

الجمهورية الجزائرية الديمقراطية الشعبية  
وزارة التعليم العالي و البحث العلمي

BADJI MOKHTAR-ANNABA UNIVERSITY



جامعة باجي مختار - عنابة

UNIVERSITÉ BADJI MOKHTAR-ANNABA

Année 2018/2019

Faculté des Sciences de l'Ingéniorat  
Département d'électromécanique  
Laboratoire Génie Électromécanique LGE

## THÈSE

Présentée en vue de l'obtention du diplôme de **DOCTORAT**

### Éléments de diagnostic des défauts dans les machines tournantes

*Option : Maintenance Des Installations Industrielles*

Présenté par

**BERREDJEM Toufik**

**DIRECTEUR DE THÈSE : BENIDIR Mohamed Prof. U-Constantine 1**

**Soutenu le : 30/01/2019**

**DEVANT LE JURY :**

<b>Président :</b>	BOURAS	Slimane	Pr.	U - Badji Mokhtar – Annaba
<b>Examineurs :</b>	HADJADJ	Aoul Elias	Pr.	U - Badji Mokhtar – Annaba
	KABOUCHE	Abdallah	MCA.	U - Badji Mokhtar – Annaba
	BOUZAOUIT	Azzeddine	Pr.	U- 20 Aout 1955- Skikda

**Eléments de diagnostic des défauts dans  
les machines tournantes : application au  
diagnostic des défauts de roulements  
dans les machines asynchrones.**

**Résumé :**

L'objectif des méthodes de diagnostic et de pronostic basées sur la surveillance vibratoire des machines tournantes est de fournir des connaissances sur l'état de fonctionnement réel de la machine à chaque moment sans arrêter la ligne de production. Ceci permet d'éviter les pertes de production et améliorer la fiabilité et la sécurité des systèmes.

Le diagnostic des défauts de roulements est une question très importante dans le cadre de la surveillance de l'État des machines à induction. Ce travail de thèse présente une application du système expert flou (FES) au diagnostic des défauts de roulements. Ici, les règles floues sont automatiquement induites à partir des données numériques en utilisant la méthode de classification par similarité. Les données des roulements défectueux présentent un niveau de bruit élevé. Subséquemment, une méthode IRO (Improved Range Overlaps) est proposée pour sélectionner les vecteurs des indicateurs caractéristiques d'entrée en leur donnant des degrés de validité. La méthode de répartition avec la similarité a été trouvée confuse avec des indicateurs caractéristiques présentant un chevauchement entre groupes. Par conséquent, on a jugé que la nouvelle méthode proposée (IRO) est tout à fait appropriée pour améliorer la précision du classificateur. La validité et l'efficacité du modèle sont prouvées à l'aide de données expérimentales sur les historiques de roulements défectueux de la base de données « Case Western Reserve University » et de NSF I / UCR sur les systèmes de maintenance intelligents (IMS).

**Mots-clés :** Analyse vibratoire, diagnostic des défauts de roulement, Analyse temporelle, transformé en ondelettes, pronostic des roulements, systèmes experts flous.

**Abstract:**

The purpose of diagnostic and prognostic methods based on vibration monitoring of rotating machines is to provide knowledge of the actual operating state of the machine at each moment without stopping the production line. This avoids production losses and improves the reliability and security of the systems.

The fault diagnosis is a capital question in the state monitoring of induction machines. This thesis presents an application of the fuzzy expert system (FES) to the diagnosis of rolling bearing defects. Here, the fuzzy rules are automatically induced from numeric data using the similarity partition method. Defective bearing data has a high noise level. Subsequently, an improved Range Overlaps (IRO) method is proposed to select the vectors of the input characteristic indicators by giving them degrees of validity. The partition method with similarity was found confusing with characteristic indicators showing overlap between ranges of groups. Therefore, the new proposed method (IRO) is entirely appropriate for improving the accuracy of the classifier. The validity and effectiveness of the model has been proven using experimental data on the defective bearings history of Case Western Reserve University database and the NSF I / UCR database on intelligent maintenance (IMS).

Keywords: Vibration analysis, diagnosis of bearing defects, Time analysis, wavelet transforms, bearings prognosis, fuzzy expert systems.

## ملخص:

إن الغرض من الطرق التشخيصية والتنبؤية القائمة على مراقبة الاهتزاز للآلات الدوارة هو توفير المعرفة بحالة التشغيل الفعلية للآلة في كل لحظة دون إيقاف خط الإنتاج. هذا يجنب خسائر الإنتاج ويحسن موثوقية وأمن النظم. تشخيص الأخطاء هو احد اهم الاشكالات في مجال مراقبة المحركات الكهربائية. تقدم هذه الرسالة تطبيق نظام خبير غامض (FES) لتشخيص عيوب المتدرجات. هنا يتم استحداث القواعد الغامضة تلقائيًا من البيانات الرقمية باستخدام طريقة التقسيم المتشابه. بيانات المتدرجات المعيبة لديها مستوى ضوضاء عالية. في هذه الحالة يتم اقتراح طريقة محسنة لقياس تداخل النطاق (IRO) لتحديد مدى تداخل مؤشرات الخصائص المميزة للأعطال من خلال منحهم درجات ترتيبية. تم العثور على ان طريقة التقسيم التشابه مركبة مع مؤشرات مميزة تظهر التداخل بين المجموعات. لذلك فإن الطريقة الجديدة المقترحة (IRO) مناسبة تمامًا لتحسين دقة المصنف. لقد تم إثبات صحة وفعالية النموذج باستخدام بيانات تجريبية حول المتدرجات المعيبة لقاعدة بيانات جامعة ( Case Western Reserve ) (University database and the NSF I / UCR database on intelligent maintenance (IMS)).

كلمات البحث: تحليل الاهتزاز ، تشخيص العيوب المتداول ، تحليل الزمني للاهتزازات ، wavelets ، التكهن ، النظم الخيرة الغامضة.

## **DEDICACE**

Je dédie ce modeste travail à :

**À ma mère et mon père, qu'ils sachent le bonheur d'avoir grandi à  
leurs côtés**

**À mes frères et sœurs,**

**À toute ma grande famille (BERREDJEM, KHAFALLAH, ...)**

**À tous mes amis**

**Aux enseignants de l'université de Badji Mokhtar Annaba et tout  
particulièrement aux enseignants de département Électromécanique,**

**À Monsieur Attoui Issam de l'unité de recherche en technologie  
industrielle Annaba, et Monsieur Labeled Nasser Eddine pour m'avoir  
aidé. Je leur suis profondément reconnaissant de m'avoir fait  
bénéficier de leurs expériences et de leurs compétences qui ont  
beaucoup compté dans ma formation.**

## **REMERCIEMENTS**

Le travail présenté dans cette thèse a été réalisé au sein du département d'électrotechnique, faculté des sciences de l'ingénierie, Université Badji Mokhtar – Annaba.

Je voudrais tout d'abord exprimer toute ma reconnaissance à Monsieur Mohamed BENIDIR, professeur à l'Université Constantine1 – Constantine, pour son encadrement et les conseils avisés qu'il a su me prodiguer tout au long de ces années. Il reçoit ici l'expression de mon profond respect et de toute ma reconnaissance.

Je tiens à remercier le président de jury, Mr : BOURAS Slimane, professeur à l'université Annaba qui a bien voulu me faire l'honneur de présider ce jury. Il trouve ici l'expression de ma toute gratitude et mes respectueux remerciements.

Je tiens également à exprimer mes profonds remerciements aux membres du jury, Mr : HADJADJ AOUL Elias, professeur à l'université de Annaba, KABOUCHE Abdallah, MCA à l'université de Annaba, BOUZAOUIT Azzeddine, Professeur à l'université de 20 Aout 1955 Skikda de m'avoir fait l'honneur de juger ces travaux en qualité d'examineurs.

Ces remerciements ne peuvent s'achever, sans une pensée pour la personne la plus importante dans ma vie: ma mère. Sa présence, ses encouragements et ses invocations sont pour moi les piliers fondateurs de ce que je suis et de ce que je fais.

Mes remerciements vont également à tous ceux qui m'ont aidé de prêt ou de loin à finaliser cette thèse et qui ont contribué dans ma formation.

## LISTE DES TABLEAUX

TABLEAUX	TITRES	N°
<b>Tableau 1.1</b>	Les indicateurs statistiques et leurs explications mathématiques [Raj 14].	15
<b>Tableau 1.2</b>	Étude comparative entre les différentes méthodes d'analyse spectrale [Boud16].	21
<b>Tableau 2.1</b>	Fréquences relatives aux défauts de roulements dans un spectre du courant [Sch95], [Blo08].	38
<b>Tableau 3.1</b>	Comparaison des différentes approches de pronostic [G-Der11].	60
<b>Tableau 4.1</b>	Les gabarits des fonctions d'appartenance les plus usagées.	79
<b>Tableau 4.2</b>	Les indicateurs issus des coefficients de paquet d'ondelettes [Shen13].	85
<b>Tableau 4.3</b>	Gestion de la base de données.	94
<b>Tableau 4.4</b>	Règles d'inférence floue pour le système de diagnostic des défauts de roulements.	95
<b>Tableau 4.5</b>	Précision du système de diagnostic proposé.	98
<b>Tableau 4.6</b>	Précision du système de diagnostic proposé (D-S).	103



## LISTE DES FIGURES:

FIGURES	TITRES	N°
Figure 1.1	Organisation de la maintenance.	7
Figure 1.2	Vue en coupe d'un roulement à billes [Diaz 17].	8
Figure 1.3	Signal simulé d'un défaut de bague externe, (a) pure, (b) bruité.	11
Figure 1.4	Signal simulé d'un défaut de bague interne, (a) pure, (b) bruité.	11
Figure 1.5	Les différentes méthodes de diagnostic appliquées aux moteurs électriques [Elt 04].	12
Figure 1.6	Procédure de calcul du Cepstre de puissance [Boud16].	16
Figure 1.7	Arbre complet de décomposition en paquets d'ondelettes au troisième niveau	22
Figure 1.8	Distribution des défauts dans une machine électrique tournante [Tra09]	23
Figure 1.9	Spectre du signal vibratoire simulé avec prise en compte d'un mode propre de la bague externe.	27
Figure 1.10	Spectre du signal simulé, défaut de bague interne.	27
Figure 1.11	Kurtogramme du signal simulé (défaut de bague externe)	28
Figure 1.12	Analyse d'enveloppe du signal simulé (défaut de bague externe).	28
Figure 1.13	Kurtogramme du signal simulé (défaut de bague interne)	29
Figure 1.14	Analyse d'enveloppe du signal simulé (défaut de bague interne).	29
Figure 1.15	Sparsogramme du signal simulé (défaut de bague externe).	30
Figure 1.16	Spectre d'amplitudes d'enveloppe (défaut de bague externe).	31
Figure 1.17	Sparsogramme du signal simulé (défaut de bague interne).	31
Figure 1.18	Spectre d'amplitudes d'enveloppe (défaut de bague interne) .	32
Figure 1.19	Étude de la stabilité des indicateurs temporels d'un défaut de bague externe.	32
Figure 1.20	Étude de la stabilité des indicateurs temporels d'un défaut de bague interne.	32
Figure 2.1	Représentation schématique d'excentricité statique et dynamique	35
Figure 2.2	Déplacement radial de la bague interne par rapport à la bague externe lors d'un défaut localisé.	39
Figure 2.3	Représentation des enroulements du stator et du rotor.	43
Figure 2.4	Courants statoriques d'un moteur asynchrone sain.	45
Figure 2.5	Paramètres de la machine saine, couple électromagnétique (a), vitesse (b)	45

Figure 2.6	PSD du courant d'une phase statorique.	45
Figure 2.7	Analyse de paquet d'ondelettes du courant d'une phase statorique (coefficients d'ondelettes).	46
Figure 2.8	Les courants statoriques d'un moteur asynchrone dans le cas des oscillations du couple de charge.	52
Figure 2.9	Paramètres de la machine dans le cas des oscillations du couple de charge, couple électromagnétique (a), vitesse (b).	52
Figure 2.10	PSD d'un des courants statoriques pour le même cas.	52
Figure 2.11	Courant statorique modulé en amplitude (excentricité dynamique).	53
Figure 2.12	Courant statorique modulé en phase (oscillation du couple de charge).	53
Figure 2.13	PSD du courant modulé en amplitude (excentricité dynamique).	54
Figure 2.14	PSD du courant modulé en phase (oscillations du couple de charge).	54
Figure 2.15	Analyse de paquet d'ondelettes du courant modulé en amplitude.	54
Figure 2.16	Analyse de paquet d'ondelettes du courant modulé en phase.	55
Figure 3.1	Courbe en baignoire donnant les phases de vie d'un équipement mécanique.	58
Figure 3.2	Élaboration des approches de pronostic [Tobon11]	59
Figure 3.3	Chaine de Markov observable à deux états	62
Figure 3.4	Diagramme de transition entre états.	63
Figure 3.5	Diagramme de calcul « Forward » (a), calcul « Backward » (b) [Rab89]..	65
Figure 3.6	Principe du calcul de $\xi_t(i, j)$ [Rab89].	68
Figure 3.7	Banc de test IMS [Qui06]	70
Figure 3.8	Exemple de décodage Viterbi.	71
Figure 3.9	Historique de roulement#1 test#2.	72
Figure 3.10	Historiques des roulements de test#2 (Spectrum peak ratio).	73
Figure 3.11	Décodage Viterbi, roulement#4.	73
Figure 3.12	Estimation du temps de vie restant (RUL) de roulement#2.	74
Figure 4.1	Phases élémentaires d'une méthode de classification par intelligence artificielle.	77
Figure 4.2	Étapes élémentaires d'un système flou.	78
Figure 4.3	Exemple d'inférence Sugeno [Zhang10].	81
Figure 4.4	Exemple d'une défuzzification par centre de gravité.	82
Figure 4.5	Exemple d'un cadre de discernement.	83

Figure 4.6	Les deux bancs de test de roulements, CWRU (a), IMS (b).	91
Figure 4.7	Séries temporelles des signaux de roulements défectueux (base de données CWRU).	92
Figure 4.8	Séries temporelles des signaux de roulements défectueux (base de données IMS).	93
Figure 4.9	Le principe de la méthode 'Improved Range Overlaps'; indicateur sans chevauchement d'intervalle (a), indicateur avec chevauchement d'intervalle (b).	93
Figure 4.10	Description de la partition de groupes à l'aide de la mesure de similarité.	94
Figure 4.11	Les valeurs de tolérance minimale (IRO) des 126 indicateurs caractéristiques extraites pour les ensembles I et II.	96
Figure 4.12	Les valeurs de tolérance minimale (IRO) des 126 indicateurs caractéristiques extraites pour l'ensemble III.	97
Figure 4.13	Les fonctions d'appartenance du SEF pour les ensembles de données I & II.	97
Figure 4.14	Les fonctions d'appartenance du SEF pour l'ensemble de données III.	98
Figure 4.15	Résultats de sortie du SEF en utilisant la base de données CWRU.	98
Figure 4.16	Résultats de sortie du SEF en utilisant la base de données IMS.	99
Figure 4.17	Composition du système de diagnostic proposé (D-S).	102
Figure 4.18	Fonction de croyance pour un roulement côté accouplement (OHP, 0,18 mm).	103
Figure 4.19	Fonction de croyance pour un roulement côté accouplement (OHP, 0,36 mm).	103

## LISTE DES SYMBOLES

Symbole	Désignation
$f_{be}$	La fréquence caractéristique de la bague externe
$f_{bi}$	La fréquence caractéristique de la bague interne
$f_{cage}$	La fréquence caractéristique de rotation de la cage
$f_{bille}$	La fréquence caractéristique de rotation des billes
$f_r$	La fréquence de rotation mécanique
$N_b$	Le nombre de billes
$BD$	Le diamètre de bille
$PD$	Le diamètre moyen du roulement
$\theta$	Angle de contact, Angle électrique, Position angulaire
$A$	Amplitude
$f_c$	La fréquence caractéristique de défaut
$f$	La fréquence de résonance excitée
$\alpha$	Paramètre d'amortissement
$Z(n)$	Un bruit blanc gaussien
$KU$	Kurtosis
$SK$	Skewness
$var$	La variance
$std$	L'écart-type
$RMS$	Root mean square
$Cr$	Facteur Crète
$s_t$	Une série temporelle
$\epsilon$	Degré de déplacement du centre de l'arbre
$D_h$	La largeur apparente du défaut localisé
$\Delta f$	Résolution d'un spectre
$f_e$	Fréquence d'échantillonnage
$f_s$	Fréquence d'alimentation
$F_{max.}$	Fréquence de résonance d'un capteur, fréquence maximal mesurée
$NLS$	Nbr de lignes d'un spectre
$T$	Période ou durée
$LPF$	Largeur de la plage de fréquence
$H(t)$	Designe un filtre

$W_f(j, n), w_j^m$	Coefficients d'ondelettes
$J, n$	Facteur d'échelle, paramètre de décalage
$\psi(t)$	Fonction mère d'ondelette
$\chi(t)$	Fonction d'échelle
$h(b)$	Filtre pass-bas
$g(b)$	Filtre pass-haut
$w_j^m(k)$	Fonction de paquets d'ondelette
$f_{bf}$	Fréquence des raies de fréquence du courant statorique
$f_{ecc^*}$	Fréquence d'excentricité
$\epsilon_H$	niveau d'indentation de la bille
$F_r$	Le poids du rotor de la machine
$E^*$	Le module d'Young normalisé
$f_c$	Fréquence d'oscillation du couple de charge
$V_{\#}, v_{\#}$	Tensions des phases
$I_{\#}, i_{\#}$	Courants des phases
$\Phi_{\#}$	Le flux
$L$	inductance propre
$M$	inductance mutuelle entre deux phases
$dq$	Repère de park
$g$	glissement
$\Lambda$	La perméance de l'entrefer
$ef$	La largeur d'entrefer
$e_{(i,bille)}$	le degré relative d'excentricité introduit par le défaut
$\omega_{cage}$	Vitesse angulaire de la cage
$\delta$	Fonction de Dirac
$\omega_s$	Pulsation de l'alimentation
$F_e$	Force magnétomotrice
$C_0$	Couple de charge dans le régime sain
$C_c$	Amplitudes d'oscillations du couple de charge
$p$	Nombre de paires de pôles
$\lambda$	Taux de défaillance
$r$	Taux de réparation
$\pi$	Vecteur de probabilité initiale (modèle de Markov)

$A^*$	Matrice de probabilité de transition
$B^*$	Matrice de probabilité d'observations
$E$	Espaces des paramètres
$Q$	Vecteur d'états
$O$	Vecteur d'observations
$P(\cdot, \cdot)$	Probabilité conditionnelle
$\alpha_t$	Probabilité Forward
$B_t$	Probabilité Backward
$\xi_t(i, j)$	Probabilité que l'on passe par l'état $S_i$ en $t$ et $S_j$ en $t+1$
$\gamma_t(i)$	Vraisemblance
$C_{jm}$	Le poids
$\mu$	Moyenne
$\sigma$	(std) l'écart-type
<b>SPR</b>	Spectral peak ratio
<b>RUL</b>	Temps de vie restant avant défaillance
$\widehat{RUL}$	Temps de vie restant avant défaillance estimé
<i>ActRUL</i>	Temps de vie restant avant défaillance actuel
$\mu_A$	Fonction d'appartenance
$X$	Espace de discernement
$A_f$	Sous ensemble flou
$s^-$	Moyenne d'une série
<b>Sup</b>	Support
$\wedge, \vee$	Opérateurs : produit et somme algébrique.
<b>COG</b>	Centre de gravité
$\Omega$	Univers, cadre de discernement
<b>Pl(.)</b>	Plausibilité (possibilité)
<b>Bel(.)</b>	Croyance.
$\oplus$	Somme orthogonale (somme logique)
<b>sort</b>	Trier
$W$	Paramètre de contrôle de la forme de la fonction d'appartenance
$K$	Degré de conflit
$RA$	Intervalle de définition
$LI, UI$	Limites inférieurs et supérieurs d'intervalle

# Table des matières

<b>Résumé</b>	<b>i</b>
<b>Abstract</b>	<b>ii</b>
<b>ملخص</b>	<b>iii</b>
<b>Dédicace</b>	<b>iv</b>
<b>Remerciements</b>	<b>v</b>
<b>Liste des Tableaux</b>	<b>vi</b>
<b>Liste des Figures</b>	<b>vii</b>
<b>Liste des Symboles</b>	<b>x</b>
<b>Introduction générale</b>	<b>1</b>
<b>1. État de l'art sur le diagnostic des défauts de la machine asynchrone</b>	
<b>1.1. Introduction</b>	<b>4</b>
<b>1.2. Maintenance industrielle dédiée aux machines électriques tournantes</b>	<b>4</b>
<b>1.3. La surveillance des défauts des machines électriques tournantes</b>	<b>10</b>
<b>1.4. Les méthodes de diagnostic des défauts de roulements</b>	<b>22</b>
<b>1.5. Les approches de diagnostic par intelligence artificielle (IA)</b>	<b>30</b>
<b>1.6. Conclusion</b>	<b>33</b>
<b>2. Analyse des défauts de roulements d'une machine électrique par modélisation des courants statoriques.</b>	
<b>2.1. Introduction</b>	<b>34</b>
<b>2.2. Effets mécaniques des défauts de roulements sur la machine asynchrone.</b>	<b>35</b>
<b>2.3. Effets des défauts de roulements sur les courants statoriques d'une machine asynchrone.</b>	<b>38</b>
<b>2.4. Modèles des courants statoriques d'un moteur asynchrone dédiés au diagnostic des défauts de roulements.</b>	<b>38</b>
<b>2.5. Conclusion</b>	<b>55</b>
<b>3. Méthodes de pronostic, estimation du temps de vie restant d'un roulement.</b>	

<b>3.1.</b>	<b>Introduction</b>	<b>56</b>
<b>3.2.</b>	<b>Les indicateurs de dégradation</b>	<b>57</b>
<b>3.3.</b>	<b>Le pronostic et les phases de vie d'un équipement</b>	<b>57</b>
<b>3.4.</b>	<b>Estimation du temps de vie restant d'un roulement</b>	<b>58</b>
<b>3.5.</b>	<b>La théorie des modèles de Markov cachés</b>	<b>61</b>
<b>3.6.</b>	<b>Estimation du temps de vie restant d'un roulement par les modèles de mélange gaussien et MMC.</b>	<b>69</b>
<b>3.7.</b>	<b>Conclusion</b>	<b>74</b>
<b>4.</b>	<b>Méthodes de diagnostic par intelligence artificielle</b>	
<b>4.1.</b>	<b>Introduction</b>	<b>75</b>
<b>4.2.</b>	<b>Méthodes basées sur l'intelligence artificielle (IA)</b>	<b>77</b>
<b>4.3.</b>	<b>La logique flou</b>	<b>78</b>
<b>4.4.</b>	<b>Théorie de l'évidence</b>	<b>82</b>
<b>4.5.</b>	<b>Fusion de l'information</b>	<b>83</b>
<b>4.6.</b>	<b>Diagnostic des défauts de roulement par les systèmes experts floues</b>	<b>84</b>
<b>4.7.</b>	<b>Procedure expéremmentale</b>	<b>90</b>
<b>4.8.</b>	<b>Diagnostic par fusion de données</b>	<b>99</b>
<b>4.9.</b>	<b>Conclusion</b>	<b>104</b>
	<b>Conclusion Générale</b>	<b>105</b>
	<b>Ressources Bibliographiques</b>	<b>108</b>
	<b>Annexe</b>	<b>123</b>



# **INTRODUCTION GENERALE**

# **Introduction générale :**

Aujourd'hui, les machines électriques tournantes et particulièrement les moteurs asynchrones représentent les piliers fondateurs d'une installation industrielle moderne. Elles assurent les fonctions importantes dans une chaîne de production où elles sont considérées dans de nombreuses applications industrielles comme étant équipements critiques tels que dans le cas des complexes sidérurgiques, pétrolières, ...etc. Cependant, elles sont affectées par un nombre important de défauts tels que les défauts de roulements qui représentent entre 40 à 50% des défauts.

Les machines tournantes sont composées essentiellement de plusieurs composants rotatifs tels que : le ventilateur, l'induit et les roulements. Les roulements sont essentiellement utilisés pour assurer l'alignement des arbres et pour faciliter leur rotation. Du point de vue mécanique et dynamique les roulements sont des éléments de comportement vibratoire stochastique, ce comportement est dû à leur architecture complexe. Cela les transforme en sources majeures de défauts. D'autre part, il a été discerné que la plupart des défauts de la machine électrique sont liés aux défauts de roulements où les conséquences d'un défaut de roulements sont incontournables, elles peuvent engendrer la fermeture totale d'une chaîne de production ou de menacer la sécurité du service de production. Pour ces raisons, notamment, le diagnostic ainsi que le pronostic des défauts de roulements sont devenus des axes de recherche fondamentaux, dont l'objectif est la détection précoce des défauts de roulements, l'estimation du temps de vie restant avant la défaillance pour éviter les substitutions inutiles des pièces et augmenter le taux de disponibilité et de fiabilité des machines. La majorité des systèmes de diagnostic et de pronostic modernes sont constitués autour de l'idée de la surveillance des machines en temps réel. Ces techniques se basent essentiellement sur la collecte des informations contenant le comportement dynamique du système.

Récemment, plusieurs techniques de diagnostic des machines électriques sont développées autour de la mesure du bruit sonore, des vibrations, de courant et de la température. Quelques approches représentent des grandes insuffisances face aux problèmes de détection des défauts naissant où les amplitudes caractéristiques de défaut sont cachées par des hauts niveaux de bruit et de l'effet de voisinage. En outre, d'autres approches exigent l'exploitation des équipements coûteux tels que les caméras infrarouges...etc.

## *Introduction générale*

---

La surveillance des courants statoriques permet la détection des défauts avec le moindre coût. D'autre part, l'analyse du spectre des mesures acoustiques est jugée moins précise à cause de l'émergence des bruits environnementaux avec les signatures sonores des défauts. En outre, les mesures vibratoires sont jugées plus étroitement associées au comportement dynamique des équipements. De ce fait, l'analyse vibratoire est jugée plus prépondérante.

Un système de surveillance vibratoire de roulements se base sur un capteur qui envoie un signal à un système d'acquisition de données relié avec un ordinateur. Les données sont ensuite traitées par un agent expert ou par un système de détection automatique de défauts. En outre, au vu de la complexité structurale des équipements mécaniques, le traitement des vibrations issues d'un roulement défaillant exige un haut niveau d'expérience et de pré-connaissances (retour d'expérience). Ceci, se reflète sur le coût de maintenance. Donc une recherche des systèmes automatiques transparents et moins coûteux est indispensable.

Dans ce cadre, plusieurs approches sont à mentionner telles que : les approches de la reconnaissance de formes (RdF) comme les réseaux de neurones artificiels (RNA), les machines à vecteurs de support (SVM) et les K-proches voisins (KNN). Elles peuvent être utilisées pour détecter et déterminer le degré de sévérité d'un défaut de roulements (localisé ou distribué). Ces outils possèdent quelques inconvénients tels que le problème de convergence lente et d'apprentissage inexact face aux petites espaces d'échantillons (le cas des ANN's) ou le problème de pré-allocation des groupes (l'algorithme d'apprentissage est guidé par l'utilisateur dans le cas des KNN's et les SVM's). Ainsi que le niveau de complexité croissant avec les SVM dans le cas de plusieurs classes (pour N classes, il faut réaliser N classificateurs binaires one versus all ou  $N(N-1)/2$  classificateurs one versus one).

L'objectif de ce travail est de réaliser un système de détection automatique des défauts de roulements avec le minimum de complexité calculatoire tout en assurant un haut niveau de précision.

**C'est donc dans ce cadre que nous allons développer notre étude à travers les chapitres suivants :**

Le premier chapitre est consacré à une étude bibliographique relative à l'état de la question dans ses divers aspects (généralités sur la maintenance industrielle et les différents

## *Introduction générale*

---

types de maintenance). De plus, un bref aperçu sur les techniques les plus utilisées dans la surveillance industrielle et ses applications dans le cadre de détection des défauts de roulements est présenté.

Dans le deuxième chapitre, une étude théorique sur la surveillance des défauts de roulements par l'analyse des courants statoriques est faite en commençant par une étude des approches les plus couramment utilisées. Ensuite, l'élaboration de l'approche-modèle des courants statoriques donnant l'effet d'un défaut de roulement sur les courants statoriques. Une application de quelques méthodes de traitement des courants statoriques comme la MCSA et la transformée de paquet d'ondelettes dans le cadre de la MCSA est achevée afin de déterminer les effets des défauts de roulements sur le spectre du courant.

Le troisième chapitre se joint à une étude théorique sur le pronostic des défauts de roulements, ainsi l'élaboration des différentes méthodes de pronostic, où une des méthodes de pronostic de roulements la plus souvent utilisée pour estimer le temps de vie restant avant la prochaine défaillance est présentée (association de la méthode de mélange de gaussien et les modèles de Markov cachés). Afin d'évaluer l'efficacité de cette approche, une brève application sur un historique des roulements à vieillissement accéléré est achevée.

Le dernier chapitre est relatif aux différents résultats obtenus par l'application du système de détection automatique des défauts de roulements utilisant la théorie de la logique floue. Ce dernier est basé sur une méthode d'apprentissage simple exploitant la mesure de similarité. Cette dernière était trouvée instable face aux espaces des indicateurs caractéristiques avec chevauchement entre classes, d'où la proposition d'une nouvelle méthode de sélection des indicateurs dite « Improved Range Overlaps IRO » pour améliorer la précision du système. Une application aux défauts de roulement localisés et distribués est faite en vue de prouver l'efficacité du système de diagnostic. Ensuite, une application de la méthode Dempster-Shafer (D-S) pour la fusion de données des capteurs est achevée afin d'éviter l'utilisation d'un capteur non fiable ou qui est mise dans une position qui influence la fiabilité de la mesure.

Nous terminons ce manuscrit avec une conclusion générale.

# **Chapitre I**

## **État de l'art sur le diagnostic des défauts de la machine asynchrone**

## **1.1. Introduction**

Dans un environnement industriel moderne, la maintenance conditionnelle domine le cadre de la politique de maintenance, elle repose sur le suivi permanent ou programmé des systèmes essentiels pour la production et la sécurité. Par conséquent, plusieurs méthodes de suivi des avariés des machines sont inventées où le choix d'une des méthodes dépend de certaines exigences telles que le coût d'exploitation, les exigences technologiques et les objectifs technico-économiques de l'entreprise.

La machine électrique occupe une grande portion des applications industrielles, où les moteurs électriques sont les piliers fondateurs d'un environnement industriel moderne. Cependant, la sûreté de fonctionnement des moteurs asynchrones et leur fiabilité sont des questions très importantes, une demande croissante de rentabilité, de fiabilité et de sécurité dans les moteurs asynchrones, qui peuvent faire l'objet de pannes ou de dysfonctionnement à un moment donné de leur temps d'utilisation. Ceci a conduit à des nouvelles méthodes de surveillance et de détection de panne. D'autre part, les moteurs électriques utilisés dans les installations industrielles sont en grande majorité des moteurs asynchrones. Un intérêt particulier est porté dans ce chapitre à l'analyse et le diagnostic des défauts mécaniques dans les machines asynchrones, et en particulier les défauts de roulements qui représentent entre 40 à 50% des défauts.

Ce chapitre vise à expliciter le cadre général dans lequel s'inscrit ce travail de thèse.

## **1.2. Maintenance industrielle dédiée aux machines électriques tournantes**

### **1.2.1. La maintenance industrielle**

D'après la norme (NF EN 13306 X60-319) : la maintenance est l'ensemble de toutes les actions techniques, administratives et de management durant le cycle de vie d'un bien, destinées à le maintenir ou à le rétablir dans un état dans lequel il peut accomplir la fonction requise.

La maintenance est un terme général qui désigne que quelqu'un/quelque chose reste dans un état déterminé. En industrie cette notion de maintenance est expliquée : l'ensemble des moyens utilisés pour l'optimisation des performances et les coûts d'entretien des équipements et les pertes de productions afin d'assurer la fiabilité, la maintenabilité, la disponibilité et la sécurité des biens.

Selon le mode d'application de la maintenance, il existe trois types de maintenance: la maintenance curative, la maintenance préventive systématique et la maintenance préventive conditionnelle (cf. figure 1.1).

Dans une installation industrielle moderne la maintenance préventive est un enjeu majeur, où elle vise l'assurance de certains objectifs comme [Héng 02]:

- L'amélioration de la fiabilité du matériel par la suppression de certaines défaillances.
- Garantir la qualité des produits : le contrôle quotidien des jeux et de la géométrie de la machine permet d'éviter les erreurs de fonctionnement.
- Améliorer l'ordonnancement des travaux par la collaboration entre le service maintenance et la production.
- Assurer la sécurité humaine : le respect des consignes de la sécurité lors des interventions de maintenance.
- Améliorer la gestion des stocks : une optimisation de la quantité des pièces en stock est assurée grâce à la planification des interventions et des remplacements programmés.

La mise en place de la maintenance préventive exige une élaboration d'un plan de maintenance, le choix des machines à mettre sous préventif et la planification des arrêts. En outre, la maintenance préventive conditionnelle est appliquée à travers un ensemble d'indicateurs et ratios dits « tableau de bord » de la maintenance, il se présente sous plusieurs formes : Graphes d'évolution, graphe de répartition, ratios économiques, ratios techniques.

### **1.2.2. Caractéristiques mécaniques et vibratoires des défauts de roulements dans une machine électrique tournante**

Les roulements sont des composants mécaniques complexes, ils sont constitués de plusieurs éléments mécaniques : bague externe, bague interne et les éléments roulants (des billes, des rouleaux ou des aiguilles) maintenus par une cage qui maintient la distance entre eux et assure la fonction de graissage. Une vue en coupe d'un roulement à billes à un seul rang de billes est présentée dans la figure 1.2. Les roulements sont essentiellement utilisés pour maintenir la rotation libre des parties rotatives et l'homogénéité de l'entrefer de la machine et supporter la masse du rotor (charges radiales). Il existe aussi quelques types de roulements qui sont favorables pour supporter les charges axiales (roulements à aiguilles ou à deux rangs de billes).

Les roulements métalliques, graissés, à un seul rang de billes, à contact radial, sont le type de roulements le plus utilisé dans les machines électriques de moyenne tension [Tra09]. Par conséquent, on a concentré nos efforts sur l'étude de ce type de roulement.

Les contraintes radiales existent nécessairement du fait de la masse de l'arbre de la machine. Elles s'exercent conséquemment sur la bague interne du roulement qui les transmet à leur tour à la bague externe par l'intermédiaire des billes réparties sur la moitié de la bague externe (zone de charge). Par conséquent, les efforts exercés au niveau des points de contact se distribuent au sein des matériaux en une contrainte de compression et une contrainte de cisaillement [Tra09]. Lorsqu'il existe une contrainte de surcharge sur le roulement, les matériaux constitutifs se mettent sous des contraintes de dégradation (surchauffes) qui vont changer la structure moléculaire et par la suite produisant des microfissures internes à cause des contraintes de compression et de cisaillement. En effet, ces microfissures vont se développer en des défauts plus sévères (écaillage des chemins de roulements, fissurations des bagues) ou encore l'éclatement des billes. De ce fait, la présence d'un défaut localisé indique la présence d'un défaut enrobé, où les défauts localisés représentent la cause principale des défauts généralisés [Diaz17].

Quand un élément roulant entre en contact avec un défaut localisé ou, inversement, le défaut sur un élément roulant entre en contact avec le chemin de la bague interne/externe, il produit des chocs mécaniques, ces chocs répétés se traduisent alors par des vibrations et par conséquent une série d'impulsions rapidement amorties est générée. Ici, l'amortissement est dû aux contacts élastiques entre les billes et le chemin de la bague. Ces impulsions excitent la fréquence de résonance du palier à roulement où le capteur est installé. Les fréquences de modulation sont les fréquences caractéristiques du défaut qui causent la modulation d'amplitudes. Ces fréquences caractéristiques sont calculées à partir de la géométrie du roulement et la fréquence de rotation de l'arbre [Diaz 17], [Tse 13a], [Tse 13b], comme suit [McFadden 84]:

$$f_{be} = \frac{N_b}{2} f_r \left( 1 - \frac{BD}{PD} \cos\theta \right) \quad (1.1)$$

$$f_{bi} = \frac{N_b}{2} f_r \left( 1 + \frac{BD}{PD} \cos\theta \right) \quad (1.2)$$

$$f_{bille} = \frac{PD}{2BD} f_r \left( 1 - \left( \frac{BD}{PD} \right)^2 \cos^2\theta \right) \quad (1.3)$$

$$f_{cage} = \frac{f_r}{2} \left( 1 - \frac{BD}{PD} \cos\theta \right) \quad (1.4)$$

Avec :

- $f_{be}$  la fréquence caractéristique de la bague externe,
- $f_{bi}$  la fréquence caractéristique de la bague interne,
- $f_{cage}$  la fréquence caractéristique de rotation de la cage,



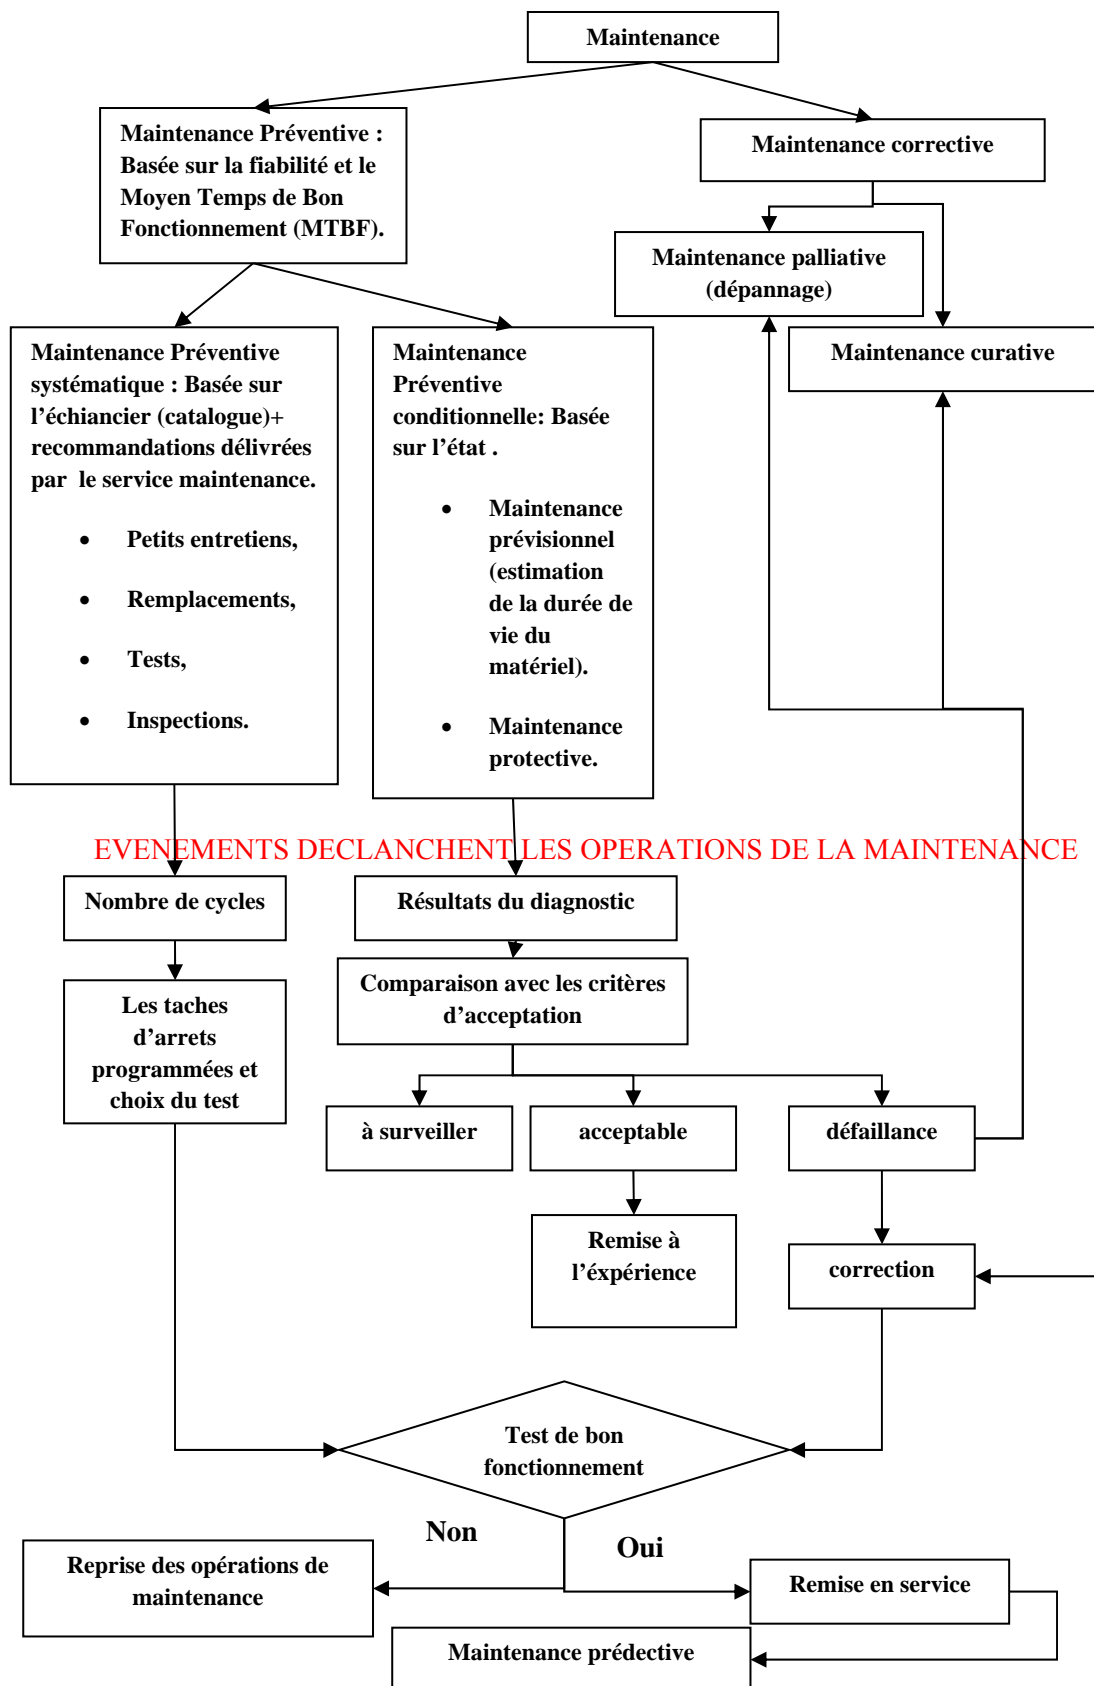


Figure 1.1. Organisation de la maintenance.

