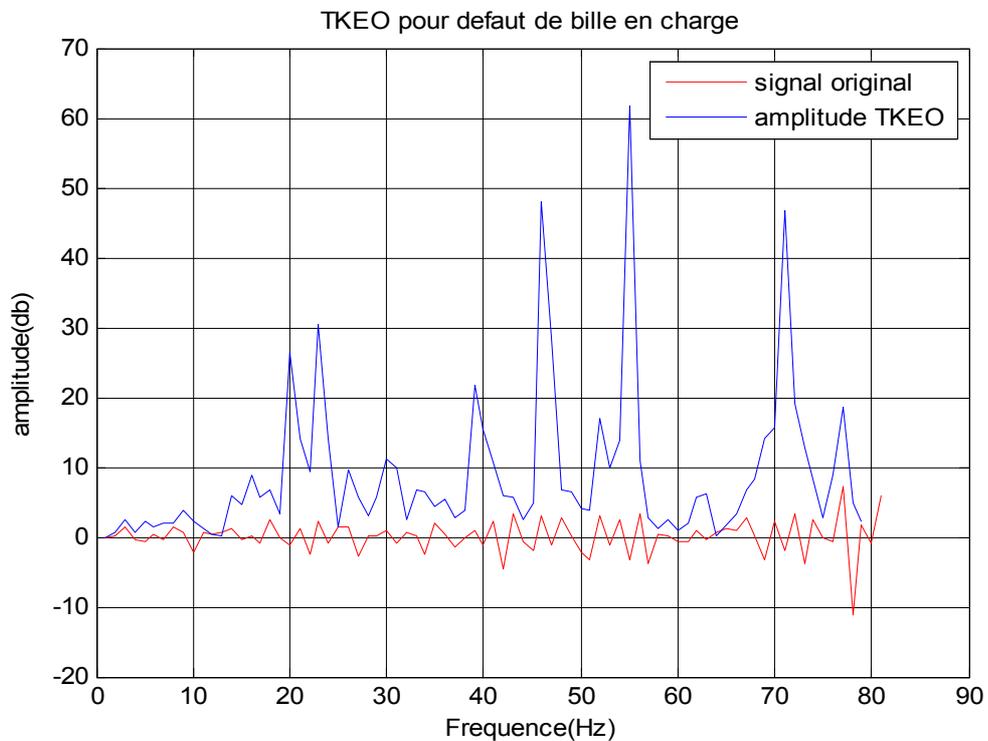


Figure.3.36 TKEO des signaux du défaut de bille en charge

➤ Extraction de caractéristique par TKEO du défaut de bague extérieure à accéléromètre centré

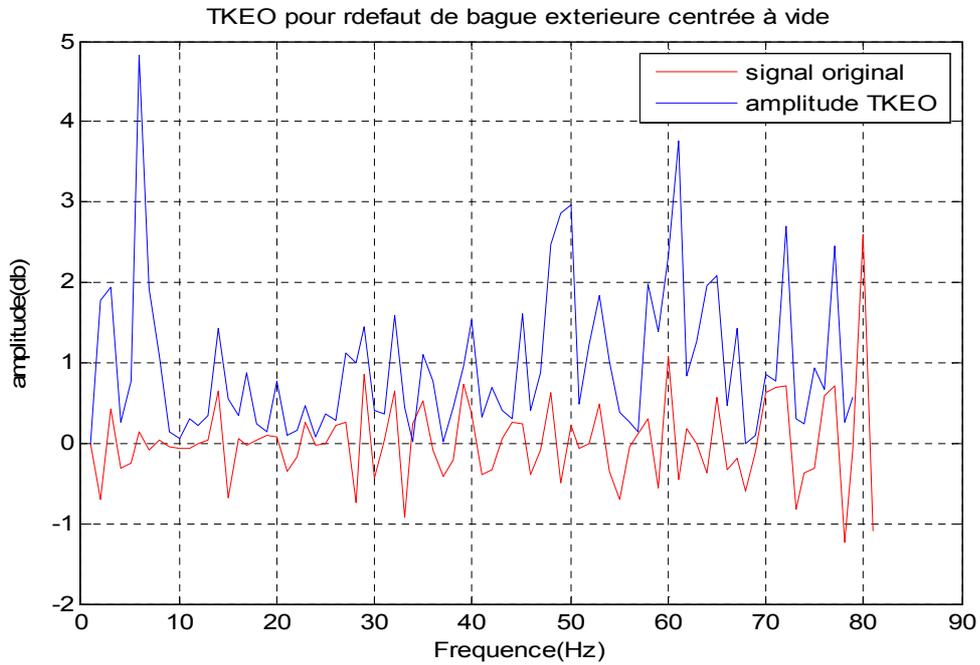


Figure.3.37 TKEO des signaux du défaut de bague extérieure à accéléromètre centré à vide

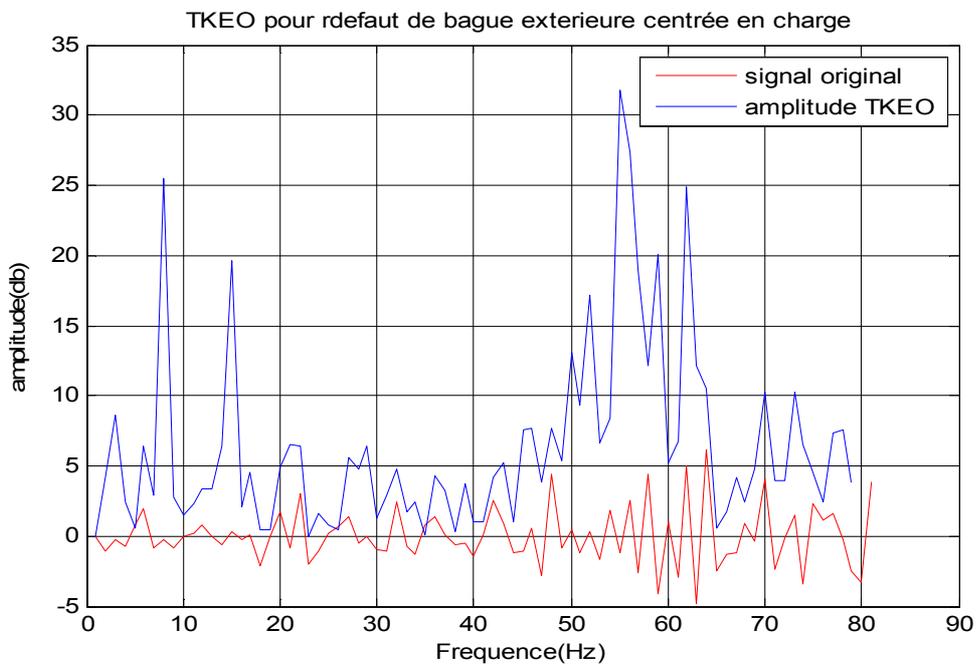


Figure.3.38 TKEO des signaux du défaut de bague extérieure à accéléromètre centré en charge

➤ **Extraction de caractéristique par TKEO du défaut de bague extérieure à accéléromètre orthogonal**

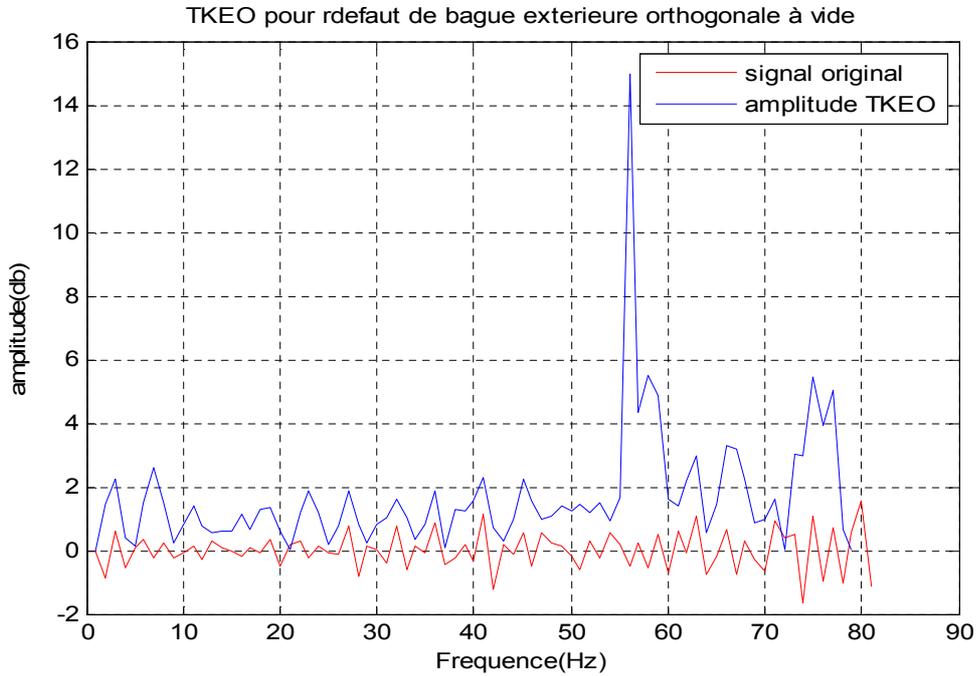


Figure.3. 39 TKEO des signaux du défaut de bague extérieure à accéléromètre orthogonal à vide

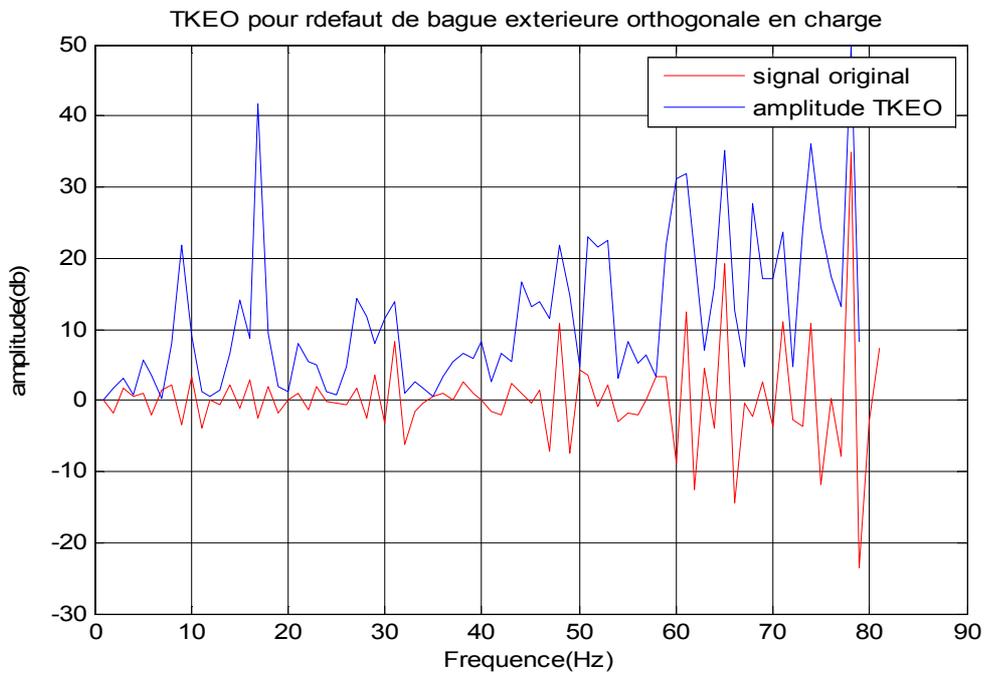


Figure.3. 40 TKEO des signaux du défaut de bague extérieure à accéléromètre orthogonal en charge

➤ **Extraction de caractéristique par TKEO du défaut de bague extérieure à accéléromètre opposé**

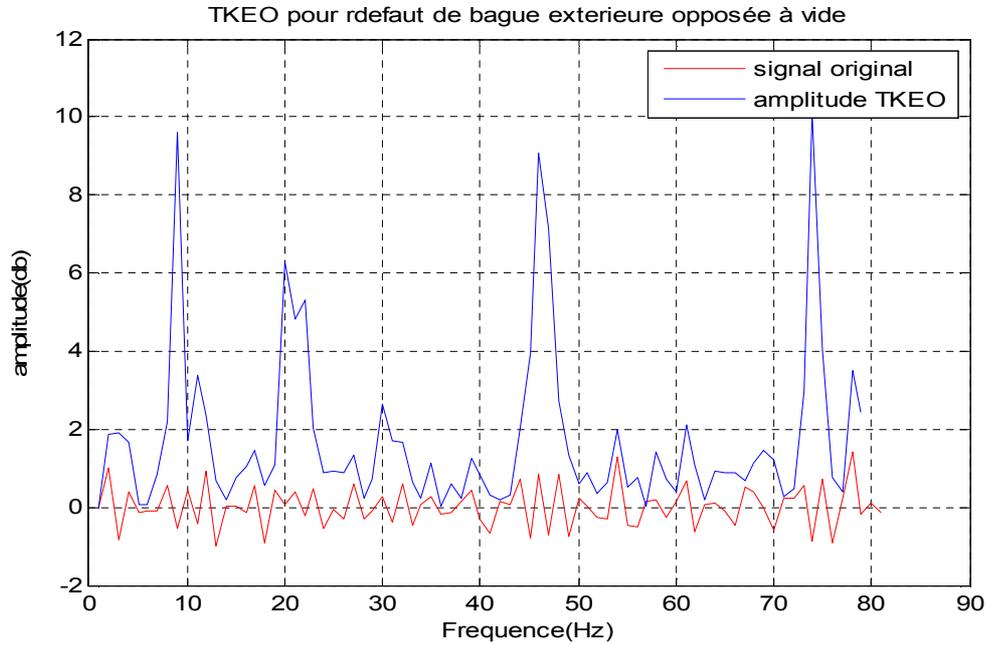


Figure.3.41 TKEO des signaux du défaut de bague extérieure à accéléromètre opposé à vide

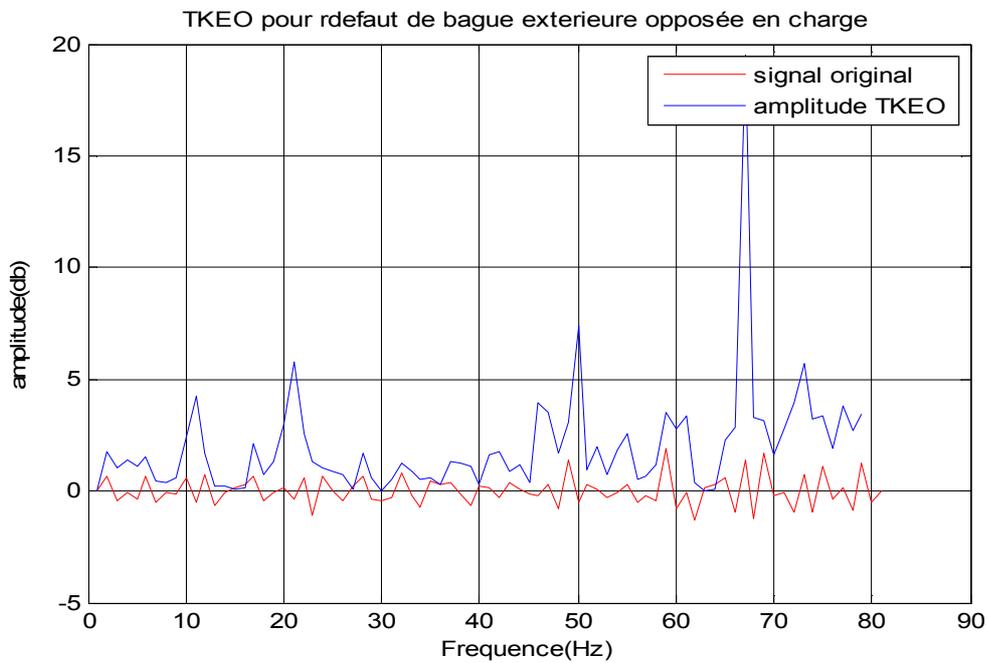


Figure.3.42 TKEO des signaux du défaut de bague extérieure à accéléromètre opposé en charge

Il est à noter que l'opérateur d'énergie TKEO a été appliqué à chaque IMFs obtenu, ce qui nous a permis d'extraire des points pertinents en forme d'enveloppe. Cette méthode permet de créer de nouveaux vecteurs formes caractéristiques des défauts de roulement (état sain, de défaut de bague intérieure, de défaut de bille et de défaut de bague extérieure à accéléromètre centré, orthogonal ou opposé). Ces vecteurs sont composés de quatre vingt points (80), considérés comme des entrées pour l'algorithme de modèle de mélange Gaussien que nous utiliserons pour la classification dans le dernier chapitre de cette thèse.

### 3.4 Conclusion

Dans ce chapitre, nous avons proposé une méthode de prétraitement des données vibratoire permettant d'augmenter significativement les valeurs des amplitudes pertinentes. Ceci afin d'avoir, à chaque type de défaut, une bonne sélection des vecteurs formes caractéristiques. Cette méthode a été appliquée à des signaux vibratoires issus du roulement du moteur. Cinq états de roulement ont été traités à savoir l'état sain, défaut de bague intérieure, défaut de bille et de défaut de bague extérieure à accéléromètre centré, orthogonal ou opposé.

Cette méthode est composée de trois étapes: La première étape utilise la décomposition du mode empirique pour séparer chaque signal vibratoire dans les différentes fonctions du mode intrinsèque, où chaque mode se trouve dans une bande de fréquence spécifique. La seconde étape permet d'extraire, pour chaque mode, les amplitudes instantanées et les fréquences instantanées. Ceci afin d'identifier sa bande de fréquence en calculant le spectre marginal de Hilbert. La troisième étape est la phase d'extraction des caractéristiques. Elle est réalisée par l'utilisation de l'opérateur d'énergie Teager- Kaiser (TKEO). Les résultats finals ont permis d'obtenir des vecteurs caractéristiques composés chacun de quatre vingt points, que nous allons utiliser pour la tâche de classification dans le prochain chapitre.

# **CHAPITRE IV**

## **OPTIMISATION ET CLASSIFICATION AUTOMATIQUE**

## **CHAPITRE IV**

### **OPTIMISATION ET CLASSIFICATION AUTOMATIQUE**

#### **4.1 Introduction**

La classification permet de regrouper les données en certain nombre de régions disjointes afin de découvrir des modèles intéressants. Elle cherche à trouver une partition de l'espace de départ telle que les données appartenant à un même groupe soient plus similaires entre elles qu'avec les données issues d'un autre groupe, elle permet aussi de découvrir les groupes (clusters) d'individus similaires.

Dans ce contexte, nous avons cherché à maximiser la similarité entre les objets de la même classe, et de minimiser la similarité interclasses afin d'obtenir les points les plus pertinents appelés les vecteurs formes caractéristiques. A cet effet, l'optimisation et la classification des ces vecteurs s'effectuent en deux étapes : la première étape consiste à optimiser la taille des vecteurs formes extraits à partir de l'opérateur d'énergie Teager-Kaiser (TKEO). L'optimisation fera appel à l'algorithme d'Optimisation par Essaim Particulaire (PSO ou Particle Swarm Optimization). La seconde étape consiste à la classification automatique des vecteurs optimisés par l'application de l'algorithme du modèle de mélange Gaussien. Ce dernier permettra de rendre la pertinence des attributs et leur sélection ou bien la classification de façon automatique.

