

Titre: Développement d'une procédure intelligente de diagnostic des défauts de roulement et étude de l'impact du chemin de transmission du signal sur sa fiabilité
Title:

Auteur: Christian Komgom Nguepjob
Author:

Date: 2008

Type: Mémoire ou thèse / Dissertation or Thesis

Référence: Komgom Nguepjob, C. (2008). Développement d'une procédure intelligente de diagnostic des défauts de roulement et étude de l'impact du chemin de transmission du signal sur sa fiabilité [Mémoire de maîtrise, École Polytechnique de Montréal]. PolyPublie. <https://publications.polymtl.ca/8387/>
Citation:

 **Document en libre accès dans PolyPublie**
Open Access document in PolyPublie

URL de PolyPublie: <https://publications.polymtl.ca/8387/>
PolyPublie URL:

Directeurs de recherche: Njuki W. Mureithi, & Aouni A. Lakis
Advisors:

Programme: Non spécifié
Program:

UNIVERSITÉ DE MONTRÉAL

**DÉVELOPPEMENT D'UNE PROCÉDURE INTELLIGENTE DE
DIAGNOSTIC DES DÉFAUTS DE ROULEMENT ET ÉTUDE DE L'IMPACT
DU CHEMIN DE TRANSMISSION DU SIGNAL SUR SA FIABILITÉ**

**CHRISTIAN KOMGOM NGUEPJOP
DÉPARTEMENT DE GÉNIE MÉCANIQUE
ÉCOLE POLYTECHNIQUE DE MONTRÉAL**

**MÉMOIRE PRÉSENTÉ EN VUE DE L'OBTENTION
DU DIPLÔME DE MAÎTRISE ÈS SCIENCES APPLIQUÉES
(GÉNIE MÉCANIQUE)
OCTOBRE 2008**

© Christian Komgom Nguerpjop, 2008.



Library and
Archives Canada

Published Heritage
Branch

395 Wellington Street
Ottawa ON K1A 0N4
Canada

Bibliothèque et
Archives Canada

Direction du
Patrimoine de l'édition

395, rue Wellington
Ottawa ON K1A 0N4
Canada

Your file *Votre référence*
ISBN: 978-0-494-47672-7
Our file *Notre référence*
ISBN: 978-0-494-47672-7

NOTICE:

The author has granted a non-exclusive license allowing Library and Archives Canada to reproduce, publish, archive, preserve, conserve, communicate to the public by telecommunication or on the Internet, loan, distribute and sell theses worldwide, for commercial or non-commercial purposes, in microform, paper, electronic and/or any other formats.

The author retains copyright ownership and moral rights in this thesis. Neither the thesis nor substantial extracts from it may be printed or otherwise reproduced without the author's permission.

AVIS:

L'auteur a accordé une licence non exclusive permettant à la Bibliothèque et Archives Canada de reproduire, publier, archiver, sauvegarder, conserver, transmettre au public par télécommunication ou par l'Internet, prêter, distribuer et vendre des thèses partout dans le monde, à des fins commerciales ou autres, sur support microforme, papier, électronique et/ou autres formats.

L'auteur conserve la propriété du droit d'auteur et des droits moraux qui protègent cette thèse. Ni la thèse ni des extraits substantiels de celle-ci ne doivent être imprimés ou autrement reproduits sans son autorisation.

In compliance with the Canadian Privacy Act some supporting forms may have been removed from this thesis.

Conformément à la loi canadienne sur la protection de la vie privée, quelques formulaires secondaires ont été enlevés de cette thèse.

While these forms may be included in the document page count, their removal does not represent any loss of content from the thesis.

Bien que ces formulaires aient inclus dans la pagination, il n'y aura aucun contenu manquant.


Canada

UNIVERSITÉ DE MONTRÉAL

ÉCOLE POLYTECHNIQUE DE MONTRÉAL

Ce mémoire intitulé :

**DÉVELOPPEMENT D'UNE PROCÉDURE INTELLIGENTE DE
DIAGNOSTIC DES DÉFAUTS DE ROULEMENT ET ÉTUDE DE L'IMPACT
DU CHEMIN DE TRANSMISSION DU SIGNAL SUR SA FIABILITÉ**

présenté par : KOMGOM NGUEPJOP Christian

en vue de l'obtention du diplôme de : Maîtrise ès sciences appliquées

a été dûment acceptée par le jury d'examen constitué de :

M. BALAZINSKI Marek, Ph.D., président

M., MUREITHI Njuki, Ph.D., membre et directeur de recherche

M. LAKIS Aouni, Ph.D., membre et codirecteur de recherche

M. MAYER René, Ph.D., membre

À mes parents...

À mes frères et soeurs...

À mes professeurs et amis...

L'adulte est un grand enfant qui croit qu'il sait...

L'enfant est un petit adulte qui sait qu'il croit...

Le blues de l'instituteur,

Grand Corps Malade.

REMERCIEMENTS

*Je n'aurai jamais assez de mots pour exprimer toute ma gratitude,
Envers ceux et celles qui m'ont aidé au cours de ces deux dernières années d'études,
À mes parents, mes professeurs, mes amis et collègues, mes soeurs et frères,
À toutes ces personnes qui, à leur insu, m'ont insufflé le souffle nécessaire,
Pour mener à terme ce projet de maîtrise de la meilleure des manières.*

*Mon parcours au second cycle supérieur a été très surprenant,
Nouveaux défis, nouvelles difficultés, nouveaux tournants ;
Et comme tout est allé vite, là je décide de me poser,
De prendre quelques secondes pour me retourner, et essayer d'analyser,
Ces deux années mouvementées, pleines de surprises et d'actions,
Où avec vous, j'ai partagé mes joies, mes doutes, et mes déceptions.
Au final, je me dis que je ne me suis pas trop trompé,
Quand une fois de plus, j'ai misé sur ma persévérance alors fragilisée.*

*À travers ces quelques mots, j'essaie de réaliser, de ressentir, de prendre conscience,
De tout ce que ça m'a apporté de recevoir votre assistance,
Merci pour votre écoute et pour votre patience,
Ce fut pour moi les plus beaux encouragements.*

*Merci à vous Dr Lakis, Dr Thomas et dédicace spéciale au Dr Mureithi,
Qui depuis plus de quatre ans maintenant, m'assiste dans mon parcours académique ;
Merci pour votre temps, votre indéfectible soutien et vos précieux conseils,
J'ai compris dans vos critiques que mes études avaient de l'utilité.*

*Je tiens également à remercier le personnel technique du laboratoire IFS,
Thierry et Bénédicte, merci pour votre aide et votre assistance dans mon dur labeur,
En m'initiant aux réalités expérimentales, vous avez fait de moi un ingénieur meilleur.*

Je termine ces mots de reconnaissance par quelques remerciements à :

*Dupuis, Béchir, Dimitri, Idriss, Bibiche, Eugène, Matthias, Adrien, Christelle, Léa,
Stéphane, Coralie, Thierry, Marilyn, Bérénice, Mélodie, Calixte, William, Dora,
Yannick, Abdel, Réza, Babak, Isabelle, Romain, Colin, Véronique, Jean-François,
Ce sera toujours un plaisir de discuter avec vous et de vous avoir près de moi...*

*Deux années de galères et de joies qui s'achèvent, ça laisse forcément quelques émotions,
Et quoiqu'il arrive demain, je me souviendrais toujours de votre attention.*

Africainement Vôtre,

Christian N. Komgom.