- $f_{bille}$  la fréquence caractéristique de rotation des billes,
- $f_r$  la fréquence de rotation mécanique,
- $N_b$  le nombre de billes,
- $BD$  le diamètre de la bille,
- $PD$  le diamètre moyen du roulement,
- $\theta$  l'angle de contact.

### 1.2.2.1. Les causes des défauts de roulements

- **Défauts de construction** : les alliages constitutifs des éléments de roulements contiennent des imperfections et des défauts de structure dus aux différentes contraintes environnementales (physiques et chimiques) et de fabrication.
- **Défauts de montage** : le montage de roulement sur un arbre ou dans un palier doit être effectué avec grand soin, un désalignement avec l'élément affût peut entraîner l'endommagement d'un des éléments de roulement.
- **Circulation des courants électriques** : les roulements métalliques sont conducteurs d'électricité par nature. À cause de phénomène de décharge diélectrique, des micro-trous ou des stries perpendiculaires se produisent dans les points de décharge.




Figure 1.2. Vue en coupe d'un roulement à billes [Diaz 17].

- **Corrosion** : les facteurs corrosifs comme les acides et la vapeur favorisent la dégradation des matériaux métalliques constitutifs et engendrent des pertes des parties de métal qui se développent avec le temps.
- **Contamination** : pendant leur fonctionnement, les machines peuvent être exposés aux contraintes climatiques et environnementales telles que l'humidité, la poussière, l'huile...etc. Ces contaminants peuvent entrer dans le roulement et dégradent également les surfaces de contact par abrasion ou indentation et entraînent l'écaillage ou la fissuration des éléments constituants de roulements. Ici, le facteur humain est un des facteurs principaux de contamination si le montage n'est pas fait avec soin.

- **Défauts de lubrification** : l'huile de lubrification ou la graisse sont essentielles pour la protection des surfaces des éléments constitutifs d'un roulement. La dégradation des qualités lubrifiantes de la graisse (comme la viscosité) par contamination ou par élévation de la température de fonctionnement produit un contact métal-métal qui favorise l'écaillage des pistes ou encore l'éclatement des billes. En outre, si la quantité de la graisse occupe tout le volume libre interne du roulement, les billes se bloquent, et se glissent sur les pistes de roulement, ceci favorise la dégradation rapide des pistes de roulements.
- **Élévation de la température de fonctionnement** : l'augmentation de la température de fonctionnement pendant une longue durée du temps conduit à la dégradation des qualités lubrifiantes et de refroidissement de la graisse qui vont par la suite engendrer la dilatation des bagues et puis la déformation. De ce fait, l'homogénéité de l'épaisseur du film d'huile va se modifier, ce qui favorise la dégradation au niveau des points de contact.

#### **1.2.2.2. Spécifications des défauts de roulements**

L'apparition des défauts localisés excite les modes propres de la bague externe à cause de la rugosité du contact bille/ bague. Pour simplifier l'étude, la bague externe est modélisée comme un cylindre, où les fréquences de ses modes propres sont détectables dans la plage de « hautes fréquences ». Ici, seuls les modes propres de la bague externe sont considérés car les modes propres de la bague interne sont amortis via les contacts élastiques bille/bague [Tra09]. En outre, les modulations d'amplitudes des fréquences caractéristiques des éléments constitutifs du roulement (bague externe, bague interne, Bille, cage) sont détectables dans la plage de « basses fréquences ». Par conséquent, le signal mesuré d'un roulement défectueux peut être modélisé par une série d'oscillations rapidement amorties avec une période fixe, qui est la période caractéristique du défaut. Si la taille de défaut augmente, l'amplitude de l'impact augmente. Autant, l'intervalle de temps entre deux impacts successifs reste égal à la période caractéristique de défaut [Cui16]. Donc, les vibrations mesurées sont la réponse impulsionnelle de la bague externe aux oscillations vibratoires où les modes propres permettent d'amplifier les effets vibratoires [Tra09]. Et la fréquence de résonance de la structure domine le signal vibratoire.

Un exemple de la réponse impulsionnelle de la structure est donné dans [Hem16] par:

$$g_i(t) = \begin{cases} A_i e^{-\alpha(t-\frac{i}{f_c})} \sin\left(2\pi f\left(t-\frac{i}{f_c}\right)\right) & \text{if } \left(t-\frac{i}{f_c}\right) > 0 \\ 0 & \text{if } \left(t-\frac{i}{f_c}\right) < 0 \end{cases} \quad (1.5)$$

Où  $A_i$  l'amplitude de la  $i^{\text{ème}}$  impulsion,  $N$  est le nombre d'impulsions,  $f_c$ ,  $f$ ,  $\alpha$  sont respectivement : la fréquence caractéristique de défaut, la fréquence de résonance excitée et le paramètre d'amortissement.

$$S(t) = \sum_{i=1}^N g_i(t) + Z(n) \quad (1.6)$$

Avec :  $g_i(t)$  est la  $i^{\text{ème}}$  impulsion, et  $Z(n)$  est un bruit blanc gaussien.

Dans cet exemple, le SNR du bruit égale à -15 dB,  $f=20\text{KHz}$  et  $f_c=4\text{ Hz}$ . Le signal impulsif est donné par la figure 1.3a, la figure 1.3b donne le signal bruité. Ce modèle est adéquat pour la simulation des défauts de bague externe.

Un autre modèle est donné par [Obu14] est préféré pour la simulation des défauts de bague interne :

$$X(t) = \sum_{i=1}^N A a_i \sin(2\pi f_{c,i} t) + \sigma Z(t) \quad (1.7)$$

Avec :  $N=6$ ,  $A=10$ ,  $a_i=0.75^{(i-1)}$ ,  $f_{c,i}=190i$ ,  $\sigma=0.1$  et  $Z(t)$  est un bruit blanc gaussien (avec SNR égale à -5dB). Les résultats de simulations sont donnés par la figure (1.4a) et (1.4b).

### 1.3. La surveillance des défauts des machines électriques tournantes

Les machines électriques tournantes occupent une grande partie des applications industrielles, elles sont essentiellement utilisées à cause de leurs qualités en: fiabilité, architecture simple et robustesse. Malheureusement, elles sont affectées par des défauts, où on pourrait distinguer deux grandes familles:

- **Rotoriques:** rupture de barres rotoriques, rupture de portions d'anneaux, défauts de roulements, rupture des ailettes du ventilateur....
- **Statoriques:** non-uniformité des enroulements, Court-circuit entre spires du stator, la détérioration des isolations des enroulements....

Les défauts de fabrication (vides, contamination par la pénétration des huiles ou des grains de métal), surtensions, les forces électrodynamiques produites par le courant du stator, les vibrations, les surchauffes, représentent les causes principales des défauts des moteurs électriques.

L'arrivée imprévue d'un défaut sévère conduit à la fermeture totale d'une installation industrielle, cause des pertes de production et des coûts excessives. Par conséquent, de nombreuses méthodes de diagnostic des défauts sont mises en place pour protéger les installations contre les conséquences brutales provoquées par ces derniers. Ces méthodes sont classées en deux grandes familles :

- **Les méthodes de diagnostic externes :** elles n'exigent pas la connaissance des paramètres internes de la machine.
- **Les méthodes de diagnostic internes :** elles se basent sur un modèle de comportement dynamique et électrique utilisant les paramètres de la machine électrique pour effectuer un diagnostic fiable. La figure 1.5 montre un organigramme détaillé incluant les méthodes internes et externes de diagnostic des défauts des machines électriques.

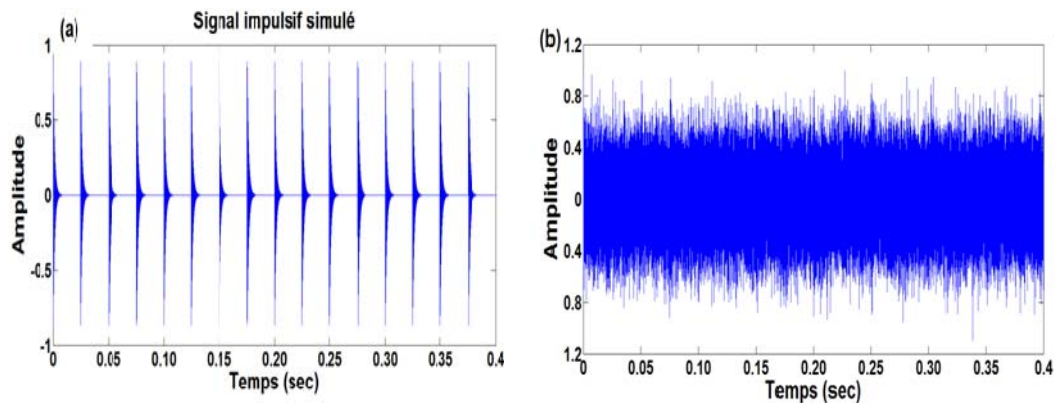


Figure. 1.3. Signal simulé d'un défaut de bague externe, (a) pure, (b) bruité.

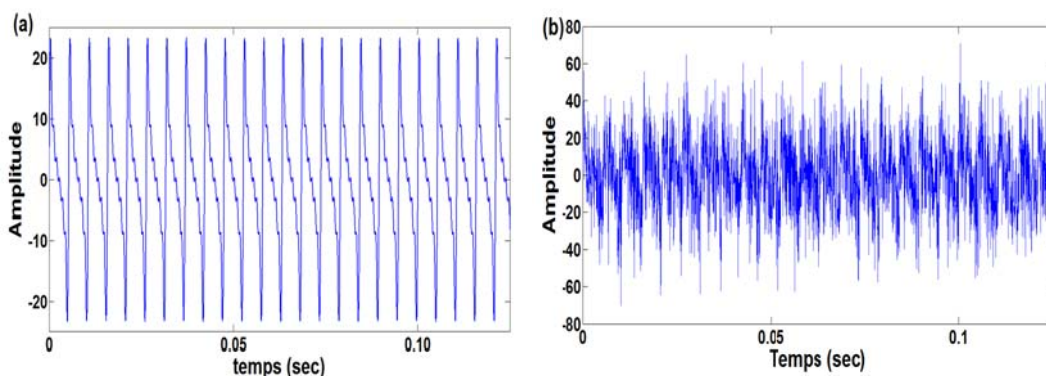


Figure. 1.4. Signal simulé d'un défaut de bague interne, (a) pure, (b) bruité.

### 1.3.1. La surveillance des paramètres électriques

Ces approches de diagnostic se basent sur le suivi des paramètres électriques de la machine, elles sont implantées autour de l'exploitation des paramètres de fonctionnement (internes et externes) et les équations qui régissent les phénomènes internes du système,

celles-ci peuvent être exploitées directement ou sous forme d'un modèle mathématique, elles se regroupent en deux familles principales :

- **L'approche-modèle :** Elle repose sur la comparaison du comportement réel du système avec celui fourni par un modèle très complet du système auquel sont appliquées les mêmes excitations qu'au système réel. Elle utilise les paramètres caractéristiques liés au fonctionnement de la machine pour en déduire un modèle régissant les grandeurs électriques et magnétiques qui caractérisent le comportement du système dans l'état sain ou défectueux, puis les résultats du modèle seront comparés avec les mesures observées du comportement réel du système (analyse des courants statoriques de la machine, courbes de Lissajous).

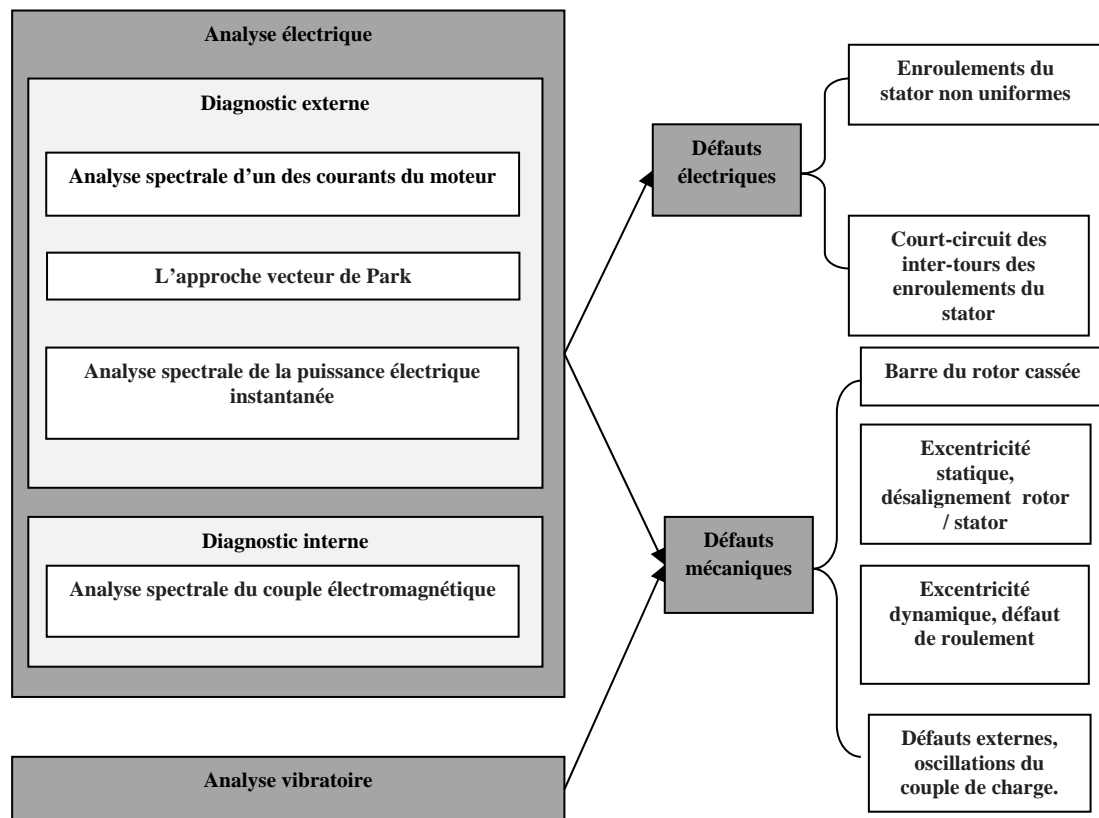


Figure 1.5. Les différentes méthodes de diagnostic appliquées aux moteurs électriques [Elt 04].

L'identification des paramètres exige la surveillance de l'évolution de certaines grandeurs physiques critiques qui ne sont pas accessibles et en déduire un modèle mathématique représentant le comportement dynamique de la machine (par exemple l'analyse spectrale du couple électromagnétique).

Il existe d'autres méthodes de diagnostic internes qu'on peut distinguer : le diagnostic de défauts par estimation paramétrique, méthode de l'espace de parité, les méthodes de filtrage [Attoui15a].

- ***L'approche analyse spectrale de la signature du courant « motor current signature analysis (MCSA) »***: Elle utilise les courants statoriques préalablement mesurés pour la commande du moteur. Les courants des phases statoriques sont analysés par la suite avec l'analyse FFT pour extraire les fréquences caractéristiques d'un défaut où: (i) les bandes latérales des fréquences de passage de pôle autour de la fréquence d'alimentation indiquent un défaut de cassure de barres; (ii) les pics qui se manifestent dans le spectre du courant et la tension sont invoqués par un défaut électrique ; (iii) les pics qui se manifestent dans le spectre du courant seul sont provoqués par un défaut d'enroulement ou mécanique ; (iv) les pics qui n'ont pas une relation avec la vitesse de rotation ou avec la fréquence d'alimentation sont dus aux défauts de roulements.

Cette méthode présente un inconvénient majeur qui est le niveau faible du rapport signal/bruit [Del 16].

### **1.3.2. La surveillance des paramètres vibratoires et de bruit sonore**

Récemment, l'analyse vibratoire reçoit un grand intérêt, car le signal vibratoire est directement associé au comportement dynamique du système [Gao06]. Cependant, il est à noter que les paramètres électriques sont moins fiables à cause des perturbations des courants d'alimentation, la MCSA est incapable de détecter les défauts dans un stade précoce ou de séparer les signatures de plusieurs roulements dans une seule machine [Corne15].

La mesure du signal vibratoire est effectuée à l'aide d'un capteur caractérisé par sa fréquence de résonance. Puis, les courants issus d'un capteur sont amplifiés, conditionnés et numérisés pour qu'ils soient prêts à exploiter par les systèmes de classification et de détection des défauts. Toutefois, la fiabilité de ceux-ci est affectée par le bruit dû aux différentes sources de vibration voisines.

La mesure des bruits sonores (Acoustic Emission AE) exige l'exploitation d'un microphone de bande de fréquence de résonance appropriée. La distance entre le microphone et le système à étudier a une grande influence sur les résultats d'analyse, selon [Glow16] la distance d'emplacement du microphone est de 0.02 à 0.05 mètres. La mesure du son généré par un défaut passe par les étapes suivantes : (i) mesurer le son à l'aide d'un microphone et une carte son, (ii) segmenter les enregistrements du son en des intervalles à durée réduite, (iii) La normalisation des amplitudes du signal mesuré [Glow15].

La plage de fréquence de résonance d'un microphone est de l'ordre de méga hertz (100 MHz), mais dans un environnement industriel la majorité des défauts sont détectables dans la plage de 1KHz jusqu'à 1MHz, ce qui rend la méthode de mesure de l'émission acoustique peu adaptée pour les systèmes de diagnostic en temps-réel (elle exige des algorithmes de filtrage fiables pour augmenter le pouvoir de séparation des systèmes de classification).

### **1.3.2.1. Les indicateurs scalaires**

Le signal vibratoire dans sa forme temporelle est utilisé pour calculer les indicateurs caractéristiques statistiques. Chaque indicateur a un sens mathématique et physique, où une valeur de seuil est fixée au-delà de laquelle on pourrait confirmer l'apparition d'un défaut. Le tableau 1.1 présente quelques indicateurs statistiques et leur sens mathématique : par exemple dans le cas sain la valeur de kurtosis égale à 3, et elle augmente avec la divergence de défaut. Le facteur crête augmente avec la divergence de défaut et présente une chute dans la phase finale du cycle de vie d'un composant défectueux. Pour améliorer la qualité des indicateurs, une méthode de filtrage des vibrations est obligatoire [Tra09].

### **1.3.2.2. L'analyse spectrale**

Cette analyse se base sur la transformée de Fourier (TF), cette transformation fait clairement ressortir le continu fréquentiel d'un signal par décomposition sur une somme infinie d'exponentiels complexes (produit scalaire de signal avec les bases exponentielles). Pourtant, cette approche n'est valable que pour les signaux stationnaires dont les propriétés statistiques sont invariantes dans le temps [Ern04]. Néanmoins, la majorité des signaux émis par des défauts mécaniques sont non stationnaires. De plus, il est aussi à noter que la TF est incapable de faire le filtrage.

Il existe plusieurs formes de la TF, où on peut distinguer : la transformée de Fourier discrète (DFT), et la transformée de Fourier rapide (FFT) ainsi que la transformée de Fourier à court terme ou à fenêtre glissante (short-time Fourier transform (STFT)).

### **1.3.2.3. L'analyse Cepstral**

Selon [Boud16], on pourra distinguer trois types: (i) Cepstre réel qui est déterminé comme l'inverse de la transformation de Fourier de logarithme d'amplitude de la transformation de Fourier d'un signal, (ii) le Cepstre complexe est déterminé comme



l'inverse de la transformation de Fourier de logarithme de la transformation de Fourier d'un signal, (iii) le Cepstre de puissance est déterminé par la figure 1.6.

#### 1.3.2.4. Les indicateurs spectraux

Ces dernières années, beaucoup d'indicateurs ont été inventés autour de l'analyse spectrale où les indicateurs sont issus du spectre vibratoire, on distinguera : spectrum peak ratio (SPR) [Attoui 15.b], [Shi 97], Method of Selection of Amplitudes of Frequency – Multiexpanded (MSAF-20-MULTIEXPANDED ) c'est-à-dire de prendre 20% des pics dominants de spectre [Glow 18], spectrum peak (SP), c'est l'ensemble des amplitudes qui correspondent aux fréquences caractéristiques du défaut [Sun 16]. Ces indicateurs offrent une base solide sur laquelle la détection de défauts est mieux assurée, où la recherche est effectuée au moyen de l'extraction d'énergie spectrale dans des plages fréquentielles relatives aux fréquences caractéristiques des défauts de roulements.

**Tableau 1.1:** Les indicateurs statistiques et leurs explications mathématiques [Raj 14]:

Indicateur statistique	Explication	Equation
Kurtosis	Il indique la forme du signal : pointue ou plate, la forme de la distribution normale de signal.	$KU = \frac{\sum_{t=1}^T (s_t - \bar{s})^4}{(T - 1)\sigma^4}$
Skewness	Il indique la symétrie du signal, direction et ampleur du signal.	$SK = \frac{\sum_{t=1}^T (s_t - \bar{s})^3}{(T - 1)\sigma^3}$
Variance	Elle désigne la dispersion du signal ondulé autour de son valeur moyenne.	$var = \frac{1}{T} \sum_{t=1}^T (s_t - \bar{s})^2$
Ecart-type	Elle désigne la distance des mesures et leur valeur moyenne.	$std = \sqrt{\frac{1}{T - 1} \sum_{t=1}^T (s_t - \bar{s})^2}$
RMS	Il désigne la sévérité de défaut par l'intensité de signal	$RMS = \sqrt{\left(\frac{1}{T} \sum_{t=1}^T s_t^2\right)}$
Facteur Crête	La valeur crête sur la valeur efficace	$Cr = \frac{\max s_t }{\sqrt{\frac{1}{T} \sum_{t=1}^T (s_t)^2}}$




Figure. 1.6. Procédure de calcul du Cepstre de puissance, Abs : est la valeur absolue, (Carré)<sup>2</sup> : est le carré, Log est le logarithme naturel [Boud16].

#### 1.3.2.5. Les méthodes de démodulation (analyse d'enveloppe)

Ces méthodes se concentrent principalement sur l'extraction du contenu spectral d'un signal qui correspond uniquement aux fréquences caractéristiques du défaut, c'est-à-dire, au lieu de prendre tout le contenu fréquentiel du signal, on ne prend que le contenu d'une bande fréquentielle bien déterminée.

Des différentes méthodes de filtrage ont été utilisées pour déterminer la bande fréquentielle utile, les méthodes les plus réputées sont : la transformée de Hilbert (TH) et les méthodes d'analyse temps-échelle comme (La transformée en ondelettes continue (TOC) ou discrète (TOD) et la transformation en paquet d'ondelettes (TPO)), et la méthode de décomposition modale empirique (EMD) [Jiang14].

Parmi les méthodes de démodulation (Détection d'enveloppe) par la TPO, on peut distinguer: la méthode de Sparsogramme [Tse13a], [Tse13b], la méthode Improved Kurtogram [Lei11], et Reinforced Kurtogram [Wang13]. D'autres approches sont aussi à noter : association de la transformée de Hilbert (TH) avec la TPO [Fan06]. L'optimisation par Essaims particulaires (Particle Swarm Optimisation (PSO)) [Tya17]. La combinaison entre les méthodes de Monte-Carlo séquentielles et la TPO [Wang15]. L'approche Wavelet Cross Spectrum (WCS) [Liu11], et Wavelet Spectrum (WS) [Liu08].

Dans [Randall11] une étude détaillée de l'ensemble de méthodes les plus réputées dans le diagnostic des défauts de roulements est donnée.

Une comparaison entre les différentes méthodes d'analyse vibratoire est donnée dans le Tableau 1.2.

#### 1.3.3. La thermographie

Récemment, les méthodes de surveillance par mesure de la température de fonctionnement sont utilisées pour le diagnostic des défauts mécaniques des systèmes, elles reposent sur la mesure de la chaleur dégagée par un système défaillant dans des zones précises. Beaucoup de travaux traitent l'analyse des moteurs électriques par analyse thermique [Glow17], [Nunez16], [Singh16], elles sont essentiellement basées sur

l'exploitation des sondes thermistance ou les caméras infrarouges pour mesurer la température de fonctionnement d'un moteur électrique. Les signaux issus de ces capteurs peuvent être traités par les méthodes de traitement d'images ou les méthodes de classification.

### **1.3.4. La pratique de l'analyse vibratoire**

#### **1.3.4.1. Mesure des vibrations**

Un système de mesures des vibrations est un ensemble de plusieurs instruments, il est utilisé pour fournir des valeurs mesurées d'une grandeur vibratoire (déplacement, vitesse, accélération). Ce système est dénommé « chaîne de mesure », il se présente sous forme d'une suite d'éléments constituant un seul chemin du signal depuis le capteur jusqu'au système d'affichage. Il est constitué d'un capteur, d'un système de traitement de l'information et un système d'affichage.

- **Capture des vibrations :** le capteur est un élément électrique qui transforme une énergie mécanique en un signal électrique suivant une loi physique bien déterminée. il est mis directement sous l'effort vibratoire par un moyen d'accrochage. Le choix d'emplacement d'un accéléromètre doit être fait en considérant une position qui reflète la direction du phénomène vibratoire visé par la mesure. Un capteur de vibration est caractérisé par sa bande de résonance. Le type Piézoélectrique est le plus courant.
- **Amplification :** le courant issu d'un capteur est amplifié pour faire apparaître toutes les amplitudes impliquées dans ce dernier.
- **Filtre anti-repliement :** le filtre de repliement (généralement un filtre pass-bas) est mis en place pour limiter la bande fréquentielle à étudier et pour faire face aux anomalies causées par le chevauchement lors de la phase d'échantillonnage.
- **Échantillonnage :** L'utilisation d'un algorithme de calcul numérique (outillage numérique) pour l'interprétation de l'information mesurée nécessite la numérisation du signal. Cette phase est effectuée à l'aide d'un convertisseur analogique/numérique (CAN), à une fréquence d'échantillonnage  $f_e$ . Cette fréquence d'échantillonnage détermine la résolution spectrale (fréquentielle)  $\Delta f$  à mesurer, où :

$$f_e = 2,56 F_{max}.$$

Le temps d'acquisition du signal est déterminé par l'intervalle de temps  $\Delta t$  qui correspond au temps d'acquisition d'un bloc de  $N$  échantillons. Pour le calcul d'un spectre, il est égal à :  $\Delta t = N/f_e = Nt_e$  avec  $t_e$  le pas d'échantillonnage, il est égal à  $1/f_e$ . Il est inversement

proportionnel à la largeur  $LPF$  de la plage fréquentielle dans laquelle on voudrait calculer le spectre :  $\Delta t = \frac{N}{f_e} = \frac{N}{2.56B} = \frac{NLS}{LPF} = \frac{1}{\Delta f}$ . où :  $NLS$  est le nombre de lignes du spectre.

Pour que les indicateurs caractéristiques issus d'un signal vibratoire soient significatifs, la durée d'acquisition du signal  $\Delta t$  doit présenter une cinquantaine de tours de l'arbre (au moins cinq périodes du phénomène qu'on cherche à identifier). Si la fréquence fondamentale de ce dernier est inférieure à la fréquence de rotation de la ligne d'arbres considérée (fréquence de passage des pôles, fréquence de coïncidence de denture, fréquence de cage de roulement) et comme cette fréquence  $F_{max}$  est inconnue, on procède de façon inverse en utilisant un filtre passe-bas très sélectif, appelé filtre anti-repliement, qui limite la plage d'analyse du signal au moins de la moitié de la fréquence d'échantillonnage [Boulanger09].

- **Collecteur de données** : ce sont des appareils compacts composés d'un CAN, de mémoire de stockage et d'interface servant à la communication avec un micro-ordinateur. Le collecteur peut aussi disposer d'entrées auxiliaires permettant de gérer d'autres capteurs (pression, température, humidité...) [Rak10].
- **Outil de traitement de données** : selon l'objectif de l'analyse et du diagnostic (sévérité, localisation, estimation de la durée de vie restante d'un composant), il est nécessaire de développer un système de traitement de données convenable, on distingue par exemple: les méthodes d'analyse spectrale (FFT, STFT), les méthodes à base de reconnaissance des formes ( $RdF$ ), les réseaux de neurones artificiels (RNAs), les systèmes experts (SE).

#### 1.3.4.2. Filtrage des signaux

Le bruit provenant de la machine ou d'autres sources externes comme l'environnement ou bien d'une machine voisine perturbent les informations collectées. Ils gâtent le signal, et par conséquent la qualité des caractéristiques du phénomène étudié (signatures des défauts). De ce fait, le rôle d'un filtre est de supprimer les composantes indésirables du signal d'entrée tout en conservant celles qui portent des informations utiles. De manière générale, le signal de sortie  $y(t)$  est obtenu par la convolution du signal d'entrée  $x(t)$  et de la réponse impulsionnelle du filtre  $H(t)$ , [Shen13] :

$$y(t) = x(t) * H(t) \quad (1.8)$$

On peut distinguer deux types de filtres principaux :

- **Les filtres analogiques :** c'est l'ensemble des composants électriques ou électroniques appliqués directement sur le signal analogique (résistance, inductance, condensateurs et composants actifs comme les amplificateurs opérationnels). Filtre anti-repliement (anti-chevauchement).
- **Les filtres numériques :** ils exigent préalablement la numérisation de signal, puis ils reposent entièrement sur un algorithme, tous les traitements sont réalisés grâce à des additionneurs, des multiplieurs numériques et des mémoires. Dans un filtre numérique, l'entrée  $x(t)$  et la sortie  $y(t)$  sont reliées par une équation de transfert. Dont l'objectif est d'améliorer le rapport signal/bruit où on peut distinguer : les filtres d'ondelettes, ainsi la moyenne synchrone temporelle « Time Synchronous Averaging, (TSA) ».

#### 1.3.4.3. Filtres d'Ondelettes

La transformée d'ondelette est une des méthodes de filtrage numérique les plus réputées. Elle est similaire principalement à la transformée de Fourier à fenêtre glissante STFT. Le signal à analyser est multiplié par une fonction d'ondelettes dite ondelette mère. Cependant, contrairement à la STFT dans la transformée en ondelettes la largeur de la fonction d'ondelettes se change pour chaque composante spectrale [Attoui15.a]. La largeur de la fonction d'ondelette est ajustable selon un facteur d'échelle jouant le rôle de l'inverse de la fréquence, où les fonctions de base couvrent une large gamme de fréquences dans un plan temps fréquence (la résolution d'analyse est proportionnelle au facteur d'échelle). Par contre la fenêtre de la transformée STFT est fixe, la résolution de l'analyse est la même pour tous les emplacements dans un plan temps fréquence.

L'avantage principal de la transformée en ondelettes est que la fenêtre de filtrage est ajustable. Pour isoler les discontinuités dans un signal et les informations spectrales de hautes fréquences la fonction mère d'ondelette se comprime, et elle se dilate pour les informations spectrales de basses fréquences. Notons que la transformée en ondelettes n'a pas une seule fonction mère comme la transformée de Fourier qui utilise seulement des sinus et des cosinus complexes, les ondelettes ont un ensemble infini de possibles fonctions de base.

Mathématiquement, la transformée en ondelettes est le produit de convolution d'un signal d'entrée avec la fonction mère d'ondelette, où les coefficients d'ondelettes sont déterminés suivant cette égalité [Rak 10]:

$$W_f(j, n) = x(t) * H(t) = \int_{-\infty}^{+\infty} x(t) \times h\left(\frac{t-n}{j}\right) dt \quad (1.9)$$

Avec :  $j$  est le facteur d'échelle qui caractérise sa localisation fréquentielle (dilatation),

**n**: le paramètre de décalage d'ondelette (translation).

Dans le cadre du diagnostic des défauts mécaniques, l'ondelette dyadique est la plus souvent appliquée. La transformée d'ondelettes dyadique permet de décomposer le signal en sous-bandes fréquentielles sans redondance, ceux-ci permettent de réaliser l'analyse sur une bande de fréquences bien déterminée [Tra 09].

Dans le cadre du diagnostic des défauts de roulements, la transformée en paquet d'ondelettes domine les méthodes habituelles de filtrage. Cependant, à l'inverse de la transformée en ondelettes continue qui se base sur des facteurs d'échelle et de translation continues, la transformée en paquets d'ondelettes (TPO) utilise un facteur d'échelle discret (d'ordre binaire) de l'ordre de  $2^j$ , ceci va diminuer la complexité algorithmique. La figure 1.7 montre une décomposition de signal  $x(t)$  en paquets d'ondelettes à trois niveaux de décomposition.

Nous constatons que la décomposition en paquets d'ondelettes permet d'aboutir une information fréquentielle plus fine que celle donnée par la transformée de Fourier.

La TPO est plus appropriée que la transformée en ondelettes discrète (TOD) pour le suivi des défauts de roulements, elle décompose le signal en des composants fréquentiels de basses fréquences (approximations) et de hautes fréquences (détails) où les composants détails sont aussi décomposés.

Une fonction de paquets d'ondelette est déterminée comme suit [Fan06]:

$$\omega_{j,n}^m(t) = 2^{j/2} \omega^m(2^j t - n) \quad (1.10)$$

Avec: **m** est le paramètre d'oscillation, le terme  $\omega^m(t)$  donne les deux premières fonctions de paquet d'ondelettes (**m=0, 1, j=k=0**) dites la fonction d'échelle  $\chi(t)$  et l'ondelette mère  $\psi(t)$ ,  $\omega^0(t) = \chi(t)$ ,  $\omega^1(t) = \psi(t)$ , avec:

$$h(n) = \frac{1}{\sqrt{2}} \langle \chi(t), \chi(2t - n) \rangle \quad (1.11)$$

$$g(n) = \frac{1}{\sqrt{2}} \langle \psi(t), \psi(2t - n) \rangle = (-1)^n h(-n + 1) \quad (1.12)$$

Les fonctions de paquet d'ondelettes pour **m=2,3,...** sont déterminées par:

$$\begin{aligned} \omega^{2m}(t) &= \sqrt{2} \sum_b h(n) \omega^m(2t - n), \\ \omega^{2m+1}(t) &= \sqrt{2} \sum_b g(n) \omega^m(2t - n) \end{aligned} \quad (1.13)$$

Où : **h(n)** et **g(n)** sont respectivement le filtre pass-bas et le filtre pass-haut. Pour les différentes valeurs de '**m**' la fonction de paquets d'ondelettes se localise dans une bande fréquentielle différente.

**Tableau 1.2:** Étude comparative entre les différentes méthodes d'analyse spectrale [Boud16].

Méthode	Avantages	Inconvénients
Transformée de Fourier rapide FFT	Le défaut est détectable	Elle exige un haut niveau d'expérience pour déterminer la nature de défaut.
Analyse Cepstral	Le défaut est détectable et la nature est identifiable avec un certain degré de confiance.	Elle génère beaucoup de pics indésirables à proximité du point zéro, qui rendent la mesure non interprétable. Aussi, la fréquence fondamentale est localisée à la droite de la figure, qui est à l'opposé des méthodes standards utilisées pour trouver la fréquence fondamentale.
Analyse d'Enveloppe	Le défaut et sa nature sont détectables.	Elle exige la connaissance de la fréquence de résonance et la largeur de la bande du filtre à l'avance. Qui demande un haut niveau d'expérience.
Transformée d'ondelette	Le défaut et sa nature sont détectables.	Comment déterminer l'ondelette mère ? Comment sélectionner le niveau de décomposition ? Comment sélectionner la bande fréquentielle qui contient les informations nécessaires ?

Les coefficients de paquet d'ondelettes d'un signal  $x(t)$  sont introduits dans le produit scalaire de signal avec toutes les fonctions de paquet d'ondelettes :

$$w_j^m(k) = \langle x, \omega_{j,n}^m \rangle = \int_{-\infty}^{+\infty} x(t) \omega_{j,n}^m(t) dt \quad (1.14)$$

À travers la manipulation de :  $m, j, k$ , chaque coefficient  $w_j^m(k)$  donne un nouveau contenu fréquentiel d'une sous-bande fréquentielle, ce dernier est contrôlé par le facteur d'échelle  $j$  et le paramètre d'oscillation  $m$ . Le but essentiel d'une TPO est le filtrage avec  $h(k)$  et  $g(k)$ . Le signal  $x(t)$  doit être analysé dans sa forme discrète :

$$x(t) = \{w_0^1(k), \text{où } k = 1, 2, \dots, N\} \quad (1.15)$$

N est la longueur du signal. Pour le  $j^{\text{ème}}$  niveau de décomposition, l'arbre de la décomposition en paquets d'ondelettes donne  $2^j$  coefficients d'une largeur de  $N/2^j$  échantillons dans le dernier niveau. Ceci est dû au fait de l'opération de décimation par 2 (down sampling)

#### 1.4. Les méthodes de diagnostic des défauts de roulements

Les roulements sont des éléments essentiels dans une machine puisqu'ils supportent les éléments rotatifs et facilitent leurs rotations. D'après un sondage de fiabilité des moteurs, 42% des défauts des moteurs de puissance de 200 HP sont dus aux roulements. Ce phénomène est plus élevé avec les moteurs de basse puissance, où plus de 90% des défauts sont dus aux roulements [Diaz17]. Les défauts de roulements représentent la majorité des défauts de la machine électrique tournante, la figure 1.8 montre la distribution des défauts dans une machine électrique tournante.