## 4.2 Optimisation par essaim particulaire (PSO)

Parmi les méthodes heuristiques, certains algorithmes se basent sur un principe générique adapté pour traiter des problèmes d'optimisation, notamment, l'Optimisation par Essaim Particulaire (OEP, ou PSO en anglais) qui s'inspire de la dynamique d'animaux se déplaçant en groupes compacts (essaims d'abeilles, vols groupés d'oiseaux, bancs de poissons) [Ido 12], [Hag 07] [Bom 11], [Eld 12].

Elle s'adapte mieux aux problèmes d'optimisation à variables continues [Eld 12]. Les particules d'un même essaim communiquent entre elles tout au long de la recherche pour construire une solution au problème posé.

### 4.2.1 Eléments de l'algorithme PSO.

L'appliquer du PSO exige de définir un espace de recherche constitué de particules et une fonction objective à optimiser. Le principe de l'algorithme est de déplacer ces particules afin qu'elles trouvent l'optimum [EID 12], [Bom 11]. Chacune de ces particules est dotée :

- D'une position, c'est-à-dire ses coordonnées dans l'ensemble de définition ;
- D'une vitesse qui permet à la particule de se déplacer. De cette façon, au cours des itérations, chaque particule change de position. Elle évolue en fonction de son meilleur voisin, de sa meilleure position, et de sa position précédente. C'est cette évolution qui permet de tomber sur une particule optimale ;
- D'un voisinage, c'est-à-dire un ensemble de particules qui interagissent directement sur la particule, en particulier celle qui a le meilleur critère.

A tout instant, chaque particule connaît :

- Sa meilleure position visitée. On retient essentiellement la valeur du critère calculée ainsi que ses coordonnées ;
- La position du meilleur voisin de l'essaim qui correspond à l'ordonnancement optimal ;
- La valeur qu'elle donne à la fonction objectif car à chaque itération il faut une comparaison entre la valeur du critère donné par la particule courante et la valeur optimale.

#### 4.2.2 Principe fondamental

L'algorithme de base de la PSO travaille sur une population appelée essaim de solutions possibles, elles-mêmes appelées particules. Ces particules sont placées aléatoirement dans l'espace de recherche de la fonction objectif [Bom 11].

A chaque itération, les particules se déplacent en prenant en compte leur meilleure position (déplacement égoïste) mais aussi la meilleure position de son voisinage (déplacement panurgien). Dans les faits, on calcule la nouvelle vitesse à partir de la formule suivante :

$$V_{K+1} = c_1 * V_K + c_2 * (best_{particule} - position_{particule}) + c_3 * (best_{voisin} - position_{particule}) \quad (4.1)$$

Où :  $V_K$  et  $V_{K+1}$  sont les vitesses de la particule aux itérations  $K$  et  $K+1$ .

$best_{particule}$  : meilleure position de la particule ;

$best_{voisin}$  : meilleure position de son voisinage à l'itération  $K$  ;

$position_{particule}$  : position de la particule à l'itération  $K$

$c_1$ ,  $c_2$ ,  $c_3$  sont des coefficients fixés,  $c_2$  est généré aléatoirement à chaque itération et, en général,  $c_3 = c_2$ .

On peut ensuite déterminer la position suivante de la particule grâce à la vitesse que l'on vient de calculer :

$$X_{K+1} = X_K + V_{K+1} \quad (4.2)$$

Où :  $X_K$  est la position de la particule à l'itération  $K$

On génère  $X_0$  et  $V_0$  au début de notre algorithme.

### 4.2.3 Algorithme de principe

L'algorithme de base est très simple :

---

*On note :*

*$g$  : meilleure position connue de l'essaim ;*

*$f(X)$  : fonction qui calcule le critère de  $X$ .*

*Pour chaque particule :*

*On initialise sa position ;*

*On initialise sa meilleure position  $p$  connue comme étant sa position initiale*

*Si  $f(p) < f(g)$ , on met à jour la meilleure position de l'essaim*

*On initialise la vitesse de la particule.*

*Tant que l'on n'a pas atteint l'itération maximum ou une certaine valeur du critère :*

*Pour chaque particule  $i$  :*

*On tire aléatoire  $c2$  et  $c3$*

*On met à jour la vitesse de la particule suivant la formule vue précédemment*

*On met à jour la position  $x_i$*

*Si  $f(x_i) < f(p_i)$ ,*

*On met à jour la meilleure position de la particule*

*Si  $f(p_i) < f(g)$ ,*

*On met à jour la meilleure position de l'essaim*

*$g$  est l'optimum.*

---

Le principe de l'algorithme peut être plus facilement visualisé grâce à la figure suivante :

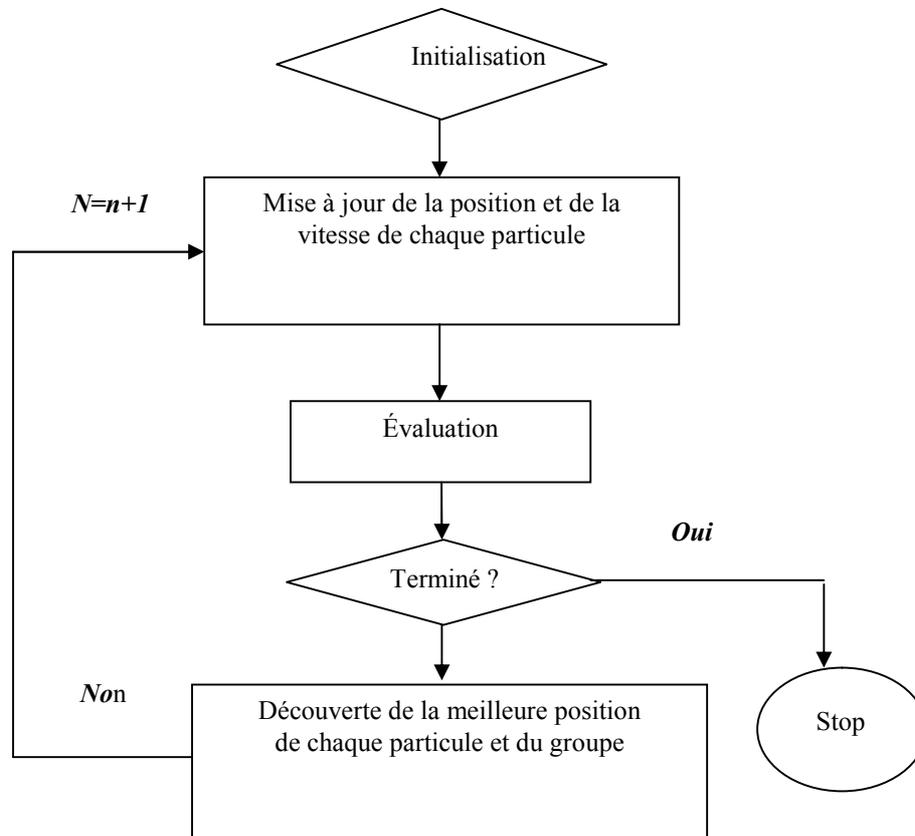


Figure.4.1 Organigramme de la méthode des essaims particulaires [Bom 11]

#### 4.2.4 Etapes de l'algorithme PSO

L'algorithme de base PSO se compose de trois étapes, à savoir [Bou 16]:

- Générer les positions et les vitesses de particules,
- Mise à jour de la vitesse
- Mise à jour de position

Lors de la première étape, Les positions et les vitesses sont données dans un format vectoriel avec l'exposant et indice désignant la particule en fonction du temps. Ici, une particule se réfère à un point dans l'espace de conception qui modifie la position d'un mouvement (itération) à une autre en fonction des mises à jour de vitesse.

Tout d'abord, les positions, et les vitesses, de l'essaim initiale de particules sont générées aléatoirement en utilisant limites supérieures et inférieures sur les valeurs des variables de conception, et, comme exprimé dans les équations 4.3 et 4.4.

$$x_0^i = x_{\min} + rand(x_{\max} - x_{\min}) \quad (4.3)$$

$$v_0^i = \frac{x_{\min} + rand(x_{\max} - x_{\min})}{\Delta t} = \frac{position}{time} \quad (4.4)$$

Dans les équations 4.3 et 4.4 une variable aléatoire uniformément répartie qui peut prendre n'importe quelle valeur entre 0 et 1. Ce processus d'initialisation permet aux particules d'essaims à être distribués au hasard dans l'espace de conception.

La deuxième étape est de mettre à jour les vitesses de toutes les particules au moment  $k+1$  en utilisant les particules objectif ou des valeurs de remise en forme qui sont fonctions des positions actuelles des particules dans l'espace de conception à temps  $k$ . La valeur de la fonction de remise en forme d'une particule qui détermine une particule a la meilleure valeur globale dans l'essaim courant  $P_k^g$ .

Enfin la troisième étape ; détermine également la meilleure position de chaque particule au fil du temps  $P^i$ , c'est à dire dans les coups précédents, actuels et tous. La formule de mise à jour de position utilise ces deux éléments d'information (position, vitesse) pour chaque particule dans l'essaim avec l'effet du mouvement actuel, de fournir une direction de recherche  $v_{k+1}^i$ , pour la prochaine itération  $v_k^i$ . La formule de mise à jour de vitesse comprend certains paramètres aléatoires, représentés par les variables uniformément réparties, pour assurer une bonne couverture de l'espace de conception et éviter d'emprisonner dans optima locaux.

A Cet effet, Les trois valeurs de la nouvelle direction de recherche, à savoir :

- mouvement actuel ;
- mémoire propre particulière ;
- influence d'essaim.

Ces valeurs sont incorporés par une approche de sommation comme indiqué dans l'équation (4.5) avec trois facteurs de pondération, à savoir respectivement, le facteur d'inertie  $w$ , auto facteur de confiance  $c_1$ , et le facteur de confiance essaim  $c_2$ .

$$v_{k+1}^i = wv_k^i + c_1 \text{rand} \left( \frac{P^i - x_k^i}{\Delta t} \right) + c_2 \text{rand} \left( \frac{P_k^g - x_k^i}{\Delta t} \right) \quad (4.5)$$

La position de chaque particule est mise à jour en utilisant son vecteur vitesse comme représenté dans l'équation (4.6) être présenté à la figure.4.2.

$$x_{k+1}^i = x_k^i + v_{k+1}^i \Delta t \quad (4.6)$$

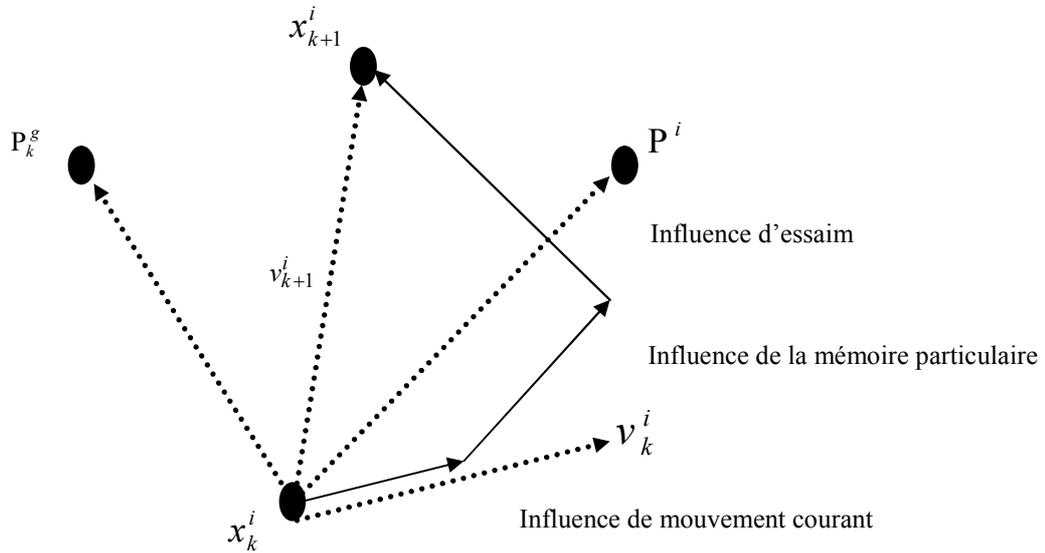


Figure.4.2 Représentation des mises à jour de vitesse et de position par l'optimisation d'essaim particulaire

Les trois étapes de mise à jour de vitesse, mise à jour de position, et des calculs de mise en forme sont répétées jusqu'à ce qu'un critère de convergence souhaité soit atteint. Dans ce travail, les critères d'arrêt de la mis en œuvre de l'algorithme PSO, est que la variation maximale de la meilleure forme physique doit être inférieure à la tolérance spécifiée pour un certain nombre de mouvements, comme indiqué dans l'équation (4.7).

$$\left| f(P_k^g) - f(P_{k-q}^g) \right| \leq \varepsilon \quad q = 1, 2, \dots, S \quad (4.7)$$

#### 4.2.5 Applications de PSO pour l'optimisation de la taille des vecteurs formes

La position des particules ainsi que leur vitesse initiale doivent être initialisés aléatoirement selon une loi uniforme sur  $[0 : 1]$ . Cependant, en ce qui concerne la position des particules, il est préférable d'utiliser un générateur de séquence qui est plus pertinent dans la disposition homogène des particules dans un espace de dimension  $n$ . La taille des vecteurs formes est de 80 points par classe, notre objectif est de réduire au maximum la taille de ces vecteurs afin de faciliter la tâche de classification [Bou 14].

Les variables d'initialisation du PSO sont illustrées dans le tableau suivant :

Table 4. 1 Variables initialisent

$N=6$	la taille de l'essaim
$Maxit = 100$	nombre maximum d'itérations
$c1 = 2$	paramètre cognitive
$C2 = 4 c1$	paramètre sociale
$w_{max} = 0,6$ et $w_{min} = 0,2$	les limites des paramètres
$x_{min} = 12$ , $x_{max} = 20$	les limites des paramètres

Nous avons traité six classes à savoir, état sain, défaut de bague intérieur, défaut de bille et défauts de bague extérieur centrée, orthogonal ou opposé, selon la position de l'accéléromètre.

##### 4.2.5.1 Optimisation par PSO du vecteur forme de roulement sain

L'optimisation par PSO du vecteur forme de roulement sain pour les deux cotés: coté accouplement et coté ventilateur, nous a permis d'obtenir des résultats qui sont présentés dans les figures 4.3 et 4.4

D'après ces figures (4.3, 4.4), on remarque que l'optimisation par PSO du vecteur forme de roulement à l'état sain nous a permis de:

- Réduire la taille du vecteur de roulement à l'état sain passant de 80points à 20points ;
- préserver l'amplitude des points optimisés ;
- suppression sous forme de filtrage des points non désirés.

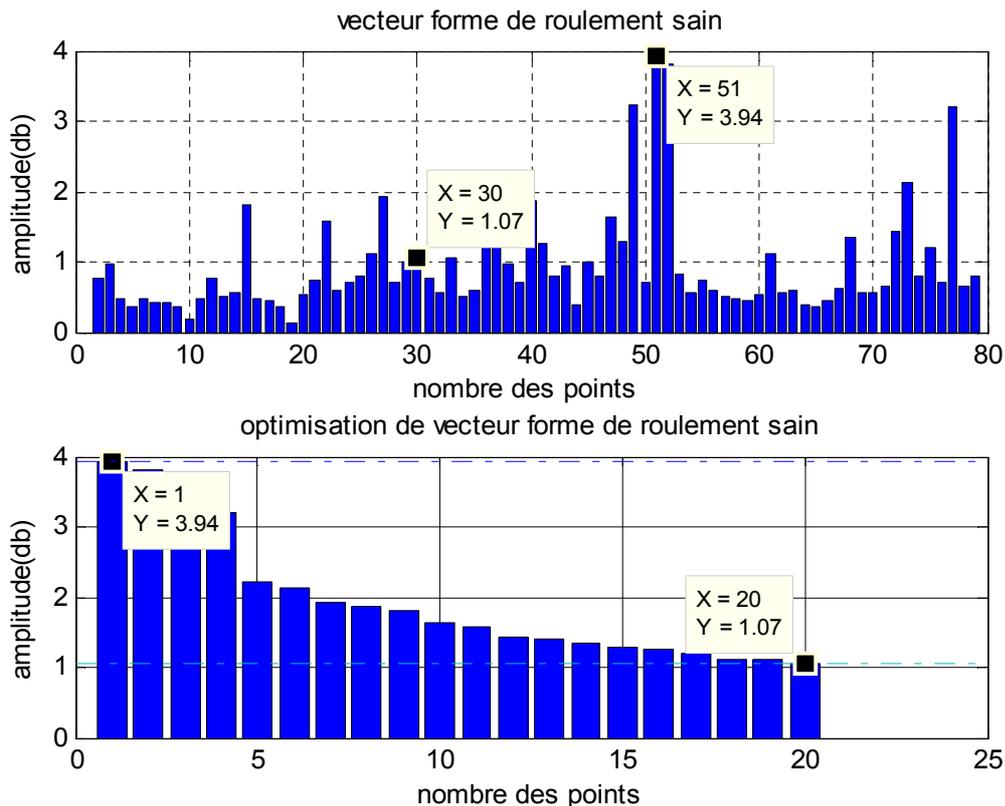


Figure.4.3 vecteur forme de roulement sain (coté accouplement) :  
avant et après optimisation

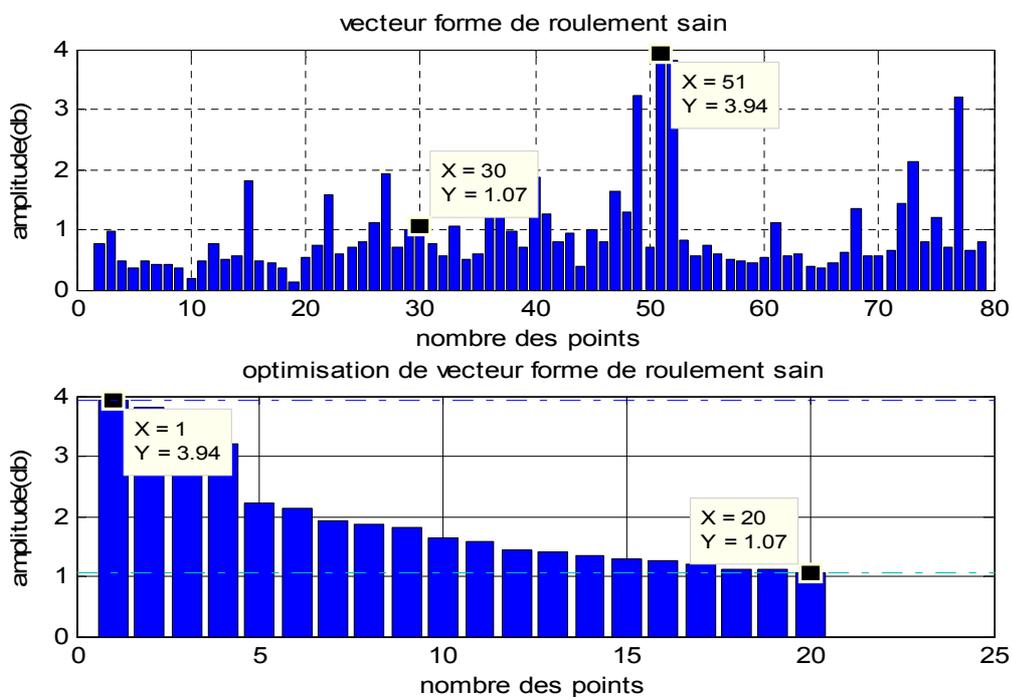


Figure.4.4 vecteur forme de roulement sain (coté ventilateur) :  
avant et après optimisation

### 4.2.5.2 Optimisation par PSO du vecteur forme des défauts de roulement

L'optimisation pas PSO du vecteurs formes de défaut de bague intérieure, défaut bille et défaut de bague extérieure à accéléromètre centrée, orthogonal ou opposé pour les deux cotés: coté accouplement et coté ventilateur, sont présentés dans les figures 4.5 à 4.14 avant et après optimisation.