ORIGINALITÉ & CONTRIBUTION DU MÉMOIRE À LA RECHERCHE

Au meilleur de mes connaissances, je, soussigné KOMGOM N. Christian, atteste que :

1. les travaux rapportés dans ce mémoire sont le fruit de mon travail personnel ;
2. la problématique de recherche traitée dans ce mémoire n'a pas encore été l'objet d'un travail de recherche ;
3. le contenu de ce mémoire n'a pas encore été publié dans un document technique ou scientifique, ni emprunté à d'autres travaux de recherche ;
4. la procédure de diagnostic développée dans ce mémoire est le résultat de mon travail personnel. Les auteurs des méthodes d'analyse qui y sont utilisées sont dûment cités en référence aux endroits appropriés ;
5. les mesures expérimentales faites sur le banc d'essai SFD du laboratoire IFS de l'École Polytechnique de Montréal ont été effectuées par moi. Je tiens à souligner l'assistance technique de Thierry Lafrance pour l'adaptation du banc d'essai, et de Bénédicte Besner pour la prise des mesures.

Ce travail de maîtrise s'attaque à l'étude de l'impact du chemin de transmission du signal de vibration sur la fiabilité du diagnostic des méthodes de reconnaissance de forme. On montre que la fiabilité du diagnostic posé par les méthodes d'apprentissage statistiques dépend fortement du chemin de transmission du signal, et des solutions sont proposées par la suite pour réduire cette influence.

RÉSUMÉ

Au cours des dernières décennies, l'analyse du comportement dynamique s'est établie comme un outil efficace et efficient pour surveiller l'état de fonctionnement des machines rotatives. Cet intérêt se justifie par le potentiel offert par les méthodes d'analyse vibratoire pour la surveillance, la détection et le diagnostic d'une éventuelle défaillance de la machine. En pratique, les signatures vibratoires mesurées à l'aide de capteurs de vibration contiennent plusieurs composantes qui sont plus ou moins utiles à la caractérisation du signal, et rendent difficile l'interprétation des résultats issus de ces analyses. Face à cette complexité grandissante, la recherche scientifique s'est orientée vers l'utilisation des méthodes de reconnaissance de formes qui permettent de représenter l'état de la machine dans un espace de grande dimension, pour faciliter la détermination de l'état de la machine.

Ce travail de recherche s'attaque à la problématique posée par le chemin de transmission du signal sur la fiabilité des méthodes d'apprentissage dans la détection des défauts de roulements à billes. On montre que le chemin de transmission des vibrations affecte la capacité à généraliser des classificateurs issus des méthodes d'apprentissage supervisé. Les vibrations sont transmises à travers la matière qui agit alors comme un filtre de telle manière qu'il devient difficile de caractériser la source de vibration peu importe la dimension de l'espace de représentation. En général, la capacité de

généralisation des classificateurs varie autour de 60% en moyenne lorsque le chemin de transmission du signal à classer diffère de celui du signal avec lequel le classificateur a été construit. La résolution de cette problématique permettrait de résoudre le problème lié à la localisation des capteurs de vibration sur les machines rotatives dont l'accessibilité est soumise à une réglementation très stricte (moteurs d'avions, turbines et compresseurs dans les réacteurs nucléaires, etc.).

Ce mémoire propose la combinaison entre les méthodes avancées de traitement de signal, que sont la synchronisation temporelle moyennée, l'analyse du kurtosis spectral, les méthodes de filtrage adaptatif de bruit, et les méthodes de reconnaissance de forme pour résoudre le problème posé par le chemin de transmission du signal de vibration. La procédure de diagnostic qui intègre ces méthodes d'analyse est implémentée selon la logique suivante : premièrement, les méthodes d'analyse vibratoires permettent d'analyser la signature vibratoire mesurée afin d'isoler le plus possible la composante du signal liée au défaut de roulement. Des indices de vibration sont extraits du signal obtenu, et sont utilisés sous forme de vecteur pour représenter l'état de la machine dans une espace de grande dimension (22 et 40 paramètres). Ensuite les méthodes de reconnaissance sont utilisées pour caractériser ces vecteurs et les classer selon leur classe de défaillance. Ces classificateurs sont ensuite utilisés pour trouver la classe de défaillance à laquelle appartient de nouveaux signaux de vibration non utilisés pendant l'apprentissage. Les signaux de vibration proviennent d'un banc d'es-

sai expérimental comprenant deux paliers de roulements, chacun d'eux étant surveillé par un accéléromètre. Seul un des deux paliers contient un roulement défectueux. Les résultats de classification de la procédure implémentée, i.e. Synchronisation temporelle moyennée + Analyse du kurtosis spectral + Filtrage adaptatif de bruit + Support Vector Machine, varient autour de 80% en moyenne, ce qui constitue un gain important étant donné la complexité des phénomènes étudiés.

Ce travail s'attaque aussi à l'utilisation d'un algorithme génétique pour trouver les paramètres les plus utiles lors du processus de classification lorsque le chemin de transmission est différent. L'algorithme génétique implémenté dans ce mémoire est un algorithme de base, dans le mesure où on se limite à trouver une combinaison de paramètre qui minimise l'erreur de classification des frontières. Les résultats montrent que parmi les 22 ou les 40 paramètres extraits, il existe des frontières où seulement 17 , 6 voire même 2 paramètres seraient suffisants pour obtenir des pourcentages de classification supérieur à 90%.

Mots Clés : *Maintenance prédictive, Défaut de roulement, Analyse des signatures vibratoires, Méthode de reconnaissance de formes, Support Vector Machine, Kurtosis spectral, Synchronisation Temporelle Moyennée, Filtrage adaptatif de bruit, Sélection des paramètres, Extraction des paramètres, Algorithme Génétique.*

ABSTRACT

During the past decades, vibration response analysis has become a cornerstone among all others methods used for the condition monitoring of rotating machinery. Many researchers have shown that using the analysis of the dynamical behaviour of rotating components, it may be possible to monitor, detect and diagnose any incipient failure in the system. In practice, vibration signals measured by sensors contain many components which may not be useful in the characterization of the signal. This makes it difficult to interpret vibration analysis results, as the research has tuned towards the use of pattern recognition methods to represent machine condition in a high dimensional hyperspace, where we expect the characterization to be simpler.

This thesis addresses the problems posed by signal path transmission on the reliability of the predictions issued from pattern recognition methods. First, we show that signal path transmission has a great influence on the generalization ability of classifiers, regardless of the dimensionality of the hyperspace. Results show that the generalization ability of the classifiers will not exceed 60% in general, when new signals, having a different signal path transmission than those used during the learning, will be presented to the classifier. Solving that issue will open many breakthroughs in the monitoring of critical components such as aircraft engines, nuclear turbines and compressors. We will no longer have to worry about the location of monitoring sensors, as these com-

ponents are under strict regulations.

This memoir proposes a combination of advance signal processing methods, like Time Synchronous Averaging, Spectral kurtosis, Adaptive Noise Cancellation, with pattern recognition methods, namely support Vector Machines, to overcome the problem posed by signal path transmission in signal identification. A diagnostic procedure that integrates these methods is implemented as follow : vibration responses analysis methods are first used to isolate the components of the vibration signal coming from the faulty components. Next, vibration parameters (22 and 40 parameters) are extracted from this component to form a feature vector that will represent machine state condition in a high dimensional hyperspace. Then Support Vector Machines are trained to characterize these vectors and classify them according to their failure class. Later, these classifiers will be used to classify new vibration signals having different signal path transmission from those used during the learning.

The implemented diagnostic procedure has been tested and validated using vibration signals coming from two different test rigs. Each test rig is composed by two bearing seats, one of them containing a faulty bearing. Accelerometers are used to pick-up vibration signals of each bearing. Using our diagnostic procedure, generalization performance of the classifiers vary between 46% and 100%, the mean being at 80%, which is a great improve regarding the complexity of these systems.

Even if, it was not first required for the completion of this thesis, this work is also addressing the use of a genetic algorithm to find features that are most useful during the learning when the transmission path is different. The genetic algorithm implemented in this memory is a basic algorithm. We are only interested in finding a feature vector that minimizes the classification error of svm-boundaries. Results show that among the 22 or 40 features extracted, there are boundaries where only 17, 6 or even 2 parameters would be sufficient to have a generalization performance higher than 90%.