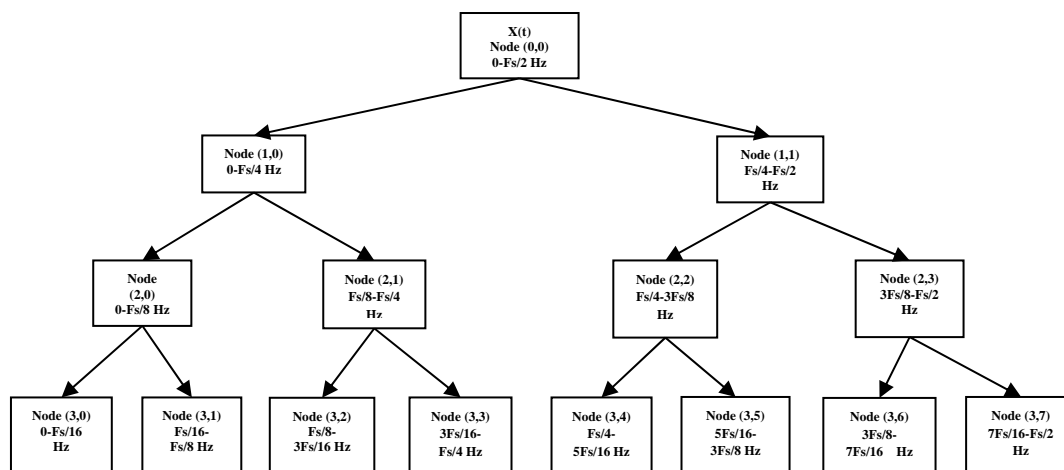


Figure 1.7. Arbre complet de décomposition en paquet d'ondelettes au troisième niveau.

##### 1.4.1. Détection des défauts de roulements par l'analyse des courants statoriques de la machine asynchrone

Il a été prouvé que le défaut de roulement produit une excentricité du rotor d'un moteur électrique, qui produit un changement périodique dans les inductances de la machine, elle peut produire des fréquences supplémentaires  $f_{bf}$  dans le courant du stator : les éléments roulants du roulement supportent le rotor, lors d'un défaut de roulement et pour chaque passage des éléments roulants sur le défaut, ils vont produire des mouvements purement



radiaux ou mixtes entre le rotor et le stator de la machine. Par conséquent, des variations d'entrefer génèrent dans le courant du stator des raies spectrales détectables dans un spectre du courant autour de la fréquence d'alimentation, elles sont données par :

$$f_{bf} = |f_s \pm kf_c| \quad (1.16)$$

Avec :  $f_s$  est la fréquence d'alimentation,  $f_c$  est la fréquence caractéristique d'un défaut de roulement, et  $k=1, 2, 3, \dots$

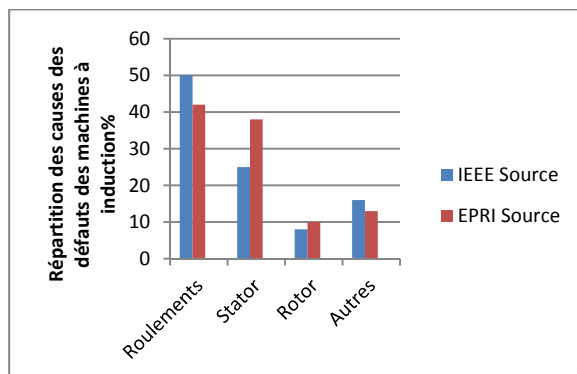


Figure. 1.8. Distribution des défauts dans une machine électrique tournante [Tra09].

La surveillance des courants statoriques nécessite une bonne connaissance des défauts et leurs signatures.

#### 1.4.2. Détection des défauts de roulements par l'analyse vibratoire

Dans le cadre d'analyse vibratoire des défauts de roulements, l'analyse est appliquée sur un signal vibratoire mesuré par un capteur installé sur l'arbre de la machine suivant une direction verticale ou horizontale. Les vibrations sont jugées favorables pour le diagnostic des défauts de roulements parce qu'elles sont directement associées au comportement dynamique du système et les conditions d'utilisation [Gao06].

Le diagnostic des défauts de roulements par la méthode FFT est une des méthodes de diagnostic classiques, elle repose sur la connaissance antérieure des fréquences caractéristiques des défauts (cf. section 1.1.2). Cependant, elle est limitée aux signaux stationnaires où le signal vibratoire issu des roulements défectueux est non stationnaire. En outre, les amplitudes dues aux phénomènes de modulation sont faibles et incompatibles avec les fréquences caractéristiques théoriques à cause du glissement, des fluctuations de la vitesse de rotation et du vieillissement des roulements [Sun16, attoui17], ce qui rend leur détection difficile.

L'analyse Cepstrale est couramment utilisée pour la détection des modulations. Néanmoins, elle génère des pics indésirables à proximité du point zéro, ce qui rend le résultat difficile à interpréter. De plus, la fréquence fondamentale est localisée à la droite de la figure, qui est non conforme aux méthodes standards utilisées pour trouver la fréquence fondamentale.

Les méthodes d'analyse d'enveloppe sont fréquemment utilisées pour la détection des défauts de roulement. Elles visent la restauration de signal modulé (fréquences de modulation) incorporé avec le signal d'onde porteuse (fréquence centrale de la fréquence porteuse), cette fréquence correspond aux multiples de la fréquence de passage d'une bille de roulement [Fan06]. Ensuite, les fréquences de modulation sont prises par la transformation de Fourier du signal restauré. Néanmoins, l'analyse d'enveloppe nécessite la connaissance antérieure de la fréquence centrale de la bande de fréquence et sa largeur [Tya17].

Parmi les méthodes de démodulation on peut distinguer : la méthode de Sparsogramme [Tse 13a], [Tse 13b], où la valeur de sparsity détermine la ou les bandes de fréquences de résonance dans l'arbre de paquet d'ondelettes. La méthode Improved Kurtogram [Lei 11], et Rienforced Kurtogram [Wang 13] déterminent la bande de résonance d'une décomposition en paquets d'ondelettes utilisant le kurtosis spectral, il mesure la saillie des coefficients de paquet d'ondelettes. La combinaison de la méthode Monte-Carlo séquentielle et la TPO [Wang 15] qui utilise la méthode d'optimisation Monte-Carlo pour estimer la fréquence centrale et la largeur de la bande du filtre d'ondelette utilisant le signal d'un défaut.

#### **1.4.2.1. La transformée de Fourier (TF)**

**Définition** (la transformée de Fourier) La transformée de Fourier  $X(f)$  d'un signal à énergie finie  $x(t)$  est déterminée comme le produit scalaire de ce dernier et une fonction de bases exponentielles complexes.

La TF est donnée pour un signal continu par (1.17), et calculée pour un signal discret par (1.18) [Tra09], [Attoui15b]. Elle est représentée par une somme de composantes de fréquences discrètes.

$$X(f) = \langle x(t), e^{2\pi jft} \rangle = \int_{-\infty}^{+\infty} x(t)e^{-2\pi jft} dt \quad (1.17)$$

$$X(m) = \sum_{k=0}^{N-1} x(k) e^{-\frac{2\pi jmk}{N}} \quad (1.18)$$

Le spectre d'un signal est la représentation en fonction des fréquences d'amplitudes des différentes composantes fréquentielles incorporées dans ce dernier.

Les résultats d'analyse spectrale par FFT des signaux des défauts simulés dans la section (1.2.2.2) sont donnés par les figures 1.9, 1.10.

#### 1.4.2.2. La démodulation par la transformée d'Hilbert

La majorité des défauts mécaniques dans une machine tournante génèrent des signaux vibratoires modulés en fréquence (défauts de roulements) ou en amplitude (défauts de balourd) ou en phase et amplitude (défauts d'engrenage). Dans le cas des défauts de roulements, ces modulations génèrent des composantes fréquentielles espacées de manière égale autour d'une fréquence centrale (cf. figure 1.9), cette fréquence centrale est dénommée la fréquence porteuse (de l'onde porteuse).

**Définition 1.2** La transformée de Hilbert est la convolution dans le domaine temporel d'un signal  $x(t)$  où la phase est changée de  $90^\circ$ , mais le contenu fréquentiel et les caractéristiques non stationnaires du signal modulé ne sont pas affectés.

Cette technique est appliquée dans le but de restaurer le signal de modulation incorporé avec le signal porteur.

La transformée d'Hilbert est donnée par:

$$H[x(t)] = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t-\tau} d\tau \quad (1.19)$$

La démodulation est accomplie par la construction du signal analytique :

$$A[x(t)] = x(t) + iH[x(t)] = a(t)e^{i\phi(t)}, i = \sqrt{-1}. \quad (1.20)$$

$a_m(t)$  et  $\phi_m(t)$  sont respectivement les fonctions de modulation d'amplitude et de phase.

Ensuite, le signal analytique dans sa forme temporelle complexe réel/imaginaire est converti en une forme amplitude/phase.

La modulation d'amplitude est donnée par:

$$a(t) = \sqrt{x^2(t) + H^2[x(t)]}, \quad (1.21)$$

La modulation de phase est donnée par:

$$\varnothing(t) = \arctan \frac{H[x(t)]}{x(t)}. \quad (1.22)$$

Et l'enveloppe est le module de la forme complexe du signal. Dans le cas de diagnostic des défauts mécaniques l'enveloppe est analysée par la FFT pour visualiser les fréquences caractéristiques comprises dans le spectre du signal démodulé.

#### 1.4.2.3. Méthode de kurtogramme

Le kurtogramme est le calcul du kurtosis des coefficients en sorties d'un banc de filtres de paquet d'ondelettes (filtre passe-haut et filtre passe-bas) [Antoni05]. Le kurtogramme est obtenu par le calcul du kurtosis sur toutes les séquences de coefficients  $w_j^m(k)$  des réponses impulsionnelles des deux filtres,  $i=0, \dots, 2^j-1$ ,  $j=0, \dots, J-1$  où  $J$  est le niveau de décomposition.

$$K_j^m = \frac{|w_j^m(k)|^4}{\langle |w_j^m(k)|^2 \rangle^2} - 2 \quad (1.23)$$

Les résultats de l'application de la méthode de Kurtogramme rapide (Fast Kurtogram) [Antoni07] sur les signaux simulés précédemment sont donnés dans les figures : 1.11, 1.12, 1.13 et 1.14. Les résultats sont trouvés conjoints avec les résultats anticipés.

La figure 1.10. donne l'application de la FFT sur le signal de défaut de bague interne simulé, la composante fréquentielle du défaut et ses multiples sont clairement montrés et indiquent l'apparition d'un défaut de bague interne. La figure 1.14. montre le même degré de résolution. La figure 1.12 montre clairement la composante qui correspond à la fréquence caractéristique de la bague externe et ses multiples.

#### 1.4.2.4. Méthode de Sparsogramme

**Définition 1.3** La mesure de sparsity est la mesure du nombre des valeurs de signal qui égale à zéro.

La valeur de sparsity d'une bande fréquentielle de paquet d'ondelettes  $w_j^m(k)$  est donnée comme suit :

$$S(j, m) = S_j^m = \frac{\sqrt{\sum_{k=0}^{Fs/2-1} (w_j^m(k))^2}}{\sum_{k=0}^{Fs/2-1} |w_j^m(k)|} = \frac{\|w_j^m(k)\|_2}{\|w_j^m(k)\|_1}, \quad (1.24)$$

$1 \leq j \leq J$ ,  $0 \leq m \leq 2^j - 1$ , où  $J$  est le niveau de décomposition,  $\|w_j^m(k)\|_2$  et  $\|w_j^m(k)\|_1$  sont respectivement le  $L_2$  norm et  $L_1$  norm. En mesurant le degré de dispersion pour chaque bande fréquentielle de l'arbre de paquet d'ondelettes. Le contenu spectral de la bande de fréquence de résonance peut être distribué dans une ou plusieurs bandes fréquentielles, donc la ou les bandes qui correspondent aux plus grandes valeurs de sparsity sont retenues. Ensuite, on reconstruit le signal qui correspond aux bandes fréquentielles retenues, le signal reconstruit est démodulé par la transformée de Hilbert pour obtenir l'enveloppe de signal. Finalement, le signal d'enveloppe est analysé par la transformée de Fourier pour visualiser les fréquences caractéristiques d'un défaut de roulements et leurs multiples.

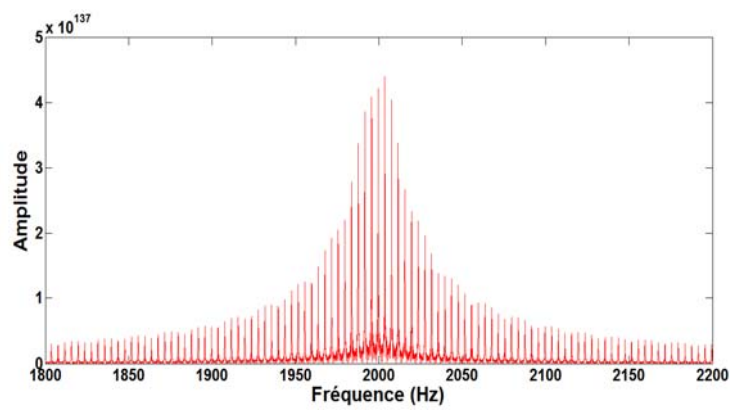


Figure.1.9. Spectre du signal vibratoire simulé avec prise en compte d'un mode propre de la bague externe (fréquence porteuse et ses harmoniques).




Figure.1.10. Spectre du signal simulé, défaut de bague interne.

Les figures 1.15, 1.16, 1.17 et 1.18, donnent l'application de la méthode de Sparsogramme sur les signaux simulés (section 1.2.2.2). Les résultats sont satisfaisants surtout pour le défaut de bague interne, l'amplitude modulée et ses harmoniques sont clairement données par le spectre d'enveloppe.

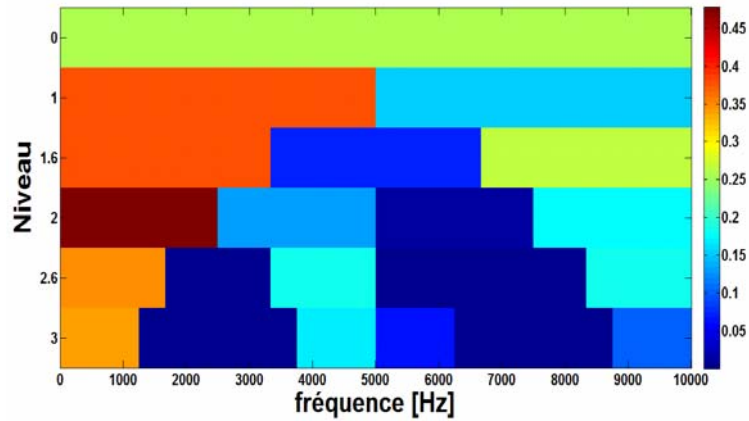


Figure. 1.11. Kurtogramme du signal simulé (défaut de bague externe)

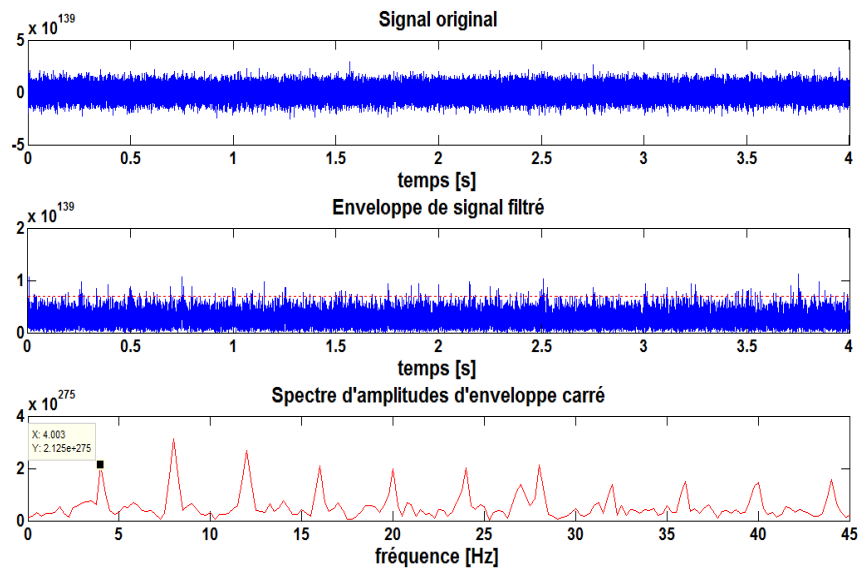


Figure. 1.12. Analyse d'enveloppe du signal simulé (défaut de bague externe), approche de Kurtogramme.

#### 1.4.2.5. Étude de la stabilité des indicateurs caractéristiques des défauts de roulements

Une étude de la stabilité des indicateurs temporels d'un défaut de roulements est réalisée sur l'ensemble des signaux simulés. Les figures 1.19 et 1.20, représentent les résultats de la variation des indicateurs caractéristiques statistiques des signaux des défauts simulés en fonction d'un bruit blanc gaussien. L'objectif de cette expérience est de repérer l'un ou les indicateurs qui représentent une instabilité face aux effets de bruits.




Figure. 1.13. Kurtogramme du signal simulé (défaut de bague interne)




Figure. 1.14. Analyse d'enveloppe du signal simulé (défaut de bague interne), approche de Kurtogramme.

La majorité des indicateurs montrent une stabilité face aux effets de bruits. Ces indicateurs peuvent être utilisés pour le suivi des défauts de roulement car l'utilisation des indicateurs dits instables affecte la fiabilité du système de surveillance. Ces derniers sont plus sensibles aux bruits qu'aux signatures des défauts.

### 1.5. Les approches de diagnostic par intelligence artificielle (IA)

Dans le cadre de la maintenance conditionnelle et prévisionnelle, les méthodes de diagnostic automatiques (détection automatique) sont mises en place pour limiter les effets de l'intervention humaine et particulièrement pour les installations qui exigent un haut

niveau de sécurité de service. Ces approches sont prénommées méthodes d'intelligence artificielle (IA). Elles reposent sur la modélisation des connaissances survenues des enregistrements de données des événements utiles et d'un retour d'expérience qui peuvent provenir des expériences passées sur le système. Parmi ces approches on peut distinguer : les réseaux de neurones (NN) [Yang04], [Yang06], [Zha12], la méthode Fuzzy C-means (FCM) et ANFIS (Adaptive Nerro-Fuzzy Inference System) [Zhang10], [Attoui15b], [Lou04], [A-Rub11], [Altug99], les systèmes experts flous [Sun16]. Ainsi les modèles de Markov cachés (HMM), le modèle de mélange gaussien (GMM) [Nelw06], et la méthode des proches voisins (notés parfois k-PPV ou k-NN, k-Nearest-Neighbor classifier).

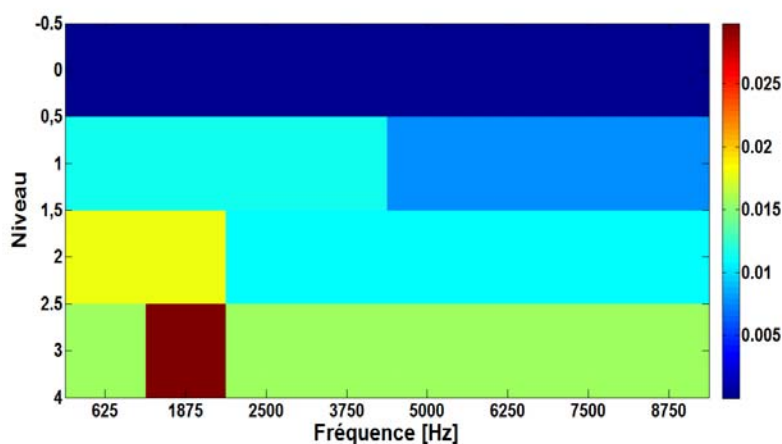


Figure. 1.15. Sparsogramme du signal simulé (défaut de bague externe).

Les réseaux de neurones reposent sur la construction d'un modèle qui décrit le comportement normal ou défectueux à partir d'une base de données, les éléments appelés couches sont reliés les uns aux autres avec des connexions (neurones), la transition entre eux est faite à travers une fonction d'activation et des poids de pondération, où pour chaque valeur de sortie non conforme à la sortie désirée, le système actualise ces poids jusqu'à ce qu'il arrive au critère voulu.

L'intérêt principal de leur utilisation en diagnostic est la robustesse d'apprentissage face aux déformations de l'information par le bruit, par contre, elles représentent deux inconvénients majeurs: la convergence lente, et une séparation conflictuelle des classes dans le cas de nombre insuffisant d'échantillons dans la phase d'apprentissage [Shen13].

Les méthodes de la logique floue sont fondées sur la construction d'un système expert modélisé par un ensemble des fonctions d'appartenance. Ces fonctions sont issues d'après une phase d'apprentissage ou d'un retour d'expérience. La prise de décision est effectuée à



partir d'un ensemble de règles 'si-alors' (if-then) qui traduisent les connaissances d'experts. La LF est appropriée pour le traitement de données imprécises et incertaines [Zhang10].




Figure. 1.16. Spectre d'amplitudes d'enveloppe (défaut de bague externe), approche de Sparsogramme.

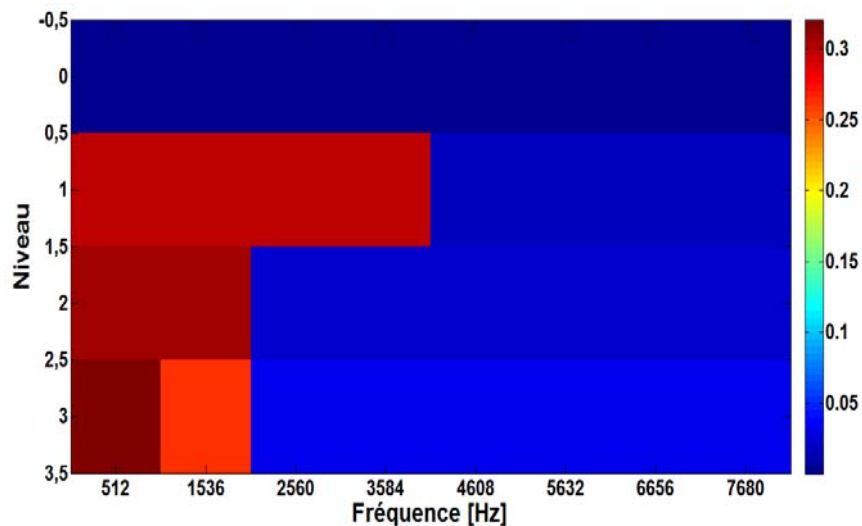


Figure. 1.17. Sparsogramme de signal simulé (défaut de bague interne).

L'ANFIS est une extension de ces deux approches discutées précédemment, elle comporte les avantages des deux approches, il est largement utilisé dans la surveillance en temps réel. Un des inconvénients majeurs est que les paramètres du modèle sont donnés par l'utilisateur dans la phase d'ajustement (nombre d'époques), aussi, le nombre de règles floues est de l'ordre de  $2^n$  ( $n$  est le nombre d'entrées). Ceux-ci diminuent la transparence du système et augmentent légèrement la complexité du système (système à plusieurs entrées).

La méthode machine à vecteurs de support (SVM) est largement appliquée au diagnostic des défauts de roulements, une application plus appropriée au diagnostic des défauts de roulements est publiée récemment par [Hui17].




Figure. 1.18. Spectre d'amplitudes d'enveloppe (défaut de bague interne), approche de Sparsogramme.

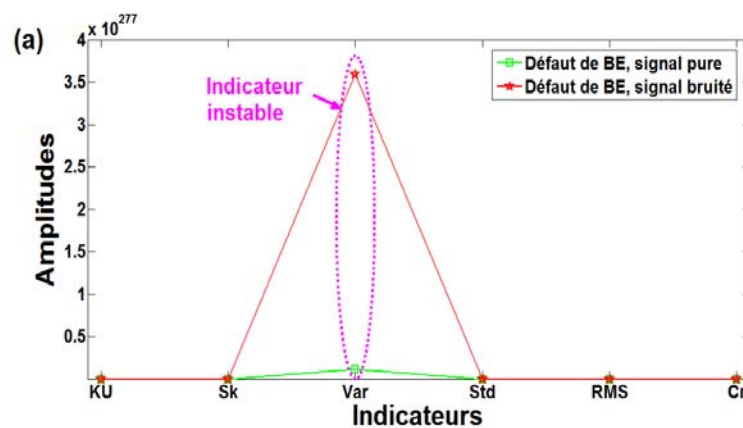


Figure. 1.19. Étude de la stabilité des indicateurs temporels d'un défaut de bague externe.

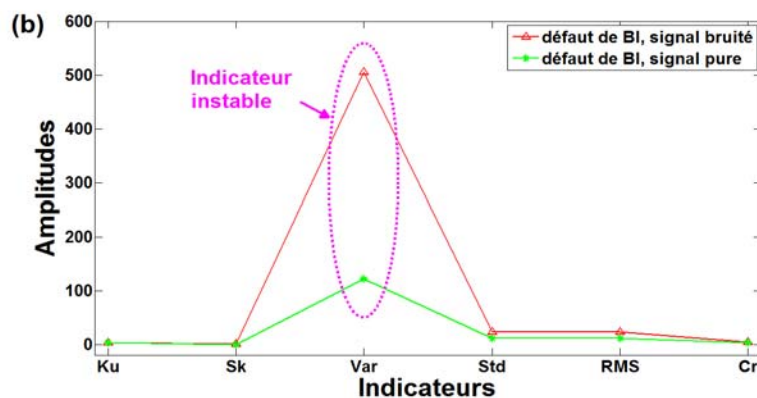


Figure. 1.20. Étude de la stabilité des indicateurs temporels d'un défaut de bague interne.

### **1.6. Conclusion :**

Le diagnostic des défauts de roulements est un enjeu majeur dans les applications industrielles modernes. Parmi les méthodes de diagnostic des défauts de roulements traitées dans ce chapitre, les méthodes d'analyse par détection d'enveloppe sont jugées très précises pour la détection des défauts localisés de roulements. Néanmoins, elles exigent un bon retour d'expérience pour la définition de la fréquence centrale dite porteuse et la largeur d'enveloppe.

Dans le cadre des méthodes de classification et de la définition de la sévérité des défauts de roulements, les méthodes de la logique floue sont jugées très adéquates, elles permettent de diminuer l'intervention humaine par l'expression des connaissances d'experts avec des fonctions d'appartenance et des règles logiques qui servent à rendre une classification précise des défauts.

En outre, la stabilité des indicateurs est un enjeu majeur dans le cadre de la détection automatique des défauts, dans lequel beaucoup de littératures ont discuté la stabilité des indicateurs caractéristiques des défauts où elles ont donné naissance aux méthodes de sélection des indicateurs.

## **Chapitre II**

**Analyse des défauts de roulements  
d'une machine électrique par  
l'analyse des courants statoriques.**

## **2.1. Introduction**

Ce chapitre est dédié à l'élaboration des méthodes de diagnostic des défauts de roulements dans les machines asynchrones par l'analyse fréquentielle des courants statoriques.

Dans un environnement industriel, les courants statoriques sont préalablement mesurés pour la commande de la machine et les dispositifs de protection, ceci va diminuer le coût d'implantation d'un système de diagnostic basé sur l'analyse des courants statoriques.

Nous allons tout d'abord nous intéresser aux défauts de roulements qui entraînent l'excentricité mécanique du rotor et les oscillations du couple de charge, dans ce chapitre on va traiter les défauts de roulements dans un entraînement électromécanique, ainsi que leurs effets sur les courants statoriques de la machine dans le cas d'excentricité rotorique et des oscillations du couple de charge.

Les défauts d'excentricité sont classés en trois types où on peut distinguer : l'excentricité statique qui est caractérisée par le déplacement de l'axe du rotor par rapport à l'axe du stator dans une seule direction (un seul degré de liberté), et l'excentricité dynamique qui est caractérisée par un mouvement circulaire de l'axe du rotor par rapport à l'axe du stator. Le phénomène composé des deux types s'appelle excentricité mixte.

L'excentricité d'entrefer dans une machine électrique cause un stress excessif sur la machine. Elle augmente la sévérité de l'usure des roulements et par la suite des vibrations nocives, où le point ultime est le frottement rotor /stator, ceci cause des dommages du corps du stator et d'enroulements. Alors, le suivi permanent des effets d'excentricité du rotor sur les paramètres électriques de la machine est hautement recommandé pour pouvoir prévenir à des scénarios indésirables [Rou08], pour cela, les mesures des paramètres les plus utilisées pour ce suivi sont : la mesure de la force électromagnétique, la mesure de flux d'entrefer, et la mesure des ondes de flux magnétique (produit de la force magnétomotrice et la perméance). L'inconvénient majeur de ces approches est l'inaccessibilité de certaines données, l'ignorance d'implication et la dépendance de certains paramètres comme le glissement rotor/stator ou les effets des charges extérieurs de la machine.

Ce chapitre présente un modèle dédié au diagnostic des défauts de roulements par l'analyse des courants statoriques. Pour mesurer l'effet des défauts de roulement sur les courants statoriques, les courants sont simulés en tenant compte de l'excentricité rotor

/stator. Ici, les courants sont donnés par l'exploitation de l'approche de la mesure de la force magnétomotrice FMM et la perméance.

L'objectif prescrit de l'approche-modèle est de fournir une fondation forte de connaissances, car il est indispensable de pouvoir caractériser précisément dans un spectre du courant : comment varient les amplitudes des harmoniques relatifs aux défauts en fonction de leurs fréquences ?

Il est à noter que les amplitudes faibles correspondantes aux fréquences caractéristiques des défauts sont cachées par le bruit et d'autres fréquences de base. Dans le régime transitoire les fréquences qui correspondent aux défauts sont très proches à la fréquence fondamentale [Lep11]. En outre, les courants d'alimentation contiennent des perturbations et les capteurs des courants statoriques sont généralement placés dans un environnement perturbant. En effet, les machines et les convertisseurs statiques rayonnent des champs électromagnétiques pouvant introduire des interférences et, de là, ils créent ainsi un bruit additif à la mesure. Certaines fréquences de ce bruit peuvent apparaître au niveau du spectre du courant lors de numérisations du signal à cause d'un mauvais choix de la fréquence d'échantillonnage [Boudinar15].

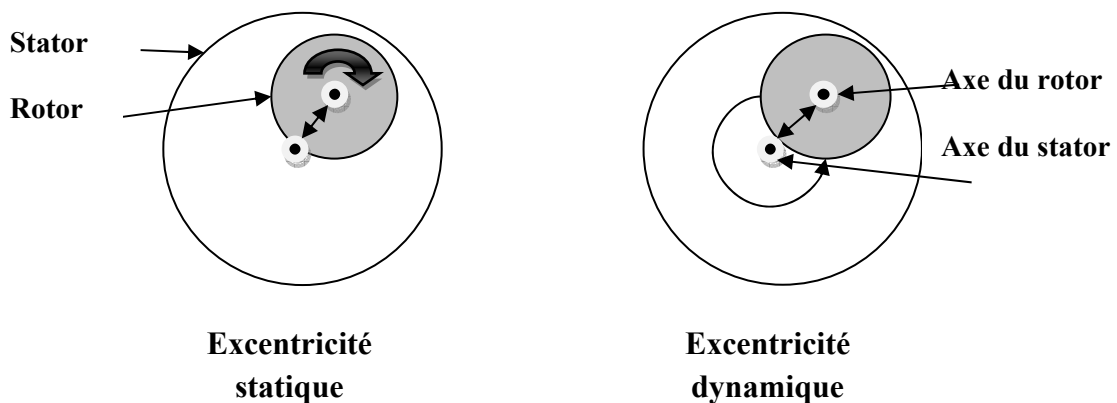


Figure. 2.1. Représentation schématique d'excentricité statique et dynamique

## **2.2. Effets mécaniques des défauts de roulements sur une machine asynchrone**

Dans une machine asynchrone les défauts mécaniques sont regroupés en deux catégories : ceux qui entraînent une excentricité rotor/stator et ceux qui entraînent une oscillation du couple de charge. Il a été souvent montré que les défauts de roulements entraînent un défaut d'excentricité dynamique.

Une excentricité dynamique dans une machine asynchrone est caractérisée par le déplacement du centre géométrique du rotor par rapport à celui du stator, comme la montre la Figure. 2.1.

### **2.2.1. Excentricités mécaniques dues aux défauts de roulements**

Il a été montré dans le chapitre précédent que les roulements sont des éléments mécaniques complexes où ils peuvent être considérés comme un système mécanique. Ils sont composés de quatre éléments principaux : bague externe, bague interne, et des billes qui sont maintenues par une cage qui assure l'espacement et le graissage.

La majorité des machines asynchrones à moyenne tension comportent deux roulements à un seul rang de billes (un de côté charge et un autre de côté ventilateur), ils sont utilisés pour supporter la charge du rotor, assurer sa rotation libre, et maintenir l'entrefer stator/rotor. La bague externe d'un roulement est fixée dans le palier que lui-même est fixé à la structure porteuse du stator. D'autre part, la bague interne tourne avec le rotor, elle supporte les charges statiques et dynamiques de celui-ci et les transmet à la bague externe à travers les billes.

Théoriquement, un défaut localisé sur la piste de la bague interne ou externe est simulé par un trou d'un diamètre et profondeur fixes. Le passage d'une bille sur le défaut produit un déplacement radial de bille et suivi d'un déplacement radial de la bague interne par rapport à la bague externe, ce phénomène génère une modification de l'entrefer, et par la suite la modification des paramètres électriques de la machine.

#### **2.2.1.1. Déplacement radial d'une bille du roulement en présence d'un défaut localisé [Tra09]**

Lorsqu'une bille entre en contact avec un défaut localisé, elle résulte un déplacement radial. Théoriquement, le degré de déplacement égale au niveau d'indentation de la bille dans cette encoche comme suit:

$$\epsilon = \frac{D_b}{2} \left( 1 - \sqrt{1 - \frac{D_h^2}{BD^2}} \right) \quad (2.1)$$

Avec :

- BD le diamètre de bille d'un roulement.
- $D_h$  la largeur apparente du défaut localisé.

Cette mesure est limitée à certains niveaux car les billes voisines répartissent la charge du rotor et par conséquent l'indentation maximale d'une bille dans la bague. Par conséquent, l'excentricité et l'épaisseur d'entrefer sont plus inférieures à cette mesure.

### **2.2.1.2. Déplacement radial de la bague interne du roulement par rapport à la bague externe (Excentricités résultante)**

Dans ce cas on suppose que les contacts bille/bague ne sont pas totalement rigides. Le niveau d'indentation de la bille est fonction des charges radiales appliquées sur la bille, le niveau d'indentation est mesuré d'après la théorie du contact bille/plan d'Hertz comme suite [Tra09]:

$$\epsilon_H = \sqrt[3]{\frac{18F_r^2}{16 \times BD \times E_*^2}} \quad (2.2)$$

Avec :

- $F_r$  le poids du rotor de la machine en N,
- $E_*$  le module d'Young normalisé.
- Le module d'Young normalisé s'exprime :  $\frac{1}{E_*} = \frac{1-cp}{E_1} + \frac{1-cp_2^2}{E_2}$  (2.3)

Avec :

- $E_1=E_2$  : le module d'Young de l'acier en GPa,
- $cp_1=cp_2$  : le coefficient de Poisson de l'acier.

On suppose que les deux matériaux constituant les bagues sont identiques.

Il est important de noter que ***n-1*** des billes de la zone de charge sont considérées pour la mesure de niveau de déplacement radial de la bague interne par rapport à la bague externe (cf. figure 2.2).

Il a été jugé que le degré d'excentricité minimale considéré comme détectable par une analyse des courants statorique est d'au moins 20% de l'entrefer moyen de la machine [Tra09].



### 2.3. Effets des défauts de roulements sur les courants statoriques d'une machine asynchrone

L'apparition d'harmoniques dans les courants statoriques de la machine asynchrone en présence d'excentricités ou d'oscillations du couple de charge est liée généralement aux défauts de roulements, où dans un spectre du courant, les défauts de roulement sont associés à l'apparition des harmoniques comme composantes latérales au fondamental d'alimentation. Les oscillations du couple de charge  $f_{osc}$  apparaissent dans le spectre de densité d'un courant aux fréquences  $f_s \pm k f_{osc}$ . Où  $k=1, 2, 3, \dots$ .

Le tableau 2.1 donne un récapitulatif sur les fréquences des défauts de roulement dans un spectre de densité spectrale du courant statorique.

**Tableau 2.1.** Fréquences relatives aux défauts de roulements dans un spectre du courant.

	Selon : Schoen [Sch95]	Selon : [Blo08]	
		Excentricité	Oscillations du couple
Défaut de bague externe	$f_s \pm k f_{BE}$	$f_s \pm k f_{BE}$	$f_s \pm k f_{BE}$
Défaut de bague interne	$f_s \pm k f_{BI}$	$f_s \pm f_r \pm k f_{BI}$	$f_s \pm k f_{BI}$
Défaut de bille	$f_s \pm k f_{bille}$	$f_s \pm f_{cage} \pm k f_{bille}$	$f_s \pm k f_{bille}$

Dans la section (2.2.1.2), il a été signalé que les défauts localisés de petite taille dans un roulement font apparaître également des micro-variations de l'épaisseur de l'entrefer qui sont presque indétectables par une analyse des courants statoriques.

### 2.4. Modèles des courants statoriques d'un moteur asynchrone dédiés au diagnostic des défauts de roulements

La modélisation des moteurs électriques est essentiellement appliquée dans le domaine de la commande de la machine. Cependant, elle donne une image claire sur le comportement mécanique et électrique du moteur utilisant des équations électriques où elles tiennent compte les contraintes physiques des défauts.

Il a été vérifié dans la section (2.2.1) que la majorité des défauts mécaniques et précisément les défauts de roulements causent le déplacement du centre du rotor par rapport au stator. Ici, l'excentricité mixte est le type le plus fréquent pour ce type de défauts. En effet, un changement de la géométrie et de l'épaisseur d'entrefer est engendré,

il cause la modification de la distribution de densité du flux dans l'entrefer. Par conséquent, il produit la modification des quantités électriques relatives à l'entrefer comme [Blo06],

- Le déséquilibre de la force d'attraction rotor/stator, en direction de la petite section d'entrefer parce que la densité du flux est plus grande dans cette région, □
- Génération des vibrations et des bruits à cause de la modification de la distribution de la densité du flux d'entrefer et le déséquilibre d'attraction rotor /stator, □
- Apparition des fréquences particulières dans le spectre du courant, □
- Le changement des composantes oscillatoires du couple électromagnétique. □

#### **2.4.1. Modèle des courants statoriques d'une machine asynchrone saine**

Dans cette partie du travail, nous nous intéresserons principalement à l'implantation des équations électriques d'une machine asynchrone en régime sain en un modèle de simulation sous Matlab/Simulink. Des résultats de simulation (du courant statorique), pour un régime de fonctionnement sain seront présentés. Puis, cette étape est associée par la suite avec une analyse fréquentielle d'un des courants statoriques.