#### A. Optimisation de vecteur forme du défaut de bague intérieure

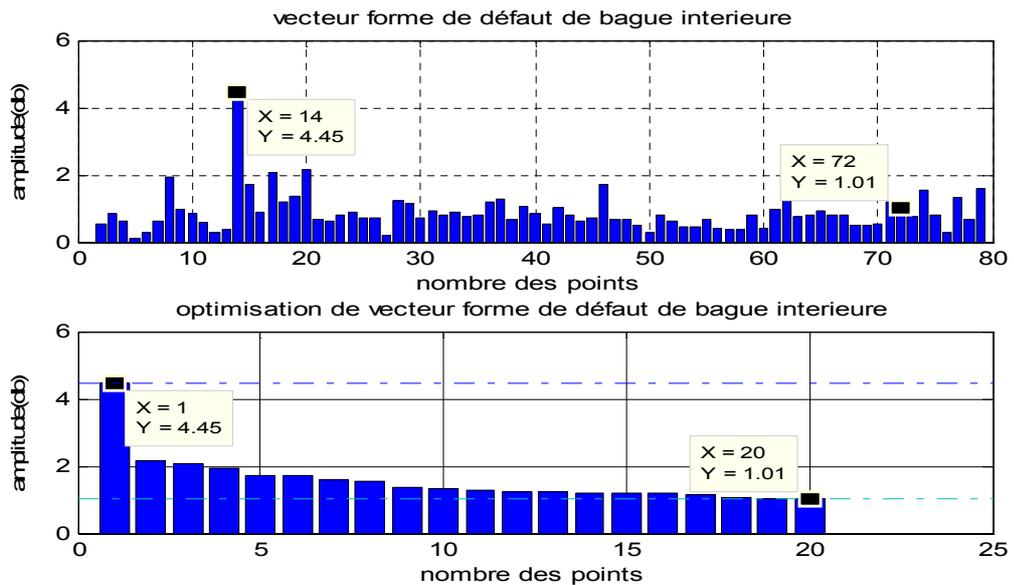


Figure.4.5 Vecteur forme du défaut de bague intérieure (coté accouplement) : avant et après optimisation

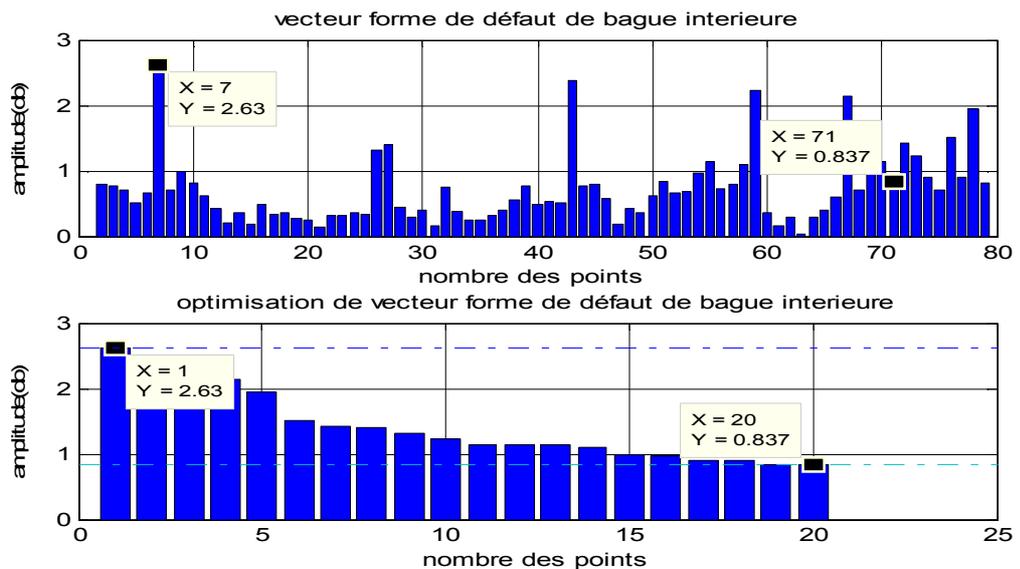


Figure.4.6 Vecteur forme du défaut de bague intérieure (coté ventilateur) : avant et après optimisation

**B. Optimisation de vecteur forme du défaut de bille**

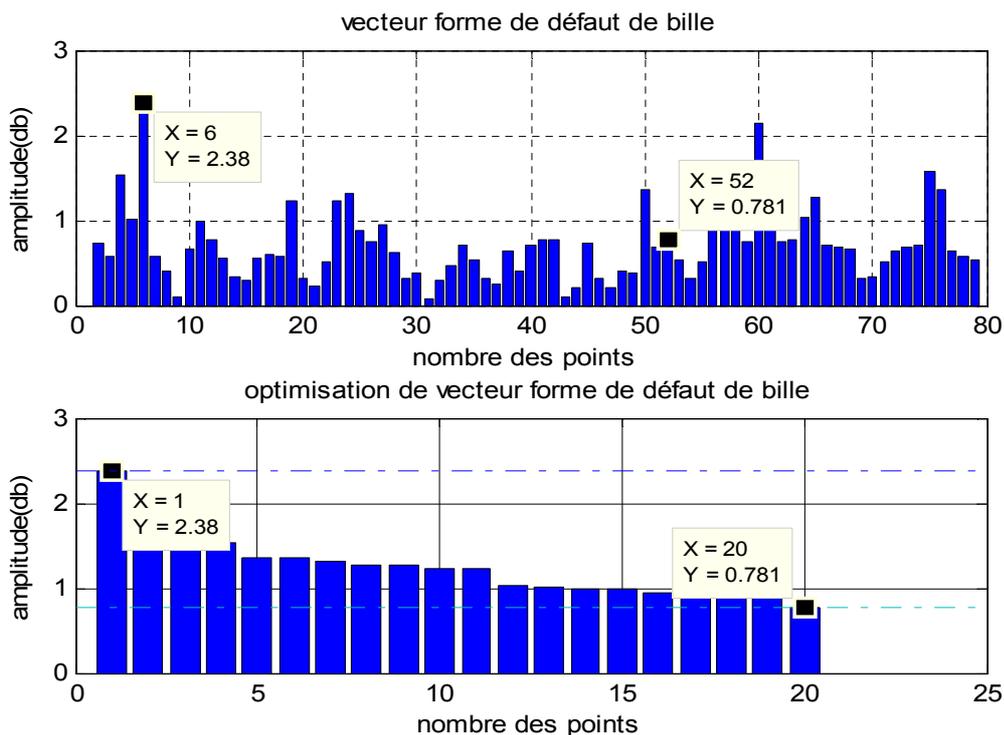


Figure.4.7 Vecteur forme du défaut de bille (coté accouplement) : avant et après optimisation

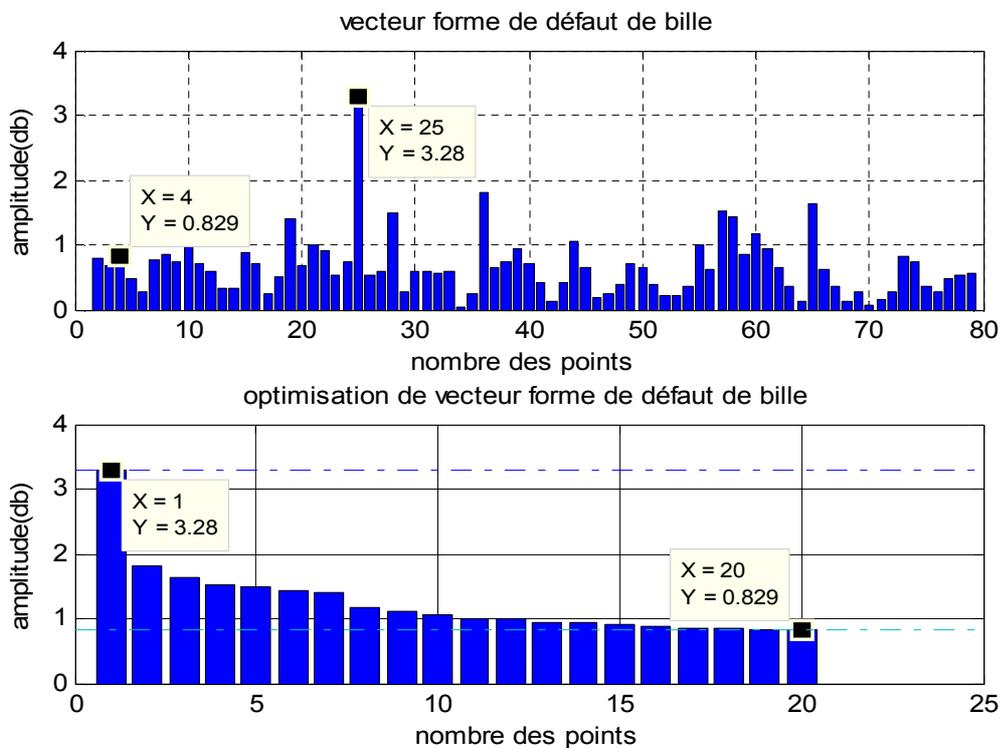


Figure.4.8 Vecteur forme du défaut de bille (coté ventilateur) : avant et après optimisation

C. Optimisation de vecteur forme du défaut de bague extérieure à accéléromètre centré

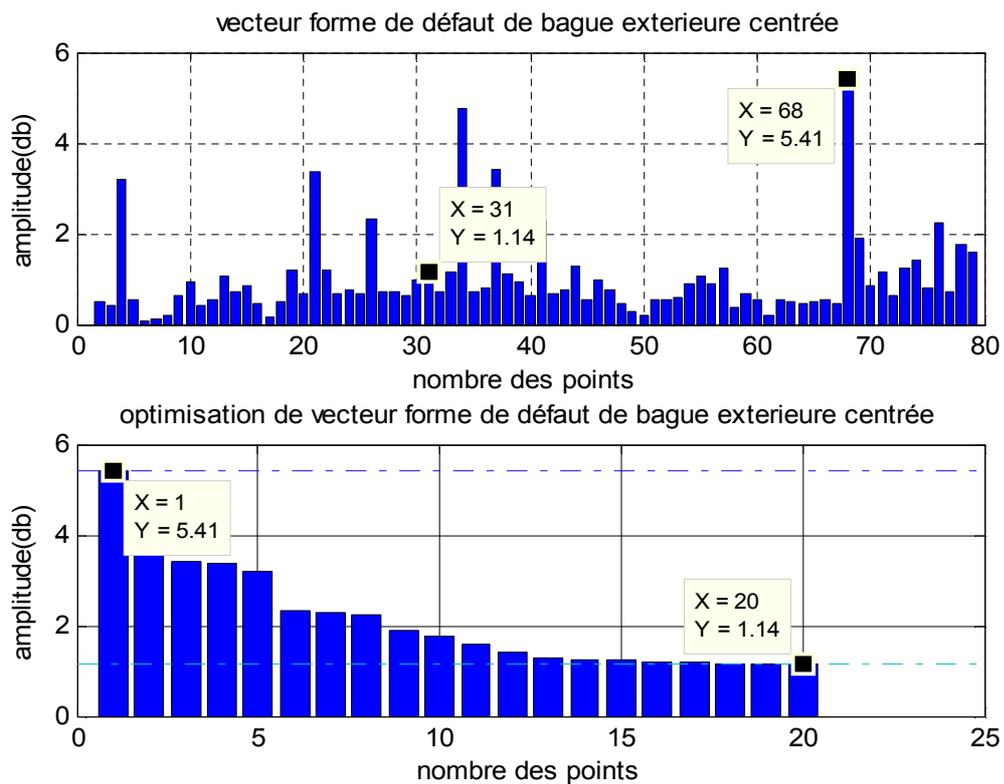


Figure.4.9 Vecteur forme du défaut de bague extérieure à accéléromètre centré (coté accouplement) : avant et après optimisation

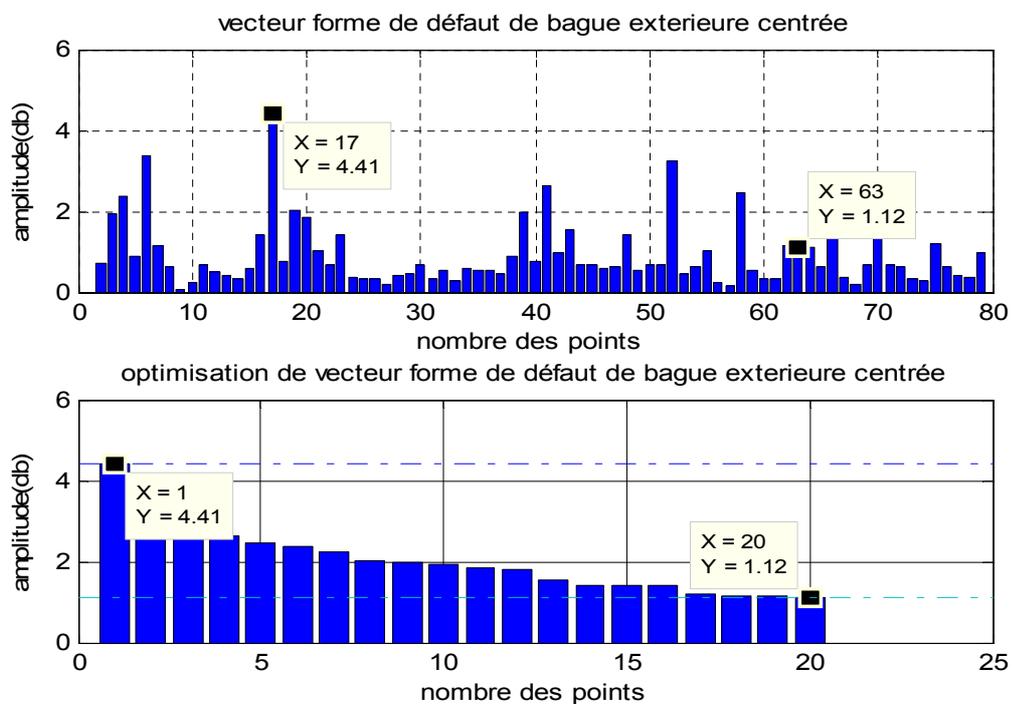


Figure.4.10 Vecteur forme du défaut de bague extérieure à accéléromètre centré (coté ventilateur) : avant et après optimisation

**D. Optimisation de vecteur forme du défaut de bague extérieure à accéléromètre orthogonal**

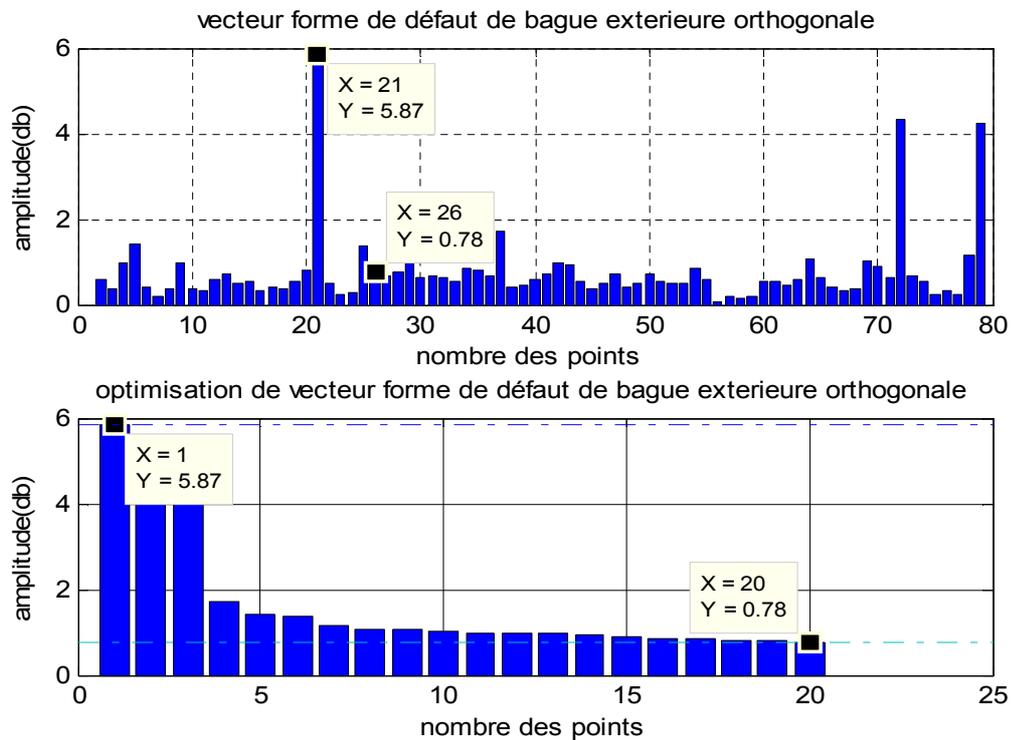


Figure.4.11 Vecteur forme du défaut de bague extérieure à accéléromètre orthogonal (coté accouplement) : avant et après optimisation