Keywords : *Condition monitoring, bearing fault, Vibration response analysis, Pattern recognition methods, Support Vector Machine, Spectral Kurtosis, Time Synchronous Averaging, Adaptive Noise Cancellation, Feature selection, Feature extraction, Genetic Algorithm.*

TABLE DES MATIÈRES

DÉDICACE	iv
REMERCIEMENTS	v
ORIGINALITÉ & CONTRIBUTION DU MÉMOIRE À LA RECHERCHE . .	vii
RÉSUMÉ	viii
ABSTRACT	xi
TABLE DES MATIÈRES	xiv
LISTE DES FIGURES	xix
LISTE DES NOTATIONS ET DES SYMBOLESxxiii
LISTE DES TABLEAUXxxvii
LISTE DES ANNEXESxxix
INTRODUCTION	1
CHAPITRE 1 REVUE DE LITTÉRATURE	6
1.1 Les activités de maintenance	6
1.1.1 La maintenance corrective	7

1.1.2	La maintenance préventive	8
1.1.3	La maintenance conditionnelle ou prédictive	9
1.1.4	Choix du programme de maintenance	13
1.2	L'analyse vibratoire au service de la maintenance prédictive	15
1.2.1	Les méthodes d'analyse temporelles	15
1.2.1.1	Allure des signatures temporelles	16
1.2.1.2	Niveaux globaux de vibration	16
1.2.2	Les méthodes d'analyse fréquentielles	24
1.2.2.1	Analyse fréquentielle en bande fine	24
1.2.2.2	Indices fréquentiels de vibration	26
1.2.2.3	High Frequency Resonance Technique - Démodulation - Analyse d'enveloppe	28
1.2.2.4	La synchronisation temporelle moyennée	30
1.2.3	Les méthodes d'analyse temps-fréquence	32
1.2.4	Les méthodes d'analyse cyclostationnaires	35
1.2.4.1	La densité spectrale cyclique	36
1.2.4.2	Le kurtosis spectral	39
1.2.5	Autres méthodes d'analyse des signatures vibratoires	40
1.2.5.1	Adaptive Noise Cancellation	40
1.2.5.2	L'analyse cepstrale	43
1.2.5.3	Les méthodes spectrales d'ordre supérieur	45

1.3	Les méthodes de reconnaissance de forme comme outils d'aide au diagnostic	46
1.3.1	Historique générale	47
1.3.2	Principe d'apprentissage statistique	49
1.3.3	La dimension de Vapnik-Chervonenkis	52
1.3.4	Application des SVM en surveillance des machines rotatives	55
CHAPITRE 2 FONDLEMENTS THÉORIQUES DES MÉTHODES D'ANALYSE		57
2.1	Méthode d'analyse des signatures vibratoires	57
2.1.1	La synchronisation temporelle moyennée	58
2.1.1.1	Modèle de McFadden & Toozhy	59
2.1.1.2	Modèle de synchronisation proposé	62
2.1.2	Analyse cyclostationnaire : le kurtosis spectral	64
2.2	Méthode de reconnaissance de formes : les Support Vector Machines	69
2.2.1	Introduction aux Support Vector Machines	69
2.2.1.1	Formulation du problème de classification	70
2.2.1.2	Autres formulations	77
2.2.2	Multi-classification	81
2.3	Sélection des paramètres par Algorithme Génétique	83
2.3.1	Plan général de l'AG	84
2.3.2	Évaluation de la fonction objectif & Condition d'arrêt	85

2.3.3	Sélection des parents, croisement & mutation	86
2.3.4	Modèle d'algorithme génétique proposé	89
CHAPITRE 3 MESURES ET PROCÉDURE EXPÉRIMENTALES		93
3.1	Base de données de l'Université Case Western	93
3.2	Banc d'essai du laboratoire IFS	95
3.2.1	Description du banc d'essai	95
3.2.2	Description des essais expérimentaux	97
3.3	Acquisition des données	99
3.4	Analyse modale expérimentale	101
CHAPITRE 4 APPLICATION DES MÉTHODES D'ANALYSE & RÉSULTATS		103
4.1	Analyse préliminaire des signatures vibratoires du SFD	104
4.2	Application des méthodes d'analyse des signatures vibratoires	109
4.2.1	Application du modèle de synchronisation temporelle proposé	110
4.2.2	Utilisation du kurtosis spectral pour l'identification des défauts de roulements	115
4.2.3	Utilisation de l'ANC en détection des défauts de roulement . .	121
4.3	Développement de la procédure de diagnostic	124
4.3.1	Description de la procédure d'apprentissage	125
4.3.2	Combinaison de la Synchronisation Temporelle Moyennée avec les Support Vector Machine	127

4.3.3	Combinaison de la Synchronisation Temporelle Moyennée avec l'analyse en composantes Indépendantes et les Support Vector Machine	130
4.3.4	Combinaison de la Synchronisation Temporelle Moyennée avec le kurtosis spectral et les Support Vector Machine	132
4.4	Diminution de l'impact du chemin de transmission du signal sur la classification	134
4.4.1	Augmentation du nombre de paramètres	135
4.4.2	Intégration de l'ANC dans la procédure de diagnostic	142
4.4.3	Sélection des paramètres par Algorithme Génétique	145
	DISCUSSIONS & RECOMMANDATIONS	150
	CONCLUSION	156
	RÉFÉRENCES	160
	ANNEXES	181

LISTE DES FIGURES

FIG. 1.1	Principe de la maintenance corrective	8
FIG. 1.2	Principe de la maintenance préventive	9
FIG. 1.3	Principe de la maintenance prédictive	10
FIG. 1.4	Courbe de tendance typique	11
FIG. 1.5	Étapes de la maintenance prédictive	14
FIG. 1.6	Niveaux globaux de vibration vs. taille du défaut d'un roulement, [Badri, 2007a]	18
FIG. 1.7	Exemples de chartes de sévérité de vibration basées sur le peak et le rms, [Thomas, 2002]	20
FIG. 1.8	Extraction des paramètres en surveillance d'engrenages [Lebold, 2000]	23
FIG. 1.9	Gabarit d'alarme rotor monté sur roulement	25
FIG. 1.10	Étapes de la méthode HFRT	29
FIG. 1.11	Illustration de la synchronisation temporelle moyennée	31
FIG. 1.12	Principe de l'Adaptive Noise Cancellation	41
FIG. 1.13	Dimension de Vapnik-Chervonenkis dans un espace de dimension 2	52
FIG. 1.14	Variation de la confiance VC en fonction du nombre de points	54
FIG. 1.15	Variation de la confiance VC en fonction de la dimension VC .	55
FIG. 2.1	Modèle simulink pour la synchronisation temporelle moyennée	63

FIG. 2.2	Illustration des support vectors	73
FIG. 2.3	Plan de l'algorithme génétique	85
FIG. 2.4	Modèle de sélection des paramètres par Algorithme génétique	90
FIG. 3.1	Banc d'essai expérimental utiliser à CWRU	94
FIG. 3.2	Banc d'essai expérimental	96
FIG. 3.3	Défaut de bague externe	98
FIG. 3.4	Défaut de bague interne	99
FIG. 3.5	Défaut de bille	100
FIG. 4.1	Roulement SKF 1211 sans défaut, 1200 rpm	104
FIG. 4.2	Roulement avec bille défectueuse, 1800 rpm	106
FIG. 4.3	Roulement avec bague interne défectueuse, 1500 rpm	107
FIG. 4.4	Roulement avec une bague externe défectueuse, défaut positionné à 6h, 900 rpm	108
FIG. 4.5	Roulement avec une bague externe défectueuse, défaut positionné à 3h, 600 rpm	110
FIG. 4.6	Signal original, défaut de 21mils sur la bague interne du roulement DE, 1797 rpm	111
FIG. 4.7	TSA-Signal, défaut de 21mils sur la bague interne du roulement DE, 1797 rpm	112
FIG. 4.8	TSA-Signal de même amplitude que le signal original	113