Figure. 2.2. Déplacement radial de la bague interne par rapport à la bague externe lors d'un défaut localisé.

De ce fait, il est indispensable d'imposer certaines hypothèses qui ont pour but de faciliter la mise en équations des circuits électriques de la machine [Ali09] :

- Pour ce modèle, on suppose la linéarité du circuit magnétique (perméabilité relative du fer très grande de 1). Cette hypothèse nous a permis d'utiliser le concept d'inductances propres et mutuelles entre les bobines statoriques et rotoriques.
- La saturation du circuit magnétique n'est pas considérée, ni son hystérésis, ce qui entraîne un champ magnétique sinusoïdal.
- On suppose que la construction mécanique est parfaitement équilibrée, l'entrefer est lisse, et la dispersion du champ magnétique aux bouts de la machine est négligeable.
- L'effet de peau est négligé.
- Nous supposons que les barres rotoriques sont parfaitement isolées les unes des autres, ce qui permet d'éliminer les courants inter-barres et leurs effets au sein de la cage rotorique.
- Les pertes fer de la machine, les effets capacitifs et les effets thermiques sont négligées dans la construction du modèle de la machine asynchrone à cage d'écureuil.
- Le neutre n'est pas relié.

Le principe de fonctionnement d'une machine asynchrone est exprimé par les principes I, II, III de l'électromagnétisme [Wil05]. Un champ tournant créé par le courant fournit aux enroulements statoriques par le réseau, au même temps, des courants sont induits dans les enroulements rotoriques (les barreaux dans notre cas), lorsque le champ tournant passe par ces conducteurs, il va créer une force d'attraction, cette force d'attraction entre pôles stator/rotor n'est possible que lorsque la vitesse du champ tournant est différente de celle du rotor (asynchronisme à cause du glissement entre le champ statorique et rotorique).

Une représentation schématique des enroulements d'un moteur asynchrone à cage d'écureuil est présentée dans la figure 2.3.

Avec :  $a_s, b_s, c_s$ , sont les enroulements des phases du stator, et  $a_r, b_r, c_r$  sont les enroulements du rotor court-circuités.  $\theta$  est l'angle électrique (position angulaire) entre le rotor et le stator.

Selon la loi de Faraday, nous pouvons écrire :

$$v = Ri + \frac{d\varphi}{dt} \quad (2.4)$$

Pour les trois phases du stator, l'équation (2.4) sera égale à :

$$\begin{bmatrix} v_{as} \\ v_{bs} \\ v_{cs} \end{bmatrix} = R_s \begin{bmatrix} i_{as} \\ i_{bs} \\ i_{cs} \end{bmatrix} + \frac{d}{dt} \begin{bmatrix} \varphi_{as} \\ \varphi_{bs} \\ \varphi_{cs} \end{bmatrix} \quad (2.5)$$

La résistance est la même pour les trois bobines du stator donc :

$$[v_{abcs}] = R_r [i_{abcs}] + \frac{d}{dt} [\varphi_{abcs}] \quad (2.6)$$

De même pour le rotor :

$$[v_{abcr}] = R_r [i_{abcr}] + \frac{d}{dt} [\varphi_{abcr}] = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} \quad (2.7)$$

Parce que le rotor est en court-circuit, ses tensions sont nulles.

- $[V_{abcs}], [V_{abcr}]$  : vecteurs des tensions statoriques et rotoriques,
- $[I_{abcs}], [I_{abcr}]$  : vecteurs des courants statoriques et rotoriques,
- $[\varphi_{abcs}], [\varphi_{abcr}]$  : vecteurs des flux statoriques et rotoriques,
- $[R_s], [R_r]$  : matrices des résistances statoriques et rotoriques.

Les flux totalisés  $\varphi_s, \varphi_r$  des phases statoriques et rotoriques s'expriment en :

$$[\varphi_s] = [L_s][I_s] + [M_{sr}][I_r] \quad (2.8)$$

$$[\varphi_r] = [L_r][I_r] + [M_{sr}][I_s] \quad (2.9)$$

L'isotropie et la symétrie de la machine font les inductances propres des phases statoriques égales et de même pour celles du rotor, où :

$$[L_s] = \begin{bmatrix} L_s & M_s & M_s \\ M_s & L_s & M_s \\ M_s & M_s & L_s \end{bmatrix}, [L_r] = \begin{bmatrix} L_r & M_r & M_r \\ M_r & L_r & M_r \\ M_r & M_r & L_r \end{bmatrix} \quad (2.10)$$

Avec :

- $L_s, L_r$  : inductances propres statoriques et rotoriques,
- $M_s$  : inductance mutuelle entre deux phases du stator,
- $M_r$  : inductance mutuelle entre deux phases du rotor.
- Les inductances mutuelles entre les phases du stator et du rotor dépendent de la position angulaire  $\theta$  entre l'axe du stator et celui du rotor.

Donc l'équation (2.8) s'écrit pour la phase 'a' statorique:

$$\varphi_{as} = L_s i_{as} + m_s i_{bs} + m_s i_{cs} + m_1 i_{ar} + m_2 i_{br} + m_3 i_{cr} \quad (2.11)$$

Généralement on peut déduire :

$$\begin{bmatrix} \varphi_{as} \\ \varphi_{bs} \\ \varphi_{cs} \end{bmatrix} = \begin{bmatrix} L_s & m_s & m_s & m_1 & m_3 & m_1 \\ m_s & L_s & m_s & m_2 & m_1 & m_3 \\ m_s & m_s & L_s & m_3 & m_2 & m_1 \end{bmatrix} = \begin{bmatrix} i_{as} \\ i_{bs} \\ i_{cs} \end{bmatrix} \quad (2.12)$$

$$\begin{bmatrix} \varphi_{ar} \\ \varphi_{br} \\ \varphi_{cr} \end{bmatrix} = \begin{bmatrix} m_1 & m_2 & m_3 & l_r & m_r & m_r \\ m_3 & m_1 & m_2 & m_r & l_r & m_r \\ m_2 & m_3 & m_1 & m_r & m_r & l_r \end{bmatrix} = \begin{bmatrix} i_{ar} \\ i_{br} \\ i_{cr} \end{bmatrix} \quad (2.13)$$

Avec :

$$\begin{cases} m_1 = m_{sr} \cos(\theta) \\ m_2 = m_{sr} \cos\left(\theta - \frac{2\pi}{3}\right) \\ m_3 = m_{sr} \cos\left(\theta + \frac{2\pi}{3}\right) \end{cases} \quad (2.14)$$

$m_{sr}$  est le maximum de l'inductance mutuelle entre une phase du stator et une autre du rotor.

Pour simplifier ce modèle et pour éviter les difficultés de résolution du système, la transformation de Park permet de résoudre ce problème. L'objectif de cette transformation est de passer d'un système triphasé  $a, b, c$  vers un système diphasé  $d, q$ , où les enroulements réelles  $d_s, q_s, d_r, q_r$ , du rotor et du stator sont substitués par des enroulements fictifs liés aux axes  $d, q$ . (cf. figure 2.3).

Dans un espace de courant, la transformation s'écrit :

$$\begin{aligned} [I_{dqo}] &= [A][I_s] \\ [I_s] &= [A]^{-1}[I_{dqo}] \end{aligned} \quad (2.15)$$

Et celle de tension:

$$\begin{aligned} [U_{dqo}] &= [A][U_s] \\ [U_s] &= [A]^{-1}[U_{dqo}] \end{aligned} \quad (2.16)$$

La transformation des flux :

$$\begin{aligned} [\varphi_{dqo}] &= [A][\varphi_s] \\ [\varphi_s] &= [A]^{-1}[\varphi_{dqo}] \end{aligned} \quad (2.17)$$

A est la matrice de transformation orthogonale modifiée :

$$[A] = \sqrt{\frac{2}{3}} \begin{bmatrix} \cos(\theta) & \cos(\theta - 2\pi/3) & \cos(\theta + 2\pi/3) \\ -\sin(\theta) & -\sin(\theta - 2\pi/3) & -\sin(\theta + 2\pi/3) \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \quad (2.18)$$

$$[A]^{-1} = [A]^T = \sqrt{\frac{2}{3}} \begin{bmatrix} \cos(\theta) & -\sin(\theta) & \frac{1}{\sqrt{2}} \\ \cos(\theta - 2\pi/3) & -\sin(\theta - 2\pi/3) & \frac{1}{\sqrt{2}} \\ \cos(\theta + 2\pi/3) & -\sin(\theta + 2\pi/3) & \frac{1}{\sqrt{2}} \end{bmatrix} \quad (2.19)$$




Figure 2.3. Représentation des enroulements du stator et du rotor.

Avec :  $\theta = \theta_s - \theta_r$ , l'angle entre l'axe de la phase  $a_s$  et la phase  $a_r$ .

Pour calculer les angles de transformation de Park  $\theta_s$ ,  $\theta_r$ , il faut fixer le repère  $dq$  au stator.

$$\begin{aligned} [I_{dqo}] &= [i_d, i_q, i_o]^T, \\ [U_{dqo}] &= [U_d, U_q, U_o]^T. \end{aligned}$$

Dans un référentiel tournant synchronisé (c.à.d. que les deux flux, statorique et rotorique tournent à la même vitesse), il s'écrit sous forme matricielle :

$$\begin{bmatrix} V_{ds} \\ V_{qs} \\ 0 \\ 0 \end{bmatrix} = \begin{bmatrix} R_s + \frac{dL_s}{dt} & -\omega_s L_s & \frac{dM}{dt} & -\omega_s M \\ \omega_s L_s & R_s + \frac{dL_s}{dt} & \omega_s M & \frac{dM}{dt} \\ \frac{dM}{dt} & -Mg\omega_s & R_r + \frac{dL_r}{dt} & -L_r g\omega_s \\ Mg\omega_s & \frac{dM}{dt} & L_r g\omega_s & R_r + \frac{dL_r}{dt} \end{bmatrix} = \begin{bmatrix} i_{ds} \\ i_{qs} \\ i_{dr} \\ i_{qr} \end{bmatrix} \quad (2.20)$$

- g: glissement,
- $V_{ds}$  : composante de la tension suivant l'axe d,
- $V_{qs}$  : composante de la tension suivant l'axe q,
- $i_{ds}$  : composante du courant statorique suivant l'axe d,
- $i_{qs}$  : composante du courant statorique suivant l'axe q,
- $i_{dr}$  : composante du courant rotorique suivant l'axe d,
- $i_{qr}$  : composante du courant rotorique suivant l'axe q,

–  $M = \frac{3}{2}M_{rs}$  : Inductance mutuelle cyclique stator/rotor.

En régime permanent, les courants statoriques s'écrivent alors sous la forme triangulaire:

$$\begin{aligned} i_a &= \sqrt{2}I_s \cos(\omega_s t + \phi), \\ i_b &= \sqrt{2}I_s \cos(\omega_s t + \phi - 2\pi/3), \\ i_c &= \sqrt{2}I_s \cos(\omega_s t + \phi + 2\pi/3). \end{aligned}$$

Dans un référentiel lié au champ tournant, l'application de la transformation de Park:

$$\begin{aligned} i_{ds} &= \sqrt{3}I_s \cos(r) = cte, \\ i_{qs} &= \sqrt{3}I_s \sin(r) = cte \\ i_{os} &= 0. \end{aligned}$$

$r$  : est l'angle de phase à l'origine entre le courant et la tension.

Les flux totalisés sont constants, donc les tensions induites sont négligées:

$$\begin{aligned} V_{ds} &= R_s i_{ds} - \omega_s L_s i_{qs} - \omega_s M i_{qr} \\ V_{qs} &= R_s i_{qs} + \omega_s L_s i_{ds} + \omega_s M i_{dr} \\ 0 &= R_r i_{dr} + g \omega_s L_r i_{qr} - g \omega_s M i_{qs} \\ 0 &= R_r i_{qr} - g \omega_s L_r i_{dr} + g \omega_s M i_{ds} \end{aligned} \quad (3.21)$$

Les équations développées sont utilisées pour construire un modèle sous Matlab/Simulink qui exprime la relation entre le comportement mécanique d'un moteur et son influence sur ses grandeurs électriques. Les paramètres de la machine sont donnés par [Tra09] (cf. annexe, tableau 3). Il est à noter que les paramètres de la machine ne sont pas toujours accessibles, une méthode d'estimation des paramètres est indispensable [Palacky13]. Le modèle sous Simulink est donné dans l'annexe (cf. annexe, figure 1).

Les résultats de simulation des courants de la machine dans le cas sain sont donnés par la figure 2.4, la figure désigne que le courant de la machine passe par deux phases distinctes (régime transitoire, et le régime permanent). La figure 2.5 donne les courbes de la variation de la vitesse et du couple électromagnétique de la machine.

Le résultat d'analyse spectrale d'un des courants des phases statoriques est donné par la figure 2.6, le spectre du courant donne une composante centrale (un pic) sur la fréquence d'alimentation.

Les résultats de ce modèle peuvent être utilisés comme référence pour l'analyse spectrale des courants statoriques.




Figure. 2.4. Courants statoriques d'un moteur asynchrone sain.




Figure. 2.5. Paramètres de la machine saine, couple électromagnétique (a), vitesse (b).

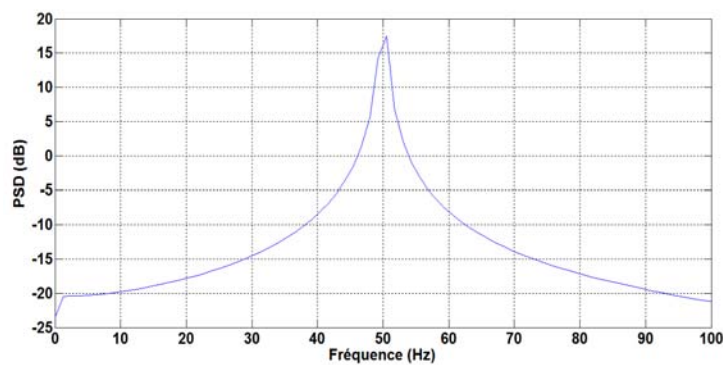


Figure. 2.6. PSD du courant d'une phase statorique.

La figure 2.7 donne les résultats de la décomposition en paquet d'ondelettes du courant de phase statorique, on observe des modulations dues à la fréquence d'alimentation au niveau de la 255<sup>ème</sup> bande fréquentielle.






Figure. 2.7. Analyse de paquet d'ondelettes du courant d'une phase statorique (coefficients d'ondelettes).

#### 2.4.2. Modèles des courants statoriques d'une machine électrique en présence d'un défaut de roulements

Cette partie repose sur le travail fait par [Blo08], [Blo06], les effets des défauts localisés de roulements sur les courants statoriques sont étudiés en matière de variations du couple de charge. Ces variations sont le résultat de déplacement radial de l'axe de gravité du rotor, ceci produit l'excentricité du rotor et donc le changement de la géométrie d'entrefer. Il est constaté que l'excentricité est proportionnelle à la fréquence caractéristique du défaut  $f_c$ , elle va donc conduire aux changements périodiques de l'inductance de la machine et par conséquent des fréquences additionnelles dans le courant statorique. Ici, l'influence du déplacement du rotor sur les courants statoriques est donnée par l'approche de force magnétomotrice (FMM) et la perméance ( $\Lambda$ ). Cette approche se base sur le calcul de la perméance d'entrefer  $\Lambda$  qui est relative à la largeur d'entrefer  $g_e$ . Le champ magnétique dans l'entrefer est déterminé par la multiplication de la perméance par les FMM du stator et du rotor, et le courant statorique peut être calculé à partir de la relation du champ magnétique et des tensions de la machine.

D'abord, il est indispensable d'imposer certaines hypothèses qui ont pour but de simplifier le modèle :

- Les effets de la zone de charge sur le roulement sont considérés.
- L'impact du défaut sur l'entrefer est donné par une série de peigne de Dirac.
- Les harmoniques de hautes fréquences du courant statorique ne sont pas considérées, seules les harmoniques de la fondamentale sont considérées.

– Les harmoniques reliées aux autres défauts du rotor ne sont pas considérées (car leurs amplitudes sont petites de nature et donc peuvent être négligées).

Dans un premier temps, la largeur d'entrefer  $g_e$  est définie en fonction du temps  $t$  et de l'angle de position  $\theta$  dans le plan de référence stator. La variation de la largeur d'entrefer et par conséquent le mouvement radial du rotor sont considérés comme fonction de la taille de défaut.

Pour un défaut de la bague externe, sa position angulaire est assumée nulle  $\theta = 0$ , l'entrefer est homogène et égal à une valeur constante  $g_{e0}$  lorsque les billes ne sont pas en contact avec le défaut, on néglige le glissement entre le stator et le rotor. Néanmoins, lorsqu'une bille est en contact avec un défaut, pour chaque instant  $t = k/f_{be}$ , le centre du rotor se déplace dans le repère fixe du stator d'une valeur relative  $e_0$  produite par le défaut de la bague externe (degré d'excentricité relative), et la largeur d'entrefer est approximativement égale à :

$$g_{e0}(\theta, t) = g_0 \left[ 1 - e_0 \cos(\theta) \sum_{k=-\infty}^{+\infty} \delta \left( t - \frac{k}{f_{be}} \right) \right] \quad (2.22)$$

Dans le cas de défaut de la bague interne, le défaut se manifeste à chaque instant  $t = k/f_{bi}$ . La position angulaire est fonction de la vitesse angulaire de rotation du rotor qui tourne à la fréquence  $\omega_r$  (car le défaut lui-même se déplace avec la rotation du rotor), sa position angulaire est égale à :

$$\Delta\theta_{BI} = \omega_r \Delta t = \frac{\omega_r}{f_{bi}} \quad (2.23)$$

$$g_{e,i}(\theta, t) = g_{e0} \left[ 1 - e_i \cos(\theta + \omega_r t) \sum_{k=-\infty}^{+\infty} \delta \left( t - \frac{k}{f_{bi}} \right) \right] \quad (2.24)$$

Avec :  $e_i$  est le degré d'excentricité relative introduite par le défaut de la bague interne.

Dans le cas de défaut de bille, le défaut se déplace avec la rotation du rotor, il change la largeur d'entrefer pour chaque instant  $t = k/f_{bille}$ . La position angulaire est fonction de la vitesse de rotation de la cage qui tourne à la fréquence  $\omega_{cage}$  qu'est donnée par :

$$\omega_{cage} = \frac{1}{2} \omega_r \left( 1 - \frac{D_b}{D_{cage}} \cos\beta \right) \quad (2.25)$$

$$\Delta\theta_{bille} = \omega_{cage} \Delta t = \frac{\omega_{cage}}{f_{bille}} \quad (2.26)$$

$$g_{bille}(\theta, t) = g_0 \left[ 1 - e_{bille} \cos(\theta + \omega_{cage} t) \sum_{k=-\infty}^{+\infty} \delta \left( t - \frac{k}{f_{bille}} \right) \right] \quad (2.27)$$

$e_{bille}$  est l'excentricité relative de défaut de bille.

Donc dans le cas général, l'excentricité est exprimée par,

$$g(\theta, t) = g_0 \left[ 1 - e \cos(\theta + \phi(t)) \sum_{k=-\infty}^{+\infty} \delta\left(t - \frac{k}{f_c}\right) \right] \quad (2.28)$$

Avec :  $f_c$  est la fréquence caractéristique d'un défaut de roulement, et la phase instantanée  $\phi(t)$  égale à:

$$\phi(t) = \begin{cases} 0 & \text{pour un défaut de la bague externe} \\ \omega_r(t) & \text{pour un défaut de la bague interne} \\ \omega_{cage}(t) & \text{pour un défaut de bille} \end{cases} \quad (2.29)$$

La perméance d'entrefer  $\Lambda$  est proportionnelle à l'inverse de la largeur d'entrefer  $ef$  :

$$\Lambda = \mu / ef.$$

Où  $\mu = \mu_r \mu_0$  est la perméabilité magnétique d'entrefer. Dans le cas d'un défaut de roulement, elle est exprimée comme suit :

$$\Lambda(\theta, t) \approx \Lambda_0 \left\{ 1 + e c_0 \cos(\theta + \phi(t)) + e \sum_{k=1}^{+\infty} c_k \cos(\theta + \phi(t) + k\omega_c t) + e \sum_{k=1}^{+\infty} c_k \cos(\theta + \phi(t) - k\omega_c t) \right\} \quad (2.30)$$

D'autre part, la densité du flux magnétique d'entrefer est calculée par la multiplication de FMM avec la perméance. Ici, les ondes fondamentales de la FMM sont considérées progressives, sinusoïdales, les FMM's fondamentales du stator et du rotor sont des ondes à la fréquence d'alimentation  $\omega_s = 2\pi f_s$  avec  $p$  paires de pôles, la FMM totale  $F_{tot}$  est donnée comme suit :

$$F_{tot} = F \cos(p\theta - \omega_s t + \varphi) \quad (2.31)$$

La densité du flux est le résultat de la multiplication de (2.30) et (2.31) :

$$\begin{aligned} B_{tot}(\theta, t) &= F_{tot}(\theta, t) \Lambda(\theta, t) \\ &= F \Lambda_0 \cos(p\theta - \omega_s t + \varphi) \\ &\quad + \sum_{k=0}^{\infty} A_k \left[ \cos((p \pm 1)\theta \pm \phi(t) \pm k\omega_c t - \omega_s t + \varphi) \right] \end{aligned} \quad (2.32)$$

Avec :  $A_k$  sont les amplitudes des ondes de densité du flux relatif au défaut. Et la notion  $\pm$  est donnée pour exprimer toutes les possibilités de combinaisons fréquentielles.

L'influence de l'excentricité produite par un défaut de roulements sur la densité du flux magnétique est approuvée par le contenu spectral  $f_{exc}$  qui égale à :

$$f_{exc} = \frac{1}{2\pi} \left( \pm \frac{d\phi(t)}{dt} \pm k\omega_c - \omega_s \right) \quad (2.33)$$

La dérivation temporelle du flux magnétique permet d'obtenir le courant statorique qui lui correspond. Finalement, on en conclut que ce dernier se présente également sous forme d'une sinusoïde de fréquence  $f_s$  modulée en amplitude à la fréquence  $f_c$  [Tra09], [Blo06].

$$I_m(t) = \sum_{k=0}^{\infty} I_k \cos(\pm\phi(t) \pm k\omega_c t - \omega_s t + \varphi_m) \quad (2.34)$$

Dans un spectre du courant, les fréquences additionnelles dues aux déplacements radiaux du rotor sont données dans le tableau 2.1.

La deuxième approche se base sur l'hypothèse d'oscillations du couple de charge. Le passage d'une bille sur un défaut produit une résistance mécanique à chaque fois que la bille quitte la zone de défaut, et par conséquent, l'augmentation du couple de charge. Ces oscillations apparaîtront dans les mêmes fréquences caractéristiques d'un défaut de roulements.

D'abord, le couple de charge représentatif des défauts de roulements est donné par une oscillation sinusoïdale de fréquence  $\omega_c$  et d'amplitude  $C_c$ , la variation du couple de charge est exprimée par:

$$C_{charge}(t) = C_0 + C_c \cos(\omega_c t) \quad (2.35)$$

$C_0$  est le couple de charge dans le régime sain, et  $\omega_c = 2\pi f_c$ .

Les oscillations du couple de charge influencent la vitesse de rotation du moteur, et par conséquent, l'angle de position mécanique du rotor  $\theta_r$ . Celles-ci influencent la FMM du rotor.

Dans un repère du rotor, la FMM rotorique est fonction de  $p$  paires de pôles et de la fréquence  $s f_c$ :

$$F_r^{(R)}(\theta, t) = F_r \cos(p\theta' - s\omega_s t) \quad (2.36)$$

$\theta'$  est l'angle mécanique dans un repère rotorique, et  $s$  est le glissement.

La transformation entre le repère stator/rotor est  $\theta = \theta' + \theta_r$  et donc,

$$\theta' = \theta - \omega_{r0} t - A_c \cos(\omega_c t) \quad (2.37)$$

Avec  $A_c = C_c / (J\omega_c^2)$ ,  $J$  est l'inertie du rotor en rotation,  $\omega_{r0} = \omega_s(1 - s)/p$

Alors, la FMM rotorique (liée au repère du rotor) modulée en phase à la fréquence caractéristique du défaut  $f_c$  peut être représentée dans un repère fixe du stator par la relation suivante:

$$F_r(\theta, t) = F_r \cos(p\theta - \omega_s t - pA_{osc} \cos(\omega_c t)) \quad (2.38)$$

La FMM du stator est indépendante de ce changement.

Le terme  $pA_c \cos(\omega_c t)$  caractérise la modulation en phase (MP) de l'onde de la FMM rotorique considérée sinusoïdale.

L'effet d'oscillations du couple de charge sur la densité du flux de l'entrefer est déterminé par la multiplication de la FMM totale et la perméance. La densité du flux magnétique dans l'entrefer est exprimée comme suit :

$$B(\theta, t) = F_{r,1} \Lambda_0 \cos(p\theta - \omega_s t - pA_c \cos(\omega_c t)) \quad (2.39)$$

Les courants statoriques sont calculés par la suite par la dérivation temporelle du flux [Blo08]:

$$I_{phase}(t) = I_1 \sin(\omega_s t + pA_c \cos(\omega_c t)) + I_2 \sin(\omega_s t + pA_c \cos(\omega_c t) + \omega_c t) - I_2 \sin(\omega_s t + pA_c \cos(\omega_c t) - \omega_c t) \quad (2.40)$$

Selon [Blo06], nous pouvons déterminer le courant statorique simulé pour une excentricité dynamique (courant modulé en amplitude AM), et le courant statorique simulé pour des oscillations du couple de charge (courant modulé en phase PM), comme suite :

$$i_{pm,r}(t) = i_{to}(t) = I_{st}(\omega_s t) + I_{rt} \cos(\omega_s t + \beta \cos(\omega_c t - \varphi_\beta) - \varphi_r) \quad (2.41)$$

$$i_{am,r}(t) = i_{de}(t) = I_1 [1 + \alpha \cos(\omega_c t - \varphi_\alpha)] \cos(\omega_s t). \quad (2.42)$$

Avec :  $\omega_{osc}$  est la fréquence de modulation, et  $\omega_s = 2\pi f_s$ .

### 2.4.3. Les méthodes d'analyse des courants statoriques

Parmi les méthodes les plus courantes on distingue l'approche analyse spectrale de la signature du courant (motor current signature analysis MCSA), elle a été inventée par 'Oak Ridge National Laboratory' en 1989 pour le diagnostic des systèmes de refroidissement des installations nucléaires [Kryter89].

Pendant les deux décennies suivantes, la MCSA était largement appliquée pour le diagnostic des défauts de rupture des barres qu'aux défauts de roulements, et pourtant, les défauts de roulements représentent 50% des défauts des moteurs électriques [Benbouzid00]. Récemment, [Rodriguez06], [Lau10], [Frosini10], ont utilisé la MCSA pour le diagnostic des défauts de roulements.

Un des inconvénients de la MCSA est qu'elle est limitée aux signaux stationnaires. Cependant, le courant statorique est non stationnaire [Ern04], [Bouzida11], [Douglas04], [Douglas05], [Lau10], où les auteurs de ces travaux ont proposés la méthode d'ondelette pour améliorer le comportement de la MCSA avec les signaux non stationnaires. L'auteur de [Pillay96] a donné trois approches de démodulation pour améliorer le comportement de la MCSA.

Nous pouvons compter plusieurs approches accompagnantes à la MCSA comme : l'approche de vecteur de Park ou l'approche Concordia [Önel08], elle est basée sur la mesure des courants diphasés (transformation triphasé/biphasé) où l'objectif de cette méthode est d'élaborer les courbes de Lissajous. Il existe plusieurs applications comme : l'approche Elliptical representation of the Park's current Vector et l'approche extended Park vector [Cruz01]. Les méthodes dites de haute résolution comme le Root-MUSIC, détectent les défauts par la définition de l'existence des modulations de fréquence et leurs caractéristiques en les comparant avec celles du signal d'une machine saine [Djeddi07].

Récemment, l'exploitation de la MCSA pour extraire le Multi-Scale Entropy (MSE) des courants statoriques pour le diagnostic des défauts d'engrenages, a donné des résultats prometteurs [Aouabdi17]. [Pere05] a combiné la MCSA et la logique floue (LF).

Les méthodes de filtrage d'ondelettes (ondelettes discrètes, paquet d'ondelettes) sont largement utilisées dans l'analyse des courants statoriques [Bouzida11], [Ern04], [Zarei07], [Lau10], elles prouvent qu'elles ont l'avantage d'éliminer les composantes fréquentielles indésirables dans un signal de défaut.

#### **2.4.4. Analyse des fréquences des courants statoriques simulés avec un défaut de roulements**

Dans un moteur asynchrone avec un défaut de roulement, le mouvement radial du rotor et les oscillations du couple de charge génèrent respectivement des modulations d'amplitude (AM) et de phase (PM) dans les courants statoriques. Dans [Gong13] il a été jugé que la démodulation d'amplitude seule ou de la fréquence sont incapables de faire apparaître les signatures d'un défaut de roulements, alors une combinaison des deux approches est jugée indispensable, mais l'application de cette approche augmente la complexité du système de diagnostic et par conséquent le coût d'exploitation.

Dans cette partie, les simulations des courants statoriques dans le cas d'un défaut de roulement sont achevées pour vérifier les effets des modulations d'amplitudes et de phase sur les courants statoriques d'une machine asynchrone. Ensuite, une application de la MCSA ainsi qu'une application de la décomposition de paquet d'ondelettes dans le cadre de la MCSA sont présentées.

Les simulations des courants statoriques dans le cas des oscillations du couple de charge sont effectuées en incluant les oscillations du couple de charge dans le modèle Simulink développé précédemment (cf. annexe, figure 2) avec  $C_e=10$  N.m, et  $f_c=32$  Hz.

*Chapitre II. Analyse des défauts de roulements dans une machine électrique par la modélisation des courants statoriques*

Les résultats de la simulation des courants statoriques dans le cas des oscillations du couple de charge pour un défaut de roulements sont donnés par la figure (2.8), leurs effets sur le couple électromagnétique et la vitesse de la machine sont donnés par la figure (2.9). Le résultat d'analyse spectrale d'un des courants des phases statoriques est donné par la figure 2.10. La figure représente des raies spectrales aux fréquences  $|f_s \pm kf_c|$ .




Figure 2.8. Les courants statoriques d'un moteur asynchrone dans le cas des oscillations du couple de charge.

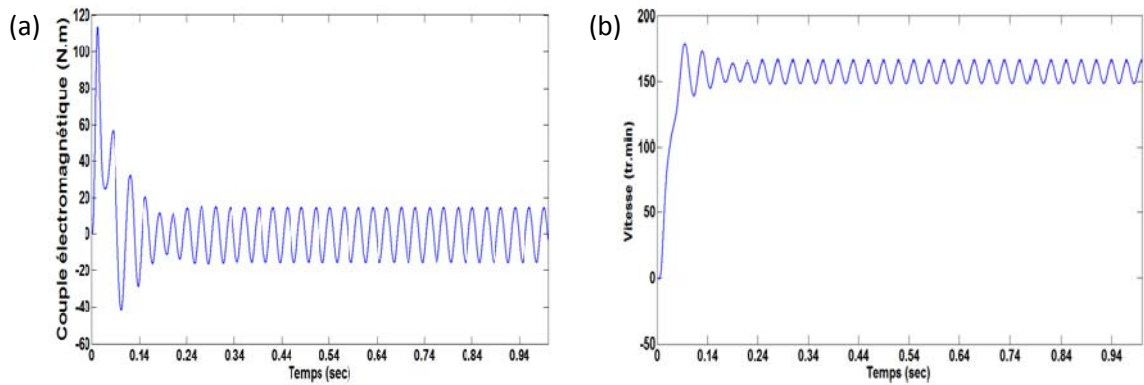


Figure 2.9. Paramètres de la machine dans le cas des oscillations du couple de charge, couple électromagnétique (a), vitesse (b).




Figure 2.10. PSD d'un des courants statoriques pour le même cas.

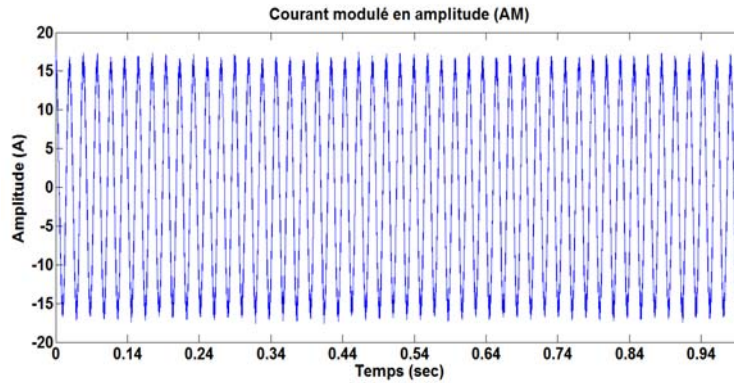


Figure. 2.11. Courant statorique modulé en amplitude (excentricité dynamique).

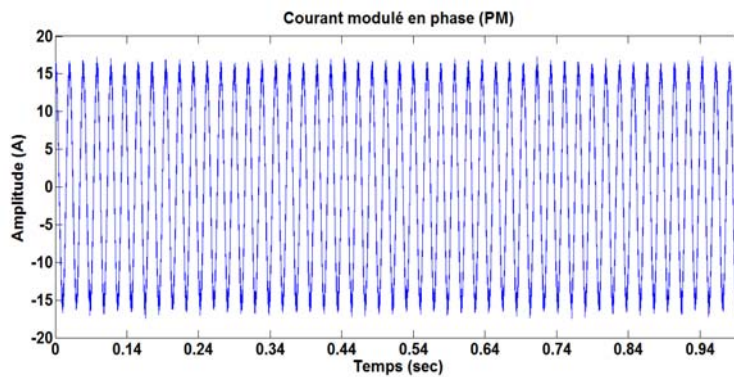


Figure. 2.12. Courant statorique modulé en phase (oscillation du couple de charge).

Pour montrer les effets des modulations en phase (PM) et en amplitude (AM), nous allons utiliser les paramètres de simulation donnés par [Lee85] (cf. annexe, tableau 4). Les résultats de simulation en utilisant l'approche d'excentricité dynamique (2.42), et d'oscillations du couple de charge (2.41) sont donnés respectivement dans les figures 2.11 et 2.12. Un bruit gaussien avec SNR égal à 5dB est ajouté aux signaux simulés.

Les résultats de l'analyse spectrale sur les courants simulés sont donnés par les figures 2.13 et 2.14. Les résultats permettant de confirmer l'apparition d'un défaut de roulements, les deux figures représentent deux peignes de raie autour de la composante principale à  $f_s \pm f_c$ .

Les figures 2.15 et 2.16 donnent l'analyse de paquet d'ondelettes des courants simulés avec un défaut de roulements, le niveau de décomposition est fixé à  $J=8$ , et l'ondelette mère 'dmey'. On observe que les effets de modulation par les fréquences caractéristiques de défaut se reflètent dans la bande fréquentielle [0-94Hz].

La transformée de paquet d'ondelette seule ne peut pas refléter les fréquences qui existent dans le courant, le PSD de cette bande donne des résultats meilleurs que celles de



l'analyse par FFT seule, les amplitudes qui correspondent aux bruits sont neutralisées par les filtres d'ondelettes.

Où les fréquences dues aux bruits sont projetées dans d'autres bandes fréquentielles.




Figure. 2.13. PSD du courant modulé en amplitude (excentricité dynamique).




Figure. 2.14. PSD du courant modulé en phase (oscillations du couple de charge).




Figure. 2.15. Analyse de paquet d'ondelettes du courant modulé en amplitude.




Figure. 2.16. Analyse de paquet d'ondelettes du courant modulé en phase.

### 2.5. Conclusion

Les méthodes de diagnostic basées sur la modélisation de la machine asynchrone supposent une connaissance antérieure du système, elles sont implantées autour du suivi de l'évolution des paramètres électriques de la machine. Une comparaison entre les paramètres réels mesurés et le modèle de référence (dans le cas sain ou défectueux) a fait apparaître le comportement de certaines grandeurs et facilite la détection d'un défaut. Elles permettent de détecter et localiser le défaut au bon moment avant qu'il soit amplifié et transmis aux structures avoisinantes.

L'inconvénient majeur de ces approches est que les paramètres du modèle sont fixés par l'utilisateur. Mais dans la majorité des cas, les paramètres électriques de la machine ne sont pas toujours accessibles et avec le vieillissement de la machine ces paramètres vont se modifier, donc une méthode d'estimation des paramètres est nécessaire. D'autre part, la MCSA a un rapport signal/bruit (SNR) faible. Cependant, l'analyse par ondelette neutralise l'effet du bruit, mais le niveau de décomposition et la bande fréquentielle utile sont fixés en se basant sur le retour d'expérience. Ceux-ci peuvent influencer la fiabilité du système de diagnostic et augmenter le coût d'exploitation.

## **Chapitre III**

**Les méthodes de pronostic :  
estimation du temps de vie restant  
d'un roulement**

### **3.1. Introduction :**

Les roulements sont des éléments mécaniques d'architecture complexe, ils sont essentiellement utilisés pour le guidage des arbres afin de faciliter leurs rotations. Dans une installation industrielle, les défauts de roulements peuvent menacer la sécurité du matériel et de l'environnement de travail. Par conséquent, un suivi permanent est indispensable dont l'objectif est de permettre la détection précoce des défauts, ceux-ci déclenchent les opérations d'estimation de la durée de vie restante avant la prochaine défaillance. Il est clair que les deux opérations précédentes sont relativement attachées, car les méthodes de pronostic reposent sur les connaissances a priori délivrées par un système de diagnostic (historique) où le diagnostic est postérieur à l'apparition d'une défaillance dans un système, tandis que le pronostic est antérieur à l'apparition d'une défaillance.

Le phénomène de dégradation d'un roulement est un phénomène stochastique irréversible, c'est-à-dire que l'évolution du défaut suit un seul sens. L'objectif d'un système de pronostic est de suivre l'évolution d'un défaut dès son apparition pour pouvoir intervenir avant que la dégradation de roulement croise un stade critique afin d'éviter les substitutions indésirables des pièces de rechange.

Les méthodes de pronostic peuvent être regroupées en trois types : les méthodes basées sur l'expérience, les techniques guidées par les données et celles fondées sur les modèles. Le choix d'une des méthodes de pronostic est basé principalement sur le type de connaissances disponibles sur le système, le domaine d'applicabilité, leur complexité, leur précision et leur coût.

Récemment, plusieurs méthodes de pronostic ont été inventées, parmi lesquelles on compte les modèles semi-markoviens cachés [Dong07], les réseaux de neurones artificiels [Tian09], les filtres particuliers (particle filtering or séquentiel Monte-Carlo méthode) [Zhu13], les approches bayésiennes [Mosallam13], l'approche relevance vector machine (RVM) et la probabilité de survie [Widodo11], l'entropie de Rényi (Rényi entropy) et le modèle de processus gaussiens [Bosk15], la logique floue (LF) [Alam14], l'approche similarity of phase space trajectory [Zhang15], l'approche carte auto-adaptative ou auto organisatrice (self organizing map SOM) [Honga14] et les modèles de Markov cachés [baruah05], [Tobon11], [Medjaher12].

Les modèles de Markov cachés (MMC) sont largement traités dans le cadre du pronostic et de la gestion de la santé d'un système (prognostic and health management PHM). L'avantage essentiel est qu'ils se basent sur des lois de probabilité qui sont appropriées pour la modélisation des processus de dégradation (utilisation des lois de

probabilité normale). Les MMC reposent sur les lois de probabilité gaussiennes et le théorème de Bayes, où la probabilité d'occurrence d'un événement dépend des événements passés et, selon celle-ci, on peut déterminer le degré du modèle de Markov. Pour des raisons de simplicité le modèle le plus souvent utilisé est le modèle de premier degré. Ici, le calcul de la probabilité d'occurrence d'un événement dépend de son état actuel et ne dépend pas des événements passés.