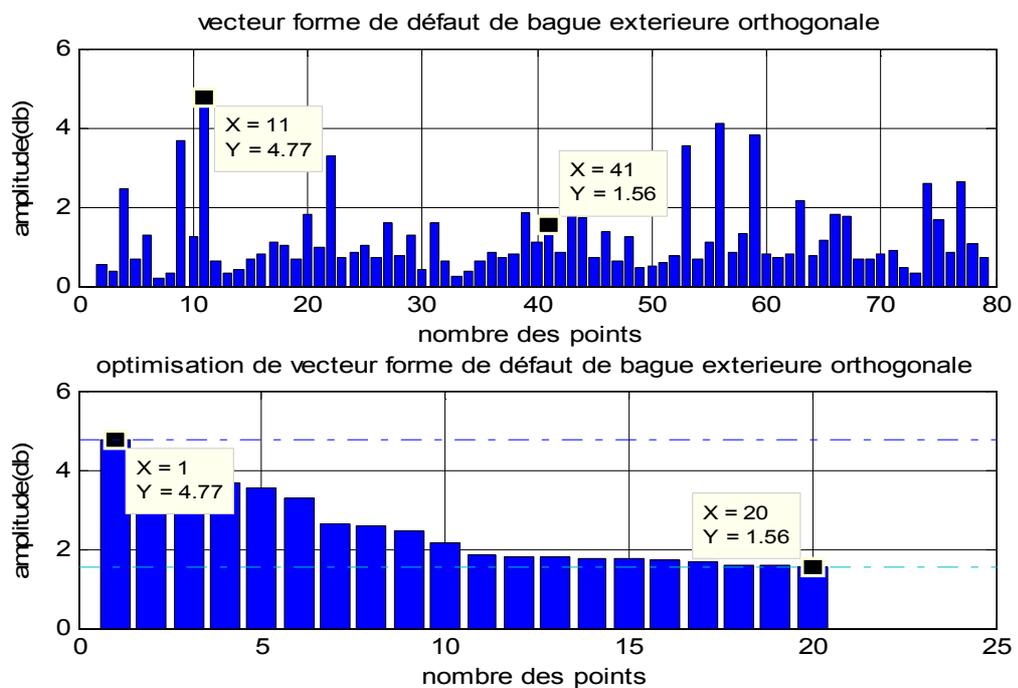


Figure 4.12 Vecteur forme du défaut de bague extérieure à accéléromètre orthogonal (coté ventilateur) : avant et après optimisation

**E. Optimisation de vecteur forme du défaut de bague extérieure à accéléromètre opposé**

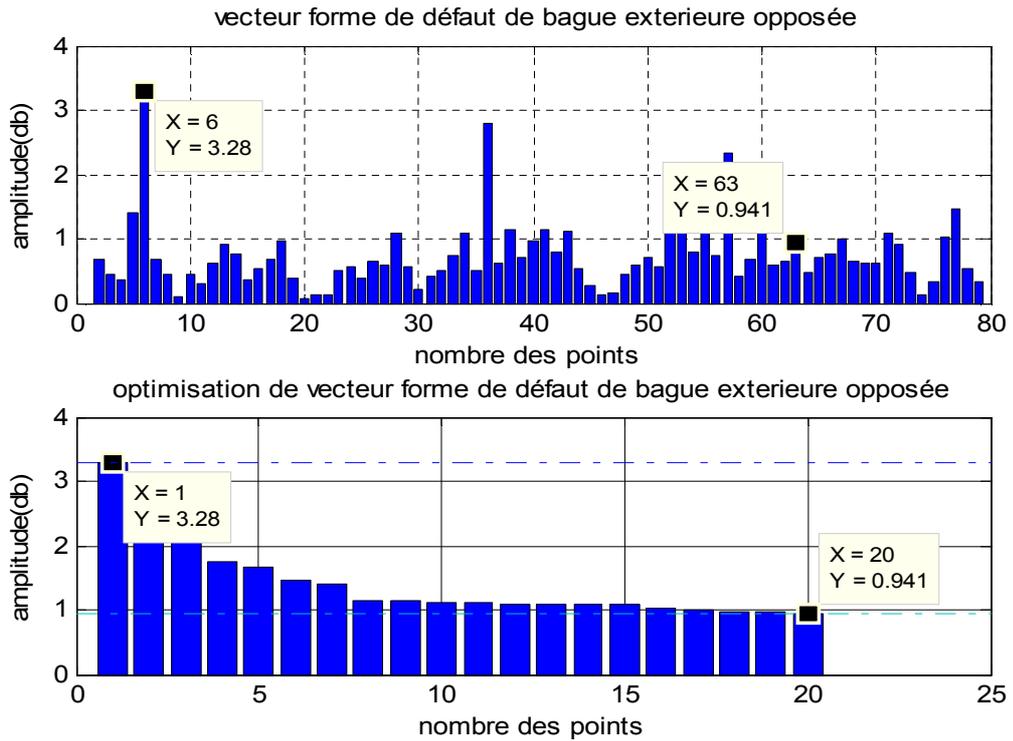


Figure.4.13 Vecteur forme du défaut de bague extérieure à accéléromètre opposé (coté accouplement) : avant et après optimisation

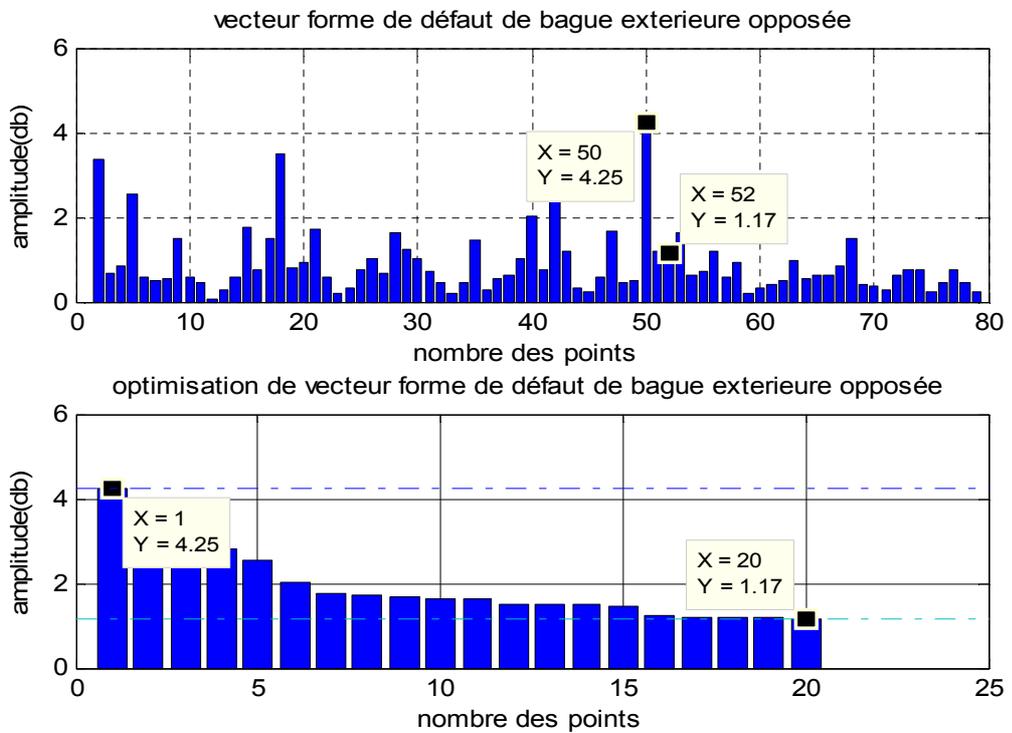


Figure.4.14 Vecteur forme du défaut de bague extérieure à accéléromètre opposé (coté ventilateur) : avant et après optimisation

Des les figures ci-dessus, on remarque que l'optimisation par PSO, dans les différentes cas des défauts de roulement, nous a permis de:

- Réduire la taille des vecteurs formes caractéristiques, passant ainsi de 80 points à 20 points ;
- préserver l'amplitude des points optimisés ;
- suppression sous forme de filtrage des points non désirés.

### **4.3 Classification automatique (non supervisée)**

L'objectif de la classification non supervisée, appelée aussi classification automatique, est de partitionner l'ensemble des  $n$  objets de  $x$  en  $g$  classes. Cet objectif n'est pas seulement formel. Il faut comprendre que l'intérêt sous-jacent de la démarche de classification est d'aider le praticien à analyser des données. Le regroupement en classes est pour lui une façon de synthétiser pour isoler l'information pertinente.

En effet, il est difficile pour un humain d'appréhender directement cette information en présence de données parfois nombreuses, éventuellement d'écrites par de multiples dimensions dans des espaces eux-mêmes un peu complexes. La classification automatique est donc généralement une procédure mathématique qui propose une ou plusieurs partitions parmi les multitudes de possibilités offertes a priori.

Nous avons fait appel pour la classification automatique les mélanges gaussiens qui sont les plus couramment utilisés en la matière. Ils correspondent souvent à la loi de distribution des variables observées. De plus, les mélanges gaussiens sont relativement bien maîtrisés et il existe des procédures efficaces pour les manipuler [Ale 11], [Pek 04].

L'algorithme proposé, inspiré fortement de l'algorithme EM (espérance-maximisation, en anglais expectation-maximization algorithm) pour l'estimation de paramètres, peut être appliqué dans plusieurs contextes où l'information sur le modèle de génération des données n'est que partiellement disponible.

### 4.3.1 Éléments de la classification automatique

La Classification automatique doit être constituée des éléments suivants :

1. Échantillon : Sélectionner l'ensemble d'objets à classer. Un échantillon ou une population ;
2. Données : Mesurer les caractéristiques des objets et construire une matrice d'évaluation ;
3. Dissimilarité : Calculer des dissimilarité entre toutes les paires d'objets ;
4. Contraintes : Choisir le type de classification désirée. Spécifier les contraintes relatives aux classes, par exemple la taille maximale des classes pour certains problèmes ;
5. Critère : Choisir le critère qui permet d'exprimer l'homogénéité et/ou la séparation des classes ;
6. Algorithme: Choisir ou développer un algorithme pour le problème défini aux étapes 4 et 5 ;
7. Calcul: Appliquer l'algorithme choisi pour obtenir les différentes classes ;
8. Interprétation : Appliquer des tests formels ou informels pour sélectionner les meilleures classifications obtenues dans l'étape 7. Décrire les classes par leurs listes d'objets et par des rapports de statistique descriptive. Procéder à une interprétation contextuelle des résultats.

Les étapes 4 et 5 définissent le problème de classification comme un programme mathématique. Les étapes 1, 2, 3 et 8 correspondent à un point de vue statistique de la classification.

Au-delà de l'utilité d'appliquer un algorithme de clustering et du cœur constituant celui-ci, figure le problème de l'évaluation. Pouvoir déterminer l'apport d'un algorithme de clustering particulier est un problème en soi.

Un cadre favorable d'évaluation se présente lorsque l'étiquette des individus est connue. lorsque l'on a à disposition des groupes cibles appelés classes, à retrouver. L'évaluation est alors dans ce contexte une vérification de la ressemblance entre les groupes produits et les classes données [Ale 11].

### 4.3.2 Modèle de mélange gaussien

Un modèle de mélange gaussien (GMM) est un modèle statistique modélisant une distribution de variables aléatoires sous la forme d'une somme de gaussiennes de formes et de tailles variées. Les paramètres à optimiser (selon un critère de maximum de vraisemblance) sont les caractéristiques de ces gaussiennes, telles que leur variance, leur moyenne et leur amplitude. Cette optimisation est le plus souvent faite au moyen de l'algorithme EM (Expectation-Maximisation).

Dans le cas de données continues, on prend habituellement le modèle Gaussien. Dans ce cas, chaque objet  $X_i$  est supposé provenir indépendamment des autres, d'un mélange de densités [Rou 04] :

$$\mathcal{G}(X_i; \theta) = \sum_{k=1}^s p_k \mathcal{G}_k(X_i; g_k; \Sigma_k) \quad (4.8)$$

Où :  $\mathcal{G}_k$  représente la densité Gaussienne de dimension  $d$ , de moyenne  $g_k$  et de variance  $\Sigma_k$ ,

$\theta = (p_1, \dots, p_{s-1}, g_1, \dots, g_s, \Sigma_1, \dots, \Sigma_s)$  est le vecteur des paramètres du mélange.

Ainsi, les classes associées aux composants du mélange sont ellipsoïdales, centrées sur la moyenne  $g_k$  et la matrice de variance  $\Sigma_k$  détermine les caractéristiques géométriques.

$$\mathcal{G}_k(X_i; g_k; \Sigma_k) = (2\pi)^{-d/2} |\Sigma_k|^{-1/2} \exp\left(-\frac{1}{2}(X_i - g_k)' \Sigma_k^{-1} (X_i - g_k)\right) \quad (4.9)$$

Dans le cadre de classification, cette approche peut être vue comme une méthode permettant d'obtenir explicitement des classes peu imbriquées. Le problème de classification initial se ramène donc à estimer la partition  $z_i$  qui a permis la réalisation de l'échantillon  $X$  de façon suivant une loi mélange  $p$ . Ce pose alors maintenant le choix des composantes  $p_k$  associées.

Ce choix dépend d'une part de la nature des données. D'autre part, c'est aussi l'occasion de fournir au praticien une modélisation interprétable et réduite de la classe. Le cadre paramétrique atteint naturellement ces deux objectifs.

En effet, pour les données continues, le choix d'une loi multi-normale est particulièrement informatif pour l'utilisateur : la moyenne  $u_k$  définit la position centrale de la classe  $k$  et  $\Sigma_k$  est la matrice de variance informe sur sa dispersion autour de ce centre. On peut ainsi facilement en déduire une zone (ellipsoïde) de confiance autour du centre. Donc, en peu de paramètres, la classe est résumée.

Pour les données catégorielles, le modèle des classes latentes décrit explicitement les classes par la probabilité  $\alpha_{kjh}$  de chacune des modalités, variable par variable. Dans tous les cas, les proportions  $\pi_k$  apportent de plus une information directement interprétable : l'effectif relatif de chaque classe.

#### 4.3.2.1 Décomposition de la matrice des variances

On peut considérer un paramétrage de la matrice des variances des composants du mélange consistant à exprimer  $\Sigma_k$  en fonction de sa décomposition en valeurs propres [Rou 04] :

$$\Sigma_k = \lambda_k D_k A_k D_k' \quad (4.10)$$

Où :  $\lambda_k = |\Sigma_k|^{1/d}$

$\lambda_k$  est un paramètre détermine le volume de la classe  $k$ ,  $D_k$  son orientation et  $A_k$  sa forme.

$D_k$  est la matrice des vecteurs propres de  $\Sigma_k$  ;

$A_k$  est une matrice diagonale telle que  $|A_k| = 1$ ,

Avec les valeurs propres normalisées de  $\Sigma_k$  sur la diagonale, de façon décroissante. En imposant certaines contraintes sur les volumes, les orientations ou les formes nous obtenons des modèles parcimonieux plus simples à interpréter qui peuvent être appropriés pour décrire diverses situations.

### ❖ *La famille générale*

Dans un premier temps, nous autorisons les volumes, les formes et les orientations à varier entre les classes. Les variations sur les paramètres  $\lambda_k$ ,  $D_k$  et  $A_k$  ( $1 \leq k \leq s$ ) conduisent à 8 modèles génériques.

Par exemple, nous pouvons supposer des volumes  $\lambda_k$  différents et garder les formes et les orientations égales en posant  $A_k = A$  (non connu) et  $D_k = D$  (non connu aussi), pour  $k = 1, \dots, s$ . Nous notons ce modèle  $[\lambda_k D A D']$ .

Avec cette notation, utiliser le modèle  $[\lambda D_k A D_k']$  signifie considérer un modèle de mélange avec des volumes égaux, des formes égales, et des orientations différentes.

### ❖ *La famille diagonale*

Une autre famille intéressante est celle où les matrices  $\Sigma_k$  sont diagonales. Dans la paramétrisation (4.10), cela signifie que les matrices d'orientation sont des matrices de permutation.

Nous écrivons alors  $\Sigma_k = \lambda_k B_k$ , où  $B_k$  est une matrice diagonale. Cette paramétrisation particulière nous donne quatre modèles :  $[\lambda B]$ ,  $[\lambda_k B]$ ,  $[\lambda B_k]$  et  $[\lambda_k B_k]$ .

### ❖ *La famille sphérique*

La dernière famille de modèles consiste à supposer des formes sphériques, où l'on a  $A_k = I$ ,  $I$  étant la matrice Identité. Dans de tel cas, deux modèles parcimonieux sont en compétition :  $[\lambda I]$  et  $[\lambda_k I]$ . Finalement, nous avons donc 14 modèles différents.

Le principal avantage de la décomposition en valeurs propres de la matrice de variance est l'interprétation simplifiée des modèles.

#### 4.3.2.2 Estimation des paramètres

Dans le cadre de la classification, le problème à résoudre consiste à retrouver pour chaque objet sa population d'origine la plus probable en fonction du vecteur d'observation qui le caractérise. Pour cela, il faut estimer préalablement les paramètres qui caractérisent la distribution des variables dans chacune des  $s$  populations [Bie 02].

Les principales techniques d'estimation utilisées pour estimer les paramètres d'un modèle de mélange sont [Rou 04]:

- techniques d'estimation des moments
- techniques d'estimation du maximum de vraisemblance

Ce dernier est la technique la plus largement utilisée pour les problèmes d'estimation de densité de mélange. Elle consiste à résoudre itérativement les équations de vraisemblance et les algorithmes les plus efficaces sont de type EM (Estimation - Maximisation) de Dempster. L'algorithme EM est composé de deux étapes.

Dans la première étape dite Estimation, on calcule la quantité  $Q(\theta|\theta^{(q)})$  et dans la seconde dite Maximisation, on maximise cette quantité. On répète ce procédé jusqu'à la convergence qu'on décrira ultérieurement.

Soit  $X = \{X_1, \dots, X_N\}$  l'ensemble des  $N$  vecteurs de taille  $M$ . Chaque vecteur  $X_i$  peut être considéré comme une variable aléatoire de densité de probabilité:

$$f(X_i|\Lambda) = \sum_{k=1}^K p_k h(X_i|\mu_k, \Sigma_k) \quad (4.11)$$

Où :  $h(\cdot|\lambda_k)$  est la distribution gaussienne associée à la classe  $k$  paramétrée par  $\lambda_k = (\mu_k, \Sigma_k)$

$\mu_k$  : La moyenne de la distribution

$\Sigma_k$  : La matrice de covariance.

$p_k$  : Représente le poids de la distribution  $h$  associée dans le mélange

tel que  $0 < p_k < 1, \forall k$  et  $p_1 + p_2 + \dots + p_K = 1$ .

$\Lambda = (p_1, \dots, p_K, \lambda_1, \dots, \lambda_K)$  représente le vecteur des paramètres à estimer.

Chaque vecteur  $X_i$  est associé à une partition  $z_i = \{z_{i1} + z_{i2} + \dots + z_{iK}\}$  tel que  $z_{iK} = 1$  si  $X_i$  est associé à la  $k^{\text{ième}}$  distribution (la classe  $k$ ).

Dans notre cas, les partitions  $z_i$  sont inconnues, ce qui revient à résoudre un problème d'estimation de densité où  $\Lambda$  doit être optimisé de sorte à maximiser la log-vraisemblance :

$$L(\Lambda|X_1, \dots, X_N) = \sum_{i=1}^N \ln \left( \sum_{k=1}^K p_k h(X_i|\lambda_k) \right) \quad (4.12)$$

Comme nous l'avons mentionné précédemment, cette optimisation peut être réalisée au moyen de l'algorithme EM. A partir d'un ensemble initial de paramètres  $\Lambda^0$  choisi arbitrairement, on alterne itérativement entre une étape de calcul de l'espérance et une étape de maximisation.

L'algorithme CEM, une variante de l'algorithme EM spécifiquement dédiée à la classification, ajoute une étape d'étiquetage entre le calcul des probabilités conditionnelles (E) et la maximisation de la log-vraisemblance (M).