FIG. 4.9	TSA-Signal, synchronisation selon le modèle de McFadden & Toozhy	114
FIG. 4.10	Distribution du kurtosis spectral du signal FEirfe014, 1772 rpm	116
FIG. 4.11	Spectre enveloppe de FEirfe014 filtre passe-bande de largeur $2^{4.5}$ centré à 3375 Hz	116
FIG. 4.12	Distribution du kurtosis spectral du signal FEorde014, 1797 rpm	118
FIG. 4.13	Spectre enveloppe FEorde014 filtre passe-bande de largeur $2^{4.5}$ centré à 4875 Hz	118
FIG. 4.14	Distribution du kurtosis spectral du signal DEblde007, 1797 rpm	119
FIG. 4.15	Spectre enveloppe DEblde007 filtre passe-bande de largeur 2^8 centré à 3281 Hz	120
FIG. 4.16	Spectre enveloppe de DEblde007 : filtre passe-bande de largeur 2^8 centré à 1687 Hz	120
FIG. 4.17	Modèle proposé pour l'Adaptive Noise Cancellation	122
FIG. 4.18	Résultats de l'ANC sur le signal rpm0600or3h05	123
FIG. 4.19	Extraction des paramètres implémentée dans l'article de conférence [Komgom, 2007a]	128
FIG. 4.20	Extraction des paramètres implémentée dans l'article de conférence [Komgom, 2008]	133
FIG. 4.21	Procédure de diagnostic : extraction de 40 paramètres	136
FIG. I.1	Géométrie et vitesse cinématique du roulement	182

FIG. II.1	Disposition des points de mesures lors de l'analyse modale . . .	187
FIG. II.2	Bande passante typique du signal d'impulsion, marteau choc à embout dur	188
FIG. II.3	Fonction de transfert au point A, partie réelle et imaginaire .	189
FIG. II.4	Fonction de transfert au point A, amplitude et phase	190

LISTE DES NOTATIONS ET DES SYMBOLES

ANC :	Adaptive Noise Cancellation
b :	Biais de la frontière de classification
bl :	Ball. Défaut de bille sur le roulement
<i>Bd</i> :	Ball diameter, diamètre des billes
blirBound :	Frontière SVM : défaut de bille ('bl') vs défaut de bague interne ('ir')
blorBound :	Frontière SVM : défaut de bille ('bl') vs défaut de bague externe ('or')
<i>BPFI</i> :	Ball Passing Frequency of Inner race fault, fréquence d'un défaut de bague interne
<i>BPFO</i> :	Ball Passing Frequency of Outer race fault, fréquence d'un défaut de bague externe
<i>BPFR</i> :	Ball Passing Frequency of Rolling element fault, fréquence d'un défaut de bille
ch1 :	Canal 1. Signal mesure au canal 1
ch1no0600 :	Signal mesuré au canal 1 , avec le roulement testé étant en bon état et le moteur tournant à 600 rpm. Banc d'essai de Polytechnique de Montréal

- ch2 : Canal 2. Signal mesuré au canal 2
- ch2ir1500 : Signal mesuré au canal 2 , avec le roulement testé ayant un défaut sur sa bague interne et le moteur tournant à 1500 rpm. banc d'essai de Polytechnique de Montréal
- CWRU : Case Western Reserve University
- DE : Drive End
- DEbl007fe : Signal du roulement ayant un défaut de 7 mils sur une de ses billes et positionné à l'extrémité Drive end ('DE'), mesuré par l'accéléromètre positionné à l'extrémité fan end ('fe') de l'arbre. Banc d'essai de CWRU
- Dimension VC : Dimension de Vapnik-Chervonenkis
- DP : Données extraites des signaux ayant un chemin de transmission différent des signaux utilisés pour construire les frontières de classification (Different Path)
- f_c : Fréquence de rotation de la cage
- f_r : Fréquence de rotation de l'arbre
- FE : Fan End

FEir014de :	Signal du roulement ayant un défaut de 14 mils sur sa bague interne ('ir') et positionné à l'extrémité Fan end ('FE'), mesuré par l'accéléromètre positionné à l'extrémité drive end ('de') de l'arbre. Banc d'essai de CWRU
$H(n, f)$:	Enveloppe complexe à la fréquence f
ir :	Inner Race. Défaut de bague interne sur le roulement
irorBound :	Frontière SVM : défaut de bague interne ('ir') vs défaut de bague externe ('or')
$K(\cdot)$:	Fonction noyau pour la projection des données vers un espace de plus grande dimension
m_x :	Moyenne de la série temporelle x
m_x^k :	Coefficient de Fourier de la moyenne périodique $m_x(t)$ de x
MTBF :	Mean Time Between Failure
MTTF :	Mean Time To Failure
NAG :	Niveau d'Alarme Global
no :	Normal. Pas de défaut sur le roulement
or :	Outer Race. Défaut de bague externe sur le roulement
Pd :	Pitch diameter, diamètre moyen du roulement
$R_x(\tau)$:	Fonction d'autocorrelaton du signal x

R_x^k :	Fonction d'autocorrelation cyclique du signal x
$S_x(f)$:	Densité spectrale du signal x
SK :	Spectral kurtosis
SP :	Données extraites des signaux ayant le même chemin de transmission que les signaux utilisés pour construire les frontières de classification (Same Path)
SVM :	Support Vector Machines
TSA :	Time Synchronous Averaging
VC :	Vapnik-Chrvoenkis
w :	Vecteur normal à la frontière de classification
x_i :	Vecteur de paramètres utilisé lors de la classification
y_i :	Identifiant associé à la donnée x_i
z :	Nombre de billes dans le roulement
α_i :	Multiplicateurs de Lagrange associé à la donnée x_i
β :	Angle de contact entre les billes et les bagues
$\phi(\cdot)$:	Transformation de l'espace induite par la fonction noyau
$\rho(f)$:	Ratio signal sur bruit à la fréquence f

LISTE DES TABLEAUX

TAB. 1.1	Quelques représentations temps-fréquences	33
TAB. 3.1	Fréquences théoriques des défauts de roulement du montage CWRU	94
TAB. 3.2	Caractéristiques des composantes du montage expérimental .	96
TAB. 3.3	Fréquences théoriques des défauts de roulement du montage SFD	97
TAB. 4.1	Impact du chemin de transmission du signal sur la généralisation des frontières SVM, [Komgom, 2007a]	129
TAB. 4.2	Impact du chemin de transmission du signal sur la généralisation des frontières SVM, [Komgom, 2007b]	131
TAB. 4.3	Impact du chemin de transmission du signal sur la généralisation des frontières SVM, [Komgom, 2008]	134
TAB. 4.4	Généralisation des frontières SVM, extraction de 22 paramètres des signaux SFD	138
TAB. 4.5	Généralisation des frontières SVM, extraction de 40 paramètres des signaux SFD	141
TAB. 4.6	Généralisation des frontières SVM, 40 paramètres , signaux ch1 traités par ANC	144
TAB. 4.7	Résultats de classification des frontière basées sur les signaux provenant du canal 1 après sélection de paramètres SK22 par AG146	

TAB. 4.8	Résultats de classification des frontière basées sur les signaux provenant du canal 1 après sélection de paramètres SKTSA40 par AG	149
TAB. II.1	Fréquences naturelles du banc d'essai expérimental	191