Dans ce chapitre, on va traiter les modèles de Markov cachés dans le cadre du pronostic en utilisant les MMC pour estimer la durée de vie restante d'un roulement. Les modèles de Markov cachés réalisés se basent sur les mesures vibratoires d'un historique des signaux de vieillissement accélérés de roulements. Cependant, le modèle de mélange gaussien est adopté pour l'apprentissage des données et par la suite les MMC sont utilisés pour estimer la durée de vie restante d'un roulement.

### **3.2. Les indicateurs de dégradation**

Ce sont des quantités d'information pertinentes aux défauts qui permettent de détecter l'apparition d'une défaillance [G-Der11]. Dans le cadre du diagnostic, beaucoup d'indicateurs de dégradation sont inventés. Néanmoins, ils montrent des degrés de sensibilité apparents selon le degré de sévérité de la dégradation. Quelques indicateurs saturent après un certain niveau de dégradation ou d'autres peuvent être sensibles aux bruits (cf. section 1.3.2). On peut citer par exemple le facteur crête qui diminue considérablement à la fin de la vie d'un roulement [Tra09]. Il y a d'autres indicateurs qui sont sensibles à la position d'emplacement d'un capteur (cas des roulements) [Gao11], [Gao06]. Donc, une phase de présélection des indicateurs est une partie essentielle pour une méthode de pronostic, le ou les indicateurs qui représentent également les différentes phases de dégradation représentant l'évolution de la taille de défaut seront retenus.

### **3.3. Le pronostic et les phases de vie d'un équipement**

Durant leur vie, tous les éléments mécaniques passent par trois phases essentielles qui caractérisent leur état de santé et leur comportement dynamique, dont la première est la phase de rodage suivie par une phase productive et ensuite une phase de dégradation ou fin de vie, ces phases sont déterminées d'après une étude de fiabilité du système où les résultats sont tracés par une courbe dite courbe en baignoire (cf. figure 3.1.).

Dans un roulement, les premiers symptômes de la défaillance se manifestent au premier moment de la phase de vieillesse, depuis ce moment là les opérations du processus du pronostic se déclenchent. Il se base sur le suivi des paramètres donnant le comportement d'un élément défaillant, ces paramètres peuvent être représentés par des signaux mesurés

par un capteur ou par un modèle mathématique simulant un phénomène de dégradation physique. Les données regroupées sont exploitées pour l'estimation de l'arrivée d'une défaillance.

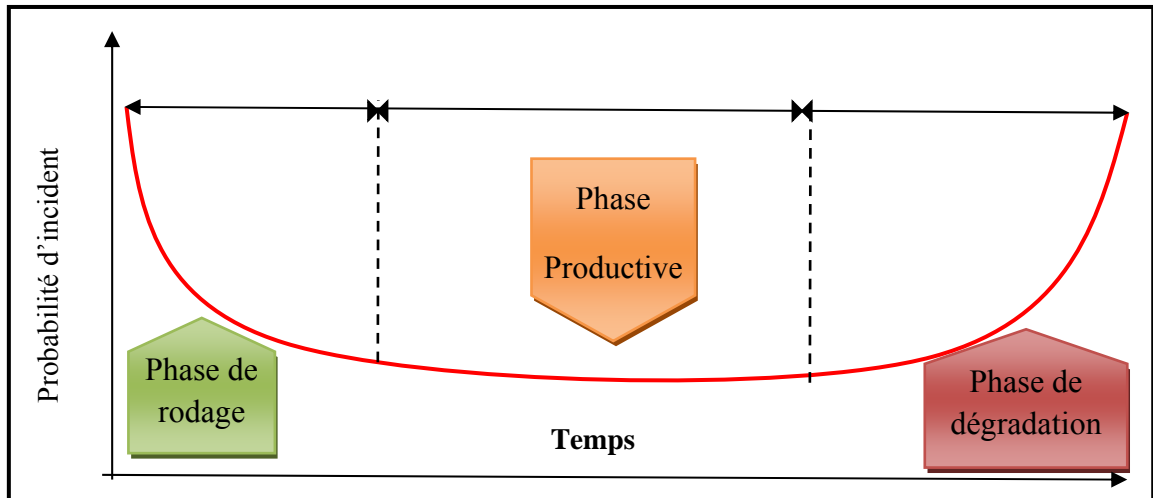


Figure. 3.1. Courbe en baignoire donnant les phases de vie d'un équipement mécanique.

Dans un système de pronostic les résultats de diagnostic sont transmis au système de pronostic pour l'actualisation des modèles construits, c'est-à-dire que les paramètres du modèle se changent pour chaque nouvelle observation, et le système donne des nouvelles valeurs.

Il existe trois types d'approches de pronostic, le premier type est le pronostic basé sur l'expertise (basé sur les connaissances) telles que les approches de fiabilité, les processus stochastiques, les systèmes experts. Le second type est le pronostic guidé par les données (le pronostic par analyse de tendance et le pronostic par l'apprentissage). Le dernier type est le pronostic fondé sur les modèles (représentation multi échelle, modèles discrets, modèles continus, Paris Formula). L'auteur de [G-Der11] a donné une comparaison entre les différents types des méthodes de pronostic avec une étude plus détaillée sur ce contexte. D'autre part, [Tobon10a] a donné quelques standards de pronostic des défauts selon la norme ISO 13381-1.

La figure 3.2. donne une évaluation des approches de pronostic du côté coût, précision, complexité et applicabilité. Il a été jugé que les approches guidées par les données sont les plus favorables.

### 3.4. Estimation du temps de vie restant d'un roulement

Dans le cadre de la maintenance conditionnelle appliquée aux moteurs asynchrones, les roulements étant définis comme source essentielle des défauts. Alors, une stratégie de

surveillance permanente est mise en place pour éviter les conséquences brutales induites par un défaut de roulements.

Les méthodes de pronostic représentent une extension des méthodes de diagnostic, elles ont pour objectif de prévenir les défauts et de fournir assez d'information pour le déclenchement des actions de maintenance programmée (arrêts programmés, remplacements). Une des approches les plus adéquates pour le pronostic de roulements est l'approche guidée par les données (data-driven approach), lorsqu'elle se base sur les mesures réelles du comportement dynamique de roulements. Les indicateurs de surveillances (supposées représentatifs) donnent une image réelle sur le processus de dégradation. Par la suite, ces indicateurs seront utilisés pour construire l'historique de dégradation (la base de données). Ensuite, cette base de données est utilisée pour l'apprentissage des modèles de pronostic (phase hors ligne).

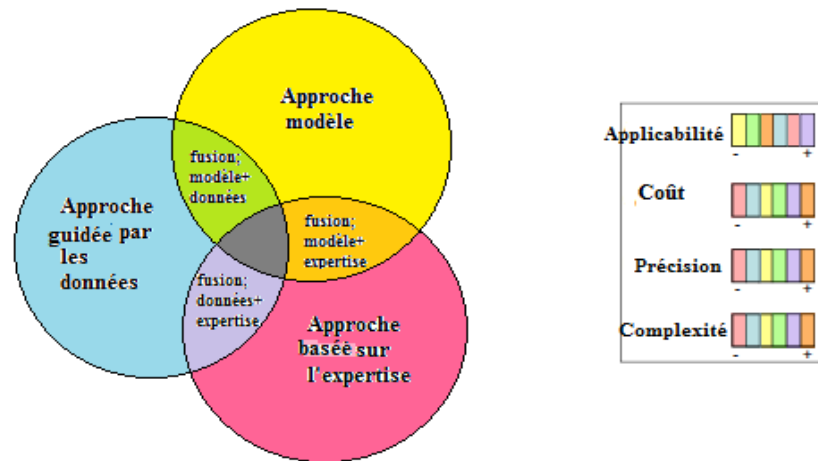


Figure. 3.2. Élaboration des approches de pronostic [Tobon11].

Les modèles de Markov cachés sont largement utilisés dans le pronostic de roulements. Zhang [Zhang05] a contribué à une des contributions originelles, il a utilisé l'analyse de la composante principale (ACP) pour extraire les indicateurs caractéristiques des défauts de roulements. Ensuite, ces indicateurs sont utilisés pour l'apprentissage des MMC's. [Tobon10b] a développé un modèle de Markov pour le pronostic des défauts de roulements par l'application du modèle de mélange gaussien pour l'apprentissage des MMC's, il suppose que les événements observés dans un processus de dégradation suivent une distribution continue. La même démarche est traitée dans un autre travail avec des indicateurs issus par la méthode de paquet d'ondelettes [Tobon11]. Une application de la même approche sur une autre base de données est achevée dans [Tobon12]. Son coauteur a

utilisé les réseaux bayésiens avec la même base de données et il a contribué à une méthode de sélection de nombre de mélanges gaussiens [Medjaher12].

**Tableau 3.1.** Comparaison des différentes approches de pronostic [G-Der11]

Approche de pronostic	Avantages	Inconvénients
Basée sur l'expérience	<ul style="list-style-type: none"> <li>• Connaissances disponibles dans de nombreux domaines d'expertise</li> <li>• Exploitations des historiques de maintenance (temps d'arrêts, nombre de pannes)</li> </ul>	<ul style="list-style-type: none"> <li>• Nécessite un bon retour d'expérience.</li> <li>• Intégration simplifiée des variations des conditions opérationnelles.</li> <li>• Non valides pour un nouveau matériel.</li> </ul>
Guidée par les données	<ul style="list-style-type: none"> <li>• Les Connaissances des mécanismes de dégradation sont directement incluses dans les données</li> </ul>	<ul style="list-style-type: none"> <li>• Nécessite plusieurs scénarios de dégradation pour différentes conditions opérationnelles.</li> </ul>
Fondée sur les modèles	<ul style="list-style-type: none"> <li>• Meilleures performances de pronostic obtenues.</li> <li>• Flexibilité de l'approche due à l'intégration de connaissance de la structure et des mécanismes de dégradation.</li> </ul>	<ul style="list-style-type: none"> <li>• Nécessite une connaissance liée aux mécanismes de dégradation.</li> </ul>



### 3.5. La théorie des modèles de Markov cachés

#### 3.5.1. Les différents types des modèles de Markov cachés

Selon le type de densité de probabilité des observations (discrète ou continue), il est possible de construire deux types de modèles de MMC : soit un MMC discret soit un MMC continu [Belbedj15].

- MMC discrets : ils sont utilisés pour le suivi des processus de dégradation longs à cause de leurs simplicités, rapidité de traitement des informations et coût d'exploitation modéré. Néanmoins, ils manquent de précision, et ils besoins beaucoup d'échantillons pour l'apprentissage.
- MMC continus : ils sont utilisés pour le suivi des processus de dégradation rapides où beaucoup d'informations sont traitées dans un intervalle de temps limité, ils sont plus précis que les premiers mais le traitement de données est trop lent à cause de l'utilisation des fonctions de densité de probabilités continues.

#### 3.5.2. La propriété de Markov

Le MMC est utilisé essentiellement pour modéliser un processus stochastique, il est défini comme l'ensemble d'états du système (événements) où pour chaque instant  $t$  la valeur de probabilité d'une état dépend de l'historique de processus qui ne garde pas la mémoire (modèle sans mémoire), c'est-à-dire que l'évaluation du processus à l'instant  $t$  ne dépend pas des états à  $t-1, \dots, t-n$  où  $n$  est le nombre d'états du système. La probabilité du processus est exprimée dans sa forme classique comme suit :

$$P(s_0 \dots s_T) = P(s_0) \times P(s_1|s_0) \times P(s_2|s_0s_1) \times \dots \times P(s_T|s_0 \dots s_{T-1}) \quad (3.1)$$

Avec : T le temps total d'observations. Ces observations peuvent être discrètes ou continues.

Un processus est dit markovien si la distribution conditionnelle de probabilité des états futurs ne dépend en fait que de l'état présent et non pas des états passés (absence de « mémoire »), cette propriété est appelée propriété de Markov. C'est-à-dire que la probabilité d'une observation à un instant  $t$  dépend uniquement de l'observation à l'instant  $t-1$  (propriété de Markov d'ordre 1). Dans la propriété de Markov d'ordre deux la probabilité d'observation à l'instant  $t$  dépend des observations à  $t-1$  et  $t-2$ .

Le modèle de ce processus est appelé modèle de Markov, où on peut distinguer deux types : le modèle observable et le modèle caché. Le premier est appelé aussi chaîne de

Markov observable déterminée par un support graphique appelé graphe des états fini de fonctionnement et de panne, il permet également de visualiser le comportement d'un système, les états sont représentés par des cercles liés entre eux par des arcs orientés désignant la transition de l'état de départ vers l'état d'arrivée (cf. figure 3.3).

Les chaînes de Markov cachés ont le même principe que les chaînes de Markov observables sauf que les états sont cachés, elles sont liées par des transitions possibles, les transitions entre états dépendent de l'État actuel et non pas sur les états passés où la séquence réelle d'états est cachée.




Figure. 3.3. Chaîne de Markov observable à deux états

### 3.5.3. Le cadre mathématique des modèles de Markov cachés

Supposons qu'on a un espace d'états  $S=\{s_1, s_2, \dots, s_N\}$  émettant une série d'observations  $O=(o_1, o_2, \dots, o_m)$  pondérées par leurs probabilités. Un modèle de Markov caché est caractérisé par l'espace des paramètres  $E=\{\pi, A^*, B^*\}$ , avec :

$\pi$  : est le vecteur des probabilités initiales, ce sont des probabilités du système d'être dans l'état 1 (ils sont assumés équiprobables).

$A^*$  : matrice des probabilités de transition, ce sont des probabilités d'aller d'un état  $i$  à un état  $j$ .

$B^*$  : matrice des probabilités d'observations, elles caractérisent la vraisemblance d'une observation  $x$  d'être à l'état  $s_i$ . Selon le type d'observation on a :

– Observations discrètes :  $x_n \in \{v_1, \dots, v_k\}$ ,  $b_{i,k} = P(x_n = v_k / q_n = s_i)$ , c'est la probabilité d'observer  $v_k$  avec  $q_n$  est dans l'état  $s_i$ , les résultats  $b_{i,k}$  sont collectées dans la matrice  $B^*$ .

– Dans le cas des observations continues,  $x_n \in \mathbb{R}^D$  :  $\mathbb{A} \not\subseteq \square \sim \approx \approx \times \square \times \sim \square > \square < \square$   
 $\square \square \sim \cup \times \square \approx \square \times \sim$  de densité de probabilité (PDF) de la forme  $\square_i(x_n) = p(x_n / q_n = s_i)$ . Avec  $B(x)$  est un vecteur de fonctions de PDF (modèle de mélange gaussien).

Un MMC est caractérisé par la séquence d'états cachés  $Q=\{q_1, q_2, \dots, q_T\}$  et la séquence d'observations  $O=\{o_1, o_2, \dots, o_T\}$ , (cf. figure 3.4.). Il décrit donc les états d'un processus Markovien utilisant les probabilités de transition entre les états et les probabilités

d'observations. Un MMC qui autorise la transition entre les états dans tous les sens est appelé MMC « ergodique ». Cependant, un MMC qui autorise la transition d'un état vers lui-même ou vers l'état suivant est appelé MMC gauche-droite.

Pour un modèle de Markov avec des paramètres dans  $E$ , la probabilité d'une séquence d'états  $Q = \{q_1, q_2, \dots, q_T\}$  est le produit des probabilités de transition entre-états :

$$P(Q|E) = \pi_{q_1} \cdot \prod_{t=1}^{T-1} a_{q_t, q_{t+1}} = \pi_{q_1} \cdot a_{q_1, q_2} \cdot a_{q_2, q_3} \dots a_{q_{T-1}, q_T} \quad (3.2)$$

Pour un MMC de paramètres dans  $E$ , la vraisemblance d'une séquence d'observations  $O$  pour un seul chemin qui donne une séquence d'états  $Q$ , où les deux sont de la même longueur (eg : chemin en rouge figure 3.4):

$$P(X|Q, E) = \prod_{t=1}^T P(x_t|q_t, E) = b_{q_1, o_1} \cdot b_{q_2, o_2} \dots b_{q_T, o_T} \quad (3.3)$$

C'est le produit des probabilités d'émissions suivant le chemin parcouru.




Figure. 3.4. Diagramme de transition entre états.

La vraisemblance jointe d'une séquence d'observations  $O$  et un chemin  $Q$  lorsque  $O$  et  $Q$  coexistent simultanément est défini comme le produit de la probabilité de transition et la vraisemblance comme suit :

$$P(O, Q|E) = P(O|Q, E) \cdot P(Q|E) \quad (3.4)$$

Par ailleurs la vraisemblance d'une séquence d'observations  $O$  en respectant le MMC de paramètres  $E$  est la somme des vraisemblances jointes d'une séquence à travers tous les états possibles  $Q$  validés par le modèle.

$$P(O|E) = \sum_{\text{tous } Q} P(O, Q|E) \quad (3.5)$$

### 3.5.4. Les trois problèmes des modèles de Markov cachés

Pratiquement, lors de la modélisation d'un processus réel avec un MMC, un trio de problèmes doit être résolu [Rab89], [Tobon11]:

#### 3.5.4.1. Problème 1 (Reconnaissance) :

Étant donné un modèle  $E$  et une séquence d'observations  $O = \{o_1, o_2, \dots, o_N\}$ , quelle est la vraisemblance  $P(O|E)$  que le modèle  $E$  génère  $O$  (quelle est la probabilité d'avoir une séquence d'observations  $O$ ?), Le calcul de cette quantité donne une complexité algorithmique exponentielle  $2T.N^T$  ( $N$  états possibles).

La solution de ce problème est obtenue à l'aide d'un algorithme « Forward-Backward ».

- Algorithme Forward-Backward:
  - La procédure de calcul «Forward» considère que les variables «Forward»  $\alpha_t(i)$  donnent la probabilité d'observer la séquence partielle  $\{o_1, o_2, \dots, o_t\}$  de début jusqu'à  $t < T$  et les états  $Q_t$  qui donnent un modèle  $E$ .

$$\alpha_t(i) = p(o_1 o_2 \dots o_t, q_t = S_i | E) \quad (3.6)$$

Cette quantité est calculée suivant les étapes ci-dessous:

Initialisation :

$$\alpha_1(i) = \pi_i b_i(O_1), \quad 1 \leq i \leq N. \quad (3.7)$$

Récursion :

$$\alpha_{t+1}(j) = [\sum_{i=1}^N \alpha_t(i) a_{ij}] b_j(X_{t+1}), \quad 1 \leq t \leq T - 1 \text{ et } 1 \leq j \leq N. \quad (3.8)$$

Terminaison :

$$P(O|E) = \sum_{i=1}^N \alpha_T(i) \quad (3.9)$$

La figure 3.5.a. exprime comment peut-on aboutir l'état  $s_j$  à  $t+1$  à travers  $N$  états possibles à  $t$ .

- La procédure « Backward » :

$$\beta_t(j) = P(o_{t+1} o_{t+2} \dots o_T | q_t = S_j, E) \quad (3.10)$$

Initialisation :

$$\beta_T(j) = 1, 1 \leq j \leq N \quad (3.11)$$

Inférence :

$$\beta_t(j) = \sum_{j=1}^N a_{ij} b_j(O_{t+1}) \beta_{t+1}(j), t = T - 1, T - 2, \dots, 1, 1 \leq i \leq N \quad (3.12)$$

La figure 3.5.b. exprime le principe de cette procédure.

### 3.5.4.2. Problème du décodage (algorithme Viterbi)

L'objectif est de déterminer la séquence d'états la plus probable entre plusieurs séquences d'états possibles. Parmi ces états, étant donnée une séquence d'observations d'états  $O$  qui maximise la probabilité d'observer  $N$  états (maximisation de la vraisemblance). Premièrement, il faut d'abord déterminer la probabilité d'être dans l'état  $S_i$  donnant une séquence d'observations  $O$  et le modèle  $E$ :

$$\gamma_t(i) = P(q_t = S_i | O, E) \quad (3.13)$$

Elle peut être exprimée selon la procédure de calcul Forward-Backward par:

$$\gamma_t(i) = \frac{\alpha_t(i) \beta_t(i)}{p(O|E)} = \frac{\alpha_t(i) \beta_t(i)}{\sum_{i=1}^N \alpha_t(i) \beta_t(i)} \quad (3.14)$$

Où :

$$\sum_{i=1}^N \gamma_t(i) = 1. \quad (3.15)$$

En utilisant cette quantité, on peut déduire :

$$q_t = \underset{1 \leq i \leq N}{\operatorname{argmax}} [\gamma_t(i)], \quad 1 \leq t \leq T \quad (3.16)$$




Figure. 3.5. Diagramme de calcul « Forward » (a), calcul « Backward » (b) [Rab89].

Donc, pour chaque instant  $t$  l'algorithme doit choisir l'état le plus probable, mais le chemin choisi n'est pas toujours le plus probable parce que l'algorithme choisit l'état le plus probable à chaque instant sans tenir en compte la probabilité d'occurrence d'une séquence d'états. La solution de ce problème est donnée par l'algorithme Viterbi.

Pour trouver la séquence d'états les plus probables  $Q = \{q_1, q_2, \dots, q_T\}$ , pour une séquence d'observations  $O = \{o_1, o_2, \dots, o_T\}$  il faut déterminer :

$$\delta_t(i) = \max_{q_1, q_2, \dots, q_{t-1}} p(q_1 q_2 \dots q_t = i, O_1 O_2 \dots O_t | E) \quad (3.17)$$

C'est la plus haute probabilité d'un chemin des premières  $t$  observations qui donnent  $S_i$ , et inversement on trouve:

$$\delta_{t+1}(j) = [\max_i \delta_t(i) a_{ij}] \cdot b_j(O_{t+1}). \quad (3.18)$$

Où l'objectif est de maximiser (3.18).

Initialisation :

$$\delta_1(i) = \pi_i b_i(O_1) \quad 1 \leq i \leq N \quad (3.19)$$

$$\psi_1(i) = 0 \quad (3.20)$$

Récursion :

$$\delta_t(j) = \max_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}] b_j(O_t) \quad 2 \leq t \leq T \text{ et } 1 \leq j \leq N \quad (3.21)$$

$$\zeta_t(j) = \operatorname{argmax}_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}], \quad 2 \leq t \leq T, \text{ et } 1 \leq j \leq N \quad (3.22)$$

Terminaison :

$$P^* = \max_{1 \leq i \leq N} [\delta_T(i)] \quad (3.23)$$

$$q_T^* = \operatorname{argmax}_{1 \leq i \leq N} [\delta_T(i)] \quad (3.24)$$

L'objectif est de déterminer la séquence d'observations les plus probables par retour en arrière « Back-traking »:

$$q_t^* = \zeta_{t+1}(q_{t+1}^*) \quad t = T - 1, T - 2, \dots, 1 \quad (3.25)$$

### 3.5.4.3. Problème d'apprentissage du modèle

Il a pour objectif de déterminer les paramètres du modèle  $E = \{\pi, A^*, B^*\}$  à partir d'une séquence d'observations  $O = \{o_1, o_2, \dots, o_T\}$ , et de maximiser la vraisemblance  $P(O|E)$ . La solution est donnée par l'algorithme Baum-Welch (l'équivalent l'algorithme maximisation d'espérance mathématique « Expectation-Maximization »). Le principe est

d'utiliser les procédures de ré-estimation qui affinent le modèle petit à petit suivant les étapes suivantes [Belbedj15] :

- Choix d'un ensemble initial de paramètres  $E_0$ ,
- Calcul de  $E_1$  à partir de  $E_0$ ,
- Répétition du processus jusqu'à un critère de fin.
- **Algorithme :** Pour chaque séquence finie d'observations  $O = \{o_1, o_2, \dots, o_T\}$ :
  - définition de  $\alpha_t(j)$  avec la procédure de calcul Forward,
  - définition de  $\beta_t(j)$  avec la procédure de calcul Backward,
  - Calcul de  $\xi_t(i,j)$  à partir des quantités  $(\alpha_t(j), \beta_t(j))$  mesurées précédemment,
  - Définition de  $\gamma_t(i)$ .
- **Description du calcul:**

La probabilité de passer par un état  $S_i$  à  $t$ , à un état  $S_j$  à  $t+1$  générant  $O$  avec  $\theta$  :

$$\xi_t(i, j) = P(q_t = S_i, q_{t+1} = S_j | O, \theta) \quad (3.26)$$

Par calcul des paramètres Forward et Backward (3.26) est exprimée par :

$$\xi_t(i, j) = \frac{\alpha_t(i) a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)}{\sum_{i=1}^N \sum_{j=1}^N \alpha_t(i) a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)} \quad (3.27)$$

Ensuite,  $\gamma_t(i)$  et  $\xi_t(i,j)$  sont reliés par la somme selon  $j$  :

$$\gamma_t(i) = \sum_{j=1}^N \xi_t(i, j). \quad (3.28)$$

On peut déterminer les mesures suivantes :

$$\sum_{t=1}^{T-1} \gamma_t(i). \quad (3.29)$$

$$\sum_{t=1}^{T-1} \xi_t(i, j). \quad (3.30)$$

Où (3.29) est la mesure de nombre de transitions à partir de  $S_i$  (nombre de visites).

L'équation (3.30) donne la mesure de nombre de transitions de  $S_i$  vers  $S_j$ .

Finalement, les paramètres du modèle estimés sont mesurés comme suit :

$\bar{\pi}_i = \gamma_1(i)$ , est la fréquence d'apparition de l'état  $S_i$  à  $t=1$ .

$\bar{a}_{ij} = \frac{\sum_{t=1}^{T-1} \xi_t(i, j)}{\sum_{t=1}^{T-1} \gamma_t(i)}$ , c'est la mesure des probabilités de transition, elle égale au quotient de la mesure de nombre de transitions de  $S_i$  vers  $S_j$  par la mesure du nombre de transitions à partir de  $S_i$ .

$\bar{b}_j(k) = \frac{\sum_{t=1}^T \gamma_t(j) \cdot s.t. o_t = v_k}{\sum_{t=1}^T \gamma_t(j)}$ , c'est la mesure des probabilités d'observations, elle égale au quotient du nombre de fois d'observer le symbole  $v_k$  pour l'état  $j$  par le nombre de fois d'observer l'état  $j$ .

### 3.5.5. Modèle de mélange gaussien

Dans les modèles de Markov discrets les observations sont modélisées par une matrice des probabilités discrètes. Mais, ces modèles ne sont pas favorables pour la modélisation de dégradation de roulements (la dégradation de roulements est un phénomène stochastique), où les observations sont modélisées par des fonctions de probabilité continue (Gaussienne), l'espace de définition des défauts est donc modélisé par un mélange de ces distributions. La méthode la plus souvent utilisée avec ce type de modèles est la méthode de mélange gaussien.

L'ensemble de données est représenté par un mélange de distributions Gaussiennes associées aux états du système étudiés. Cette distribution de probabilité est donnée par [Tobon11] comme suit :

$$b_i(O) = \sum_{m=1}^M C_{jm} \xi(O, u_{jm}, U_{jm}), 1 \leq j \leq N \quad (3.31)$$

Avec :  $O$  est le vecteur d'observations,  $C_{jm}$  sont les coefficients de mélange (poids),  $\xi$  est la densité multidimensionnelle gaussienne, avec  $\mu_{ij}$  est le vecteur de moyennes et  $U_{ij}$  est la matrice de covariance,  $m : 1 \dots M$  est l'ordre de mélange,  $j$  est l'indice d'états. Un modèle de mélange gaussien est déterminé par :  $\pi_i$  la matrice des probabilités initiales,  $A^*$  la matrice des probabilités de transition et  $B^*$  la matrice des probabilités d'observations définies par la densité de probabilité gaussienne de paramètres :  $\mu$  le centre de gravité de la population,  $\sigma$  l'écart-type, et  $M$  la matrice de mélange (poids). Ces paramètres sont optimisés pour chaque nouvelle observation utilisant l'algorithme maximisation de l'espérance « Expectation-Maximization ».




Figure. 3.6. Principe du calcul de  $\xi_t(i, j)$  [Rab89].



### **3.6. Estimation du temps de vie restant d'un roulement par les modèles de mélange gaussien et MMC**

#### **3.6.1. Description du banc de test**

Une base de données de vieillissement accéléré du roulements est utilisée pour la mise en application de la méthode étudiée. Cette base de données contient les vibrations de roulements collectées par le Centre NSF I / UCR sur la maintenance intelligente (IMS) [Lee07], [Qiu06]. Le banc d'essai contient quatre roulements lubrifiés, installés sur un arbre et fonctionnent sous une charge radiale (cf. figure 3.7.). Un moteur à courant alternatif soutient le mouvement de l'ensemble par une courroie. Les conditions de travail sont maintenues constantes, la vitesse de rotation est de 2000 tr / min et la charge radiale est 6000 lbs (677,9089 N m). L'essai s'arrêtera lorsque les débris accumulés sur la prise magnétique dépassent un certain seuil, il indique que le défaut a atteint un stade avancé de dégradation, ce qui provoque la fermeture d'un interrupteur électrique [Qiu06],

Les enregistrements des vibrations de roulements ont été collectées toutes les 10 minutes par une carte d'acquisition de données National Instruments DAQCard-6062E. La fréquence d'échantillonnage est de 20 kHz et la taille des segments de données est de 20480 échantillons. Tous les enregistrements ont une durée de 1s.

#### **3.6.2. Phases d'implantation du modèle**

##### **3.6.2.1. Choix des indicateurs caractéristiques de dégradation**

Le choix des indicateurs est fait analytiquement ou par les méthodes de sélection des indicateurs avant la phase de classification, plusieurs méthodes sont utilisées, on peut distinguer : la méthode d'analyse en composantes principales (ACP) [Gao11]. Analyse linéaire discriminative (ALD) (linear discriminant analysis LDA) [Gao11], [Liu12], elles sont utilisées principalement pour diminuer la taille de l'espace de définition des défauts (la matrice des indicateurs caractéristiques) et pour éliminer la redondance et les indicateurs sensibles aux bruits.

##### **3.6.2.2. Construction du vecteur des indicateurs**

Chaque historique de roulement est transformé en un vecteur d'indicateurs caractéristiques en utilisant les indicateurs temporels ou les indicateurs temps-fréquence ou les indicateurs fréquentiels. La structure du vecteur d'indicateurs caractéristiques est présentée comme suit :

$$F_N = \begin{bmatrix} f_{1,1} & \cdots & f_{1,N} \\ \vdots & \ddots & \vdots \\ f_{L,1} & \cdots & f_{L,N} \end{bmatrix} \quad (3.32)$$

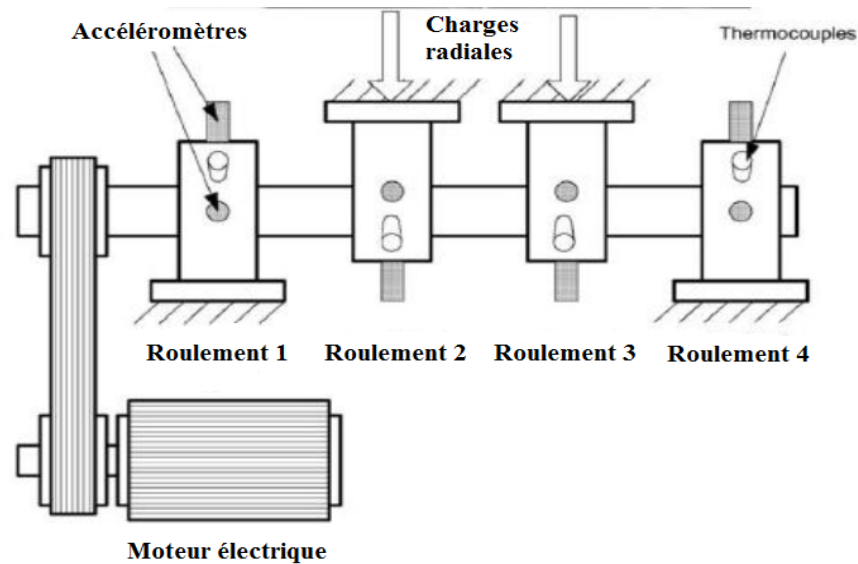


Figure. 3.7. Banc de test IMS [Qui06].

Où chaque ligne représente un indicateur, et chaque colonne représente une valeur de cet indicateur mesuré à partir d'un enregistrement du signal (observation). Ensuite, les indicateurs seront traités par un algorithme de sélection des indicateurs pour avoir un espace d'indicateurs réduit ce qui permet de réduire le temps de calcul et augmenter la précision du système.

Dans cette expérience, les indicateurs sont choisis analytiquement.

### 3.6.2.3. Choix du modèle

Avec ce type de modèles, nous ne sommes pas limités à un seul type de modèles (gauche-droite, ergodique), les paramètres du modèle ( $\pi$ , A, B) sont choisis au hasard. Puis, ils vont être optimisés pour chaque nouvelle observation. La phase d'apprentissage est faite à l'aide de l'algorithme Maximisation de l'espérance (EM) et les informations temporelles sont estimées par l'algorithme Viterbi, il mesure le nombre de visites par état et la durée de séjour pour chaque visite. Ceux-ci vont être utilisés par la suite pour estimer le temps de vie restant et l'état final du composant défaillant. La figure 3.8 donne un exemple de décodage Viterbi pour un espace de 100 échantillons (observations), et trois états de santé.

### 3.6.2.4. Phase d'apprentissage (hors-ligne)

Cette phase est exécutée hors-ligne. Elle se base sur le modèle de mélange gaussien qui mesure les paramètres du modèle pour des différents historiques disponibles, elle contient les différentes étapes illustrées précédemment. Les paramètres temporels sont supposés suivants une loi normale, ils sont déterminés par l'algorithme Viterbi comme suit :

– La moyenne :

$$\mu(D(S_i)) = \frac{1}{V} \sum_{\bar{v}=1}^V D(S_{i\bar{v}}) \quad (3.33)$$

– L'écart-type :

$$\sigma(D(S_i)) = \sqrt{\frac{1}{V} \sum_{\bar{v}=1}^V [D(S_{i\bar{v}}) - \mu(D(S_i))]^2} \quad (3.34)$$

$D$  est la durée de visite (séjour),  $i$  est l'index de l'état,  $\bar{v}$  est l'index de la visite et  $V$  est le nombre total des visites.

Donc, le modèle sera:

$$E = (\pi, A, B, \mu(D(S_i)), \sigma(D(S_i)), S_{final}) \quad (3.35)$$

L'algorithme Viterbi donne aussi le meilleur chemin avec le moindre nombre de visites par état.




Figure. 3.8. Exemple de décodage Viterbi.

### 3.6.2.5. Phase d'exploitation (en ligne)

La phase de test est exécutée en ligne, elle consiste à évaluer l'état actuel du système à partir d'une nouvelle observation utilisant les modèles qui ont été constitués dans l'étape d'apprentissage. Ensuite, le modèle qui correspond à la plus grande vraisemblance est retenu pour estimer le temps de vie restant avant défaillance. Ensuite, l'algorithme Viterbi est utilisé pour déterminer l'état actuel des nouvelles observations et donner la meilleure séquence d'états. Ici, le meilleur chemin est déterminé comme l'ensemble d'états qui donnent des probabilités de transition non nulles. À partir de la meilleure séquence d'états, les paramètres temporels, et les valeurs des probabilités de transition du modèle, le temps de vie restant (dénommé RUL) d'un roulement est calculé comme suit,

$$\begin{aligned}
 RUL_{supérieure} &= \sum_{i=\text{état actuelle}}^N [\mu(D(S_i)) + \rho \cdot \sigma(D(S_i))], \\
 RUL_{moyenne} &= \sum_{i=\text{état actuelle}}^N \mu(D(S_i)), \\
 RUL_{inférieure} &= \sum_{i=\text{état actuelle}}^N [\mu(D(S_i)) - \rho \cdot \sigma(D(S_i))]. \quad (3.36)
 \end{aligned}$$

$\rho$  : est le coefficient de confiance déterminé analytiquement,  $i$  : est l'index de l'état actuel,  $N$  : est le nombre total des visites.

### 3.6.3. Application et résultats de simulations

Dans cette phase on a appliqué le modèle étudié précédemment pour construire un algorithme Matlab. Cet algorithme est utilisé pour estimer le temps de vie restant d'un roulement. Les historiques de roulements de test#2 de la base de données IMS sont utilisés pour l'apprentissage. La figure 3.9 donne l'historique vibratoire complet de roulement#1.

Dans la Première phase (hors ligne), on a utilisé la transformée en paquet d'ondelette dans le troisième niveau avec l'ondelette mère 'db10' pour extraire les indicateurs fréquentiels à partir des signaux temporels, Ici, l'indicateur 'Spectral peak ratio SPR' est calculé à partir de la bande fréquentielle [0, 2500Hz] (cf. (3.37)), les résultats sont donnés par la figure 3.10, ils représentent la matrice des indicateurs 'FN'. Ensuite, cet historique est utilisé pour l'apprentissage des paramètres du modèle.

$$SPR = N \frac{\sum_{h=1}^n P_h}{\sum_{i=1}^n A_i} \quad (3.37)$$




Figure 3.9. Historique de roulement#1 test#2.




Figure 3.10. Historiques des roulements de test#2 (Spectrum peak ratio).

La matrice 'FN' est utilisée pour construire les différents modèles où trois MMC's sont construits. Ensuite, les paramètres du modèle sont estimés (la séquence d'états la plus probable et les durées de séjour) à l'aide de l'algorithme Viterbi. Les matrices des probabilités de transitions et des observations sont estimées par l'algorithme EM.

Dans la deuxième phase, l'historique de roulement #3 est utilisé pour la validation de la méthode proposée, les paramètres du modèle de roulement #4 sont utilisés pour estimer la RUL où le modèle de roulement#4 correspond à la plus grande valeur de vraisemblance. Les indices de la séquence d'états les plus probables, les paramètres temporels (cf. (3.34), (3.35)) et la matrice des probabilités de transition sont utilisés pour calculer la RUL (cf. (3.36)).




Figure 3.11. Décodage Viterbi, roulement#4.

Les résultats de la première et la deuxième phase sont donnés par les figures (3.11) et (3.12). La figure 3.11 donne le décodage Viterbi de la séquence d'états, l'état final défini par l'algorithme est l'état 1, la figure 3.12 donne la mesure de RUL, les limites supérieures et inférieures ainsi que le RUL réel et les intervalles alpha confiance à 30%.




Figure 3.12. Estimation du temps de vie restant (RUL) de roulement#2.

L'erreur de la mesure est calculée par la relation suivante [PHM12] :

$$E_{ri}(\%) = 100 \times \frac{ActRUL - \widehat{RUL}}{ActRUL} \quad (3.38)$$

Avec :  $ActRUL$  est la vraie valeur de RUL fixée par le fondateur de la base de données, elle égale à 159 heures et  $\widehat{RUL}$  est le temps de vie restant estimé.

Les résultats sont jugés satisfaisants où l'erreur maximale est égale à 37.49 % et la minimale est de 2.68%, la précision de la méthode est égale à 97.32 %. La durée de vie de roulement estimée est égale à 157 heures.

### 3.7. Conclusion

Dans ce chapitre, on a adopté les méthodes de pronostic guidées par les données pour l'estimation du temps de vie restant avant défaillance d'un roulement. Les méthodes d'estimation utilisant le modèle de mélange gaussien étant trouvées assez précises où elles n'exigent pas des pré-connaissances sur le système comme l'approche-modèle, l'algorithme lui-même développe des connaissances à partir de l'historique du système. Cependant, elle nécessite plusieurs scénarios de dégradation pour différentes conditions opérationnelles ce qui exige une grande capacité de mémoire et de calcul pour pouvoir améliorer la précision de la méthode. Ceci augmente le coût d'exploitation du système. En outre, la qualité des indicateurs caractéristiques des défauts de roulements peut affecter la précision de la méthode.