En pratique,  $L(\theta; X, z)$  est optimisée par l'algorithme CEM [Cel 92], sorte de version classification de l'algorithme EM. Partant d'un paramètre initial  $\theta^-$  arbitraire, l'algorithme CEM itère sur les étapes suivantes [Bie 06] :

- étape E (espérance): calculer  $t_{ik}$  comme EM;
- étape C (classification): calculer la partition  $z^+ = MAP(t^+)$ ;
- étape M (maximisation): calculer  $\theta^+ = \arg \max_{\theta} L(\theta; X, z^+)$ .

#### 4.3.2.2.1 Étape estimation

Lors de cette première étape, les probabilités conditionnelles relatives à chaque classe sont calculées de la façon suivante :

$$t_{ik}^q = t_k^q(X_i | \Lambda^{q-1}) = \frac{p_k^{q-1} h(X_i | \lambda_k^{q-1})}{\sum_{l=1}^K p_l^{q-1} h(X_i | \lambda_l^{q-1})} \quad (4.13)$$

Où  $q$  est l'itération courante. Puis l'ensemble de paramètres de l'itération suivante  $\Lambda^q$  est calculé par maximisation.

On remarque, qu'au delà d'une estimation  $\hat{z}$  de la partition, le modèle fournit aussi deux informations supplémentaires intéressantes pour le praticien :

- Une estimation  $\hat{\vartheta}$  des paramètres dont nous savons maintenant toute l'importance pour aider à l'interprétation des classes;
- Une estimation  $\hat{t}$  des probabilités conditionnelles d'appartenance aux classes, ce qui permet d'évaluer le risque de classement de chaque individu.

#### 4.3.2.2.2 Étape Maximisation

Dans cette étape, l'ensemble de paramètres  $\Lambda^q$  de l'itération suivante est calculée par :

$$F(\Lambda | X_1, \dots, X_N, t^q) = \sum_{i=1}^N \sum_{k=1}^K t_{ik}^q \ln \left( p_k^{q-1} h \left( X_i | \lambda_k^{q-1} \right) \right) \quad (4.14)$$

Avec :  $t^q = (t_{ik}^q), i \in \{1, \dots, N\}, k \in \{1, \dots, K\}$

$p_k$  est ensuite mis à jour :

$$p_k^q = \frac{\sum_{i=1}^N t_{ik}^q}{N} \quad (4.15)$$

La mise à jour des  $\lambda_k$  dépend quant à elle de la distribution que l'on a choisi pour  $h(\cdot | \lambda_k)$ . Dans notre cas, une distribution gaussienne de paramètres  $\lambda_k = (\mu_k, \Sigma_k)$  aura pour expression :

$$h \left( X_i | \mu_k, \Sigma_k \right) = (2\pi)^{-d/2} |\Sigma_k|^{-1/2} \exp \left\{ -\frac{1}{2} (X_i - \mu_k)^T \Sigma_k^{-1} (X_i - \mu_k) \right\} \quad (4.16)$$

La classe associée à une telle distribution est ellipsoïdale, centrée sur la moyenne  $\mu_k$  et ses caractéristiques géométriques sont reflétées par sa matrice de covariance  $\Sigma_k$  [Rou 04].

Afin de simplifier le modèle, nous considérons que  $\Sigma_k$  est diagonal, ce qui nous permet de diminuer de façon drastique le nombre de paramètres du modèle. A chaque maximisation, la moyenne  $\mu_k$  et la matrice de covariance  $\Sigma_k$  sont ainsi mises à jour de la façon suivante:

$$\mu_k^q = \frac{\sum_{i=1}^N t_{ik}^q X_i}{\sum_{l=1}^N t_{il}^q} \quad (4.17)$$

Et :

$$\Sigma_k^q = \frac{\text{diag}(W_k^q)}{\sum_{l=1}^N t_{il}^q} \quad (4.18)$$

Telle que :

$$W_k^q = \sum_{i=1}^N t_{ik}^q (X_i - \mu_k^q)(X_i - \mu_k^q)^T \quad (4.19)$$

Soit  $z_i = (z_{ik})_{k \in \{1, \dots, K\}}$  la partition associée au vecteur  $X_i$ , tel que  $z_{ik} = 1$  si  $X_i$  appartient à la classe  $K$  et  $z_{ik} = 0$  sinon. Une fois l'itération finale  $f$  terminée, les  $z_i$  sont calculés par l'intermédiaire d'un algorithme type Maximum A Posteriori:

$$z_{ik} = \begin{cases} 1 & \text{si } k = \underset{l=1, \dots, K}{\operatorname{arg\,max}} \left( t_{il}^q \right) \\ 0 & \text{sinon} \end{cases} \quad (4.20)$$

#### 4.3.2.2.3 Étape de classification

Lors de cette étape, une classification intermédiaire est réalisée en associant chaque vecteur  $X_i$ , à la classe maximisant la probabilité conditionnelle. Une partition  $P^q = (P_1^q, \dots, P_K^q)$  est ainsi créée. Dans l'étape suivante, la log-vraisemblance à maximiser n'est plus celle de l'équation (4.14) mais la suivante :

$$CF(\Lambda | X_1, \dots, X_N, t^q) = \sum_{i=1}^N \sum_{k=1}^K z_{ik}^q \ln \left( p_k^{q-1} h \left( X_i | \lambda_k^{q-1} \right) \right) \quad (4.21)$$

De même, la mise à jour des paramètres est modifiée de sorte que :

$$p_k^q = \frac{|P_k^q|}{N} \quad (4.22)$$

$$\mu_k^q = \frac{\sum_{i=1}^N z_{ik}^q X_i}{|P_k^q|} \quad (4.23)$$

Et,

$$\Sigma_k^q = \frac{\text{diag}(W_k^q)}{|P_k^q|} \quad (4.24)$$

Telle que :

$$W_k^q = \sum_{i=1}^N z_{ik}^q (X_i - \mu_k^q)(X_i - \mu_k^q)^T \quad (4.25)$$

Contrairement à l'algorithme EM, la variante CEM converge en un nombre fini d'itérations. Elle ne converge cependant pas vers un maximum local de la vraisemblance  $\Lambda$  et peut ainsi résulter sur des paramètres suboptimaux, surtout lorsque les différents éléments du mélange se superposent ou que la proportion de chacun dans le mélange est trop disparate.

### 4.3.3. Application à la classification des vecteurs formes

Nous disposons de six classes et chaque classe est réalisée sur deux cotés: coté accouplement et coté ventilateur. Les six classes en question concernent l'état sain, défaut de bague intérieure, défaut de bille et défauts de bague extérieure centrée, orthogonale et opposée (selon les positions de l'accéléromètre).

L'application de l'algorithme de classification du modèle de mélange gaussien (GMM) est effectuée en trois phases principales :

La première phase consiste à l'initialisation de l'ensemble des paramètres du modèle et le nombre de groupes (classes) ainsi que le nombre des points dans chaque groupe.

Dans cette phase on subdivise chaque classe en deux collections et puis on combine chaque point de la première collection par un autre point correspondant de la seconde collection.

Le vecteur aléatoire est choisi pour avoir une distribution formée par les distributions de mélange gaussiennes bi-variables. Les paramètres du modèle GMM (équation 4.11) initialisés et estimés sont :

$u_k$  : moyenne de la distribution ;

$p_k$  : poids de la distribution  $h$  associée dans le mélange ;

$R$  : matrice de covariance.

Dans la deuxième phase l'estimation par CEM a été faite comme suite : pour chaque itération (10 itérations) de CEM la log-vraisemblance accroit. Il converge en outre vers un point stationnaire de la vraisemblance qui peut être typiquement le maximum global, un maximum local ou un point résidu. On peut faire plusieurs essais en changeant les paramètres initiaux pour obtenir du maximum global, puis on ne retient que la plus grande vraisemblance de la solution donnée.

Dans la troisième et dernière phase, on cherche à calculer le taux de classification. Celui-ci est déterminé par le rapport des sommes des points bien classés sur la somme totale de nombre des points dans la même classe:

$$Tc = \frac{N_b}{N_t} \quad (4.26)$$

où

$$Pc = \frac{N_b}{N_t} * 100 \quad (4.27)$$

Avec ,

$Tc$  : taux de classification ;

$N_b$  : nombre des points bien classés ;

$N_t$  : nombre total des points dans une classe.

Les tableaux 4.2, 4.3 illustrés les valeurs initiales et estimées des paramètres du modèle de mélange gaussien utilisé pour l'entraînement à coté accouplement, ainsi que le taux de classification.

Tableau 4.2 : Valeurs initiales et estimées des paramètres de modèle GMM ainsi que le taux de classification (Coté accouplement)

classes	Nombre des points	Nombre d'itération	paramètres	Valeurs initiales	valeurs estimées	Taux de classification
classe1 (état sain)	20/2	10	p1	0.2000	0.1833	10/10
			u1	[0.9100 1.2000]	[0.9081 1.2000]	100%
			R1	[1.4329 0.0025 0.0025 0.0056]	[1.4329 0.0914 0.1000 0.0339]	
Classe 2 (défaut de bague intérieure)	20/2	10	p2	0.1500	0.1333	8/10
			u2	[1.2100 1.4000]	[1.1980 1.338]	80%
			R2	[1.2750 0.0003 0.0003 0.0040]	[1.3595 0.0870 0.0032 0.0062]	
Classe 3 (défaut de bille)	20/2	10	p3	0.2000	0.2000	10/10
			u3	[1.4500 1.4900]	[1.4480 1.4880]	100%
			R3	[1.3595 0.0032 0.0032 0.0062]	[1.3595 0.0870 0.0998 0.0333]	
Classe 4 (défaut de bague extérieure centrée)	20/2	10	p4	0.1500	0.1333	9/10
			u4	[1.57 1.59]	[1.567 1.589]	90%
			R4	[1.2884 0.0015 0.0015 0.0060]	[1.2884 0.1006 0.1055 0.0339]	
Classe 5 (défaut de bague extérieure orthogonale)	20/2	10	p5	0.17	0.1667	10/10
			u5	[1.75 1.79]	[1.744 1.789]	100%
			R5	[1.4452 0.0009 0.0009 0.0044]	[1.4452 0.1033 0.1341 0.0342]	
Classe 6 : (défauts de bague extérieure opposée)	20/2	10	p5	0.2	0.1933	10/10
			u5	[1.82 1.97]	[1.819 1.966]	100%
			R5	[1.2535 -0.0432 -0.0432 0.0517]	[1.2535 0.1544 0.1447 0.0339]	

Tableau 4.3 : Valeurs initiales et estimées des paramètres de modèle GMM ainsi que le taux de classification (coté ventilateur)

classes	Nombre des points	Nombre d'itération	paramètres	Valeurs initiales	valeurs estimées	Taux de classification
classe1 (état sain)	20/2	10	p1	0.2000	0.2000	10/10
			u1	[1.20 1.45]	[2.7499 1.2321]	100%
			R1	[1.1746 0.0059 0.0059 0.0020]	[0.8598 0.2477 0.2477 0.0940]	
classe2 (défaut de bague intérieur)	20/2	10	p2	0.1833	0.1833	10/10
			u2	[1.47 1.55]	[2.4269 1.2719]	100%
			R2	[0.8921 -0.0015 -0.0015 0.0081]	[0.8598 0.2477 0.2477 0.0940]	
Classe 3 (défaut de bille)	20/2	10	p3	0.1333	0.1333	9/10
			u3	[1.64 1.68]	[2.4279 1.2731]	90%
			R3	[0.8958 -0.0010 -0.0010 0.0031]	[0.8598 0.2477 0.2477 0.0940]	
Classe 4 (défauts de bague extérieure centrée)	20/2	10	p4	0.1333	0.1333	8/10
			u4	[1.87 1.89]	[2.3725 1.2743]	80%
			R4	[0.8186 -0.0079 -0.0079 0.0222]	[0.8598 0.2477 0.2477 0.0940]	
Classe 5 (défauts de bague extérieure orthogonale)	20/2	10	p5	0.1833	0.1833	10/10
			u5	[1.94 1.99]	[2.3445 1.2849]	100%
			R5	[0.7658 -0.0351 -0.0351 0.0318]	[0.8598 0.2477 0.2477 0.0940]	
Classe 6 (défauts de bague extérieure opposée)	20/2	10	p5	0.1667	0.1667	10/10
			u5	[2.01 2.19]	[2.6237 1.1901]	100%
			R5	[1.0429 0.0101 0.0101 0.0081]	[0.8598 0.2477 0.2477 0.0940]	

La figure 4.15 illustre les points des six classes optimisés. Un ensemble de six (06) classe à raison de 20points par classe, la somme est de  $6 \times 20 = 120$  points. Cette représentation bidimensionnelle est réalisée dans le premier cas du coté accouplement.

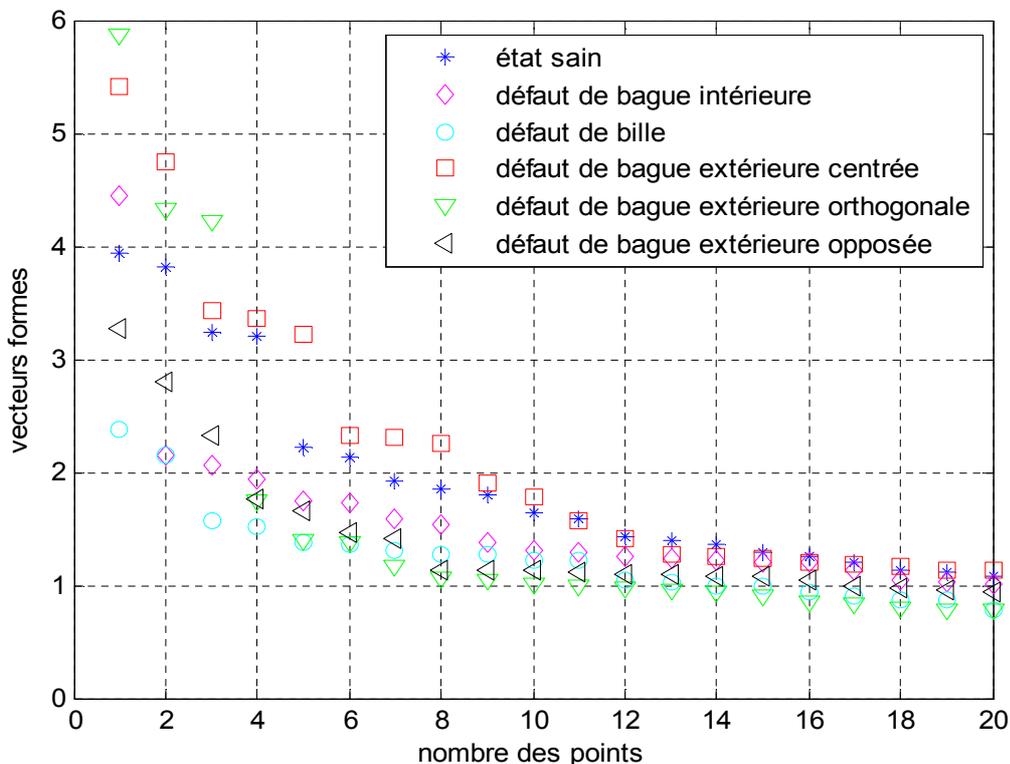


Figure.4.15 Représentation des vecteurs formes caractéristiques (coté accouplement)

La figure 4.16, illustre la classification des  $10 \times 6 = 60$  points optimisés par le modèle de mélange Gaussien (GMM) bi-variable. L'application du modèle de mélange gaussien (GMM), pour la classification des vecteurs formes nécessite que le nombre de classes soit la seule information connue a priori du processus de classification.

Par contre, le nombre des points dans chacune des ces classes est supposé inconnu. Il est déterminé par la probabilité de gaussien. À cet effet, nous allons observer une différence du nombre de points d'une classe à une autre.

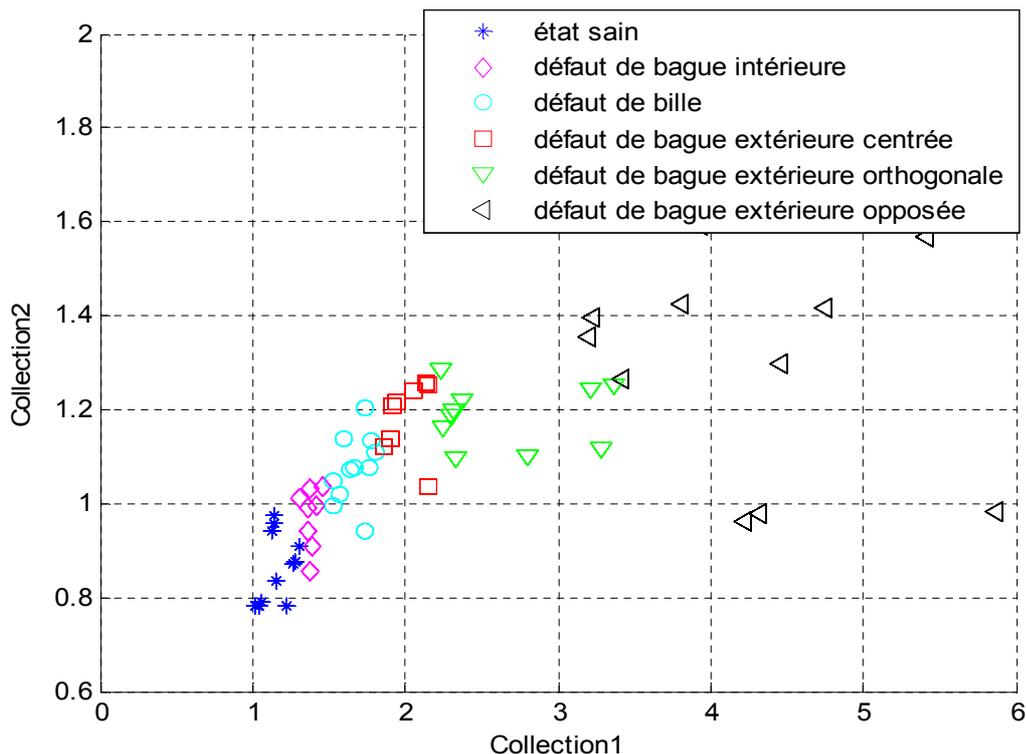


Figure.4.16 Classification des vecteurs formes (Coté accouplement)

La figure 4.17 est une représentation bidimensionnelle des vecteurs formes (coté ventilateur) optimisés par PSO, c'est le même principe que la figure 4.15. Concernant la classification des classes, coté ventilateur, on peut distinguer d'après la figure 4.18 le regroupement des points appartenant à la même classe. Par conséquent la séparabilité interclasse est bien établie.

Les points de la même classe sont proches les uns des autres par rapport aux points des autres classes, on peut conclure qu'il y a une bonne compacité intra-classe. Ceci, nous amène à faire la corrélation avec le critère de Fisher, qui maximise la séparabilité inter-classe et minimise la compacité intra-classe. L'algorithme GMM optimise, par conséquent, la compacité et la séparabilité entre classes.