LISTE DES ANNEXES

ANNEXE I	CALCUL DES FRÉQUENCES DE DÉFAUT D'UN ROULE- MENT À BILLES	181
I.1	Fréquence d'un défaut de cage	182
I.2	Fréquence d'un défaut sur les bagues	183
I.3	Fréquence d'un défaut sur la bille	185
ANNEXE II	ANALYSE MODALE DU SFD	187

INTRODUCTION

L'évolution sans cesse croissante des marchés de consommation depuis le 19^{ième} siècle et la compétitivité qu'elle a engendrée, ont sans doute été le moteur de l'optimisation des procédés industriels. Pour les entreprises, il est essentiellement question d'améliorer leur productivité, tout en diminuant autant que possible leurs coûts d'opération. Les opérations de maintenance représentent environ la moitié des coûts d'opération dans les industries manufacturières et de procédés. Selon l'AFNOR ¹, la maintenance regroupe l'ensemble des actions permettant de maintenir ou de rétablir un bien dans un état où il est en mesure d'assurer un service déterminé. Ces activités ont toujours été présentes dans toute industrie, à cause de l'usure inévitable des pièces mécaniques. Afin d'améliorer leur productivité, il devient impératif pour les industries de production et de transformation de réduire les coûts associés à ces activités, en implémentant un programme de maintenance efficace et efficient.

Contexte & Problématique

À l'heure actuelle, les activités de maintenance les plus répandues en industrie se classent en deux grandes catégories : la maintenance *corrective*, et la maintenance *préventive*. Cependant, ces deux types de maintenance ne favorisent pas une réduction

¹Association Française de NORmalisation

des coûts associés aux activités de maintenance. La maintenance corrective entraîne un arrêt complet et imprévu de la production tandis que la préventive exige le remplacement systématique des pièces mécaniques même si elle sont encore en bon état. C'est donc pour pallier à ces inconvénients qu' a été introduit le troisième type de maintenance auquel on s'intéresse : la maintenance *conditionnelle* (*Condition based-Maintenance* CBM en anglais), encore appelée maintenance *prédictive*. Elle consiste à suivre l'état de dégradation d'un équipement à l'aide de relevés ou de mesures et à effectuer les opérations de maintenance lorsque les performances de la machines sont affectées par l'usure ou le vieillissement d'une ou plusieurs composantes.

En milieu industriel, l'application des principes de maintenance prédictive se heurte aux difficultés liées à l'interprétation adéquate des données recueillies. Plusieurs paramètres peuvent être utilisés pour fournir des informations pertinentes sur l'état de la machine : température, émission acoustique, état de l'huile, vibrations... etc. Chacune de ces méthodes a ses avantages et ses inconvénients. Cependant, la vulgarisation industrielle des analyseurs fréquentiels a permis à l'analyse vibratoire de s'établir comme un standard dans la surveillance de l'état des machines. L'analyse vibratoire consiste à utiliser des indicateurs de niveau de vibration pour détecter les cas de fonctionnement anormal, poser un diagnostic et suivre l'évolution de cette défaillance.

L'intérêt porté aux méthodes d'analyse vibratoire pour la surveillance des machines

rotatives ne date pas d'aujourd'hui. Plusieurs travaux y ont été consacrés au cours du demi-siècle écoulé. Cependant, dans la majorité des cas, les méthodes de surveillance ont été développées à partir des signaux qui sont soit simulés soit obtenus à partir de mesures expérimentales. Mais lors de leur implémentation, l'efficacité de ces méthodes est sérieusement affectée par la complexité et le niveau de bruit des signaux mesurés en industrie. La constitution d'un échantillon de mesures aussi représentatif que possible des signaux mesurés en industrie constitue donc une des priorités de ce travail. Les travaux de cette thèse s'inscrivent dans le domaine de la maintenance prédictive par analyse vibratoire des signaux. L'emphase sera mise sur la fiabilité du diagnostic posé par la procédure de maintenance conditionnelle. On utilisera à cet effet les méthodes de reconnaissance de formes.

Les méthodes de reconnaissance de forme permettent d'augmenter la fiabilité de la maintenance prédictive car elles peuvent s'appuyer sur une infinité d'indicateurs de vibration. De plus, elles favorisent la vulgarisation des pratiques de maintenance prédictive dans la mesure où elles servent d'outils d'aide au diagnostic et à la prise de décision. L'utilisateur n'a pas besoin d'être un expert en analyse de signatures vibratoires pour décider de la tenue des activités de maintenance. La méthode de reconnaissance de forme permet la détection d'un état de fonctionnement anormal et son diagnostic. De plus, elle rend possible le suivi de cette défaillance dans le temps, donnant ainsi une plus grande marge de manoeuvre lors de la planification des arrêts de production.

Objectif & Plan du mémoire

Ce travail a pour objectif de développer une procédure de diagnostic fiable et facile d'utilisation destinée à la surveillance de l'état des machines rotatives. On mettra l'emphase sur la combinaison d'une ou plusieurs méthodes d'analyse vibratoire avec un algorithme de reconnaissance de forme. En plus de développer une procédure de diagnostic à partir de signaux expérimentaux, la procédure de diagnostic développée doit aussi être facile à implémenter en milieu industriel avec un niveau de fiabilité semblable ou supérieur aux programmes de maintenance actuellement utilisés en industrie. Les travaux de ce mémoire seront concentrés sur l'étude des défaillances des roulements à billes. Ils constituent à ce jour, l'une des composantes les plus critiques dans les machines rotatives.

Au chapitre 1, une revue de littérature sur les méthodes de maintenance prédictive basée sur l'analyse vibratoire est présentée. On y recense toutes les méthodes d'analyse jusqu'à lors développées et qui semblent prometteuses. L'emphase est mis sur les méthodes d'analyse des signatures vibratoires ainsi que sur l'utilisation des méthodes de reconnaissance de forme comme outils d'aide au diagnostic.

En se basant sur l'efficacité des méthodes présentées au chapitre 1, on propose au chapitre 2 une procédure de diagnostic pour la détection et le diagnostic des défaillances. Cette procédure combine plusieurs méthodes de traitement de signal (transformée de

Fourier, analyse d'enveloppe, synchronisation temporelle moyennée) pour l'extraction de paramètres, ainsi qu'une méthode d'apprentissage (Support Vector Machine). Les fondements théoriques des méthodes utilisées y seront brièvement présentés.

Les détails des deux bancs d'essai expérimentaux utilisés utilisés pour obtenir les signaux de vibration des roulements défectueux sont présentés au chapitre 3. Les dimensions des roulements testés serviront au calcul des fréquences de défaut rapportées dans les analyses spectrales du chapitre 4. Dans ce dernier chapitre, on présentera les résultats obtenus lorsque les signaux de vibration ont été analysés avec les méthodes d'analyse proposées. On y présente aussi deux procédures d'extraction des paramètres afin de caractériser le signal analysé dans un espace de grande dimension. Suite à cette représentation, des méthodes d'apprentissage statistique seront utilisées pour construire des frontières de classification. L'amélioration de la capacité à généraliser de ces frontières de classification lorsque les conditions expérimentales des signaux d'apprentissage et de test sont différentes constituera l'objectif principal lors de l'analyse des résultats. Cette analyse sera suivie d'une discussion et de recommandations de l'auteur sur la poursuite de travaux de recherche dans ce domaine d'étude.

CHAPITRE 1

REVUE DE LITTÉRATURE

Dans ce chapitre, on présente l'état actuel de la recherche scientifique en détection et en identification des défaillances des machines rotatives. L'emphase est mis sur les méthodes de détection basées sur l'analyse des signatures vibratoires de ces machines. Premièrement, on présente les avantages et les inconvénients associés à l'implémentation d'un programme de maintenance prédictive en industrie. Ensuite, on passe en revue les méthodes d'analyse vibratoire qui sont actuellement utilisées en détection de défaillances. On termine en montrant comment les méthodes de reconnaissance de forme peuvent être utilisées comme outils d'aide à la prise de décision.