## **Chapitre IV**

# **Méthodes de diagnostic par intelligence artificielle.**

#### **4.1. Introduction**

Fréquemment, les méthodes de diagnostic des défauts de roulements se basent sur l'analyse spectrale des signaux issus d'un capteur installé sur le palier d'une machine. Néanmoins, la mise en place de certaines approches exige des connaissances préalables du comportement dynamique et vibratoire de l'élément défaillant (par exemple la fréquence centrale d'un filtre d'enveloppe et sa largeur). Aussi, un signal vibratoire ne contient pas que des fréquences vibratoires de roulement mais aussi des fréquences d'autres sources voisines comme les fréquences d'engrènement d'une boîte de vitesse ou les fréquences de désalignement d'un accouplement. De ce fait, ces approches exigent un bon retour d'expérience pour analyser et interpréter les résultats, où les seuils d'alarme et d'arrêt sont fixés selon des normes internationales (ISO 10816-1) ou analytiquement.

Pour les raisons citées précédemment et pour limiter l'effet de l'intervention humaine, plusieurs méthodes de détection automatique des défauts sont inventées. Quelques approches sont basées sur la théorie des probabilités comme les modèles de mélange de gaussien [Nelw06], [Mar06], la combinaison MMC/modèles de mélange de gaussien [Miao10] ou la régression logistique (Logistic Regression)[Yan05]. Il y en a d'autres qui utilisent les approches de reconnaissances de formes comme : la méthode de K-proches voisins (K-Nearest Neighbors KNN)[Safi14], les machines à vecteurs de support (SVM) [Hui17], [Shen13], [Raj14], l'approche K-means [Ioannis09], l'analyse en composantes principales (ACP) [Zvo10], l'analyse discriminante linéaire (ADL) [Harm14], les arbres de décision [Sugu11], et l'ACP probabiliste [Xiang15].

Il existe d'autres approches qui se basent sur la théorie de l'évidence (Théorie de croyance) comme la méthode Dempster-Shafer (D-S) [Hui17], [Lep11], [Yi10]. Il existe aussi des méthodes qui se basent sur les réseaux de neurones (RN) [Kumar13], [Gao11], [Lei09], [Li00], [Yu11], et les réseaux de neurones artificiels (RNA) [Zarei12], [Zarei14], qui représentent une instabilité (classification conflictuelle) avec les espaces de petite taille (nombre insuffisant d'échantillons) et une convergence lente avec les grands espaces [Shen13]. En outre, les réseaux de neurones probabilistes [Shao14], [Chen14], sont inventés pour améliorer les qualités de classification des RN's classiques. Également, les approches de la logique floue sont aussi appliquées pour la classification des défauts mécaniques: les C-moyennes floues (FCM) [Wentao08], les systèmes experts [Eber08], [Sun16].

Ceux-ci font la base d'une extension dénommée 'Adaptive Neuro-Fuzzy Inference System (ANFIS)', elle repose sur les avantages des deux approches mais elle a aussi leurs



propres inconvénients, elle est largement appliquée dans le domaine de diagnostic des roulements [Attoui15, Attoui17], [Lou04], [Zhang10]. Une autre approche prometteuse qui repose sur la combinaison des algorithmes de classification par la méthode Dempster-Shafer. Cette approche a pour objectif d'améliorer la précision de classification [Moosavian15], [Yang06], [Sun16] ou d'améliorer les qualités d'un algorithme de classification. Par exemple : L'algorithme SVM est incapable de classer une multitude de classes en une seule fois, il marche d'une manière binaire c'est-à-dire classe défaut/classe saine, il existe plusieurs méthodes pour étendre l'algorithme pour la classification de plus de deux classes comme la méthode « One versus One » ou « One versus All ». Récemment, la D-S est adoptée pour combiner les différentes sorties de classificateurs et de fournir une décision finale sur la classe de défaut [Hui17].

Un système de détection automatique des défauts est souvent composé des phases élémentaires suivantes : captage, prétraitement, extraction d'indicateurs, sélection des indicateurs, classification et décision (cf. figure 4.1), mais généralement elles sont résumées en trois étapes essentielles: extraction des indicateurs, sélection des indicateurs et classification. La précision d'une méthode de classification est considérablement affectée par la qualité des indicateurs caractéristiques de défaut, d'où les méthodes de sélection des indicateurs sont employées pour éliminer les indicateurs instables, redondants ou inconsistants avec les signatures de défaut.

Alors, ce chapitre traite les méthodes de classification automatique des défauts et précisément celles qui sont basées sur la logique floue (systèmes experts). Ensuite un nouveau système expert est implanté pour le diagnostic des défauts de roulements, ce classificateur est basé sur la mesure de similarité, ou cette mesure est incapable de séparer des classes avec chevauchement d'intervalle. Ici, une nouvelle méthode de sélection des indicateurs dite « Improved Range-Overlaps » est proposée pour améliorer le comportement de classificateur.

La contribution de ce travail est résumée comme suit: (i) on a proposé une nouvelle méthode de sélection des indicateurs dite « improved range overlaps » ;(ii) cette méthode proposée augmente les performances de la méthode de classification par mesure de similarité, cette dernière offre un modèle simple (complexité algorithmique minimale), compact, et transparent (plus accessible par l'utilisateur) ;(iii) on a utilisé une nouvelle mesure pour optimiser les fonctions d'appartenance et pour maintenir la nature floue du système, ce qui résulte en un système impartial.

## 4.2. Méthodes basées sur l'intelligence artificielle (IA)

### 4.2.1. Réseaux de neurones artificiels

Un réseau de neurones se compose d'une succession de couches dont chacune prend ses entrées sur les sorties de la précédente, et chaque couche se compose de N nombre de neurones. Comme on a signalé dans la section précédente les réseaux de neurones requièrent assez d'exemplaires (échantillons) et assez de classes pour la phase d'apprentissage.

Pendant cette phase le réseau s'auto-organise et les prototypes d'entrée reliés à la sortie désirée par une fonction d'activation et donner les résultats de sortie à travers l'évaluation de la somme pondérée et l'actualisation des poids. Après cette phase le système pouvait discriminer tous les paradigmes qui ressemblent aux prototypes. Ces systèmes présentent une certaine robustesse contre les effets de bruits. mais le choix des paramètres du système (nombre de couches, la taille de réseau, la taille des espaces d'apprentissage et de test) représentent l'enjeu majeur face à ce type de systèmes.




Figure. 4.1. Phases élémentaires d'une méthode de classification par intelligence artificielle.

### 4.2.2. Logique floue

La logique floue sert à représenter des connaissances incertaines ou imprécises d'un expert sous forme d'un modèle mathématique logique (Fonctions d'appartenances), la décision est réalisée à travers des règles si/alors (if/then) qui relieront les différents modèles. L'étape intermédiaire est appelée inférence. La figure 4.2 représente les trois étapes d'un système flou. Ici, l'apprentissage est fait d'après les connaissances d'un expert ou à l'aide de l'une des méthodes de classification (Algorithmes Génétiques (GA), KNN, K-means, C-moyennes Flous... etc).

Les systèmes flous sont les plus favorables pour le traitement des données des défauts mécaniques à cause de la nature floue des indicateurs des défauts [Sugul1].

### 4.2.3. Reconnaissances des formes (RDF)

Elles ont pour objectif d'associer une observation à un mode de fonctionnement (signature) qui correspond à une classe à partir d'une base de données pour l'apprentissage, les symboles de classes sont connus (classification supervisée), ils sont fixés par

l'utilisateur comme sortie, ou inconnus (classification non supervisée basée sur les méthodes d'optimisation). Parmi ces méthodes on peut distinguer : machine à vecteurs de support (SVM), Analyse en composante principale (ACP), le seul inconvénient de ces approches est que la qualité du diagnostic dépend de la préallocation des classes déterminée dans la phase d'apprentissage ou par les connaissances à priori des états de fonctionnement du système (ensemble de mesures des modes de fonctionnement ou classes connues à priori).

### 4.3. La logique floue

Elle est définie comme la notion des sous-ensembles flous, elle a pour objectif de fournir un moyen de représenter et de manipuler des connaissances imparfaitement décrites, vagues ou imprécises.

Dans ce cadre, la logique floue est inventée pour éviter les inconvénients de la logique classique, la figure 4.1 donne un exemple de la logique floue et la logique classique qui traite un problème d'analyse de la température souvent appliqué dans le monde réel.

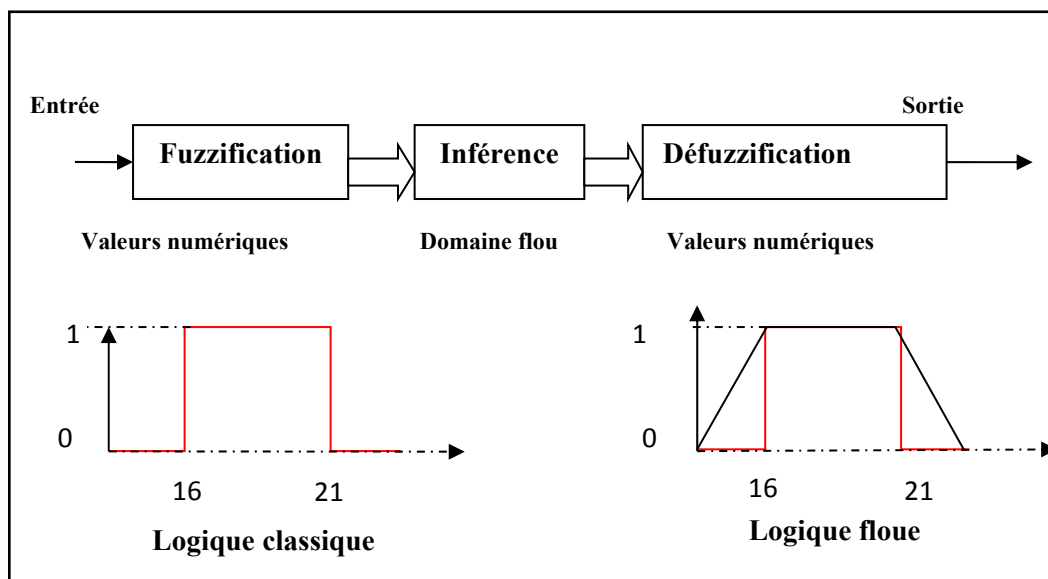


Figure. 4.2. Étapes élémentaires d'un système flou.

L'un des inconvénients majeurs des méthodes de la logique classique est qu'elles refusent toutes les valeurs non incluses dans l'espace support, selon notre exemple les valeurs inférieures à 16 (e.g:  $T=15.9999^{\circ}\text{C}$ ) et supérieures à 21 (e.g:  $21.001^{\circ}\text{C}$ ) ne sont pas considérées, par contre dans le domaine de la logique floue ces valeurs sont considérées avec un certain degré de certitude.

**Définition 1** (Un sous-ensemble flou) Un sous-ensemble flou  $A$  dans un univers de discours  $X$  est caractérisé par sa fonction d'appartenance  $\mu_A(x)$  qui associe à chaque

élément  $x$  de  $X$  une valeur dans l'intervalle des nombres réels  $[0, 1]$ . Cette valeur est dénommée degré d'appartenance.

$$\mu_A: X \rightarrow [0, 1]. \tag{4.1}$$

Ainsi, un sous-ensemble flou  $A_f$  dans  $X$  peut être représenté par un ensemble de couples ordonnés:

$$A_f = \{(x, \mu_A(x)) | x \in X\}. \tag{4.2}$$

Pour chaque valeur  $x$  de  $X$ , il y a un degré d'appartenance joint  $\mu_A(x)$ .

Les gabarits de fonction d'appartenance les plus utilisés sont représentés dans le tableau 4.1.

**Définition 2** (Support) Le support d'un sous-ensemble flou  $A$  dans un univers de discours  $X$  est les éléments lesquels ont des valeurs d'appartenance strictement positives.

$$S(A) = \{x | \mu_A(x) > 0\} \tag{4.3}$$

**Tableau 4.1.** Les gabarits des fonctions d'appartenance les plus usagées.

Fonction	Équation	Courbe
<b>Triangulaire</b>	$f(x, a, b, c) = \max\left(\min\left(\frac{x-a}{b-a}, \frac{c-x}{c-b}\right), 0\right) \tag{4.3}$	
<b>Gaussienne</b>	$f(x, \sigma, c) = e^{-\frac{(x-c)^2}{2\sigma^2}} \tag{4.4}$	

**Définition 3** (point de croisement) Le point de croisement d'un sous-ensemble flou  $A$  dans un univers du discours  $X$  c'est les éléments de  $A$  lesquels ont un degré d'appartenance égale à 0.5, c'est l'ensemble des éléments qui appartiennent à  $A$  qu'à son complémentaire.

$$C(A) = \{x | \mu_A(x) = 0.5\} \tag{5.6}$$

**Définition 4** (Noyau) Le noyau d'un sous-ensemble flou  $A$  dans un univers du discours  $X$  est les éléments de  $X$  pour lesquels la fonction d'appartenance vaut 1, c'est l'ensemble de points qui appartiennent certainement à  $A$  :

$$N(A) = \{x | \mu_A(x) = 1\} \tag{4.7}$$

**Définition 5** (Hauteur) La hauteur d'un sous-ensemble flou  $A$  dans un univers de discours  $X$  est la valeur maximale de la fonction d'appartenance  $\mu_A$  sur l'ensemble  $X$ .

$$H(A) = \sup_{x \in X} \mu_A(x) \quad (4.8)$$

**Définition 6** ( $\alpha$ -coupe) Pour toute valeur  $\alpha$  de l'intervalle  $[0, 1]$ , on appelle  $\alpha$ -coupe d'un sous-ensemble flou  $A$  de  $X$ , le sous-ensemble  $A_\alpha$  des éléments de  $X$  pour lesquels la fonction d'appartenance est supérieure ou égale à  $\alpha$  :

$$A_\alpha = \{x \in X | \mu_A(x) \geq \alpha\} \quad (4.9)$$

#### 4.3.1. Opérations sur la logique floue

Les opérations sur la logique floue comme l'intersection et l'union sont définies à travers les opérateurs  $\min$  ( $\wedge$ ) et  $\max$  ( $\vee$ ), qui sont équivalents au produit et la somme dans l'algèbre. Pour  $A$  et  $B$  deux sous-ensembles de  $X$  :

$$\forall x \in X \quad \mu_{A \cap B} = \min(\mu_A(x), \mu_B(x)) = \mu_A(x) \wedge \mu_B(x) \quad (4.10)$$

$$\forall x \in X \quad \mu_{A \cup B} = \max(\mu_A(x), \mu_B(x)) = \mu_A(x) \vee \mu_B(x) \quad (4.11)$$

Le complémentaire de  $A$  noté  $A^c$  est égale à :

$$\forall x \in X \quad \mu_{A^c} = 1 - \mu_A(x) \quad (4.12)$$

#### 4.3.2. Inférence floue (variables linguistiques)

Comme l'indique la figure 4.2, un système d'inférence floue est formé de trois étapes, la première est l'étape de fuzzification où les valeurs numériques sont transformées en des degrés d'appartenances en utilisant les algorithmes d'apprentissage où les fonctions d'appartenance construites modélisant les sous-espaces. La deuxième étape est le moteur d'inférence, il est constitué de l'ensemble des règles linguistiques déterminées comme suit:

Si ( $x$  est  $A$ ) ; Alors ( $y$  est  $B$ ).

Ces règles permettant de déduire des connaissances concernant l'état du système, elles sont basées sur les connaissances et les expériences prises par un expert (opérateur de la machine, agent de maintenance).

Les inférences floues sont des relations floues définies entre deux sous-ensembles et font intervenir n'importe quel opérateur de combinaison ( « ET » et « OU »). La phase d'inférence consiste à calculer le degré de vérité des différentes règles et d'associer à chaque règle une valeur de sortie.

Les deux types d'inférences les plus souvent appliquées sont celles définies par Mamdani et Sugeno.

Les règles de type Mamdani sont exécutées en quatre étapes : Fuzzification, évaluation, groupement, et la défuzzification, elles sont de la forme : Si  $x$  est  $A$  OU  $z$  est  $B$  Alors  $y$  est  $C$ , ou Si  $x$  est  $A$  ET  $y$  est  $B$  Alors  $z$  est  $C$ , où bien Si  $x$  est  $A$  Alors  $z$  est  $C$ . En outre, les

règles de type Sugeno sont de la forme : Si x est A ET y est B Alors  $f(x, y)$ , où  $f$  est une fonction mathématique continue de variables réelles (cf. figure 4.3). Ce type de règles est largement utilisé dans la commande des machines.

L'étape de défuzzification : cette étape est basée sur le retour aux grandeurs de sortie réelles. L'une des méthodes de défuzzification est la méthode de calcul du centre de gravité, elle consiste à calculer l'abscisse du centre de gravité d'un espace A dans un intervalle [a, b] selon :

$$COG = \frac{\int_a^b \mu_A(x)x dx}{\int_a^b \mu_A(x) dx} \quad (4.13)$$

Pratiquement ce problème est expliqué par le problème d'estimation suivant :

$$COG = \frac{\sum_{x=a}^b \mu_A(x)x}{\sum_{x=a}^b \mu_A(x)} \quad (4.14)$$

La figure 5.4 donne un exemple d'une défuzzification par centre de gravité.

**Exemple 1** Exemple de calcul de l'âge moyen d'une population, dans cet exemple la valeur du centre de gravité (triangle en rouge) est calculée pour les valeurs données comme suit:

$$COG(age) = \frac{((10 + 20) \times 0.2 + (30 + 40) \times 0.4 + (50 + 60) \times 0.7)}{(0.2 + 0.2 + 0.4 + 0.4 + 0.7 + 0.7)} = 42.69 \text{ ans}$$




Figure. 4.3. Exemple d'inference Sugeno [Zhang10]

De ce fait, on peut construire un système expert flou suivant les étapes suivantes :

- On détermine le problème et on crée les variables linguistiques,
- On détermine l'espace flou,
- On obtient et on construit les règles floues,

- On alimente le système par les règles floues et les fonctions d'appartenance pour déclencher l'inférence floue ,
- Évaluation et accord du système.




Figure 4.4. Exemple d'une défuzzification par centre de gravité.

#### 4.4. Théorie de l'évidence

La théorie d'évidence se base sur les mesures suivantes : croyance, plausibilité, nécessité, possibilité et probabilité.

D'après [Zadah 78] la théorie de la logique floue est la base de la possibilité, donc c'est une fraction de la théorie d'évidence. La théorie de l'évidence se base sur deux mesures : la croyance et la plausibilité [Wiem10].

On a  $m$  une fonction déterminée de l'espace de l'univers du discours  $\Omega$  vers un intervalle unitaire  $[0, 1]$ , où  $\Omega$  est fini. La fonction  $m$  où  $m: Pl(\Omega) = [0, 1]$  est déterminée pour satisfaire les conditions suivantes :

$$m(\emptyset) = 0 \quad (4.15)$$

$$\sum_{A \in Pl(\Omega)} m(A) = 1 \quad (4.16)$$

La fonction  $m$  est la fonction de masse de croyance, en anglais (basic probability assignment (bpa)), la valeur  $m(A)$  exprime la proportion de tous les evidances supportant l'affirmation que un élément particuleir de  $\Omega$  se place dans  $A$ . cette valeur  $m(A)$  est particulière au set ( $A$ ), si il ya  $B \subseteq A$  il faut déduire une autre valeur  $m(B)$ .

**Definition 7** Tout  $A \subseteq \Omega$ ,  $m(A) > 0$  est appelé élément focal (EF) de  $m$ . et  $m(\emptyset)$  est le degré d'ignorance totale.

**Definition 8** La fonction de croyance et de plausibilité sont exprimées comme suit :

$$Bel(A) = \sum_{\emptyset \neq B \subseteq A} m(B), \quad \forall A \subseteq \Omega \quad (4.17)$$

$Bel(A)$  représente la part de croyance soutenant  $A$ .

$$Pl(A) = \sum_{B \cap A \neq \emptyset} m(B), \forall A \subseteq \Omega \quad (4.18)$$

$Pl(A)$  représente la part maximale de croyance qui pourrait soutenir  $A$ .

On peut déduire :  $Bel(A) = 1 - Pl(A^c)$  et  $Pl(A) = 1 - Bel(A^c)$  (4.19)

**Exemple 2** on Considère l'exemple dans la figure 4.5 :

$$\begin{aligned} Bel(C) &= m(B_1) + m(B_2) \text{ et} \\ Pl(C) &= m(B_1) + m(B_2) + m(B_3) \end{aligned} \quad (4.20)$$

Avec :

$$b(A) = \sum_{B \subseteq A} m(B), \forall A \subseteq \Omega \quad (4.21)$$

$b(A)$  est la fonction d'implicabilité, elle représente la somme des masses allouées aux sous-ensembles de  $A$ ,  $b(\Omega)=1$ .

et :

$$q(A) = \sum_{B \supseteq A} m(B), \forall A \subseteq \Omega \quad (4.22)$$

$q(A)$  est la fonction dite « function of commonality », elle représente la somme des masses allouées aux sur-ensembles de  $A$ ,  $q(\emptyset)=1$ .




Figure 4.5. Exemple d'un cadre de discernement.

#### 4.5. Fusion de l'information

D'après la règle de fusion de Dempster-Shafer, supposons  $Bel_1$  et  $Bel_2$  sont des fonctions de croyance dans le même cadre de discernement  $\Omega$ ,  $m_1$  et  $m_2$  sont respectivement leurs fonctions de masse, et les éléments focaux sont  $A_1, A_2, \dots, A_i$  et  $B_1, B_2, \dots, B_j$  respectivement [Lep11].



Supposons :

$$\sum_{A_i \cap B_j = \Omega} m_1(A_i)m_2(B_j) < 1 \quad (4.23),$$

et  $m: 2^\Omega \rightarrow [0, 1]$  est défini comme la fonction de masse après fusion :

$$m = m_1 \oplus m_2 = \frac{\sum_{A_i \cap B_j = \Omega} m_1(A_i)m_2(B_j)}{1-K} \quad (4.24)$$

Avec :  $K$  est le degré de conflit où les éléments focaux de  $m_1$  et  $m_2$  n'ont pas des éléments en communs, où :

$$K = \sum_{A_i \cap B_j = \emptyset} m_1(A_i)m_2(B_j) \quad (4.25)$$

#### **4.6. Diagnostic des défauts de roulement par les systèmes experts flous**

Les roulements sont des éléments mécaniques d'architecture complexe, il sont utilisés essentiellement pour guider et supporter le poids des arbres afin de faciliter leurs rotation [Diaz17]. Cependant, les roulements ne sont pas fabriqués pour supporter les chocs, ce qu'exprime la haute portion des défauts de roulements dans les machines à induction.

Parmi les méthodes de surveillance automatiques des défauts des machines on peut distinguer : les méthodes probabilistes, les réseaux de neurones artificiels et les systèmes experts.

Les systèmes experts sont largement appliqués dans le domaine industriel pour la commande, la surveillance des défauts...etc. Comme tous les systèmes de surveillance automatique, le système expert flou dans sa forme initiale est composé des étapes suivantes : extraction d'indicateurs, sélection des indicateurs et l'étape de classification.

##### **4.6.1. Extraction des indicateurs**

Après numérisation des signaux vibratoires mesurés, l'étape suivante est l'extraction des indicateurs de défauts de roulements, les signaux mesurés sont directement associés au comportement dynamique du système [Gao06], mais ils ne comportent pas seulement des signatures fréquentielles des défauts de roulements mais aussi du bruit et d'autres composantes fréquentielles venantes d'autres sources voisines, ils peuvent infecter ou détériorer l'information [Jiang14]. De ce fait, les indicateurs des défauts de roulements sont incertains par nature.

Beaucoup de méthodes d'extraction de l'information sont inventées autour de l'idée de filtrage des signaux, parmi ces méthodes on pourra distinguer : la décomposition en modes empiriques (EMD) [Zvo15], [Jiang14], les ondelettes discrètes [Attoui15], [Lou04], les paquets d'ondelettes [Gao11], [Shen13].

Le travail fait par [Shen13] représente la base de cette étape de travail, les paquets d'ondelettes permettent de surveiller les signatures de défauts de roulements dans des projections fréquentielles à multi-résolutions (bandes fréquentielles) et ir-redondantes (cf. figure 1.7), chaque nœud représente les coefficients de paquet d'ondelettes dans une bande fréquentielle de contenu fréquentiel différent. Cette méthode mesure la similarité du signal vibratoire avec l'ondelette mère selon cette formule :

$$w_{j,n} = \langle f, W_{j,n,t}^m \rangle \quad (4.26)$$

Ensuite les indicateurs de défaut de roulements sont calculés à partir des coefficients de paquet d'ondelette pour identifier les signatures caractéristiques de défauts incorporés dans le signal vibratoire. Un récapitulatif des indicateurs de défauts de roulements est tabulé dans le tableau 4.2.

**Tableau 4.2.** Les indicateurs issus des coefficients de paquet d'ondelettes [Shen13]

<b>Valeur absolu de l'amplitude moyenne:</b> $m = \frac{1}{N} \sum_{t=1}^N  W_{j,n,t} $	<b>Skewness:</b> $Sk = \frac{1}{N} \sum_{t=1}^N W_{j,n,t}^3$
<b>Kurtosis:</b> $Ku = \frac{1}{N} \sum_{t=1}^N W_{j,n,t}^4$	<b>Facteur de Clearance:</b> $Cl = \frac{\max( W_{j,n,t} )}{(\frac{1}{N} \sum_{t=1}^N \sqrt{ W_{j,n,t} })^2}$
<b>Facteur crête:</b> $Cf = \frac{\max( W_{j,n,t} )}{\sqrt{\frac{1}{N} \sum_{t=1}^N W_{j,n,t}^2}}$	<b>Facteur d'impulsion:</b> $imf = \frac{\max( W_{j,n,t} )}{\frac{1}{N} \sum_{t=1}^N  W_{j,n,t} }$
<b>facteur de forme:</b> $Sf = \frac{\sqrt{\frac{1}{N} \sum_{t=1}^N W_{j,n,t}^2}}{\frac{1}{N} \sum_{t=1}^N  W_{j,n,t} }$	<b>RMS:</b> $rms = (\frac{1}{N} \sum_{t=1}^N \sqrt{ W_{j,n,t} })^2$
<b>Variance:</b> $V = \frac{1}{N} \sum_{t=1}^N W_{j,n,t}^2$	

La majorité des indicateurs ne sont pas relatives aux signatures des défauts de roulements. Également, la grande taille des espaces d'indicateurs est un fardeau pour le système de diagnostic, ce qui exige l'utilisation des méthodes de sélection des indicateurs.

#### 4.6.2. La sélection des indicateurs

Les méthodes de sélection des indicateurs sont surtout employées pour la réduction de la taille de l'espace des indicateurs, éliminer les indicateurs redondants et éliminer les indicateurs gâtés par le bruit, alors améliorer l'efficacité et la précision du système de diagnostic.

Des travaux de recherche récents ont classés les méthodes de sélection des indicateurs caractéristiques en trois familles:

#### **4.6.2.1. Méthodes de filtre**

Elles sont dénommées de filtre puisqu'elles interviennent avant l'algorithme de classification.

#### **4.6.2.2. Méthodes Wrapper**

Les méthodes Wrapper considèrent l'algorithme de classification comme une boîte noire et la performance de l'algorithme comme fonction objective pour évaluer l'espace des indicateurs caractéristiques [Chand14].

#### **4.6.2.3. Méthodes embarquées**

Les méthodes embarquées visent la réduction du temps de calcul pris pour reclasser les différents sous-ensembles de l'espace des indicateurs. L'objectif principal consiste à intégrer la sélection des indicateurs caractéristiques dans le cadre du processus d'apprentissage [Chand14].

#### **4.6.2.4. La méthode de sélection des indicateurs proposée 'Improved Range-Overlaps method'**

Parmi les méthodes de filtrage, on peut distinguer: l'information de Fisher (Fisher score FS), l'analyse en composantes principales (PCA) [Gao11], [Malhi04], la similarité cosinus « cosine similarity » (CS) [Suebsing09], ou khi deux (khi-Square CS), relief F ou leur combinaison [Vakhariaa16], cross-entropy (CE) [Walcz96], dependent feature vector (DFV) [Chen14], distance evaluation technique (DET) [Shen13], ils offrent une évaluation plus rapide de l'ensemble de caractéristiques avec le coût d'exploitation le plus bas. Cependant, les méthodes wrapper ont la plus grande précision, mais elles désirent également une complexité de calcul élevée. D'autre part, les méthodes embarquées impliquent l'algorithme de sélection des indicateurs caractéristiques dans le cadre du processus d'apprentissage afin de réduire le temps de calcul en basant sur les étiquettes des classes pour guider l'algorithme de sélection des indicateurs caractéristiques.

Dans le contexte des méthodes de filtre on a proposé une nouvelle méthode de sélection des indicateurs caractéristiques, elle est basée sur le contexte de la mesure de chevauchement entre classes où on a amélioré la mesure classique dite Range-Overlaps method ROM et on a donné une nouvelle mesure quantitative au lieu de l'ancienne mesure (1 ou 0), cette méthode est dénommée « Improved Range-Overlaps method IRO».

– **Contexte général:** de nos jours, il existe un nombre limité de méthodes de sélection des indicateurs caractéristiques qui ont discuté l'idée de chevauchement d'intervalle. [Yeh10] présente la méthode Range-Overlaps (ROM) pour classer les données ECG de l'arythmie cardiaque. Certains travaux utilisent des limites de décision optimisées

entre les classes pour mesurer la validité des indicateurs caractéristiques [Rafiee10], [Chandra11]. Récemment, [Liu17] a proposé une nouvelle mesure statistique appelée LW-Index, elle repose sur la mesure du degré de liberté (ou tolérance) entre les intervalles de groupes voisins pour évaluer la sensibilité de l'indicateur caractéristique.

De ce fait, nous pouvons expliquer la méthode IRO comme suit: La ROM est définie comme la mesure d'intersection entre deux classes voisines:  $\tilde{R} = R_i \cap R_j$ , elle donne 1 s'il y a chevauchement d'intervalles entre les classes et 0 sinon, cette mesure est inutile pour le classement d'importance des indicateurs. La mesure IRO conduite à la mesure du jeu minimum entre les intervalles de deux classes voisines.

– **Description de la nouvelle mesure :** la procédure de la méthode de sélection des indicateurs caractéristiques IRO proposée est expliquée comme suit:

Soit  $X = \{f_1, f_2 \dots f_d\}$  un ensemble d'indicateurs caractéristiques de taille  $N$  et de dimension  $d$ . Supposons que le sous-ensemble  $f_d$  de  $X$  peut être décomposé en  $M$  groupes non vides selon  $M$  classes où  $f_d = \{C_1, C_2 \dots C_j\}$ , et chaque classe est représentée par un vecteur  $C_j; j = 1, 2, \dots, M$ .

Pour chaque sous-ensemble de l'espace des indicateurs caractéristiques, on trie en ordre croissant les vecteurs de classes en fonction de leurs valeurs minimales:

$$\min \{C_1\} < \min \{C_2\} < \dots < \min \{C_M\}.$$

Leurs intervalles (limites inférieures et supérieures) sont définis par:

$$RA_{C_j} = [Ll, Ul] \tag{4.27}$$

Où  $Ll$  et  $Ul$  sont respectivement les limites inférieure et supérieure de la classe  $j$ .

Ensuite, nous déterminons le degré de jeu entre une classe  $C_1$  et la classe la plus proche  $C_2$  comme suit:

$$dc = (\max(Ll_{C_1}, Ll_{C_2}) - \min(Ul_{C_1}, Ul_{C_2})) / (mx - mn) \tag{4.28}$$

Où  $mn$  et  $mx$  sont respectivement les limites inférieure et supérieure de l'indicateur, la valeur minimale entre les valeurs d'espacement ( $dc$ ) est utilisée pour évaluer l'indicateur caractéristique. Pour tous les indicateurs, on met les valeurs  $dc$  correspondantes dans l'ordre descendant, puis on conserve les entités dominantes correspondantes aux plus grandes valeurs de  $dc$ .

#### **4.6.3. Étape de classification**

Comme était signalée dans la section 4.2.3, un système expert flou est implanté sur trois étapes, la Fuzzification, l'inférence et la défuzzification. Les Systèmes Expert Flous

(SEF's) sont largement utilisés pour le diagnostic des défauts de roulements [Eber08], [Sun16], ils tiennent en compte l'imprécision des connaissances reconstruites autour d'un ensemble de données numériques collectées (vibrations, courants, températures...) due aux contraintes de mesure (capteur défaillant, contraintes de mesure ...). [Medasani98] a donné un aperçu des méthodes les plus réputées discutant la construction d'un SEF à partir des données d'apprentissage.

La plupart des algorithmes qui sont fréquemment utilisés pour l'apprentissage des systèmes flous ont une convergence lente et exigent un grand espace mémoire. Alors, ils sont jugés plus au moins favorables à cause de leur complexité algorithmique. Cependant, les applications industrielles réelles requièrent des systèmes de diagnostic peu complexes avec un temps de réponse élevé. Cependant, la méthode de similarité [Hong96], [Touil15] est un algorithme simple et rapide qui nécessite une configuration mathématique moins complexe et un espace mémoire réduit. Il besoin une seule phase pour la construction du système et les fonctions d'appartenance.

Ce travail traite la construction d'un FES de deux entrées et une seule sortie. L'ensemble des indicateurs caractéristiques sélectionné alimente le moteur d'inférence floue comme entrée et les règles floues résultent de l'algorithme d'apprentissage présenté par [Hong96], il divise les données selon la mesure de similarité entre un point de données et le point suivant. Cette méthode offre une configuration mathématique simple et réalise l'apprentissage des données dans un laps de temps court. En effet, l'algorithme atteint une grande précision d'apprentissage avec les échantillons de petite taille, ce qui n'est pas abordable par les algorithmes d'apprentissage classiques tels que; Réseaux neuronaux (NN), algorithmes génétiques (GA), ou encore algorithmes Fuzzy C-means (FCM). L'algorithme proposé est construit comme suit :

- Étant donné un vecteur caractéristique  $\vec{f}_a$ , on met en ordre croissant les  $n$  échantillons d'apprentissage de la variable  $x$ .

$$\vec{f} = x_1, x_2, \dots, x_n.$$

$$\vec{Y} = \text{sort}[\vec{f}] = y_1 + y_2 + \dots + y_n \quad (4.29)$$

- On calcule la différence entre les points de données adjacentes de  $Y \vec{}$ .

$$\text{diff}_i = y_{i+1} - y_i, \text{ for } i = (1, 2, \dots, n-1) \quad (4.30)$$

- On fait le mapping des similarités entre les points de données adjacentes, les similarités se trouvent entre des nombres réels 0 et 1:

$$S_i = \left\{ \begin{array}{l} \left\{ 1 - \frac{diff_i}{W * \sigma_s}, \text{ for } diff_i \leq W * \sigma_s \right\} \\ 0 \quad \text{otherwise} \end{array} \right\} \quad (4.31)$$

Où  $\sigma_s$  est l'écart type de  $diff_i$ ,  $W$  est le paramètre de contrôle utilisé pour déterminer la forme de la fonction d'appartenance.

– Les données sont regroupées en fonction de leurs similarités, si l'on veut obtenir  $m$  groupes, les premiers  $(m-1)$  échantillons qui correspondent aux valeurs minimales de similarités pourraient être pris comme des points limites entre des groupes adjacents. Pour une classe  $j$ , le centre de classe pourrait être défini par la formule suivante:

$$b_j = \frac{y_i * s_i + y_{i+1} * \frac{s_i + s_{i+1}}{2} + \dots + y_{k-1} * \frac{s_{k-2} + s_{k-1}}{2} + y_k * s_{k-1}}{s_i + \frac{s_i + s_{i+1}}{2} + \dots + \frac{s_{k-2} + s_{k-1}}{2} + s_{k-1}} \quad (4.32)$$

Où  $k$  représente l'index du dernier point dans la  $j^{\text{ème}}$  classe.

– L'écart-type d'une classe  $C$  définie par l'intervalle  $W = [a, c]$ , et  $a$  et  $c$  sont les limites supérieure et inférieure:

$$\sigma = \sqrt{\frac{(W / 2)^2}{-2 \ln \alpha}} \quad (4.33)$$

Où  $\alpha$  est le  $\alpha$ -coupe correspondant au support de l'ensemble flou [Tay11]. La fonction d'appartenance gaussienne est calculée comme suit:

$$F(x, b, \sigma) = e^{\left(-\frac{(x-b)^2}{2\sigma^2}\right)} \quad (4.34)$$

Ici, on a proposé la mesure de l'écart-type par le principe de  $\alpha$ -coupe pour avoir un système impartial.

La valeur d'appartenance d'un échantillon de test est calculée comme suit:

$$F(x_d) = e^{\left(-\frac{(x_d - b_d)^2}{2\sigma_d^2}\right)} \quad (4.35)$$

Les règles floues ont été définies pour une variable  $x$  dans l'univers du discours  $X$  comme suit [Wu07] :

$$(A_1 \cap A_2 \cap \dots \cap A_n)(x) = \min \{A_1(x), A_2(x) \dots A_n(x)\}, \forall x \in X. \quad (4.36)$$

Où  $A(x)$  est une règle de la fonction d'appartenance.

#### **4.7. Procédure expérimentale**

Le potentiel du système proposé est vérifié à l'aide de trois ensembles de données différents comprenant deux types de défauts de roulements couramment étudiés (défauts localisés et généralisés).

Les défauts de roulements localisés produisent des signatures vibratoires assez simples. Néanmoins, les vibrations excitées par les défauts de roulements distribués tendent à être plus complexes. La réponse est composée de deux réponses impulsionnelles dominantes qui sont l'événement d'entrée et de sortie et une série de vibrations mineures excitées par la surface rugueuse de la zone défectueuse [Dolenc16].

Le système proposé comprend les étapes suivantes: (i) les signaux de vibration provenant du palier de la machine tournante ont été acquis par des capteurs piézoélectriques; (ii) les signaux acquis ont été traités pour atteindre une certaine résolution d'information. Ensuite, la TPO pourrait extraire les caractéristiques du signal de vibration; (iii) le système applique la IRO pour sélectionner les indicateurs caractéristiques significatives; (iv) le système classe les défauts de roulements à l'aide du SEF formé.

##### **4.7.1. Base de données des défauts de roulements localisés**

Nous avons utilisé l'ensemble de données collectées à partir de la base de données de roulements de la Case Western Reserve University [Lou04]. La figure 4.6a représente le banc d'essai qui est composé des éléments suivants: moteur à induction triphasé de 2 hp sur la gauche, accouplement, et alternateur. Les roulements du type 6205-2RS JEM SKF roulements rainurés à billes soutiennent l'arbre du moteur. Les défauts ont été mis artificiellement sur le roulement de côté charge et sur celui de côté ventilateur en utilisant le perforage par électro-érosion pour garder la taille du défaut sous contrôle. Les signaux de roulement amont moteur correspondant aux classes de défauts de la bague interne (BI), défaut de la bille (Bille), défaut de la bague externe (BE), collectés sous une charge de 2hp sont pris en compte dans ce travail. Alors, deux ensembles ont été construits en fonction de la taille du défaut (0,007, 0,021 pouce), étant donné que la sévérité du défaut suit sa taille. Dans cette partie de travail un total de six classes de défauts de roulements est considéré.