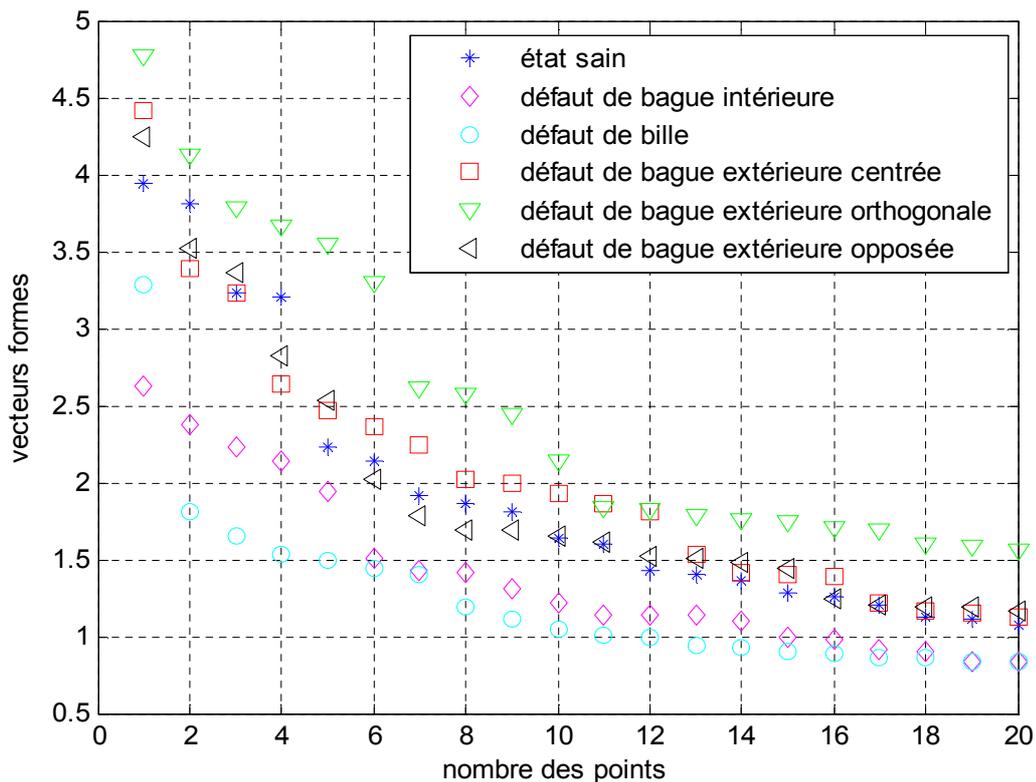


Figure.4.17 Représentation des vecteurs formes des caractéristiques (coté ventilateur)

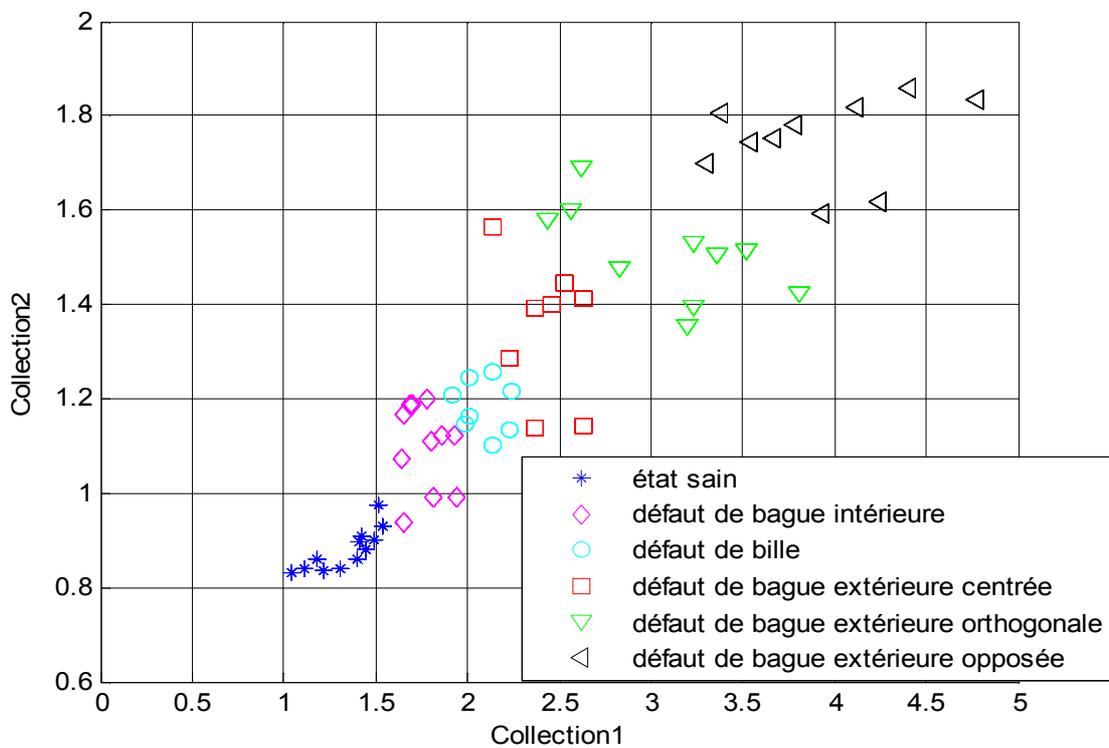


Figure.4.18 Classification des vecteurs formes (coté ventilateur)

Les deux figures précédentes montrent que :

- Les classes associées aux composants du mélange sont ellipsoïdales, centrées à la moyenne  $\mu_k$  et les matrices de variance  $\Sigma_k$  déterminent leurs caractéristiques géométriques ;
- La distribution des vecteurs formes dans les deux figures est presque la même que la distribution initiale. Ce qui explique que le nombre de points par classe a été réduit ;
- Le regroupement des six classes montre la séparabilité inter-classes ;
- Les points de la même classe sont proches les uns des autres par rapport aux points des autres classes. On peut conclure qu'il y a une bonne compacité intra-classe.

#### 4.4 Evolution des modes de fonctionnement

La classification optimale nécessite de prendre en compte l'évolution des modes de fonctionnement par rapport au niveau de charge du moteur mais aussi l'évolution due à la sévérité des défauts.

Le suivi de l'évolution de ces modes est réalisé par les mêmes modèles que précédemment afin de prévoir une évolution vers de nouvelles zones de l'espace. Pour cela, on applique notre approche sur un ensemble des données sain et en défaut que ce soit coté accouplement ou coté ventilateur, à vide ou en charge.

La sévérité des défauts se traduit par la croissance des différents diamètres de défaut de roulement : 0.007, 0.014, 0.021 et 0.028. Le tableau 4.4 résume les différents modes de fonctionnement.

Tableau. 4. 4. Modes de fonctionnement étudié

	Niveau de charge	Diamètres de défaut	classes
Coté accouplement	à vide	0, 0.007, 0.014, 0.021	4 classes
	à charge	0, 0.007, 0.014, 0.021, 0.028	5 classes
Coté ventilateur	à vide	0, 0.007, 0.014, 0.021	4 classes
	à charge	0, 0.007, 0.014, 0.021	4 classes

Le suivi de l'évolution des modes de fonctionnement sert d'une part, à estimer les états manquants de base des données vibratoires. D'autre part, il permet de prédire l'évolution des modes de fonctionnement aussi bien en fonction de la charge qu'en fonction de la sévérité des défauts.

Les figures suivantes représentent l'évolution de la défaillance du roulement dû à la sévérité du défaut pour les diamètres de 0.007, 0.014 et 0.021 avec l'état sein pour les deux cotés soit coté accouplement ou coté ventilateur, à vide ou en charge.

Enfin, la représentation des vecteurs formes, par rapport à la sévérité du défaut, a montré d'une part l'efficacité de l'algorithme d'optimisation de ces vecteurs et d'autre part l'utilité de ces vecteurs à l'apparition d'un nouveau mode de fonctionnement. Ce mode peut, par conséquent, définir le stade de dégradation de roulement.

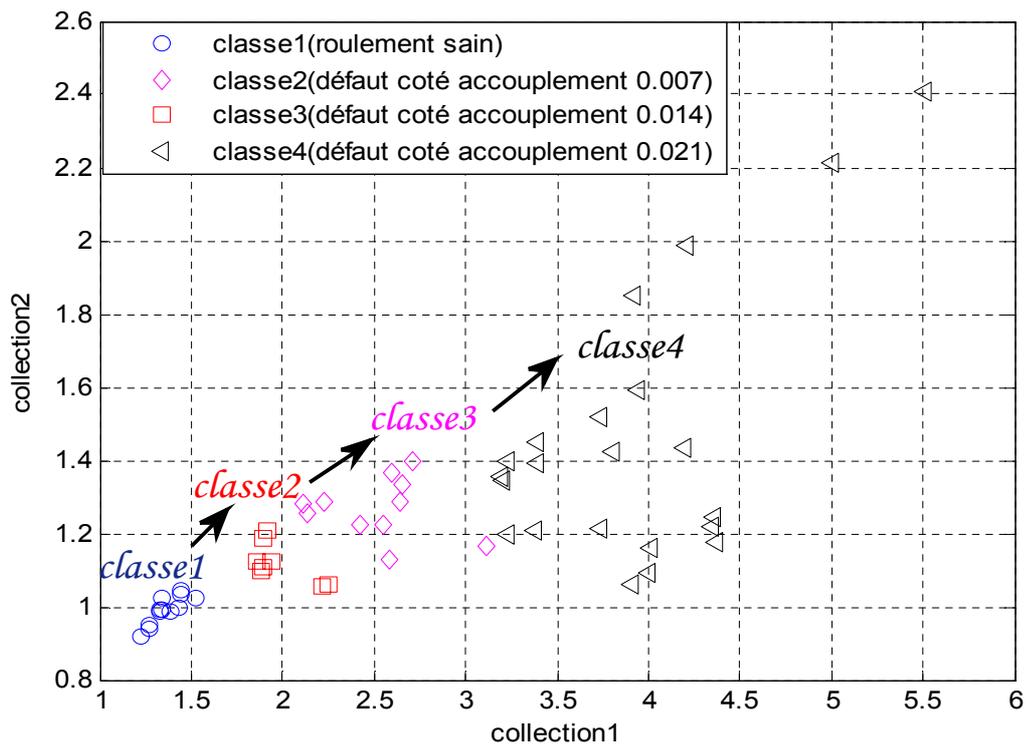


Figure.4.19 Evolution des défauts de roulement suivant la sévérité  
(Coté accouplement à vide)

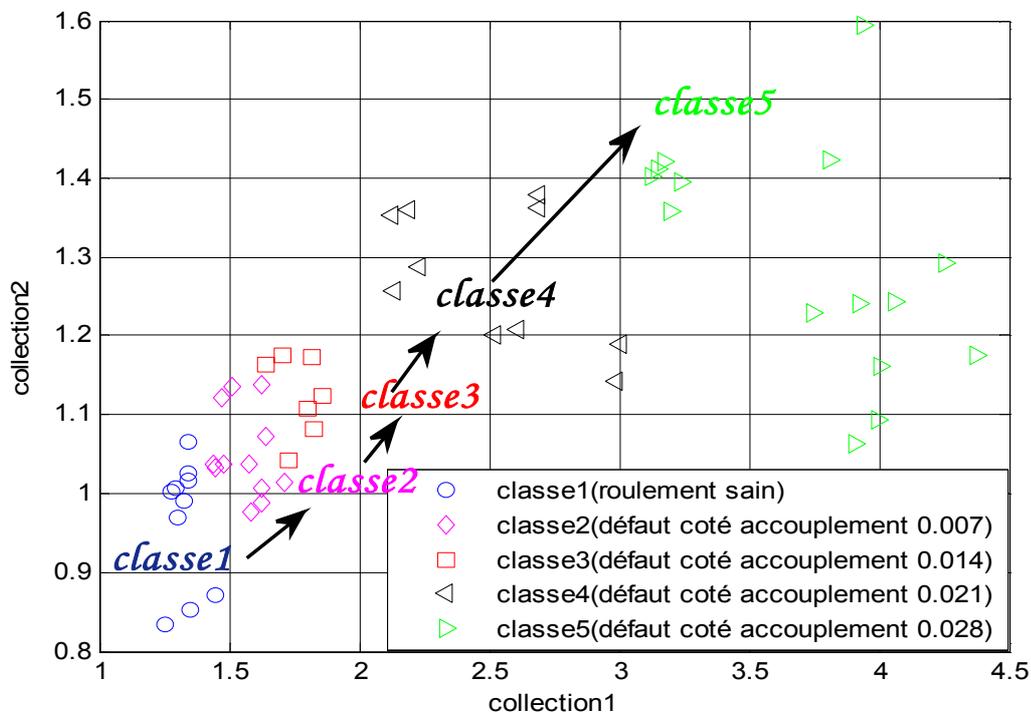


Figure.4.20 Evolution des défauts de roulement suivant la sévérité  
(Coté accouplement à charge)

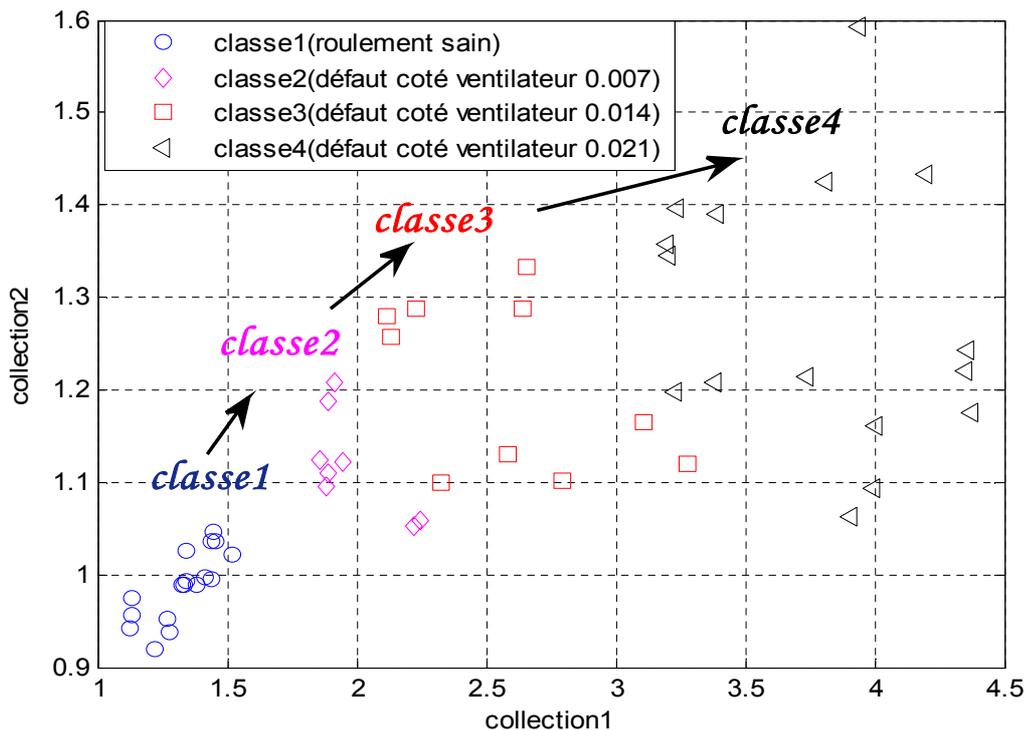


Figure.4.21 évolution des défauts de roulement suivant la sévérité  
(Côté ventilateur à vide)

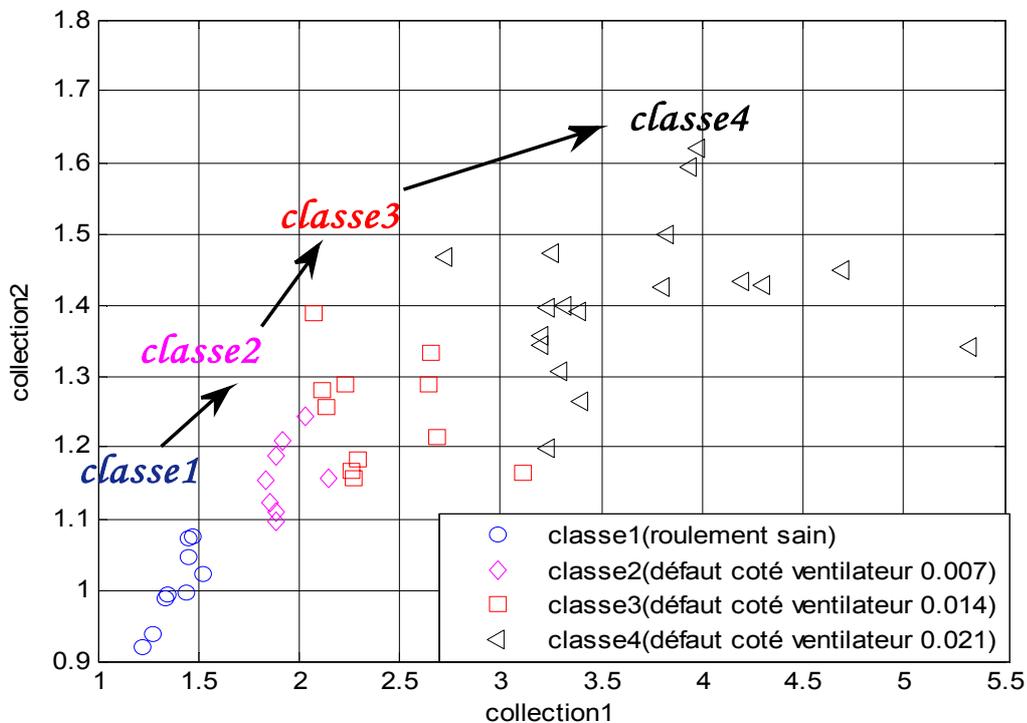


Figure.4.22 évolution des défauts de roulement suivant la sévérité  
(Côté ventilateur à charge)

## 4.5 Conclusion

L'optimisation par l'algorithme PSO des vecteurs formes a permis de réduire de quatre fois la taille initiale des ces vecteurs que ce soit coté accouplement ou coté ventilateur. Les vecteurs optimisés ont facilités le processus de la classification automatique par l'application de l'algorithme de modèle de mélange gaussien (GMM). Les modèles de mélange apparaissent encore comme une approche suffisamment flexible et rigoureuse pour apporter des réponses pertinentes. Cet algorithme a prouvé sa robustesse et son efficace lors de la classification non supervisé de six classes à savoir roulement sain, défaut de bague intérieure, défaut de la bille et défaut de bague extérieure à accéléromètre centré, orthogonal et opposé.

L'algorithme GMM a permis de maximiser la séparabilité inter-classe et de minimise la compacité intra-classe. On peut conclure que l'algorithme GMM optimise la compacité et la séparabilité entre classes. Ce qui rejoint le principe même du critère de Fisher. Le suivi de l'évolution des modes de fonctionnement a permis d'une part, d'estimer les états manquants de base des données vibratoire. D'autre part, il a permis de prédire l'évolution des modes de fonctionnement aussi bien en fonction de la charge qu'en fonction de la sévérité des défauts.