1.1 Les activités de maintenance

La défaillance d'une machine peut être définie comme son incapacité à accomplir adéquatement sa fonction. C'est une caractéristique propre à chaque machine, car elle dépend de ses conditions d'opération et de la nature de sa fonction. Les activités de maintenance regroupent toutes les activités effectuées pour permettre à la machine de continuer à effectuer sa fonction malgré l'usure inévitable de ses composantes.

Les activités de maintenance peuvent être classées en trois grandes catégories selon le programme de maintenance auquel elles appartiennent : les activités *correctives*, *préventives* et *prédictives*. Le choix du type de maintenance dépend des conditions d'opération du système étudié.

1.1.1 La maintenance corrective

La maintenance corrective consiste à laisser fonctionner la machine jusqu'à sa défaillance avant d'effectuer les activités de maintenance. Dans ce programme de maintenance, les activités *palliatives* permettent d'effectuer un dépannage provisoire de la machine. Elles sont suivies des activités *curatives* qui remettent la machine à son état initial. Ce type de maintenance est utilisé lorsque l'indisponibilité de la machine n'a pas de conséquences majeures sur la production ou encore pour des raisons financières. Ce type de maintenance est implémenté lorsque les modes de défaillance de la machine sont bien connus et qu'ils ne constituent pas un danger pour la sécurité des utilisateurs.

La figure 1.1 illustre le principe du programme de maintenance corrective en fonction de la capacité estimée de la machine et de son chargement actuel. La défaillance survient lorsque les courbes de chargement et de capacité se rencontrent et les activités de maintenance sont alors effectuées pour remettre la machine dans son état initial.




FIG. 1.1: Principe de la maintenance corrective

1.1.2 La maintenance préventive

C'est probablement le programme de maintenance le plus utilisé dans l'industrie à l'heure actuelle. Elle a pour but de réduire la probabilité de défaillance d'un équipement et présente le principal avantage d'éviter les coûts engendrés par un arrêt imprévu de la production ou par une défaillance catastrophique. La maintenance préventive consiste à effectuer des opérations systématiquement et périodiquement selon un calendrier ou selon une périodicité d'usage (Mean Time Between Failure, MTBF). Ce type de maintenance est adéquat lorsque les MTBF et MTTF (Mean Time To Failure) de chaque composante et des données statistiques sur les taux de défaillance du système sont connus. Cela permet de planifier adéquatement les arrêts de production. La régularité des activités de maintenance permet de maintenir la machine dans son état optimal de fonctionnement en permanence.




FIG. 1.2: Principe de la maintenance préventive

En maintenance préventive, il existe une *marge* entre la capacité et le chargement de la machine au moment où sont effectuées les activités de maintenance, cf. Fig. 1.2. En théorie, il ne devrait jamais se produire une défaillance dans ce type de maintenance. Par contre, l'existence de cette marge présente l'inconvénient de remplacer souvent des pièces (celles qui ont le plus petit MTBF) alors qu'elles sont encore en bon état de fonctionnement.

1.1.3 La maintenance conditionnelle ou prédictive

La maintenance prédictive consiste à surveiller l'état de dégradation du système à l'aide de relevés ou de mesures. Les opérations de maintenance sont effectuées uniquement lorsque l'usure ou le vieillissement d'une ou plusieurs composantes affectent les performances du système. La surveillance de l'état de la machine rend possible

l'identification de la composante problématique, ce qui permet de cibler l'activité de maintenance à effectuer. Ce type de maintenance est envisageable lorsque les conditions suivantes sont réunies :

- La machine surveillée est critique et très coûteuse, et la disponibilité des pièces de rechange est incertaine.
- Les réparations requièrent des techniciens hautement qualifiés car les défaillances ne sont pas toujours facilement détectables
- L'interruption de la production accidentelle ou fréquente est intolérable
- Les coûts engendrés par la mise en place du programme de surveillance sont abor-

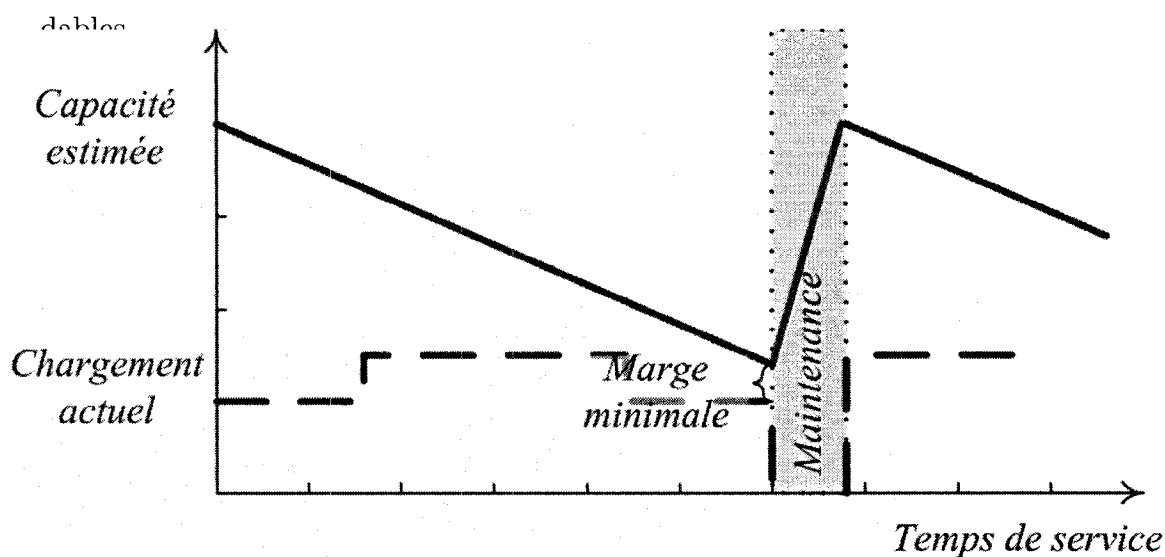


FIG. 1.3: Principe de la maintenance prédictive

La maintenance prédictive se situe à mi-chemin entre les maintenances préventive et corrective. La marge permise entre la capacité de la machine et son chargement est plus petite que dans le cas du programme préventif, mais les deux courbes ne

se rencontrent pas comme c'est le cas dans une maintenance corrective. Une bonne interprétation des relevés de mesures, ainsi que la constitution d'un historique des défaillances de la machine permettent de fiabiliser le diagnostic posé. La fréquence des mesures dépend de la courbe de tendance de la machine surveillée, cf. Fig. 1.4.