Puisque la fréquence de modulation du signal vibratoire ne dépasse pas 5 kHz, l'enregistrement de données est effectué avec une fréquence d'échantillonnage de 12 kHz. L'enregistreur de données est équipé d'un filtre passe-bas (anti-repliement) pour limiter la gamme de fréquences à étudier. Chaque enregistrement dure 10 secondes.

#### 4.7.2. Base de données des défauts de roulements distribués

On a construit une troisième base de données à partir la base de données IMS (cf. chapitre 3, section 3.6.1) où les enregistrements qui correspondent aux défauts (BI, Bille, BE) ont été considérés dans cette application pour la mise en évidence de l'utilité du système avec des défauts de roulements répartis. Cette base de données est construite par les signaux enregistrés à partir des historiques de roulements : 3 et 4 du test 1 et de roulement 1 du test 2. Ici, les défauts sont considérées comme des défauts «Brutaux».




Figure. 4.6. Les deux bancs de test de roulements, CWRU (a), IMS (b).

Lorsqu'on a vu une évolution rapide de défaut de la bague externe de roulement 1 dans les 10 dernières secondes, on a considéré seulement les 5 derniers enregistrements. On a considéré les enregistrements des fichiers 2147- 2151 du test 1, et les enregistrements des fichiers 975-979 du test 2.

#### 4.7.3. Extraction des indicateurs caractéristiques

Un bruit gaussien blanc avec une valeur de SNR égale à 20 dB est ajouté au signal pur de vibration pour prouver l'efficacité de la méthode d'extraction des indicateurs caractéristiques et le système de diagnostic proposé. Chaque mesure est divisée en des segments égaux avec 1024 points chacun, comme le montre les figures 4.7 et 4.8.

La décomposition en paquet d'ondelettes (TPO) au troisième niveau de décomposition permet au système d'atteindre des différentes résolutions de fréquences et de mesurer les indicateurs caractéristiques statistiques pour chaque niveau de résolution. Par conséquent, 126 indicateurs caractéristiques statistiques sont extraits des coefficients de paquet d'ondelettes à partir de chaque nœud de l'arborescence du paquet d'ondelettes. Le tableau 4.2 donne les neuf indicateurs caractéristiques statistiques extraits. Le tableau 4.3, donne la gestion des ensembles de données, y compris le nombre d'échantillons utilisés pour l'apprentissage et le test. En plus, selon le type de défaut, les entités résultantes sont concaténées pour construire l'ensemble de caractéristiques (espace des indicateurs).



Finalement, il convient de signaler que la sensibilité de l'indicateur caractéristique est affectée par la similarité du signal de défaut avec la forme de la fonction d'ondelette mère, l'ondelette mère 'db6' est sélectionnée empiriquement, où elle présente le plus grand nombre de classes sans superposition.

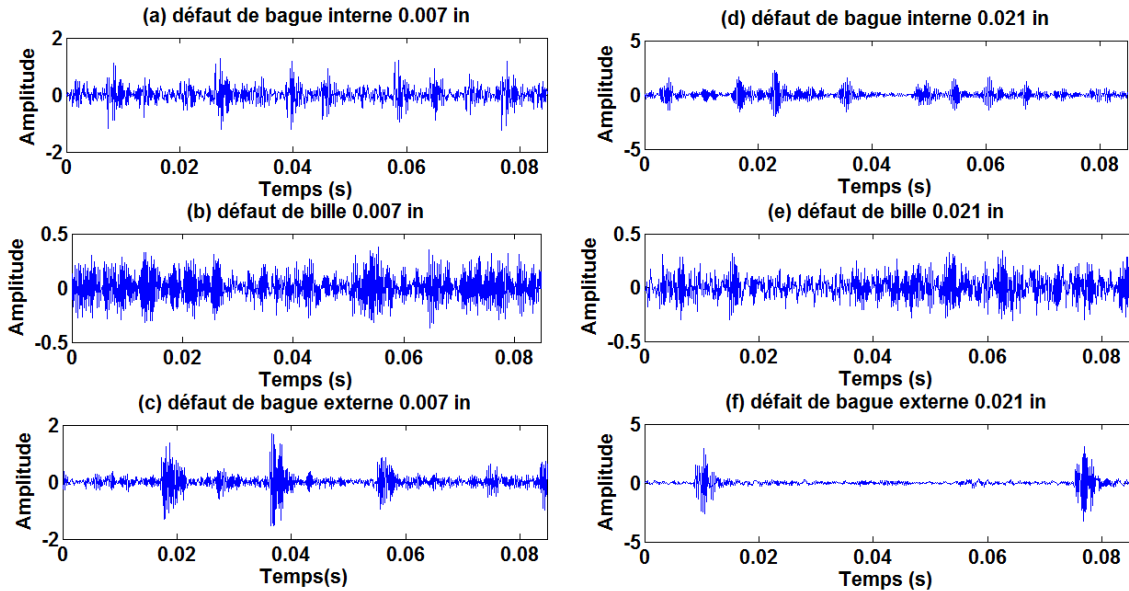


Figure. 4.7. Séries temporelles des signaux de roulements défectueux (base de données CWRU).

#### 4.7.4. Sélection des indicateurs

La méthode de sélection des indicateurs caractéristiques consiste à identifier les indicateurs caractéristiques à partir d'un groupe des indicateurs extraient par la TPO, car certaines bandes de fréquences contiennent des informations non liées aux défauts. En outre, la validité des indicateurs caractéristiques peut être affectée par des facteurs tels que l'emplacement d'un capteur. Donc, une méthode robuste de sélection des indicateurs est une étape primordiale pour un système de diagnostic automatisé. De ce fait, on a proposé la IRO pour la sélection des entrées du système. La figure 4.9 montre le concept de la méthode de sélection des indicateurs proposée, la figure à droite montre deux groupes chevauchants, et l'autre figure montre des groupes sans chevauchement. La figure 4.10, donne la répartition en groupes en utilisant la mesure de similarité, nous avons considéré que les points qui correspondent aux valeurs de seuil inférieures à 0.8 comme limites entre les classes de défauts. Ici, nous observons que le chevauchement d'intervalle entre classes affecte la mesure de similarité, où l'indicateur qui a des intervalles chevauchés donne une répartition en groupes conflictuelle (cf. figure 4.10b). De ce fait, pour pallier les faiblesses de la classification par la mesure de similarité, on a adopté la méthode IRO qui est jugée

« hautement sensible » au chevauchement d'intervalle. Cette méthode est considérée capable de distinguer entre les indicateurs faiblement dépendants de défauts et les indicateurs hautement dépendants.




Figure.4.8. Séries temporelles des signaux de roulements défectueux (base de données IMS).

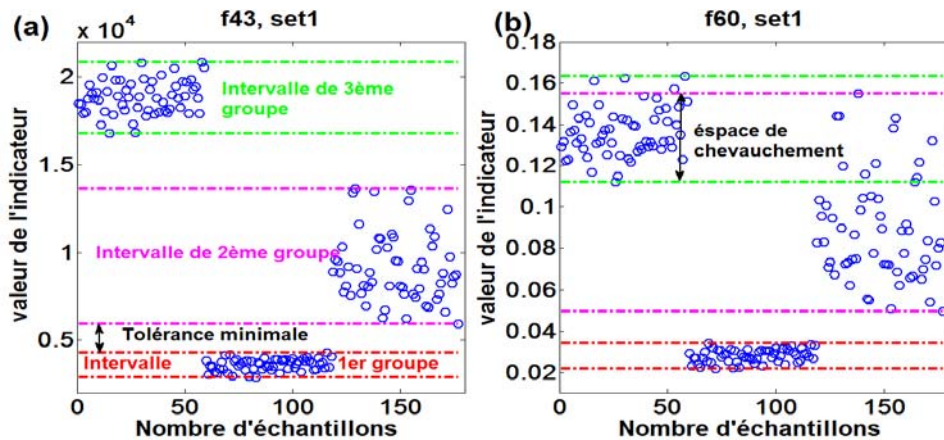


Figure 4.9. Le principe de la méthode 'Improved Range Overlaps'; indicateur sans chevauchement d'intervalle (a), indicateur avec chevauchement d'intervalle (b).

#### 4.7.5. Construction du système expert flou

Le système construit trois fonctions d'appartenance gaussiennes pour chaque vecteur d'entrée tout en garantissant une fonction pour chaque classe de (BI, Bille, BE). Elles sont prouvées plus tard d'être suffisantes pour confirmer la faisabilité du SEF proposé. De plus, pour optimiser les fonctions d'appartenance, nous utilisons le principe de la  $\alpha$ -coupe pour

calculer l'écart-type. Sinon, pour ne pas introduire d'orientations en faveur du système de classification, la valeur  $\alpha$ -coupe est fixée à 0,6 dans ce travail.

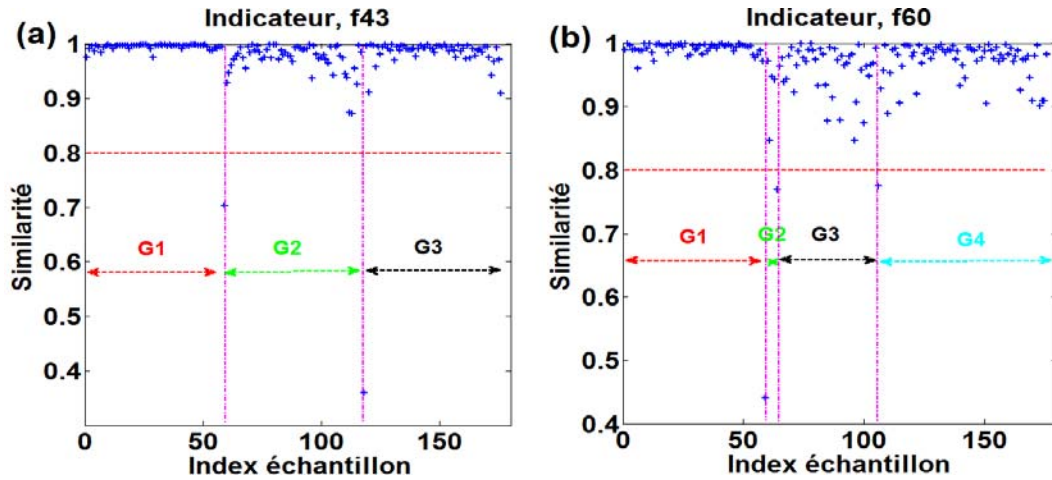


Figure. 4. 10. Description de la partition de groupes à l'aide de la mesure de similarité,  $G_i$  se réfère au groupe.

Tableau 4.3. Gestion de la base de données.

Ensemble	Etat de Roulement	Taille de défaut (inch)	N° d'échantillons d'apprentissage	N° d'échantillons de test	Étiquette de Classe
I	BI	0.007	59	59	3
	Bille		59	59	1
	BE		59	59	2
II	BI	0.021	59	59	3
	Bille		59	59	1
	BE		59	59	2
III	BI	/	50	50	2
	Bille		50	50	1
	BE		50	50	3
Total			504	504	
			1008		

Au stade de test, nous vérifions la validité du modèle. Chaque échantillon  $x_t$  de vecteurs de tests est évalué en utilisant l'équation (4.34) en lui donnant des degrés d'appartenance. Puis, en s'appuyant sur les connaissances acquises, le système résulte des décisions selon un ensemble de règles «si-alors» de deux entrées  $\{x_1, x_2\}$  et une sortie  $y$ . Le tableau 4.4 montre l'application de l'équation (4.35) au système de diagnostic proposé compte tenu de la nature floue des défauts de roulements : «tous les défauts n'apparaissent pas instantanément dans le roulement» [Sugu11]. Sinon, la survenance de deux défauts instantanément est considérée comme une défaillance combinée de roulements, ce qui est hors de portée de ce travail.

#### 4.7.6. La prise de décision

Quand une nouvelle observation est délivrée au système de diagnostic, le système construit un vecteur de diagnostic qui contient trois valeurs d'appartenance correspondant respectivement aux classes de défauts (BI, Bille, BE). Finalement, le système choisit la classe avec la plus grande valeur d'appartenance. Pour un diagnostic correct, il est nécessaire de respecter certains critères: (i) pour considérer l'apparition d'un défaut sa valeur d'appartenance doit être supérieure ou égale à 0,6; (ii) Les valeurs d'appartenance maximales inférieures au seuil fixé sont considérées comme incertaines.

**Tableau 4.4.** Règles d'inférence floue pour le système de diagnostic des défauts de roulements.

Si		Alors		
x1	x2	y est BI	y est Bille	y est BE
BI	BI	✓		
Bille	Bille		✓	
BE	BE			✓

#### 4.7.7. Résultats expérimentaux et discussions

À la fin de l'étape d'extraction des indicateurs caractéristiques, cent vingt-six (126) indicateurs sont extraits à l'aide de l'algorithme TPO. La raison de cette démarche est de refléter les différentes caractéristiques et signatures de défauts incorporées dans un signal, puisque chaque indicateur caractéristique a une sensibilité (résolution) différente pour chaque contenu fréquentiel des bandes de fréquences.

On applique la méthode IRO à l'ensemble des indicateurs caractéristiques constitué à la phase d'extraction d'indicateurs. Parmi les 126 indicateurs, onze éléments sont sélectionnés pour l'ensemble de données I, les indicateurs caractéristiques de la liste d'abréviations : f15, f17, f43, f45, f52, f57, f59, f113, f115, f122 et f126 liés aux valeurs de sensibilité supérieures au seuil ( $th = 0$  dans ce travail) sont retenus, parmi ceux-ci, les indicateurs f43, f126 sont identifiés comme étant les plus convenables. Pour le deuxième ensemble II, les indicateurs caractéristiques : f43, f46, f51, f113 sont sélectionnés, les indicateurs f43, f113 sont identifiées comme étant les plus appropriés. Les résultats d'analyse sont donnés par la figure 4.11.

Les indicateurs caractéristiques de la liste d'abréviations : f16, f20, f44, f48, f55, f58, f62, f118, f125 sont sélectionnés pour le troisième ensemble où les indicateurs, f118, f125 sont retenus comme les plus appropriés. La figure 4.12 donne les résultats de cette analyse.

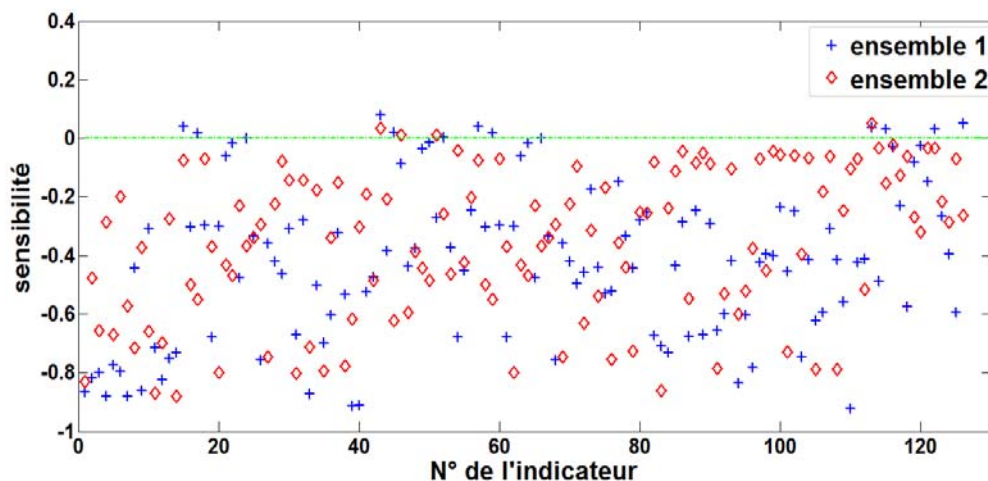


Figure. 4.11. Les valeurs de tolérance minimale (IRO) des 126 indicateurs caractéristiques extraites pour les ensembles I et II.

Ensuite, les indicateurs caractéristiques sélectionnés dans cette expérience sont utilisés pour construire un SEF avec six fonctions d'appartenance en utilisant la méthode de similarité, ces fonctions se correspondent aux classes de défauts désirées. La figure 4.13 montre les fonctions d'appartenance construites à partir des ensembles de données I et II. La figure 4.14 donne les fonctions d'appartenance construites pour l'ensemble III. Par conséquent, un ensemble de trois règles Si-Alors est introduit au moteur d'inférence floue pour vérifier l'appartenance de l'ensemble des échantillons de tests.




Figure. 4.12. Les valeurs de tolérance minimale (IRO) des 126 indicateurs caractéristiques extraites pour l'ensemble III.

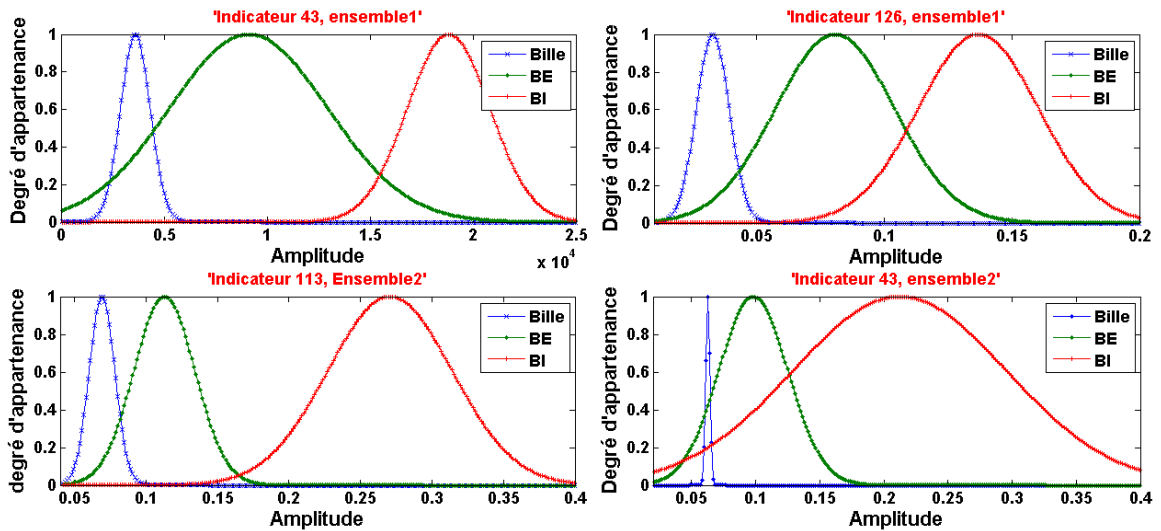


Figure. 4.13. Les fonctions d'appartenance du SEF pour les ensembles de données I & II.

Le tableau 4.5 résume les résultats de la phase de tests. La figure 4.15 donne les sorties du SEF correspondant aux ensembles de données I et II respectivement. La figure 4.16 donne les sorties du SEF pour l'ensemble de données III. Finalement, les résultats de diagnostic obtenus sont encourageants, où la précision minimale du système de diagnostic est de 84%, et la précision maximale est de 100% et la précision moyenne du système de diagnostic est de 96,08%. Les résultats obtenus sont satisfaisants et vérifient la validité de l'objectif désiré du système de diagnostic automatique des défauts de roulements.

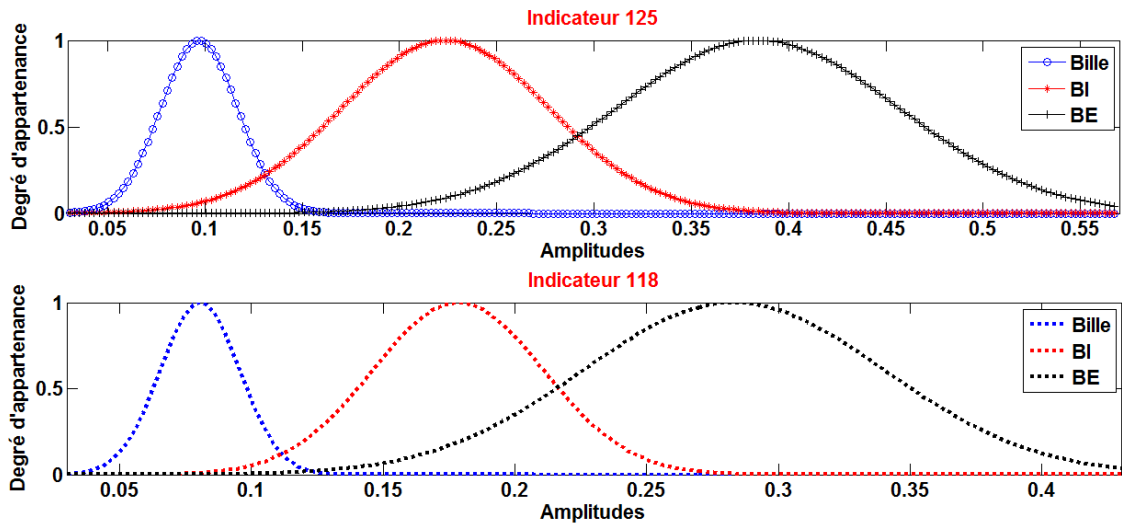


Figure. 4.14. Les fonctions d'appartenance du SEF pour l'ensemble de données III.

Tableau 4.5. Précision du système de diagnostic proposé.

Précision %				
	BI	Bille	BE	Moyenne
<b>Ensemble 1</b>	98.31	100	91.45	96.61
<b>Ensemble 2</b>	98.31	100	96.61	98.31
<b>Ensemble 3</b>	100	84	96	93.33
<b>Moyenne</b>	98.87	94.67	94.69	<b>96.08</b>




Figure. 4.15. Résultats de sortie du SEF en utilisant la base de données CWRU.






Figure. 4.16. Résultats de sortie du SEF en utilisant la base de données IMS.

#### 4.8. Diagnostic par fusion de données

Au cours des dernières décennies, les techniques de fusion de données ont attiré davantage l'attention. Elles reposent sur le fait qu'un seul capteur ne peut pas saisir toutes les informations utiles sur le comportement d'une structure ou d'un composant complexe, où en cas de capteurs non fiables les résultats de diagnostic seront conflictuels.

Dans les systèmes de surveillance des défauts de roulements, la fiabilité des mesures est affectée par l'emplacement du capteur et l'algorithme d'extraction des indicateurs caractéristiques [Gao11].

Les questions les plus fréquemment posées dans le cadre de fusion de données de capteurs sont: (i) Comment peut-on aboutir des informations précises et fiables avec des systèmes multicapteurs redondants ? ;(ii) quelle méthode de fusion qu'elle doit être utilisée pour la fusion de données et à quel niveau peut-on effectuer l'algorithme de fusion (au niveau de mesure ou au niveau de décision) ? [Basir07].

Leping et ses collègues [Lep11] utilisent le courant statorique des trois phases du moteur asynchrone pour établir les degrés de croyance sur la gravité des défauts de rupture de barres du rotor utilisant la TPO et la règle de combinaison D-S. Avec Yang [Yang06] les NN sont utilisés pour classifier les défauts selon la matrice des indicateurs caractéristiques construites, puis les résultats de sorties des classificateurs de courant et de vibration sont combinés par la règle de combinaison D-S pour augmenter la précision de la classification. Dong et Zhang [Dong11] ont inventé une règle modifiée de combinaison D-S à la base de la distance de Jusselme pour déterminer les facteurs d'actualisation (FA). Les FA sont utilisés pour conduire à de nouveaux degrés de croyance pour diagnostiquer



les défauts d'un système hydraulique. [Hui17] a proposé un système de diagnostic à la base de la combinaison de l'algorithme machines à vecteurs de support (SVM) utilisant la D-S pour résoudre le conflit généré par chaque modèle SVM. [Pei17] a utilisé la D-S pour combiner les différentes evidences calculées à partir des mesures effectuées par les capteurs .

L'avantage principal de ces techniques est qu'elles nécessitent le minimum de complexité algorithmique, car elles ne requièrent ni une analyse détaillée du mécanisme de défaillance, ni une modélisation du système. De plus, ils facilitent l'exploitation des systèmes de diagnostic automatiques des défauts tout en évitant le besoin de l'intervention de l'utilisateur [Geo13].

#### **4.8.1. Application de la méthode de fusion des prototypes**

Pour construire l'algorithme de diagnostic de Dempster-Shafer [Lep11], nous devons suivre les étapes suivantes:

Étape 1. Dédicée à la construction du cadre d'identification des défaillances (matrice des vecteurs prototypes). Ils sont définis selon les classes de défauts: Roulement sain (S), défaut de chemin de roulement interne (BI), défaut de bille (Bille), défaut de chemin de roulement externe (BE). La matrice des indicateurs caractéristiques des prototypes est construite comme suit:

$$F_i = \begin{pmatrix} f_{j,0,i} & \cdots & f_{j,n,i} \\ \vdots & \ddots & \vdots \\ f_{j,0,M} & \cdots & f_{j,n,M} \end{pmatrix} \quad (4.37)$$

Où  $f_{j, n, m}$ , est la valeur caractéristique du nœud  $n$  au niveau  $j$  de l'arbre de paquet d'ondelettes, et  $i = 1 \dots M$ , représentant l'indice du type de défaillance.

Étape 2. Construction du vecteur caractéristique des preuves (mesures pour test), il est construit de la même façon:

$$E_r = \begin{pmatrix} e_{j,0,r} & \cdots & e_{j,n,r} \\ \vdots & \ddots & \vdots \\ e_{j,0,K} & \cdots & e_{j,n,K} \end{pmatrix} \quad (4.38)$$

Où  $e_{j, n, k}$ , est la valeur de l'indicateur caractéristique calculé à partir du nœud  $n$  au niveau  $j$  de l'arbre de paquet d'ondelettes, et  $r = 1 \dots K$  est l'indice du capteur.

Etape3. On calcule la distribution de probabilité de base liée à chaque preuve, celle-ci est calculée d'après une fonction de distance, dans ce travail la distance d'Hausdorff de 1<sup>er</sup> ordre est utilisé:

$$d(E_r, F_i) = \max_{e \in E} \left( \min_{f \in F} (\|E_{r,n} - F_{i,n}\|) \right) \quad (4.39)$$

$n=0 \dots 2^{j-1}$  et  $r=1 \dots K$ ,  $i=1 \dots M$ .

Les lignes de la matrice  $D_{K,M}$  représentent la distance entre la preuve (nouvelle observation) et le prototype.

$$D_{K,M} = \begin{bmatrix} d_{11} & \dots & d_{1M} \\ \vdots & \ddots & \vdots \\ d_{K1} & \dots & d_{KM} \end{bmatrix} \quad (4.40)$$

Si la distance est minimale, la pertinence est grande et la probabilité de la preuve  $r$  pour un défaut  $i$  est élevée, le coefficient de pertinence de la preuve  $E_i$  et le prototype  $F_i$  est déterminé comme suit:

$$C_{ri} = \left( \frac{1}{d_{ri}} \right) / \left( \sum_{i=1}^M \frac{1}{d_{ri}} \right) \quad (4.40)$$

La matrice de corrélation est définie comme suit:

$$C_{K,M} = \begin{bmatrix} c_{11} & \dots & c_{1M} \\ \vdots & \ddots & \vdots \\ c_{K1} & \dots & c_{KM} \end{bmatrix} \quad (4.41)$$

Chaque ligne de la matrice de corrélation  $C$  est prise comme la fonction de probabilité de base (fonction de masse). Ensuite, la règle de combinaison de D-S est utilisée pour combiner les différentes fonctions de masse (4.23), (4.24), (4.25).

#### **4.8.2. Application au diagnostic des défauts de roulements (bague externe)**

Le système de fusion de données de capteurs proposé est effectué sur la même base de données 'Case Western Reserve'. Comme le montre la figure 4.17, les données ont été collectées à partir d'accéléromètres montés sur le boîtier du moteur à induction dans les positions (vertical, horizontal) où les historiques correspondants au défaut de la bague externe sont utilisés pour l'évaluation du potentiel de la méthode proposée.

Dans ce travail, on a utilisé l'environnement Matlab pour la mise en œuvre de l'approche de diagnostic proposée. Le signal collecté est segmenté en 20 segments, chaque segment contient 6144 échantillons. Ensuite, chaque mesure est introduite à l'algorithme d'extraction des caractéristiques TPO au niveau 3 ( $J = 3$ ) et la fonction mère 'db10' pour mettre en évidence les paramètres de santé de la machine. Ici, l'énergie par bande de fréquences au dernier niveau de l'arbre de paquet d'ondelettes est utilisée comme le vecteur d'entrée pour alimenter l'algorithme de diagnostic. Là, 50% des données sont utilisées pour l'apprentissage et l'autre partie est utilisée pour le test.

Les résultats sont présentés dans la figure 4.18 pour un défaut de bague externe de taille 0,18 mm sous une charge de 0HP, et la figure 4.19 pour un défaut de taille 0,36mm et une charge de 0HP. Le tableau 4.6 donne la précision de la méthode pour chaque type de défauts selon leurs tailles et leurs conditions de tests, le taux de classification minimale pour la refusion d'une proposition est fixé à 0,6 (refusion d'occurrence d'un défaut).

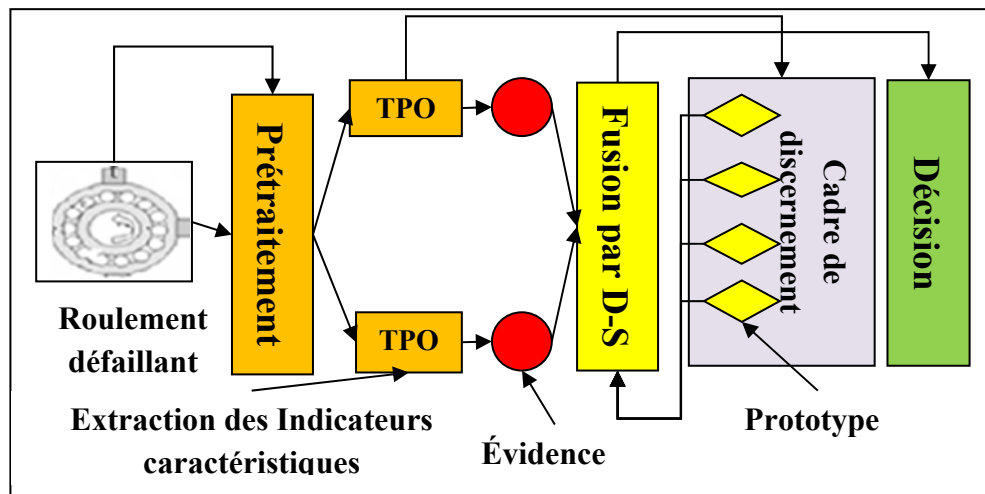


Figure. 4.17. Composition du système de diagnostic proposé (D-S).

#### 4.8.3. Résultats et discussions

Les figures 4. 18 et 4.19 montrent les résultats de la combinaison finale (fonction de croyance) qui donne le degré de croyance sur les quatre défauts proposés. Le tableau 4.6 donne la précision du système de diagnostic. Pour les défauts de petite taille (0.18mm), la précision du système atteint 100 %, et elle atteint un degré moindre pour les défauts de roulement de plus grandes tailles (0.36mm). Cette chute est due aux qualités des mesures vibratoires qui sont influencées par la position du capteur par rapport à la zone de charge.




Figure.4.18. Fonction de croyance pour un roulement côté accouplement (0HP, 0,18 mm).




Figure. 4.19. Fonction de croyance pour un roulement côté accouplement (0HP, 0,36 mm).

Tableau 4.6. Précision du système de diagnostic proposé (D-S).

Charge (Hp)	Précision (%)
<b>Défaut de bague externe 0.18 mm</b>	
0 HP	100
1HP	100
2HP	100
3HP	100
<b>Défaut de bague externe 0.36mm</b>	
0HP	90
1HP	100
2HP	100
3HP	100

#### **4.9. Conclusion:**

Dans ce chapitre, le système expert flou proposé est utilisé pour le diagnostic des défauts de roulements localisés ainsi que pour les défauts distribués. De ce fait, pour trouver les caractéristiques et les signatures de défauts incorporées dans le signal de vibration, un groupe d'indicateurs caractéristiques statistiques est extrait des coefficients de paquet d'ondelettes dans des différentes résolutions de fréquences. Ensuite, la méthode IRO (Improved Range Overlaps) est adoptée pour éviter les inconvénients de la mesure de similarité utilisée pour construire le système expert flou, dont les connaissances sont générées automatiquement à partir des données classifiées générant un ensemble de règles floues pour pouvoir maintenir au minimum l'implication de l'expertise humaine. La méthode proposée donnerait des résultats satisfaisants même avec un défaut de roulement distribué où les amplitudes de défaut sont cachées par un haut niveau du bruit et d'autres composantes de vibration ce qui entraîne des oscillations vibratoires plus compliquées. De plus, elle permet au système d'avoir atteint une haute précision dans le cas du diagnostic précoce d'un défaut de roulements. Le système présente des bonnes performances où la précision moyenne totale de la classification est de 96,08%.

L'approche de diagnostic par fusion de données des capteurs (D-S) représente une haute précision avec les défauts de la bague extérieure, où l'emplacement et le nombre de capteurs ont un impact sur la précision du diagnostic. En outre, plus le nombre de prototypes est élevé, plus la précision du système de diagnostic est élevée.

# **CONCLUSION GENERALE**

# Conclusion générale

Le cadre de diagnostic et de pronostic des défauts de roulements est un enjeu majeur dans une industrie moderne, il a pour objectif de maintenir la production, augmenter le taux de disponibilité et de fiabilité des machines afin d'éviter les arrêts non programmés et les substitutions indésirables des pièces de rechange. L'objectif de cette thèse était la mise en œuvre d'une démarche de diagnostic automatisée des défauts de roulements pour les moteurs asynchrones.

Après avoir présenté, dans le chapitre 1, un état de l'art sur les moteurs asynchrones en analysant les différents types de défauts de roulements dans un moteur asynchrone, un rappel sur les notions de surveillance et de diagnostic des défauts de roulements est discuté dans ce chapitre en dévoilant l'approche signal vibratoire qui est l'approche privilégiée dans notre travail avec une brève présentation de la technique de démodulation (analyse d'enveloppe) des signaux vibratoires des défauts de roulements ainsi une étude de l'effet de bruit sur quelques indicateurs caractéristiques de défauts de roulements.

Parmi les méthodes de diagnostic des défauts de roulements les plus souvent utilisées, les méthodes d'analyse d'enveloppe sont jugées plus convenables et précises pour la détection des défauts localisés, Néanmoins, elles exigent un haut niveau d'expérience et de pré-connaissances sur le comportement dynamique d'un roulement (connaissance de la fréquence de résonance et la largeur d'enveloppe). En outre, il a été démontré que la stabilité des indicateurs est un enjeu primordial dans un système de diagnostic des défauts de roulements.

Les méthodes de diagnostic qui se basent sur la modélisation de la machine électrique supposent une connaissance a priori du système, où une comparaison entre les paramètres réels mesurés et le modèle de référence des paramètres suivis (dans les conditions saines et défectueuses) faite apparaitre le comportement de certaines grandeurs et facilite la détection d'un défaut.

Dans le deuxième chapitre, dans un premier temps, nous nous sommes intéressés à la modélisation de la machine asynchrone à cage d'écurieuil dans le repère de Park pour émuler à la fois les défauts de roulements de la machine en tenant compte des effets d'excentricité et des oscillations de couple de charge.

## *Conclusion générale*

---

Ensuite, deux procédures de diagnostic de défaut qui se basent sur l'analyse du courant statorique ont été proposées. La première procédure de diagnostic de défauts est basée sur l'application de l'algorithme *FFT* sur le courant statorique, tandis que la deuxième est basée sur une combinaison entre *FFT* et *TPO* appliquée sur le courant statorique bruité dont l'algorithme de *TPO* est employé pour éliminer le bruit dans le signal original et également pour décomposer le signal de domaine temporel en différents groupes de fréquences. Cependant, le *FFT* est employé pour analyser en fréquence les groupes choisis contenant l'information utile de défaut. Ces procédures permettent l'identification des défauts de roulements qui s'expriment par un changement dans le continu fréquentiel du signal du courant statorique. Ailleurs, les paramètres de modèle sont fixés par l'utilisateur d'après des abaques ou une méthode d'estimation, où ils peuvent influencer la fiabilité du système de diagnostic.

Dans le troisième chapitre, nous avons orienté le cadre de notre travail vers le pronostic au niveau des roulements. L'approche de pronostic guidée par les données est privilégiée dans notre cas pour les raisons suivantes :

- Difficulté de disposer de connaissance sur les phénomènes de dégradation complexes.
- Insuffisance d'expériences passées pour déployer des approches statistiques significatives à cause de la variabilité de conditions d'usage et de détérioration.

L'approche qu'on a présentée dans ce chapitre est basée sur l'identification des caractéristiques de pronostic avancées susceptibles d'améliorer la prédiction de la durée de vie utile restante avant la prochaine défaillance (RUL) en utilisant l'algorithme de mélange gaussien et le modèle de Markov caché (MMC) pour estimer cette prédiction. Nous avons abordé le problème du pronostic en effectuant une analyse de données sur des tests de vieillissement accéléré des roulements en utilisant des indicateurs statistiques dans le domaine fréquentiel. En outre, ces approches n'exigent pas des pré-connaissances du système comme les approches « modèle », l'algorithme lui-même développe des connaissances d'après un historique du système. Cependant, la taille de l'historique de défauts de roulements peut affecter la précision de la méthode.

Le dernier chapitre est relatif aux différents résultats obtenus par l'application du système de détection automatique des défauts de roulements utilisant la théorie de la logique floue. Ce dernier est basé sur une méthode d'apprentissage simple exploitant la



## *Conclusion générale*

---

mesure de similarité. Cette dernière était trouvée instable face aux espaces des indicateurs caractéristiques avec chevauchement entre classes, d'où la proposition d'une nouvelle méthode de sélection des indicateurs dite « Improved Range Overlaps IRO » pour améliorer la précision du système. Une application aux défauts de roulements localisés et distribués est faite en vue de prouver l'efficacité du système de diagnostic. En outre, la méthode Dempster-Shafer (fusion de données des capteurs) a donnée des résultats prometteurs surtout dans le cas des défauts naissants.

Pour conclure, au vu de l'objectif initial de la thèse, la nouvelle approche qui a été développée dans ce travail, a donnée des résultats intéressants. Traitant des défauts des roulements dans les machines tournantes, cette approche présente également une opportunité de développements futurs. Elle mérite d'être testée sur d'autres types de défauts voire leur combinaison.

## Ressources bibliographiques :

- [Alam14] Alamaniotis M , Grelle A, Tsoukalas L. H., 2014. Regression to fuzziness method for estimation of remaining useful life in power plant components, *Mechanical Systems and Signal Processing*. 48, 188–198.
- [Ali09] Ali, I. Contribution au diagnostic de machines électromécaniques : Exploitation des signaux électriques et de la vitesse instantanée. Thèse doctorat, Université de Saint-Etienne, 2009.
- [Altug99] S. Altug, M.Y. Chow, H. J. Trussell., 1999. Fuzzy Inference Systems Implemented on Neural Architectures for Motor Fault Detection and Diagnosis, *IEEE Trans. Indus. Elec.* 46(6), 1069-1079.
- [Antoni05] Antoni, Jérôme. 2005. « Calcul Rapide du Kurtogramme et Applications ». In *20 Colloque sur le traitement du signal et des images*. (France), p. 460-463. GRETSI, Groupe d'Etudes du Traitement du Signal et des Images.
- [Antoni07] J. Antoni, Fast Computation of the Kurtogram for the Detection of Transient Faults, *Mechanical Systems and Signal Processing*, Volume 21, Issue 1, 2007, pp.108-124.
- [Aouabdi17] S. Aouabdi, M. Taibi, S. Bouras, N. Boutasseta, Using multi-scale entropy and principal component analysis to monitor gears degradation via the motor current signature analysis, *Mechanical Systems and Signal Processing*, Volume 90, 2017, pp.298-316.
- [A-Rub11] H. Abu-Rub, A. Iqbal, SK. M. Ahmed, J. Guzinski, M. Adamowicz, M. Rahiminia., 2011. Rotor Broken Bar Diagnostics in Induction Motor Drive Using Wavelet Packet Transform and ANFIS Classification. In: *Proceedings IEEE International Electric Machines & Drives Conference (IEMDC)* . pp. 365-370.
- [Attoui 15.a] I. Attoui., 2015. Contribution au diagnostic de défauts d'une génératrice asynchrone dans une chaîne de conversion d'énergie éolienne. Thèse Doctorat ; Université Baji-Mokhtar Annaba « Annaba », Algérie.
- [Attoui 15.b] I. Attoui, N. Boutasseta, N. Fergani, B. Oudjani, A. Deliou., 2015. Vibration-Based Bearing Fault Diagnosis by an Integrated DWT-FFT Approach and an Adaptive Neuro-Fuzzy Inference System, *proceedings 3rd International Conference on Control, Engineering & Information Technology (CEIT) 2015*. DOI: [10.1109/CEIT.2015.7233098](https://doi.org/10.1109/CEIT.2015.7233098).