## **CONCLUSION GENERALE**

Le travail de cette thèse a porté sur la classification automatique des défauts de roulement de la machine asynchrone. Bien que la machine asynchrone ait la réputation d'être robuste, elle peut présenter comme toute autre machine électrique, des défaillances d'ordre électrique ou mécanique. Cependant, statistiquement les défauts de roulements constituent la grande part des défauts de la machine asynchrone. La plupart des études portant sur la détection de ces défauts utilisent des mesures vibratoires issues de capteurs placés au plus près des éléments mécaniques à surveiller. Pour cette raison ; nous avons présenté un état de l'art de diagnostic des défauts de roulements, tout en s'intéressant à des exemples de différents types de défauts de roulements.

C'est dans cette perspective, que nous avons mis l'accent sur les différentes techniques de diagnostic et leurs intérêts d'utilisation. Contrairement à la transformée de Fourier ou en ondelettes, la base de décomposition de l'EMD est propre au signal. Une des motivations du développement de l'EMD est la recherche d'une estimation de la fréquence instantanée du signal. En effet, l'approche classique d'estimation de la fréquence instantanée basée sur la transformée de Hilbert est strictement limitée aux signaux mono-composante.

Cette méthode est la combinaison d'un algorithme de décomposition temporelle d'un signal en composantes de base, appelée décomposition modale empirique (EMD pour Empirical mode decomposition) et de la transformation de Hilbert pour l'estimation des AI et FI. A cause de sa robustesse et son efficacité de traitement des données vibratoires en termes de la taille, qualité et quantité du signal, nous avons retenu cette méthode pour le traitement des données vibratoires.

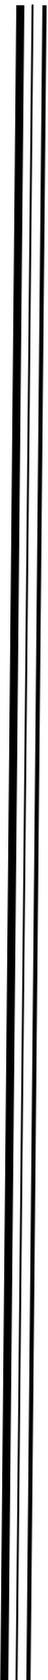
Nous avons, également, proposé une méthode de prétraitement des données vibratoire permettant d'augmenter significativement les valeurs des amplitudes pertinentes. Ceci afin d'avoir une bonne sélection des vecteurs formes caractéristiques à chaque type de défaut. Cette méthode a été appliquée à des signaux vibratoires issus du roulement du moteur. Six états de roulement ont été traités à savoir l'état sain, défaut de bague intérieure, défaut de bille et de défaut de bague extérieure à accéléromètre centré, orthogonal ou opposé.

Cette méthode est composée de trois étapes: La première étape utilise la décomposition du mode empirique pour séparer chaque signal vibratoire dans les différentes fonctions du mode intrinsèque, où chaque mode se trouve dans une bande de fréquence spécifique. La seconde étape permet d'extraire, pour chaque mode, les amplitudes instantanées et les fréquences instantanées. Ceci afin d'identifier sa bande de fréquence en calculant le spectre marginal de Hilbert. La troisième étape est la phase d'extraction des caractéristiques. Elle est réalisée par l'utilisation de l'opérateur d'énergie Teager- Kaiser (TKEO). Les résultats finals ont permis d'obtenir des vecteurs de caractéristiques composés chacun de quatre vingt points. Ces vecteurs ont servi comme d'entrées au système de classification.

L'optimisation par l'algorithme PSO de ces vecteurs formes a permis de réduire de quatre fois la taille initiale des ces vecteurs que ce soit coté accouplement ou coté ventilateur. Les vecteurs optimisés ont facilité le processus de la classification automatique par l'application de l'algorithme de modèle de mélange gaussien (GMM). Ce dernier a permis de maximiser la séparabilité inter-classe et de minimise la compacité intra-classe. On peut conclure que l'algorithme GMM optimise la compacité et la séparabilité entre classes. Ce qui rejoint le principe même du critère de Fisher. Le suivi de l'évolution des modes de fonctionnement a permis d'une part, d'estimer les états manquants de base des données vibratoire. D'autre part, il a permis de prédire l'évolution des modes de fonctionnement aussi bien en fonction de la charge qu'en fonction de la sévérité des défauts.

Les travaux effectués dans cette thèse nous orientent vers quelques perspectives de recherche qu'il nous apparaît utile à savoir :

- ❖ Le développement d'un modèle de diagnostic à taux de classification amélioré capable d'être intégré dans un environnement réel ;
- ❖ L'utilisation des autres méthodes de classification automatique pour l'analyse des signaux vibratoires des défauts des machines asynchrones ;
- ❖ Etude comparative des plusieurs approches de classification supervisé et non supervisé ;
- ❖ Proposition d'un modèle avancé pour le pronostic en vue d'une application en monde réel ;
- ❖ Validation des modèles proposés en utilisant les données expérimentales.



## **BIBLIOGRAPHIE**

### ***A. Publications internationales***

1. **Abla Bouguerne**, Abdessalam Lebaroud, «Classification of vectors forms dedicated to bearings fault detection of electrical machines based on PSO algorithm », MECHANIKA. Volume 20(6): 559-565, 2014, ISSN 1392-1207
2. **Abla Bouguerne**, Abdessalam Lebaroud, Aziz Boukadoum, « Optimization of Vibration Data Vectors by Particle Swarm optimization algorithm », International Journal of Control, Energy and Electrical Engineering (CEEE). <http://ipco-co.com/CEEE.html>. Ipco, vol 02. ISSN 2356-5608, 2013.
3. **Abla Bouguerne**, Abdessalam Lebaroud, «Clustering Optimized Analytic Vibration Signal of Rolling Bearing Faults Using K- Means Algorithm», International Journal of ChemTech Research CODEN (USA): IJCRGG, ISSN: 0974-4290, Vol.9, No.04 pp 400-406, 2016.

### ***B. Communications Internationales***

4. Bouguerne Abla, **Lebaroud Abdessalam**, Boukadoum Aziz, «Optimisation of vibration data using particle swarm optimisation applied to induction machine faults», Conférence Internationale des Energies Renouvelables (CIER'13) , 15-17 Décembre 2013 - Sousse, Tunisie
5. **Abla Bouguerne** , A. Lebaroud, A. Medoued, A. Boukadoum, «Classification of Induction Machine Faults by K-nearest Neighbor», 7th International Conference on Electrical and Electronics Engineering, (ELECO), 1-4. December, Bursa, TURKEY, 2011. ISBN: 978-9944-89-819-5. <http://ieeexplore.ieee.org/Xplore/guesthome.jsp>
6. Bouguerne Abla, **Lebaroud Abdessalam**, Boukadoum Aziz, « New Method of Data Treatment Related to Induction Machine Bearing Fault Using Axial Vibration Analytic Signal», EVER' 13, International conference and exhibition on ecologic vehicles and renewable energies, 27-30 March, Monaco, 2013.  
978-1-4673-5271-0/13/\$31.00 ©2013 IEEE,  
<http://ieeexplore.ieee.org/Xplore/guesthome.jsp>
7. Bouguerne Abla, **Lebaroud Abdessalam**, Boukadoum Aziz, «Time-Frequency Representation and Neural Networks for Classification of Induction Machine Faults», EVER' 12, International conference and exhibition on ecologic vehicles and renewable energies, 22-25 March, Monaco, 2012  
[http://conference.evermonaco.com/files/ever12\\_final\\_program.pdf](http://conference.evermonaco.com/files/ever12_final_program.pdf)
8. **Abla Bouguerne** , Lebaroud Abdessalam, Aziz Boukadoum, « A New diagnosis Method of Induction Machine Faults Using Fuzzy K Nearest Neighbor », The 13th International conference on Sciences and Techniques of Automatic control & computer engineering – STA'2012 December 17–19, 2012 Hammamet, Tunisia.

9. **Abla Bouguerne**, Abdessalam Lebaroud ,Aziz Boukadoum «Backpropagation algorithm for diagnosis of Induction Machine Faults », The 4 International Renewable Energy Congress (IREC) December 20 - 22, 2012, Sousse – Tunisia.
10. **Abla Bouguerne** , Abdessalam Lebaroud , Aziz Boukadoum, « Classification Method of Vibration Data For Bearing Faults », La 2<sup>ème</sup> Conférence Internationale sur la Maintenance et la sécurité industrielle (CIMSI'2013) Skikda, Algeria, 28-29 October 2013.
11. **Abla Bouguerne** , Abdessalam Lebaroud, «Classification of vibration signal faults occurs in ball bearing using K-menas clustering algorithm » 2nd *International Conference on Electrical energy and system, Annaba, Algeria, October 21-23,2014.*
12. **Abla Bouguerne** , Abdessalam Lebaroud, «K-menas clustering algorithm for classification of ball bearing faults », *International conference on electro-energy (ICEE'2014), Skikda, Algeria, 10-11 November 2014.*
13. **Abla Bouguerne** , Abdessalam lebaroud, «Automatic Diagnosis of Induction Machine Faults », *International Conference on Electromechanical Engineering (ICEE'2012) Skikda, Algeria, 20-22 November 2012..Algeria.*

## BIBLIOGRAPHIE

- [Ale 11] Alexandre Boulch, Bertrand Decoster « K-means, EM, Mélanges de Gaussiennes », *Théorie des graphes*, 2010/2011
- [Alt 99] Altug S., Chen M.-Y., Trussell H. J., « Fuzzy inference systems implemented on neural architectures for motor fault detection and diagnosis », *IEEE Transaction on Industry Electronics*, vol. 46, n .6, p. 1069-1079, 1999.
- [Alt 91] J. L. Alty and L. I. Mikulich. « Industrial applications of artificial intelligence ». Kluwer Academic Publishers, 2nd ed., 1991.
- [And 94] Andria G., Savino M., Trotta A., « Application of Wigner-Vill distribution to measurement on transient signal », *IEEE Transaction on Instrumentation and measurement*, vol. 43, n .2, April 1994.
- [Ant 05] J. Antoni and R. B. Randall. « On the use of the cyclic power spectrum in rolling element bearings diagnostics ». *Journal of Sound and Vibration*, vol. 281(no. 1-2) :pp. 463–468, March 2005.
- [Aya 03] N. Ayat. « Sélection de modèle automatique des machines à vecteurs de support : application à la reconnaissance d'images de chiffres manuscrits ». Thèse de doctorat, l'école de technologie supérieure, Montréal, Canada, 2003.
- [Aub 92] Aublin A. , « Systèmes mécaniques », Dunod (1992).
- [Awa 03] Awadallah M. A., Morcos M., « Application of AI tools in fault diagnosis of electrical machines and drives-an overview », *IEEE Transaction on Energy Conversion*, vol. 18, n .2, p. 245-251, 2003.
- [Azé 03] Jérôme Azé « Extraction de connaissances à partir de données numériques et textuelles » Doctorat de l'Université Paris\_Sud, décembre 2003
- [Bac 02] Bachir S., « Contribution au diagnostic de la machine asynchrone par estimation paramétrique », Thèse de doctorat, Université de Poitiers, 2002.
- [Bal 07] Ballal M. S., Khan Z. J, Suryawanshi H. M., Sonolikar R.L, « Adaptive neural fuzzy inference system for the detection of inter-turn insulation and bearing wear faults in induction motor », *IEEE Transaction on Industry Electronics*, vol. 54, n.1, p. 250-258, 2007.
- [Bau 09] Jean-Patrick Baudry « Sélection de Modèle pour la Classification Non Supervisée. Choix du Nombre de Classes ». thèse doctorat en sciences, 2009

- [Bas 93] M. Basseville and I. V. Nikiforov. «Detection of abrupt changes - Theory and Application». Prentice Hall Inc., 1993.
- [Baz 09a] Bazine I. B. A., Bazine S., Tnani S., Champenois G., « On-line broken bars detection diagnosis by parameters estimation », 13th European Conference on Power Electronics and Applications EPE, SPAIN, Barcelona, September 8-10 2009.
- [Baz 09b] Bazine S., « Conception et implémentation d'un Méta-modèle de machines asynchrones en défaut», Thèse de doctorat, L'Université de Poitiers en France et l'Ecole Nationale d'Ingénieurs de Tunis en Tunisie, Juin 2009.
- [Ben 03] H. Ben Attia, «Détection et localisation de défauts mécaniques d'un entraînement électrique à vitesse variable», Thèse de doctorat de l'Institut National Polytechnique de Toulouse, 2003.
- [Ber 10] D. Berschandy. «Comparaison des approches classiques dans l'architecture d'un système d'intelligence artificielle embarqué. Application à la détection temps réel de danger automobile». Thesis de Paris XI d'Orsay University.
- [Bez 81] Bezdek, J. C. (1981). «Pattern Recognition with Fuzzy Objective Function Algorithms». Plenum Press, New York.
- [Bie 02] C. Biernacki, F. Beninel, and V. Bretagnolle. « A generalized discriminant rule when training population and test population differ on their descriptive parameters». *Biometrics*, 58(2) :387–397, 2002.
- [Bie 06] C. Biernacki, G. Celeux, A. Anwuli, G. Govaert, and F. Langrognnet. «Le logiciel mixmod d'analyse de mélange pour la classification et l'analyse discriminante». *La Revue de Modulad*, 35 :25–44, 2006.
- [Blo 06] M. Blodt, « Condition monitoring of mechanical faults in variable speed induction motor drives, Application of stator current time-frequency analysis and parameter estimation», These de doctorat de l'Institut National Polytechnique de Toulouse, 2006.
- [Boa 03] A. Boashash. «Time-Frequency Signal Analysis and Processing : A Comprehensive Reference». Elsevier Ltd., Oxford, UK, 2003.
- [Bol 79] S. Boll. «Suppression of acoustic noise in speech using spectral subtraction». *IEEE Transactions on Acoustic, Speech and Signal Processing*, Vol. 28, No. 2, 1979.
- [Bom 11] maxime Bombrun ,abdoulaye sene « L'optimisation par essaim particulaire pour des problèmes d'ordonnement » Rapport d'ingénieur Projet de 2ème année,2011

- [Bou 99]** Bourdon, A.; Rigal, J.F. ; Play D.: «Static rolling bearing models in a C.A.D. Environment for the study of complex mechanisms» : Part I – Rolling bearing model. *J. of Tribology* 121 (1999) 205214.
- [Bou 14]** Abla Bouguerne , abaessalam lebaroud «Classification of vectors forms dedicated to bearings fault detection of electrical machines based on PSO algorithm » ISSN 1392-1207. *MECHANIKA*. Volume 20(6):pp: 559-565. 2014.
- [Bou 16]** Abla Bouguerne , abaessalam Lebaroud, «Clustering Optimized Analytic Vibration Signal of Rolling Bearing Faults Using K- Means Algorithm», *International Journal of ChemTech Research CODEN (USA): IJCRGG*, ISSN: 0974-4290, Vol.9, No.04 pp 400-406, 2016.
- [Bou 03]** A. Boulanger, et C. Pachaud, «Analyse vibratoire en maintenance», 2ème édition, DUNOD, 2003
- [Bou 05]** Guillaume Bouchard, « Les modèles génératifs en classification supervisée et applications `a la catégorisation d'images et `a la fiabilité industrielle ». Thèse Doctorat de l'université Joseph Fourier – Grenoble 1, 2005
- [Bau 09]** Jean-Patrick Baudry « Sélection de Modèle pour la Classification Non Supervisée. Choix du Nombre de Classes ».thèse doctorat en sciences,2009
- [Bri 99]** Brie D. «Modelling of the Spalled Rolling Element Bearing Vibration Signal: An overview and some new results», *Mechanical and Signal Processing*, (1999).
- [Cas 03a]** R. Casimir, E. Boutleux, G Clerc, «Fault diagnosis in an induction motor by pattern recognition methods», *SDEMPED2003\_Symposium on Diagnostics for Electric Machines, Power Electronics and Drives*,pp.294-299,Atlanta,GA,USA,24-26 August 2003.
- [Cas 03b]** Casimir R., «Diagnostic des défauts des machines asynchrones par reconnaissance des formes», Thèse de doctorat, Ecole Centrale de Lyon, 2003.
- [Cel 92]** G. Celeux and G. Govaert. « A classification EM algorithm for clustering and two stochastic versions». *Computational Statistics and Data Analysis*, 14(3) :315–332, 1992.
- [Cex 05]** Jean-Christophe Cexus, « Analyse des signaux non-stationnaires par Transformation de Huang, Opérateur de Teager-Kaiser, et Transformation de Huang-Teager (THT) », thèse de l'Université de Rennes 1, décembre 2005
- [Cex 06]** Jean-Christophe Cexus and Abdel-Ouahab Boudraa, « nonstationary signals analysis by teager-huang transform (THT) »14th European Signal Processing Conference (EUSIPCO 2006), Florence, Italy, September 4-8, 2006, copyright by EURASIP

- [**Cha 81**] G. Chaturverdi et D. Thomas. «Bearing fault detection using adaptive noise cancelling ». Publication of the ASME, Vol. Paper 81-DET-7, New-York, 1981.
- [**Chi 07**] Chimentin 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. », Thèse de l'université de reims champagne ardenne, 2007
- [**Cle 04**] Guillaume Cleuziou. «Une méthode de classification non-supervisée pour l'apprentissage de règles et la recherche d'information». Other. Universities d'Orléans,2004.
- [**Cor 02**] A Cornuéjols et L. Miclet : « Apprentissage Artificiel : Concepts et Algorithmes». Eyrolles, Paris, France, 2002.
- [**Das 02**] Dash (M.), Choi (K.), Scheuermann (P.) et Liu (H.). « Feature selection for clustering-A Filter Solution». In : proceedings of IEEE International Conference of Data Mining (ICDM 2002). { Maebashi City, Japan, December 2002.
- [**Dat 04**] M. Datig and T. Schlurmann, «Performance and limitations of the Hilber t-Huang transformation (HHT) with an application to irregular water waves», Ocean Engineering, Vol.31, no.14-15, pp.1783-1834, 2004.
- [**Dav 00**] M. Davy. «Noyaux optimisés pour la classification dans le plan temps-fréquence – Proposition d'un algorithme constructif et d'une référence bayésienne basés sur les méthodes MCMC – Application au diagnostic d'enceintes acoustiques». Thèse de doctorat, Université de Nantes, September 2000.
- [**Day 69**] Day, N. E. «Estimating the Components of a Mixture of Normal Distributions». *Biometrika*, 56:464\_474, 1969.
- [**Dem 77**] Dempster, A., Laird, N., and Rubin, D. (1977). «Maximum Likelihood from Incomplete Data via the EM Algorithm». *Journal of Royal Statistical Society B*, 39:1–38.
- [**Deb 04**] K. Debray, P. Estocq, F. Bogard, Y.Q. Guo, «Numerical tools for defect detection in predictive maintenance using vibration analysis», soumis à WCCM VI, September 2004, Beijing, China
- [**Dhi 05**] Dhillon, I. S., Guan, Y., and Kulis, B. (2005). « A unified view of kernel k means,spectral clustering and graph cuts». Technical Report TR-04-25, University of Texas Dept. of Computer Science.
- [**Did 04**] Didier G., « Modélisation et diagnostic de la machine asynchrone en présence de défaillances», Thèse de doctorat, Université Nancy 1, France, 2004.