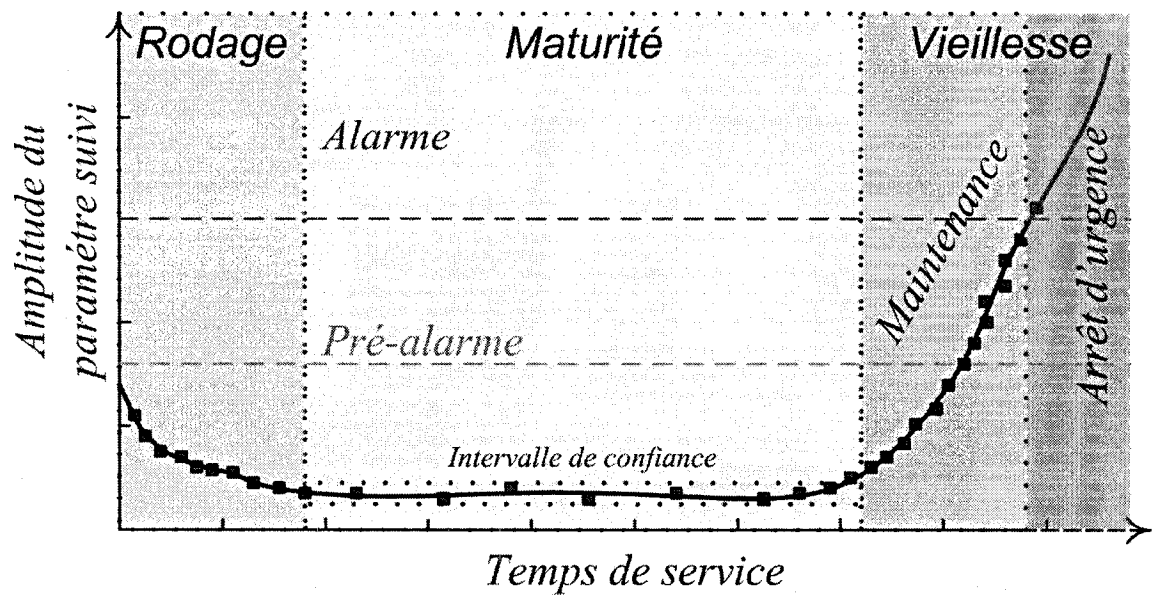


FIG. 1.4: Courbe de tendance typique

En général, il est conseillé d'espacer les mesures lorsque que les modes de défaillance de la machine sont bien connus ou encore lorsque la machine est dans sa période de maturité. La périodicité des mesures est augmentée pendant les périodes de rodage et de vieillesse, car la machine est plus à risque dans ces périodes. Thomas [Thomas, 2002], établit la méthodologie de maintenance conditionnelle comme suit :

- i) *Choix du paramètre à surveiller* : il doit être représentatif du fonctionnement de la machine. Les choix les plus courants sont les vibrations, le niveau de bruit, la

température, l'analyse des débris mécaniques contenus l'huile.

- ii) *Suivi périodique ou en temps réel de l'évolution du paramètre* : il consiste à établir une courbe de tendance où seront identifiés les périodes de rodage, de maturité et de vieillesse de la machine selon l'évolution du paramètre suivi, Fig. 1.4.
- iii) *Établissement des seuils d'alarme* : étant donné l'inévitable variation des paramètres d'opérations entre deux prises de mesures, il est judicieux d'établir des intervalles d'incertitude (écart type) ainsi que des niveaux d'alarme et de pré-alarme. Pour ce faire, on se base sur l'historique de la machine ou sur les normes appropriées.
- iv) *Analyse des données* : lorsqu'une pré-alarme est déclenchée, les données sont analysées dans le but d'en identifier la cause et de commander les pièces de rechange appropriées.
- v) *Programmation de l'arrêt de la production* : une fois la cause de la panne identifiée, les pièces de rechange sont commandées, et l'équipe de maintenance planifie la période d'entretien de manière à minimiser le temps d'arrêt de la production.

Thomas rapporte aussi qu'en milieu industriel, la maintenance prédictive se heurte généralement aux difficultés liées à l'interprétation adéquate des données recueillies.

1.1.4 Choix du programme de maintenance

De la présentation faite des différents types de maintenance, il en ressort qu'il serait erroné de penser qu'un programme de maintenance serait toujours meilleur qu'un autre. Le choix du type de maintenance doit se faire en tenant compte d'un certain nombre de critères comme

- Le type machine et son importance dans la chaîne de production
- Le coût et les délais de remplacement de la machine ou de ses composantes
- L'historique de défaillance de la machine, ses MTBF et MTTF, ses modes de défaillance
- La disponibilité d'un système d'urgence qui prend le relais en cas de panne
- La sécurité environnementale des modes de défaillances
- L'allocation d'un budget pour les opérations associées à une surveillance permanente

Thomas [Thomas, 2002], rapporte que malgré l'augmentation directe des coûts liés à l'achat des équipements de surveillance (capteurs, systèmes d'acquisition et de traitement des données, etc.), l'entretien prédictif permet d'augmenter la rentabilité de 25% par rapport à l'entretien préventif et de 50% par rapport à l'entretien correctif. Malgré cette réduction potentielle des coûts, l'implantation d'un programme de maintenance prédictive ne sera envisageable que si on réussit à garantir un niveau de fiabilité similaire ou plus élevé que celui de la maintenance préventive. Actuellement,

dans tous les systèmes aéronautiques, la redondance des systèmes mécaniques et leur sur-dimensionnement permet de garantir des niveaux de fiabilité très élevés. Que ce soit chez Pratt & Whitney, où les roulements qui supportent l'arbre principal du moteur sont critiques, ou chez Bombardier où la broche de l'écospeed est problématique, une défaillance en cours de fonctionnement ne peut être tolérée.




FIG. 1.5: Étapes de la maintenance prédictive

Dans ces deux cas, des programmes de maintenance préventive sont utilisés. Les roulements et les broches sont régulièrement remplacés indépendamment de leur état réel. De plus, leur méthode d'analyse est basée sur des critères difficilement quantifiables et non répétitifs. Cependant, la fréquence des remplacements rend ce programme de maintenance non rentable à long terme d'où l'intérêt suscité pour l'implémentation d'un programme de surveillance intelligent, qui est l'objet du présent travail. Les étapes d'un programme de maintenance prédictif sont résumées à la figure 1.5. L'identification et le diagnostic de la défaillance constituent l'étape primordiale du programme prédictif et l'estimation de la durée de vie restante rend possible la minimisation de la marge entre la capacité restante de la machine et son chargement. Si la détection et la prédiction sont assez fiables, il serait alors inutile de sur-dimensionner les composants mécaniques ou de dupliquer les systèmes dans les avions.

1.2 L'analyse vibratoire au service de la maintenance prédictive

L'analyse des signatures vibratoires a été l'objet de nombreuses études depuis des décennies. Tandon [Tandon, 1999], Jardine [Jardine, 2005], Forrester [Forrester, 1996] dressent un portrait assez complet des travaux effectués dans la surveillance du comportement dynamique des machines rotatives. L'avantage des méthodes d'analyse vibratoire sur d'autres méthodes comme les émissions acoustiques, l'analyse des débris d'huile, thermographie réside peut-être dans le fait qu'elles permettent de détecter la défaillance et d'en identifier la cause. Dans cette section, on passe en revue les méthodes d'analyse de signatures vibratoires jusqu'à lors développées et utilisées pour la détection des défaillances des machines rotatives.

1.2.1 Les méthodes d'analyse temporelles

Les méthodes d'analyse temporelles des signatures vibratoires sont les premières méthodes d'analyse de vibration qui ont été développées. De Silva [DeSilva, 2005] passe en revue celles qui sont couramment utilisées en surveillance des machines.

1.2.1.1 Allure des signatures temporelles

La majorité des analyseurs de vibrations (oscillographes, oscilloscopes, vibrographes) affichent la réponse des systèmes vibrants sous forme temporelle. Pour les systèmes mécaniques simples, l'analyse de la périodicité de la réponse vibratoire permet de détecter la présence de défauts. En effet, pour des systèmes mécaniques simples, la réponse vibratoire attendue devrait être harmonique, et elle deviendra aléatoire lorsqu'un défaut apparaîtra. De nos jours, ce type d'analyse est très peu utile car les systèmes mécaniques sont de plus en plus complexes, et leur réponse vibratoire est de nature aléatoire même lorsqu'ils sont en bon état de fonctionnement.