- [Attoui17] I. Attoui., N. Fergani., N. Boutasseta., B. Oudjani., A. Deliou., (2017). A new time–frequency method for identification and classification of ball bearing faults, *Journal of Sound and Vibration*, <http://dx.doi.org/10.1016/j.jsv.2017.02.041>
- [Basir07] O. Basir, X. Yuan., 2007. Engine fault diagnosis based on multi-sensor information fusion using Dempster–Shafer evidence theory’, *Journal of Information Fusion*, 8, 379–386.
- [Belbedj15] Belbedj, F., 2015. Les modèles de Markov Cachés et leur application dans un processus industriel : Application à un système de pompage de ciment, Thèse Magister ; Université HADJ LAKHDAR « BATNA », Algérie.
- [Baruah05] P. Baruah , R. B. Chinnam., 2005. HMMs for diagnostics and prognostics in machining processes, *International Journal of Production Research*, Vol. 43, No. 6, 15 March 2005, 1275–1293.
- [Benbouzid00] M. H. Benbouzid., 2000. A Review of Induction Motors Signature Analysis as a Medium for Faults Detection. *IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS*, VOL. 47(5), 984-993.
- [Blo06] M. Blodt, Condition monitoring of mechanical faults in variable speed induction motor drives, Application of stator current time-frequency analysis and parameter estimation, Thèse de doctorat de l’Institut National Polytechnique de Toulouse, 2006.
- [Blo08] Blödt, M. Granjon, P. Raison, B. Rostaing, G., 2008. Models for Bearing Damage Detection in Induction Motors Using Stator Current Monitoring, *IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS*. 55 (4), 1813-1822.
- [Bošk15] Boškoski, P. Gašperin, M. Petelin, D. Juričić, D., 2015. Bearing fault prognostics using Rényi entropy based features and Gaussian process models, *Mechanical Systems and Signal Processing*. 52-53, 327–337.
- [Boud16] Boudiaf, A, Moussaoui, A, Dahane, Attoui, I., 2016. A Comparative Study of Various Methods of Bearing Faults Diagnosis Using the Case Western Reserve University Data, *J. Fail. Anal. and Preven.* DOI 10.1007/s11668-016-0080-7.

- [Boudinar15] Boudinar, A. H, Benouzza, N, Bendiabdellah, A., 2015. Diagnostic des défauts de roulements d'un moteur asynchrone, *Rev. Roum. Sci. Techn. – Électrotechn. et Énerg.*, **60**, 1, p. 39–48, Bucarest, 2015.
- [Bouzida11] Bouzida, A, Touhami, O, Ibtouen, R, Belouchrani, A, Fadel, M, and Rezzoug, A., 2011. Fault diagnosis in industrial induction machines through discrete wavelet transform, *IEEE Transactions on Industrial Electronics*. 58 (9), 4385-4395.
- [Bou 09] Boulenger, A, Pachaud, C. Aide-mémoire : Surveillance des machines par analyse des vibrations, Livre, L'Usine nouvelle, Paris, Dunod, 2009, ISBN 978-2-10-054190-4.
- [Chand14] Chandrashekar, G, Sahin, F.,2014. A survey on feature selection methods, *Computers and Electrical Engineering*. 40, 16–28.
- [Chen14] X. Chen, J. Zhou, J. Xiao, X. Zhang, H. Xiao, W. Zhu, W. Fu., 2014. Fault diagnosis based on dependent feature vector and probability neural network for rolling element bearings, *Applied Mathematics and Computation*. 247, 835–847.
- [Corne15] B. Corne, B. Vervisch, C. Debruyne, J. Knockaert, J. Desmet.,2015. Comparing MCSA with Vibration Analysis in order to detect Bearing Faults - A Case Study. Published in: 2015 IEEE International Electric Machines & Drives Conference (IEMDC), Coeur d'Alene, ID, USA.
- [Cruz01] Cruz, S. M. A, Cardoso, A. J. M., 2001. Stator Winding Fault Diagnosis in Three-Phase Synchronous and Asynchronous Motors, by the Extended Park's Vector Approach, *IEEE TRANSACTIONS ON INDUSTRY APPLICATIONS*. 37(5), 1227-1233.
- [Cui 16] L, Cui ., Y, Zhang ., F, Zhang ., J, Zhang., S, Lee., 2016. Vibration response mechanism of faulty outer race rolling element bearings for quantitative analysis, *Journal of Sound and Vibration*. 364, 67–76.
- [Del 17] Delgado-Arredondo PA., Morinigo-Sotelo D., Osornio-Rios RA., Avina-Cervantes JG., Rostro-Gonzalez H., Romero-Troncoso RD.,(2017). Methodology for fault detection in induction motors via sound and vibration signals, *Mech. Syst. Signal Process*. 83, 568-589.

- [Djeddi 07] Djeddi, M, Granjon, P, Leprettre, B., 2007. Bearing Fault Diagnosis in Induction Machine Based on Current Analysis Using High- Resolution Technique, *Diagnostics for Electric Machines, Power Electronics and Drives, SDEMPED 2007, IEEE International Symposium*.
- [Diaz 17] Diaz, M., Henriquez, P., Ferrer, M. A., Pirlo, G., Alonso, J. B., Carmona-Duarte, C., Impedovo, D., 2017. Stability-Based System for Bearing Fault Early Detection, *Exp. Sys. Appli.* 79, 65-75.
- [Douglas04] H. Douglas, P. Pillay, A. K. Ziarani., 2004. A New Algorithm for Transient Motor Current Signature Analysis Using Wavelets, *IEEE TRANSACTIONS ON INDUSTRY APPLICATIONS*, 40(5), 1361-1368.
- [Douglas05] H. Douglas, P. Pillay., 2005. The Impact Of Wavelet Selection On Transient Motor Current Signature Analysis, Published in: *IEEE International Conference on Electric Machines and Drives, 2005*. DOI: 10.1109/IEMDC.2005.195705.
- [Dong07] Dong, M, He, D.,2007. Hidden semi-Markov model-based methodology for multi-sensor equipment health diagnosis and prognosis, *European Journal of Operational Research*. 178, 858–878.
- [Dong11] DONG Z, ZHANG X., 2011. Modified D-S evidential theory in hydraulic system fault diagnosis, *Procedia Environmental Sciences*. 11, 98 – 102.
- [Dolenc16] Dolenc, B., Bošković, P., Juričić, D.,2016. Distributed bearing fault diagnosis based on vibration analysis, *Mech. Syst. Signal Process.* 66-67, 521–532.
- [Eber08] S. Ebersbach, Z. Peng.,2008. Expert system development for vibration analysis in machine condition monitoring, *Exp. Sys. Appli.* 34, 291–299.
- [Elt 04] Eltabach, M, Charara, A,Zein, I., 2004. A Comparison of External and Internal Methods of Signal Spectral Analysis for Broken Rotor Bars Detection in Induction Motors, *IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS*. 51(01), 107-121.
- [Ern04] Eren, L, Devaney, M. J., 2004. Bearing Damage Detection via Wavelet Packet Decomposition of the Stator Current, *IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT*. 53(2), 431-436.

- [Fan06] Fan, X, Zuo, M. J., 2006. Gearbox fault detection using Hilbert and wavelet packet transform, *Mech. Syst. Signal Process.* 20, 966–982.
- [Frosini10] L. Frosini., Ezio Bassi., 2010. Stator Current and Motor Efficiency as Indicators for Different Types of Bearing Faults in Induction Motors, *IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS*, 57(1), 244-251.
- [Gao06] Gao, R. X, Yan, R, Sheng, S, and Zhang, L., 2006. Sensor Placement and Signal Processing for Bearing Condition Monitoring, Published In: *Condition monitoring and control for intelligent manufacturing*, vol. 7, Springer-Verlag, Berlin, pp 167-191.
- [Gao11] R.X. Gao, R. Yan., 2011. Wavelet Packet-Transform for Defect Severity Classification, Springer Science+Business Media, chapter 8 (2011) 125-147.
- [G-Der11] David Gucik-Derigny. Contribution au pronostic des systèmes non linéaires à base de modèles : Théorie et application. thèse PHD, Automatique. Université Paul Cézanne - Aix-Marseille III, 2011.
- [Glow15] Glowacz, A., 2015. Recognition of acoustic signals of induction motor using fft, smofs-10 and lsvm. *Eksploracja i Niezawodność – Maintenance and Reliability*, 17 (4), 569–574, DOI: <http://dx.doi.org/10.17531/ein.2015.4.12>.
- [Glow16] Glowacz, A. (2016). Diagnostics of rotor damages of three-phase induction motors using acoustic signals and SMOFS-20-EXPANDED. *Archives of Acoustics*, 41 (3), 507–515 .
- [Glow17] Glowacz A., Glowacz Z.,(2017). Diagnosis of the three-phase induction motor using thermal imaging, *Infrared Physics & Technology*. 81, 7-16.
- [Glow18] Glowacz A., Glowacz W., Glowacz Z., Kozik J.,(2018). Early fault diagnosis of bearing and stator faults of the single-phase induction motor using acoustic signals, *Measurement*. 113, 1-9.
- [Gong13] X Gong., W Qiao.,(2013). Bearing Fault Diagnosis for Direct-Drive Wind Turbines via Current-Demodulated Signals, *IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS*. 60(8), 3419-3428.

- [Qiu06] Qiu, H., Lee, J, Lin, J.,(2006). Wavelet Filter-based Weak Signature Detection Method and its Application on Roller Bearing Prognostics, *Journal of Sound and Vibration*. 289, 1066-1090
- [Harm14] J. Harmouche, D. Diallo, C. Delpha., 2014. Discrimination des défauts de roulements par une analyse spectrale globale. Symposium de Génie Electrique, Cachan, France. Hall archives ouvertes ; HAL Id: hal-01065224, <https://hal.archives-ouvertes.fr/hal-01065224>.
- [Hem16] Hemmati, F., Orfali, W., Gadala, MS.,(2016). Roller bearing acoustic signature extraction by wavelet packet transform, applications in fault detection and size estimation, *Applied Acoustics*. 104, 101-118.
- [Héng02] Jean Héng, *Pratique de la maintenance préventive*, Livre, L'Usine nouvelle, Série : Gestion Industrielle. Dunod, Paris, 2002, ISBN 2 10 006561 0.
- [Hong96] Hong, T. P., Leeb, C. Y., (1996). Induction of fuzzy rules and membership functions from training examples 1, *Fuzzy Sets and Systems*. 84, 33 -47.
- [Honga14] Honga S, Zhoub Z, Zioc E, Wange W., 2014. An adaptive method for health trend prediction of rotating bearings. *Digital Signal Processing*. 35, 117–123.
- [Hui17] Hui, K. H, Lim, M. H, Leong, M. S, Al-Obaidi, S. M., 2017. Dempster-Shafer evidence theory for multi-bearing faults diagnosis, *Engineering Applications of Artificial Intelligence*. 57, 160–170.
- [Ioannis09] Ioannis .A, Y. Christos, K. Gryllias., 2009. Rolling element bearing fault classification using k-means frequency domain based clustering. *Proceedings of the ASME 2009 International Design Engineering Technical Conferences & Computers and Information in Engineering Conference IDETC/CIE*, San Diego, California, USA. pp.1-8.
- [Jiang 14] F. Jiang, Z. Zhu, W. Li, G. Chen and G. Zhou., 2014. Robust condition monitoring and fault diagnosis of rolling element bearings using improved EEMD and statistical features. *Meas. Sci. Technol*. 25, 1-14.
- [Kumar13] Kumar. H. S, Srinivasa. P. P, Sriram. N. S, Vijay. G. S., 2013. ANN based evaluation of performance of wavelet transform for condition monitoring of rolling

element bearing, International Conference on Design and Manufacturing, IConDM 2013, Procedia Engineering. 64, 805 – 814.

[Kryter89] R. C. Kryter., H. D. Haynes.,1989. Condition monitoring of machinery using motor current signature analysis. Seventh Power Plant Dynamics, Control and Testing Symposium, Knoxville, Tennessee May 15-17, 1989.

[Lau10] Enzo C. C. Lau., H. W. Ngan., 2010. Detection of Motor Bearing Outer Raceway Defect by Wavelet Packet Transformed Motor Current Signature Analysis. IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT, 59(10), 2683-2690.

[Lee85] R. J. Lee., P. Pillay., R. G. Harley., 1985. D,Q Reference Frames for the Simulation of Induction Motors. Electric Power Systems Research, 8, 15 -26.

[Lee07] Lee, J., Qiu, H., Yu, G., & Lin, J. (2007). Rexnord technical services, 'bearing data set'. IMS, University of Cincinnati. NASA Ames Research Center. Accessed 13.02.17 <http://ti.arc.nasa.gov/tech/dash/pcoe/prognostic-data-repository>.

[Lei09] Y. Lei, Z. He, Y. Zi., 2009. Application of an intelligent classification method to mechanical fault diagnosis, Exp. Syst. Appli. 36, 9941–9948.

[Lei11] Lei, Y, Lin,J, He,Z, Zi, Y., 2011. Application of an improved kurtogram method for fault diagnosis of rolling element bearings, Mech. Syst. Signal Process. 25, 1738–1749.

[Lep11] B, Leping, L. K. pei and H. Xinguo., 2011. The Rotor Fault Diagnosis Method of the Induction Motor Based on the D-S Evidential Theory, Published in: Power and Energy Engineering Conference (APPEEC), 2011 Asia-Pacific, DOI: [10.1109/APPEEC.2011.5748619](https://doi.org/10.1109/APPEEC.2011.5748619).

[Li00] B. Li, M-Y. Chow, Y. Tipsuwan, J. C. Hung.,2000. Neural-Network-Based Motor Rolling Bearing Fault Diagnosis, IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS, 47(5), 1060-1069.

[Liu11] Liu, J, Wang, W & Ma, F., 2011. Bearing system health condition monitoring using a wavelet cross-spectrum analysis technique, Journal of Vibration and Control. 0(0), 1–11.



- [Liu08] Liu, J, Wang, W, Golnaraghi, F & Liu, K., 2008. Wavelet spectrum analysis for bearing fault diagnostics, *Meas. Sci. Technol.* **19**, 015105 (9pp), doi:10.1088/0957-0233/19/1/015105.
- [Liu12] T Liu, J Chen, X N Zhou and W B Xiao., 2012. Bearing Performance Degradation Assessment Using Linear Discriminant Analysis and Coupled HMM, 25th International Congress on Condition Monitoring and Diagnostic Engineering, Published In: *Journal of Physics: Conference Series* 364 (2012) 012028 doi:10.1088/1742-6596/364/1/012028.
- [Lou04] X. Lou, K.A. Loparo., 2004. Bearing fault diagnosis based on wavelet transform and fuzzy inference, *Mech. Syst. Signal Process.* 18, 1077–1095.
- [Malhi04] Malhi A, Gao R., 2004. PCA-based feature selection scheme for machine defect classification, *IEEE Trans Instrum Meas* 53(6), 1517–1525.
- [Mar06] T. Marwala, U. Mahola and F. V. Nelwamondo., 2006. Hidden Markov Models and Gaussian Mixture Models for Bearing Fault Detection Using Fractals, Published In : *IEEE 2006 International Joint Conference on Neural Networks Sheraton Vancouver Wall Centre Hotel, Vancouver, BC, Canada July 16-21, 2006.*
- [Medjaher12] K. Medjaher, D.A. Tobon-Mejia, N. Zerhouni., 2012. Remaining useful life estimation of critical components with application to bearings, *IEEE Transactions on Reliability* 61, 2 (2012) 292-302" DOI : 10.1109/TR.2012.2194175.
- [Medasani98] Medasani, S. , Kim, J. , & Krishnapuram, R. (1998). An overview of membership function generation techniques for pattern recognition. *International Journal of Approximate Reasoning.*, 19 , 391–417 .
- [McFadden 84] McFadden, P. , & Smith, J. (1984). Model for the vibration produced by a single point defect in a rolling element bearing, *Journal of Sound and Vibration*, 96 (1), 69–82 .
- [Miao10] Q. Miao, D, Wang, M, Pecht., 2010. A probabilistic description scheme for rotating machinery health evaluation, *Journal of Mechanical Science and Technology* 24 (12) , 2421-2430, DOI 10.1007/s12206-010-0908-0.

- [Mosallam13] Mosallam, A, Medjaher, K, Zerhouni, N., 2013. Bayesian Approach for Remaining Useful Life Prediction, The Italian Association of Chemical Engineering, Vol 33, 2013, ISSN 1974-9791, DOI: 10.3303/CET1333024
- [Moosavian15] A. Moosavian, M. Khazaei, G. Najafi, M. Kettner, R. Mamat., 2015. Spark plug fault recognition based on sensor fusion and classifier combination using Dempster-Shafer evidence theory, *Applied Acoustics*. 93, 120–129.
- [Nelw06] F. V. Nelwamondo and Tshilidzi Marwala., 2006. Faults Detection Using Gaussian Mixture Models, Mel-Frequency Cepstral Coefficients and Kurtosis, Published In: 2006 IEEE Conference on Systems, Man, and Cybernetics October 8-11, 2006, Taipei, Taiwan
- [Nunez16] Nunez, JAR., Velazquez, LM., Hernandez, LAM., Troncoso, RJR., Osornio-Rios RA.,(2016). Low-Cost thermographic analysis for bearing fault detection on induction motors. *Journal of Scientific & Industrial Research*, 75 (7), 412-415.
- [Obu14] Obuchowski, J , Wyłomańska, A, Zimroz, R., 2014. Selection of informative frequency band in local damage detection in rotating machinery, *Mech. Syst. Signal Process.* 48, 138–152.
- [Önel08] I. Y. Önel., M. H. Benbouzid., 2008. Induction Motor Bearing Failure Detection and Diagnosis: Park and Concordia Transform Approaches Comparative Study, *IEEE/ASME TRANSACTIONS ON MECHATRONICS*, 13(2), 257- 262.
- [Palacky13] P. Palacky, P, Hudecek, A, Havel., (2013). Real-Time Estimation of Induction Motor Parameters Based on the Genetic Algorithm. Published In: *Int. JointConf. CISIS'12-ICEUTE'12-SOCO'12, AISC 189*, pp. 401–409.
- [Pei17] D. Pei, J. Yue, J. Jiao., 2017. Rolling bearing fault diagnosis based on information fusion using Dempster-Shafer evidence theory, 5th Asia Conference on Mechanical and Materials Engineering (ACMME 2017) IOP Publishing, *Materials Science and Engineering* **241** (2017) 012035 doi:10.1088/1757-899X/241/1/012035.
- [Pere05] Pereira, L. A, Gazzana, D. d. S, Pereira, L. F. A., 2005. Motor Current Signature Analysis and Fuzzy Logic Applied to the Diagnosis of Short-Circuit Faults in Induction Motors. 31<sup>st</sup> Annual Conference of IEEE. Industrial Electronics Society, IECON 2005.

- [PHM12] IEEE PHM 2012 Prognostic challenge Outline, Experiments, Scoring of results, Winners, <http://www.phmconf.org/>
- [Pillay96] P.Pillay., Z. Xu., 1996. Motor Current Signature Analysis. Published in: IAS '96. Conference Record of the 1996 IEEE Industry Applications Conference Thirty-First IAS Annual Meeting. DOI: 10.1109/IAS.1996.557096
- [Rab89] Rabiner, L. R., 1989. A tutorial on hidden markov models and selected applications in speech recognition, *Proceedings of IEEE*, 77(2), 257-286.
- [Raj 14] Rajeswari, Ca., Sathiyabhama, Bb., Devendiran, Sc & Manivannan, Kd., 2014. Bearing fault diagnosis using wavelet packet transform, hybrid PSO and support vector machine, *Procedia Engineering*. 97, 1772 – 1783.
- [Rak 10] Rakoto Razafindrazato, G. M. Méthodes numériques pour la caractérisation de structures complexes. Thèse doctorat, Université Paris-Est Créteil, 2010.
- [Rou08] Vicente Jover Rodríguez, P, Belahcen, A, Arkkio, A, Laiho, A, José A. Antonino-Daviu., 2008. Air-gap force distribution and vibration pattern of Induction motors under dynamic eccentricity, *Electr Eng*. 90, 209–218, DOI 10.1007/s00202-007-0066-2
- [Rodriguez06] Rodriguez, I, Alves, R., 2006. Bearing Damage Detection of the Induction Motors using Current Analysis, 2006 IEEE PES Transmission and Distribution Conference and Exposition Latin America, Venezuela.
- [Safi14] M.S. Safizadeh, S.K. Latifi., 2014. Using multi-sensor data fusion for vibration fault diagnosis of rolling element bearings by accelerometer and load cell. *Information Fusion*. 18, 1–8.
- [Shao14] K. Shao<sup>1</sup>, M. Cai<sup>1</sup>, G. Zhao., 2014. Rolling Bearing Fault Diagnosis Based on Wavelet Energy Spectrum, PCA and PNN, In: 26th Chinese Control and Decision Conference (CCDC), 800-804.
- [Sch95] R. R. Schoen, T. G. Habetler, F. Kamran, and R. Bartheld., 1995. Motor bearing damage detection using stator current monitoring, *IEEE Trans. Ind. Appl.* 31 (6), 1274–1279.

- [Shi 97] Shiroishi, J, Li, Y, Liang, S, Kurfess, T, and Danyluk, S., 1997. Bearing Condition Diagnostics via Vibration and Acoustic Emission Measurements, *Mech. Syst. Signal Process.* 11, 693-705.
- [Singh16] Singh G., Kumar, TCA., Naikan, VNA.,(2016). Induction motor inter-turn fault detection using infrared thermographic analysis, *Infrared Physics & Technology.* 77, 277-282.
- [Sugu11] V. Sugumaran, K.I. Ramachandran., 2011. Fault diagnosis of roller bearing using fuzzy classifier and histogram features with focus on automatic rule learning, *Exp. Sys. Appli.* 38, 4901–4907.
- [Sun 16] Sun, X., Tan, J., Wen, Y., Feng, C., (2016). Rolling bearing fault diagnosis method based on data-driven random fuzzy evidence acquisition and Dempster–Shafer evidence theory. *Advances in Mechanical Engineering.* 8(1), 1–8.
- [Shen13] C. Shen, D. Wang, F. Kong, P. W. Tse., 2013. Fault diagnosis of rotating machinery based on the statistical parameters of wavelet packet paving and a generic support vector regressive classifier, *Measurement.* 46, 1551–1564.
- [Suebsing09] Suebsing, A., Hiransakolwong, N., (2009). Feature Selection Using Euclidean Distance and Cosine Similarity for Intrusion Detection Model, Published In: IEEE computer society, 2009 First Asian Conference on Intelligent Information and Database Systems, pp. 86-91, DOI 10.1109/ACIIDS.2009.23.
- [Tay11] Tay, K. M. , & Lim, C. P., 2011. Optimization of gaussian fuzzy membership functions and evaluation of the monotonicity property of fuzzy inference systems. In *Proceedings IEEE international conference on fuzzy systems* .
- [Tian09] Tian, Z., 2009. An artificial neural network method for remaining useful life prediction of equipment subject to condition monitoring, *J Intell Manuf.* DOI 10.1007/s10845-009-0356-9
- [Tobon11] D. A. Tobon-Mejiaa, K. Medjaher, N. Zerhouni , G. Tripot., 2011. Estimation of the Remaining Useful Life by using Wavelet Packet Decomposition and HMMs, published in: *IEEE Aerospace Conference AIAA - 2011., Big Sky - Montana : United States (2011).*

[Tobon10a] D. A. Tobon-Mejiaa, K. Medjaher, N. Zerhouni., 2010. The ISO 13381-1 Standard's Failure Prognostics Process through an Example, published in: IEEE Prognostics & System Health Management Conference, PHM'2010, Macau (China) 2010

[Tobon10b] D. A. Tobon-Mejiaa, K. Medjaher, N. Zerhouni , G. Tripot., 2010. A Mixture of Gaussians Hidden Markov Model for failure diagnostic and prognostic, Published In: 6th Annual IEEE Conference on Automation Science and Engineering, CASE'10., Toronto : Canada (2010).

[Tobon12] D. A. Tobon-Mejiaa, K. Medjaher, N. Zerhouni , G. Tripot., 2012. A Data-Driven Failure Prognostics Method based on Mixture of Gaussians Hidden Markov Models, IEEE TRANSACTIONS ON RELIABILITY. 61(2), 491-503

[Touil15] Touil, S., Attous, D. B., (2015). Effect of different membership functions on fuzzy power system stabilizer for synchronous machine connected to infinite bus, Int J Syst Assur Eng Manag, DOI 10.1007/s13198-015-0344-8.

[Tra 09] B. TRAJIN, Analyse et traitement de grandeurs électriques pour la détection et le diagnostic de défauts mécaniques dans les entraînements asynchrones : Application à la surveillance des roulements à billes. Thèse doctorat, 2009.

[Tse 13a] P. W.Tse, D. Wang., 2013. The design of a new sparsogram for fast bearing fault diagnosis: Part1of the two related manuscripts that have a joint title as “Two automatic vibration-based fault diagnostic methods using the novel sparsity measurement – Parts1 and 2”, Mech. Syst. Signal Process. 40, 499–519.

[Tse 13b] P.W.Tse, D.Wang., 2013. The automatic selection of an optimal wavelet filter and its enhancement by the new sparsogram for bearing fault detection Part 2 of the two related manuscripts that have a joint title as “Two automatic vibration-based fault diagnostic methods using the novel sparsity measurement—Parts1 and 2”, Mech. Syst. Signal Process. 40, 520–544.

[Tya 17] Tyagi, S, Panigrahi, S. K, 2017. An improved envelope detection method using Particle Swarm Optimisation for rolling element bearing fault diagnosis, Journal of Computational Design and Engineering. 4, 305-317.

- [Vakhariaa16] Vakhariaa, V., Guptab, V. K., Kankarb, P. K., (2016). Bearing Fault Diagnosis Using Feature Ranking Methods and Fault Identification Algorithms, In, *Procedia Engineering*. 144, 343 – 350.
- [Walcz96] Walczak, B., Bogaert, B. V. D., Massart, D. L., (1996). Application of Wavelet Packet Transform in Pattern Recognition of Near-IR Data, *Anal. Chem.* 68, 1742-1747.
- [Wang 13] Wang, D, Tse, P. W, Tsui, K. L, 2013. An enhanced Kurtogram method for fault diagnosis of rolling element bearings, *Mech. Syst. Signal Process.* 35, 176–199.
- [Wang 15] Wang, D, Sun, S, Tse, P. W. A general sequential Monte Carlo method based optimal wavelet filter: A Bayesian approach for extracting bearing fault features, *Mech. Syst. Signal Process.* 52-53, 293–308.
- [Weirm10] Wierman, J. M., 2010. An introduction to the mathematics of uncertainty: including Set Theory, Logic, Probability, Fuzzy Sets, Rough Sets, and Evidence Theory. Book; Center for the Mathematics of Uncertainty, Creighton University.
- [Wentao08] S. Wentao L. Changhou Z. Dan., 2008. Bearing Fault Diagnosis Based on Feature Weighted FCM Cluster Analysis, *IEEE International Conference on Computer Science and Software Engineering*. Pp. 518-521.
- [Widodo11] Widodo, A , Yang, B. S., 2011. Application of relevance vector machine and survival probability to machine degradation assessment, *Expert Systems with Applications*. 38, 2592–2599.
- [Wil05] Wildi, T, Sybille, G. *ELECTROTECHNIQUE*. Book, 4<sup>th</sup> edition, ISBN PUL 2-7637-8185-3, Paris, 2005.
- [Wu07] Wu, J-D. , Wang, Y-H. , & Bai, M. R., 2007. Development of an expert system for fault diagnosis in scooter engine platform using fuzzy-logic inference. *Expert Systems with Applications*, 33 , 1063–1075 .
- [Xiang15] J. Xiang, Y. Zhong, H. Gao., 2015. Rolling element bearing fault detection using PPCA and spectral kurtosis, *Measurement*. 75, 180–191
- [Yan05] J, Yan, J, Lee., 2006. Degradation Assessment and Fault Modes Classification Using Logistic Regression, Article in *Journal of Manufacturing Science and Engineering*. 127, 912-914. DOI: 10.1115/1.1962019

- [Yang04] B.S. Yang, T. Han, J.L. An., 2004. ART–KOHONEN neural network for fault diagnosis of rotating machinery, *Mech. Syst. Signal Process.* 18, 645–657.
- [Yang06] B.S. Yang, K.J. Kim., 2006. Application of Dempster–Shafer theory in fault diagnosis of induction motors using vibration and current signals, *Mech. Syst. Signal Process.* 20, 403–420.
- [Yi10] D. Yi, C. Yilin, W. Xing., 2010. A Probabilty Box and Demstpter Shafer Structure theory-based method for the Bearing fault pattern recognition, Published In: IEEE computer society, 2010 International Conference on Measuring Technology and Mechatronics Automation, 301-305, DOI 10.1109/ICMTMA.2010.16
- [Yu11] Y. Yu, Z. Yu, and J. Zhao., 2011. Rolling Bearing Fault Diagnosis Using Neural Networks, Springer (Eds.): CSEEE 2011, Part II, CCIS 159, pp. 424–429, 2011.
- [Zadah78]Zadeh, L. A., 1978. Fuzzy sets as basis for a theory of possibility. *Fuzzy sets and systems* 1(1), 3-28.
- [Zarei07] Zarei, J, Poshtan, J., 2007. Bearing fault detection using wavelet packet transform of induction motor stator current, *Tribology International.* 40, 763–769.
- [Zarei12] J, Zarei., 2012. Induction motors bearing fault detection using pattern recognition techniques, *Exp. Sys. Appli.* 39, 68–73.
- [Zarei 14] J. Zarei, M. A. Tajeddini, H. R. Karimi., 2014. Vibration analysis for bearing fault detection and classification using an intelligent filter, *Mechatronics.* 24, 151–157
- [Zhang10] L. Zhang a, G. Xiong, H. Liu, H. Zou, W. Guo., 2010. Bearing fault diagnosis using multi-scale entropy and adaptive neuro-fuzzy inference, *Exp. Syst. Appli.* 37, 6077–6085.
- [Zhang05] X. Zhang, R. Xu, C. Kwan, S. Y. Liang, Q. Xie, L. Haynes, An integrated approach to bearing fault diagnostics and prognostics, *Proceedings of American Control Conference, Portland, OR, USA, 2005*, pp. 2750–2755.
- [Zha 12] Zhang, Z, Wang, Y, Wang, K., 2012. Fault diagnosis and prognosis using wavelet packet decomposition, Fourier transform and artificial neural network, *J Intell Manuf*, DOI 10.1007/s10845-012-0657-2.

[Zhang15] Zhang Q, Tse P. W. T, Wan X, Xu G., 2015. Remaining useful life estimation for mechanical systems based on similarity of phase space trajectory, *Expert Systems with Applications* 42 (2015) 2353–2360

[Zhu13] Zhu, J, Yoon, J. M1, He, D, Qu, Y, Bechhoefer, E., 2013. Lubrication Oil Condition Monitoring and Remaining Useful Life Prediction with Particle Filtering, *International Journal of Prognostics and Health Management*, ISSN 2153-2648, 2013 020, 1-15.

[Zvo10] M. Zvokelj, S. Zupan, I. Prebil., 2010. Multivariate and multi scale monitoring of large-size low-speed bearings using Ensemble Empirical Mode Decomposition method combined with Principal Component Analysis, *Mech. Syst. Signal Process.* 24, 1049–1067



# **ANNEXE**

**Tableau 1.** Les défauts de roulements du coté accouplement (12kHz), \* : Données non disponibles.

Diamètre De défaut (inch)	Charge Du moteur (HP)	Vitesse de rotation (rpm)	Bague Intérieur	Bille	Bague Extérieur Position Relative à la zone de charge, la zone de charge centrée à		
					Centrée @6:00	Horizontale @3:00	Verticale @12:00
0.007"	0	1797	105.mat	118.mat	130.mat	144.mat	156.mat
	1	1772	106.mat	119.mat	131.mat	145.mat	158.mat
	2	1750	107.mat	120.mat	132.mat	146.mat	159.mat
	3	1730	108.mat	121.mat	133.mat	147.mat	160.mat
0.014"	0	1797	169.mat	185.mat	197.mat	*	*
	1	1772	170.mat	186.mat	198.mat	*	*
	2	1750	171.mat	187.mat	199.mat	*	*
	3	1730	172.mat	188.mat	200.mat	*	*
0.021"	0	1797	209.mat	222.mat	234.mat	246.mat	258.mat
	1	1772	210.mat	223.mat	235.mat	247.mat	259.mat
	2	1750	211.mat	224.mat	236.mat	248.mat	260.mat
	3	1730	212.mat	225.mat	237.mat	249.mat	261.mat
0.028"	0	1797	3001.mat	3005.mat	*	*	*
	1	1772	3002.mat	3006.mat	*	*	*
	2	1750	3003.mat	3007.mat	*	*	*
	3	1730	3004.mat	3008.mat	*	*	*

**Tableau 2.** Caractéristique du roulement coté entraînement:6205-2RS JEM SKF, roulement à un seul rang de billes de cannelure profonde.  
Taille: (inches)

Diamètre Intérieur	Diamètre Extérieur	Épaisseur	Diamètre de Bille	Diamètre primitif
0.9843	2.0472	0.5906	0.3126	1.537

**Tableau 3.** Paramètres du moteur asynchrone modélisé [Tra09].

Paramètre	Valeur
Tension du stator $U_s$ (Volts)	220
Résistance du stator $R_s$ (ohm)	1.14
Résistance du rotor $R_r$ (ohm)	1.102
Inductance du stator $L_s$ (H)	0.110
Inductance du rotor $L_r$ (H)	0.124
Inductance mutuelle $L_m$ (H)	0.110
Nbr de paires de poles	2
Inertie du rotor (kg.m <sup>2</sup> )	0.014

**Tableau 4.** Paramètres de simulation de courant de défaut de roulement.

Paramètre	Valeur
Fréquence d'alimentation (Hz) ' $f_s$ '	50
Fréquence de défaut (Hz) ' $f_c$ '	32
Fréquence d'échantillonnage (Hz) ' $F_s$ '	48000
Index de AM ' $\alpha$ '	0.01
Index de PM ' $\beta$ '	0.01
Angle de AM ( $\pi$ rad) ' $\varphi_\alpha$ '	$\pi/4$
Angle de PM ( $\pi$ rad) ' $\varphi_\beta$ '	$\pi/4$
Angle de phase du rotor ( $\pi$ rad) ' $\varphi_r$ '	$\pi/8$
Amplitude de courant PM du rotor (A) ' $I_{rt}$ '	7.85
Amplitude de courant PM du stator (A). ' $I_{st}$ '	7.85
amplitude fondamentale courant statorique (A) ' $I_1$ '	15.70

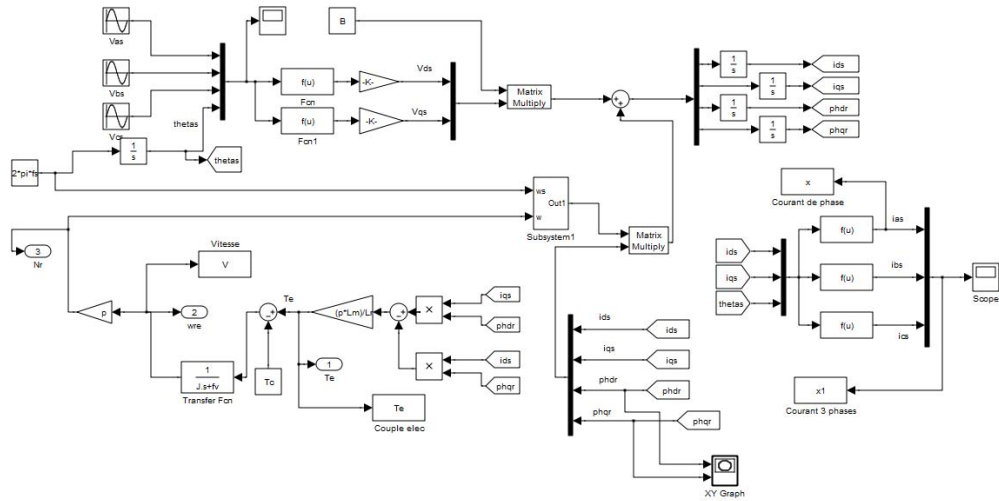


Figure 1. Modélisation de la machine asynchrone saine (Matlab/Simulink).

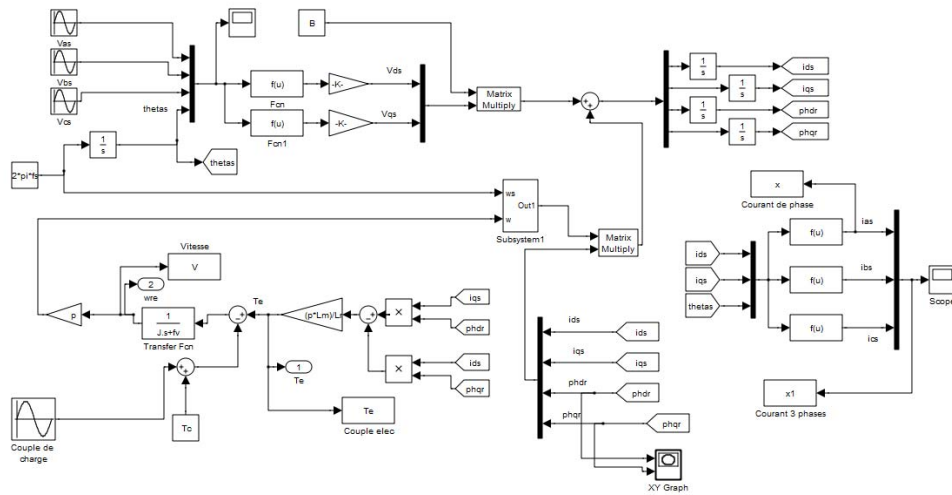


Figure 2. Modélisation de la machine asynchrone défectueuse (Matlab/Simulink).

**Publications Internationals:**

- Toufik Berredjem, Mohamed Benidir “Bearing faults diagnosis using fuzzy expert system relying on an Improved Range Overlaps and Similarity method” Expert Systems With Applications 108 (2018) 134–142.

**Communications :**

- Toufik Berredjem, Mohamed Benidir « Décomposition en paquet d'ondelettes et la méthode Dempster-Shafer pour le diagnostic des défauts de roulements » 3<sup>ème</sup> Conférence Internationale sur la Maintenance et la Sécurité Industrielle, CIMSI'2015.