- [Die 08] Edouard Diez Lledo. «Diagnostic et Pronostic de défaillances dans des composants d'un moteur d'avion. Automatic». Université Paul Sabatier - Toulouse III, 2008. French.
- [Don 95] D. Donoho. «Denoising by soft-thresholding». IEEE Trans. Inform. Theory, 1995.
- [Dre 02] G. Dreyfus, J. M. Martinez, M. Samuelides, M. B. Gordon, F. Badran, S. Thiria et L. Héroult, «Réseaux de Neurones, Méthodologies et Applications». Eyrolles, Paris, France, 2002.
- [Eld 12] Abbas El Dor. «Perfectionnement des algorithmes d'optimisation par essaim particulaire : applications en segmentation d'images et en électronique». Autre [cs.OH]. Université Paris-Est, 2012. Français. <NNT : 2012PEST1074>. <tel-00788961>
- [Eng 95] R. H. Engelmann, W. H. Middendorf, «Handbook of Electric Motors, Marcel Dekker, New York, 1995.
- [EPR 82] EPRI. «Improved motors for utility applications». Final report Publication EL-2678, vol. 1, 1763-1, EPRI, October 1982.
- [Est 96] Ester, M., Kriegel, H.-P., Sander, J., and Xu, X. (1996). «A density-based algorithm for discovering clusters in large spatial databases with noise». In KDD, pages 226–231.
- [Est 04] P. Estocq. «Une approche méthodologique numérique et expérimentale d'aide à la détection et au suivi vibratoire de défauts d'écaillage de roulements à billes». Thèse, Université de Reims, 2004.
- [Fen 11] Z. Feng, T. Wang, M. Zuo, F. Chu, S. Yan, «Teager energy spectrum for fault diagnosis of rolling element bearings», J. Phys.: Confer. Ser., 305 (2011), 012129.
- [Fla 93] P. Flandrin : Temps-Fréquence. Editions Hermes, Paris, 1993.
- [Fla 04] P. Flandrin : «Some aspects of Huang's empirical mode decomposition, from interpretation to applications». In Int. Conf. On Computational Harmonic Analysis CHA '04, Nashville, TN, mai 2004.
- [Fla 98] P. Flandrin. «Temps-Fréquence, volume 2ème. Ed. of Traité des Nouvelles Technologies», série Traitement du Signal. Hermès, Paris, 1998.
- [Gab 46] D. Gabor. «Theory of Communication». J. IEE (London), 93(3) :429–457, November 1946.
- [Gan 14] Yu Gan, Lifen Sui, Jiangfei Wu, Bing Wang, Qinghua Zhang, Guorui Xiao, —An EMD threshold de-noising method for inertial sensors», Measurement, Vol.49, pp.34-41, March 2014.
- [Gen 90] Gennari J. H «An experimental study of concept formation». Technical Report No 90-06, Irvine : University of California, Department of Information and Computer Science, 1990.

- [Gen 07] Gentil S., Celse B., Charbonnier S., Cocquempot V., Hamelin F., Lesecq S., Maquin D, Montmain J, Ragot J, Sauter D, «Supervision des Procédés Complexes», Lavoisier, 2007.
- [Gou 85] P. Goupillaud, A; Grossmann, and J. Morlet. «Cycle-octave and related transforms in seismic signal analysis». Combes J. M. Ed, *Geoexploration*, vol.23 :p.85–102, Elsevier, 1984/1985.
- [Gué 06] Sébastien GUÉRIF « Réduction de dimension en Apprentissage Numérique Non Supervisé » THÈSE doctorat, UNIVERSITÉ PARIS 13 décembre 2006
- [Hag 07] Atousa ASSADI-HAGHI, « Contribution au développement de méthodes d'optimisation structurelle pour la conception assistée par ordinateur de composants et de circuits hyperfréquences », thèse doctorat de l'université de limoges, 27 MARS 2007
- [Has 96] C. E. Hassani, A. Nabil, et J. Hèrault. «Séparation auto-adaptative de sources dans les mélanges convolutifs». Application à la téléphonie mains-libres dans les voitures. Thèse, Institut national polytechnique de Grenoble, 1996.
- [Hay 99] S. Haykin : «Neural Networks : A Comprehensive Foundation». 2 Edition. Upper SaddleRiver, NJ : Prentice Hall, 1999.
- [Her 82] Hertz H., «On the contact of elastic solids». *J. Reine und Angew. Math.*, Vol.92, pp156-171, (1882).
- [Hla 92] F. Hlawatsch and G. Boudreaux-Bartels. « Linear and Quadratic Time- Frequency Signal Representations». *IEEE Signal Process. Mag.*, 9 :21–67, 1992.
- [Hua 98] W. Huang, Z. Shen, N. E. Huang and Y. C. Fung, «Engineering Analysis of Intrinsic Mode and Indicial Response in Biology: the Transient Response of Pulmonary Blood Pressure to Step Hypoxia and Step Recovery», *Proc of the National Academy of Science, USA*, vol.95, 1998, pp.12766-12771.
- [Hua 99] W. Huang, Z. Shen, N. E. Huang and Y. C. Fung, «Nonlinear Indicial Response of Complex Nonsta-tionary Oscillations as Pulmonary Hypertension Responding to Step Hypoxia», *Proc of the National Academy of Sciences, USA*, Vol.96, 1999, pp.1834-1839.
- [Ibr 09] Ali Ibrahim. «Contribution au diagnostic de machines électromécaniques : Exploitation des signaux électriques et de la vitesse instantanée». Traitement du signal et de l'image. Université Jean Monnet - Saint-Etienne, 2009. Français . <tel-00454915>
- [Ido 12] Ilassane Idoumghar « Métaheuristiques Hybrides et Leurs Applications » Mémoire d'habilitation a diriger des recherches, 2012

- [IEEE 85a]** IEEE Motor reliability working group, Report of large motor reliability survey of industrial and commercial installations, Part I, IEEE Transactions on Industry applications, vol. IA-21, no. 4, Juillet- Aout 1985, pp. 853-864.
- [IEEE 85b]** IEEE Motor reliability working group, Report of large motor reliability survey of industrial and commercial installations, Part II, IEEE Transactions on Industry applications, vol. IA-21, no. 4, Juillet- Aout 1985, pp. 865-872.
- [Ise 93]** Iserman R., « Fault Diagnosis of Machines via Parameter Estimation and Knowledge», Processing - Tutorial Paper, Automatica, vol. 29, n .4, p. 815-835,1993.
- [Isa 07]** C. V. Isaza narvaez « diagnostic par techniques d'apprentissage floues : conception d'une methode de validation et d'optimisation des partitions» thèse de l'Université de Toulouse,2007
- [Jar 05]** A. Jardine, D. Lin, et D. Banjevic. « A review on machinery diagnostics and prognostics implementing condition-based maintenance». Mechanical Systems and Signal Processing, Vol. 20, pp. 1483\_1510, 2005.
- [Kar 99]** Karypis (G.), Han (E.-H.) et Kumar (V.). «CHAMELEON : Hierarchical Clustering Using Dynamic Modeling». Computer, vol.32, No 8, 1999, pp. 68{75.
- [Kia 07]** S. H. Kia, H. Henao, and G.-A. Capolino. «A high-resolution frequency estimation method for three-phase induction machine fault detection». Trans. On Industrial Electronics, vol. 54(no. 4) :pp. 2295–2304, August 2007.
- [Kil 96]** D.H. Kil ,F.B. Frances : «Pattern Recognition and Prediction With Applications to Signal Characterization». AIP Press in Modern Acoustics and signal Processing, Woodbury, New York, 1996.
- [Koh 88]** Kohonen, T. (1988). Neurocomputing: «foundations of research. chapter Self-organized formation of topologically correct feature maps», pages 509–521. MIT Press, Cambridge, MA, USA.
- [Koh 01]** Teuvo Kohonen. «Self-Organizing Maps, volume 30 of Springer Series in Information Sciences. Springer, Berlin, Heidelberg, New York, third extended edition edition, 1995,1997,2001
- [Kra 04]** Kral C., Habetler T. G., Harley R. G., « Detection of mechanical unbalances of induction machines without spectral analysis of time-domain signals », IEEE Transactions on Industrial Applications, vol. 40, n .4, p. 1101-1106, Aug 2004.
- [Kwa 14]** D. Kwak, D. Lee, J. Ahn, B. Koh, «Fault detection of roller-bearings using signal processing and optimization algorithms», Sensors,SA Transactions, 14(1) (2014), 283-298.

- [**Law 02**] Law (M.), Figueiredo (M.) et Jain (A. K.). «Feature selection in mixture-based clustering». In : *Advances in Neural Information Processing Systems 15 (NIPS 2002)*, pp. 609-616. Vancouver, Canada, 2002.
- [**Leb 08**] Abdesselam Lebaroud and Guy Clerc. « Classification of induction machine faults by optimal time-frequency representations». *IEEE Transaction on Industrial Electronics*, vol. 55(no. 12) :pp. 4290–4298, 2008.
- [**Lel 08**] Alain Lelu. « La méthode de classification non-supervisée K-means axiales». [Technical Report] 2008, pp.12. <inria-00333865>
- [**Li 06**] W. D. Li, C. K. Mechefske, «Detection of induction motor faults : a comparison of stator current, vibration and acoustic methods», *Journal of Vibration and Control*, vol. 12, no. 2, F'évrier 2006, pp. 165-188.
- [**Li 04**] Hui Li, Haiqi Zheng, Liwei Tang, «Wigner-Ville Distribution Based on EMD for Faults Diagnosis of Bearing», *Lecture Notes in Computer Science*, 2006, pp.803-812.
- [**Liu 96**] Liu (Huan) et Setiono (Rudy). «A Probabilistic Approach to Feature Selection – A Filter Solution. In : *International Conference on Machine Learning*, pp. 319{327. { Bari, Italy, 1996.
- [**Liu 13**] H. Liu, J. Wang, C. Lu, «Rolling bearing fault detection based on the Teager energy operator and Elman neural network», *Mathematical problems in engineering*, 10 (2013),
- [**Lju 87**] Ljung L., « System identification: Theory for the user», Prentice Hall, 1987.
- [**Lor 98**] Loron L., «Identification et commande des machines électriques», *Habilitation a diriger des recherches*, UTC Compiègne, 1998.
- [**Lou 04**] S. J. Loutridis, «Damage detection in gear system using empirical mode decomposition», *Engineering Structure*, Vol.26, no.12, pp.1833-1841, 2004.
- [**Lou 06**] Loures R., «Surveillance et diagnostic des phases transitoires des systemes hybrides basés sur l'abstraction des dynamiques continues par réseau de pétri temporel flou» *Thèse de Doctorat*, Université Paul Sabatier de Toulouse, France, 2006.
- [**Lux 07**] Luxburg, U. (2007). «A tutorial on spectral clustering. *Statistics and Computing*, 17(4):395–416.
- [**Mac 67**] MacQueen (J.). « Some methods for classi\_cation and analysis of multivariate observations». In : *Proceedings of the Fifth Berkeley Symposium on Mathematical statistics and probability*. pp. 281 {297. { Berkeley, 1967.
- [**Mar 95**] H. Martin et F. Honarvar. «Application of statistical moments to bearing failure detection». *Applied Acoustics*, Vol. 44, pp. 67\_77, 1995.

- [**McF 84**] P. McFadden, J. Smith, «Vibration monitoring of rolling element bearings by the high-frequency resonance technique-a review». *Tribology International*, Vol.17, pp. 3-10, 1984.
- [**McF 87**] P. McFadden. «A revised model for the extraction of periodic wave forms by time domain averaging». *Mechanical Systems and Signal Processing*, Vol. 1, pp. 83\_95, 1987
- [**McI 03**] S. A. McInerny, Y. Dai, «Basic vibration signal processing for bearing fault detection, *IEEE Transactions on Education*, vol. 46, no. 1, Fevrier 2003, pp. 149-156..
- [**Nia 00**] Niabot, « Rolling-element bearing (numbered) - Wikimedia Commons.»  
[http://commons.wikimedia.org/wiki/File:Rollingelement\\_bearing\\_\(numbered\).png?uselang=fr#filelinks](http://commons.wikimedia.org/wiki/File:Rollingelement_bearing_(numbered).png?uselang=fr#filelinks)
- [**Mit 02**] Mitra (P.), Murthy (C.A.) et Pal (S.K.). « Unsupervised Feature Selection Using Feature Similarity». *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol.24, No 4, 2002.
- [**Miy 86**] T. Miyachi et K. Seki. « An investigation of the early detection of defects in ball bearings using vibration monitoring, practical limit of detectability and growth speed f defects». Dans : *Proceedings of the international Conference of Rotordynamics*, pp. 403\_408, JSME-IFTToMM, Tokyo, 1986.
- [**Mon 04**] M. Montesinos, J. Munoz-Cobo, C. Perez, «Hilbert-Huang analysis of BWR detector signals: application to DR calculation and to corrupted signal analysis», *Annals of Nuclear Energy*, Vol.30, no.6, pp. 715-727, 2003.
- [**Mul 89**] DeMul, J.M., Vree, J.M.;Maas, D.A.: «Equilibrium and associated load distribution in ball and roller bearings loaded in 5 degrees of freedom while neglecting frictions».
- [**Nun 04**] Nunes, Y. Bouaoune, E. Delechelle, O. Niang and P. Bunel, «Image analysis by bi-dimensional empirical mode decomposition», *Image and Vision Computing*, Vol.21, no.12, pp.1019-1026, 2003.
- [**Ond 06**] Ondel O, «Diagnostic par reconnaissance des formes : Application a un ensemble convertisseur-machine asynchrone», Thèse de doctorat, Ecole Centrale de Lyon, 2006.
- [**Oum 12**] Mohamed El Kamel Oumaamar « surveillance et diagnostic des défauts rotoriques et mécaniques de la machine asynchrone avec alimentation équilibrée ou déséquilibrée », Thèse doctorat de l'université de lorraine, 19 mars 2012.
- [**Pal 59**] Palmgren, A.: «Ball and roller bearing engineering», 3<sup>rd</sup> Ed., S. Burbank & Co, Philadelphia (1959).

- [Pek 04]** Pekka Paalanen, « Bayesian classification using Gaussian mixture model and EM estimation: implementations and comparisons », Information Technology Project, 2004
- [Ran 01]** R. Randall, J. Antoni, et S. Chobsaard. « The relationship between spectral correlation and envelope analysis in the diagnostics of bearing faults and other cyclostationary machine signals ». *Mechanical Systems and Signal Processing*, Vol. 15, No. 5, pp. 945\_962, 2001.
- [Rod 13]** P. Rodriguez, J. Alonso, M. Ferrer, C. Travieso, « Application of the Teager-Kaiser energy operator in bearing fault diagnosis », *ISA Transactions*, 52 (2013), 278-284.
- [Rou 03]** A. Roue.. « Traitements des Signaux sismiques Multicapteurs et Multicomposantes, utilisant les Représentations Temps-Fréquences ». Thèse de doctorat, Laboratoire des Images et des Signaux de Grenoble, 2003.
- [Rou 04]** Guillaume ROUSSEL, « Développement et évaluation de nouvelles méthodes de classification spatiale-spectrale d'images hyperspectrales », thèse doctorat de l'université de toulouse, 10 juillet 2012
- [Sal 00]** Salles G., Filippetti F., C.Tassoni, Crellet G., G.Franceschini, « Monitoring of induction motor load by neural network techniques », *IEEE Transaction on Power Electronics*, vol. 15, n .4, p. 762-768, 2000.
- [Sch 95a]** R. R. Schoen, T. G. Habetler, « Effects of time-varying loads on rotor fault detection in induction machines », *IEEE Transactions on Industry Applications*, vol. 31, no. 4, Juillet-Août 1995, pp. 900-906.
- [Sch 95b]** R. Schoen, T. Habetler, F. Kamran, and R. Bartheld. « Motor bearing damage detection using stator current monitoring ». *IEEE Transactions on Industry Applications*, vol. 31(no. 6) :pp. 1274–1279, Nov.-Dec. 1995.
- [Sta 03]** J. R. Stack, T. G. Habetler, and R. G. Harley. « Effects of machine speed on the development and detection of rolling element bearing faults ». *IEEE Power Electronics Letter*, vol. 1(no. 3) :pp. 19–21, March 2003.
- [Sub 11]** Sublemontier, J.-H., Martin, L., Cleuziou, G., and Exbrayat, M. « Integrating pairwise constraints into clustering algorithms: optimization-based approaches ». In *ICDMW 2011, The Eleventh IEEE International Conference on Data Mining Workshops*, Vancouver, Canada.
- [Sub 12]** Jacques-Henri Sublemontier. « Classification non supervisée : de la multiplicité des données à la multiplicité des analyses ». *Machine Learning*. Université d'Orléans, 2012.

- [**Tab 15**] Ali Akbar Tabrizi Zarringhabaei. «Development of new fault detection methods for rotating machines (roller bearings) ». PhD thesis, 2015.
- [**Tan 99**] N. Tandon et A. Choudhury. «A review of vibration and acoustic measurement methods for the detection of defects in rolling element bearings». Tribology International, Vol. 32, pp. 469\_480, 1999.
- [**Tea 83**] H. M. Teager et S. M. Teager : « A phenomenological model for vowel production in the vocal tract». In CA : College-Hill, pages 73–109, San Diego, 1983.
- [**Tea 89**] H.M. Teager et S.M. Teager : «Evidence for nonlinear speech production mechanisms in the vocal tract». In Proc. NATO Advanced Study Institute on Speech Production and Speech Modeling, pages 214–261, juillet 1989.
- [**Tri 01**] Trigeassou J.-C., Poinot T., «Identification des systèmes»,Chapitre Identification des systèmes a représentation continue -Application à l'estimation de paramètres physiques», p.177-211,Sous la direction de I.D. Landau et A. Besanc on-Voda. Traite Information, Commande, Communication - Section Systèmes Automatisés, Editions Herm es, 2001.
- [**Tos 05**] rosaeio Toscano « commande et diagnostic des systemes dynamique »,ISBN 2-7298-2038-8,ellipses edition marketing S.A,2005
- [**Tur 01**] Nicolas Turenne, « Etat de l'art de la classification automatique pour l'acquisition de connaissances à partir de textes ». Technical Report, INRA, 2001
- [**Ver 07**] Sylvain VERRON, «Diagnostic et surveillance des processus complexes par réseaux bayésiens», Thèse de doctorat, école doctorale d'ANGERS, décembre 2007.
- [**Wei 12**] Wei Guo, Peter W. Tse, Alexandar Djordjevich, «Faulty bearing signal recovery from large noise using a hybrid method based on spectral kurtosis and ensemble empirical mode decomposition», Measurement, Vol.45, no.5, pp.1308-1322, June 2012.
- [**Wol 65**] Wolfe, J. H. «Pattern Clustering by Multivariate Mixture Analysis. Multivar. Behavior». Res., 5:329\_350, 1970.
- [**Zad 65**] Zadeh, L. A. (1965). «Fuzzy sets. Information and Control», 8(3):338–353.
- [**Zid 08**] Zidani F., Diallo D., Benbouzid M. E. H., Nait-Said R., « A fuzzy based approach for the diagnosis of fault modes in a voltage-fed PWM inverter induction motor drive », IEEE Transaction on Industry Electronics, vol. 55, n .2, p. 586-593, Feb. 2008