1.2.1.2 Niveaux globaux de vibration

Un niveau global est un indice (en général d'ordre statistique) qui est calculé à partir de la signature vibratoire de la machine. Les indices de vibrations permettent de codifier l'information contenue dans le signal temporel afin de simplifier l'interprétation des données lors d'éventuelles comparaisons. en industrie, ces indices sont utilisés pour établir les seuils d'alarme de vibration cf. Fig. 1.7. Les niveaux globaux de vibration sont relativement faciles à calculer, simples d'interprétation et permettent de détecter l'apparition des défauts [Badri, 2007a, Monk, 1972, Uli, 1993]. Les niveaux globaux de vibration tendent à augmenter suivant l'état de dégradation du système. Les pre-

miers travaux qui ont démontré la sensibilité des moments statistiques aux défauts de fonctionnement sont ceux de Stewart [Stewart, 1977] et de Dyer [Dyer, 1978]. Ils ont montré que les moments statistiques d'ordre pair sont ceux qui permettent de détecter la déviation de la normalité.

Les moments de deuxième et quatrième ordre ont été proposés pour détecter les cas de fonctionnement anormal. Il s'agit de la *valeur efficace* ou *valeur rms* et du *kurtosis* :

$$rms = \sqrt{\frac{1}{N} \sum_{n=0}^{N-1} (x(n) - \bar{x})^2} \quad (1.1)$$

$$Ku = \frac{\frac{1}{N} \sum_{n=0}^{N-1} [x(n) - \bar{x}]^4}{rms^4} \quad (1.2)$$

Dans certains cas, la valeur rms du signal varie très peu, alors que le kurtosis pondère les évènements isolés tout en accordant une grande importance aux amplitudes élevées. Pour corriger l'inefficacité de la valeur rms, Swansson [Swansson, 1980] propose le *facteur crête*. C'est le ratio de la valeur crête du signal sur sa valeur rms. Cependant, comme la valeur crête n'est pas un moment statistique, elle est souvent corrompue par le bruit, mais cette influence est pondérée par la valeur rms.

$$CF = \frac{peak}{rms} \quad (1.3)$$

$$peak = \max_{k=1 \dots N} |a_k| \quad (1.4)$$

Le facteur de forme (Shape Factor, SF) et le facteur d'impulsion (Impulse Factor, IF)

ont aussi été définis suivant une logique semblable à celle du facteur crête : le premier pondère la valeur crête par rapport à la moyenne du signal en valeur absolue, alors que le second pondère la valeur rms par rapport à la même moyenne.

$$IF = \frac{\text{peak}}{\frac{1}{N} \sum_{n=1}^N |x(n)|} \quad (1.5)$$

$$SF = \frac{\text{rms}}{\frac{1}{N} \sum_{n=1}^N |x(n)|} \quad (1.6)$$

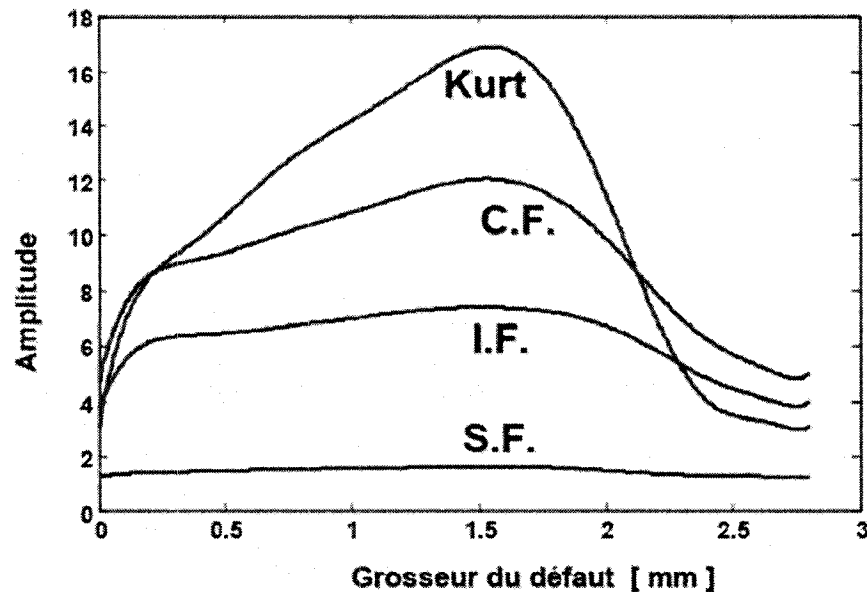
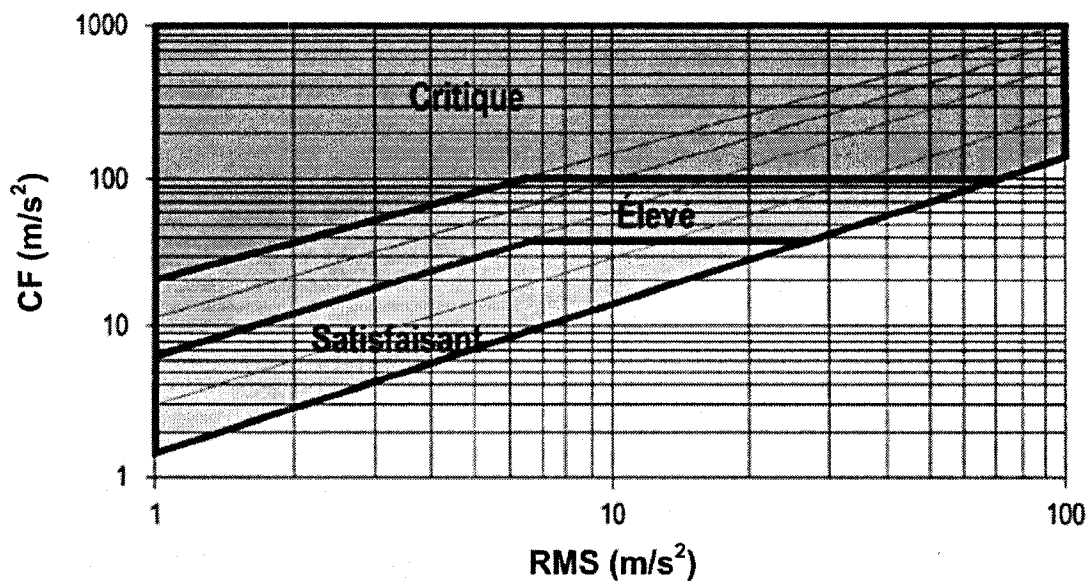


FIG. 1.6: Niveaux globaux de vibration vs. taille du défaut d'un roulement, [Badri, 2007a]

Badri [Badri, 2007a] montre que dans le cas d'un défaut sur la bague externe d'un roulement le kurtosis est l'indice de vibration le plus sensible à la présence d'un défaut, suivi du facteur crête et du facteur d'impact. Badri montre aussi que si tous ces indices de vibrations croissent avec la taille du défaut, ils décroissent lorsque le défaut dépasse une taille critique qui est de 1.5 mm dans son cas, cf. Fig. 1.6. Des observa-

tions similaires ont été rapportées à maintes reprises dans la littérature [B&K, 1980, Downham, 1980, Ray, 1980]. Cela démontre l'importance du suivi l'évolution des indices de vibration. Swansson [Swansson, 1984] montre que les niveaux globaux de vibration de base comme le kurtosis, la valeur efficace (rms) et le facteur crête, ne seront efficaces à la détection des défaillances qu'à condition que le ratio signal/bruit soit élevé. Aussi, les niveaux globaux de vibration permettent de détecter un fonctionnement anormal de la machine mais ils ne permettent pas d'en identifier la cause.

En industrie, des chartes de sévérité, cf. Fig. 1.7, ont été établies pour quantifier la sévérité des défaillances des machines selon leurs conditions d'opération et leurs fonctions [Robichaud, 2007]. Ces chartes sont souvent établies en fonction de la valeur efficace de la vibration et/ou de la valeur crête.



(a) CF vs. rms

CDA/MS/NVHS107

Vitesse efficace (mm/s)	Machines neuves		Machines usagées (mesurage à puissance et vitesse maximales)	
	À longue durée de vie (>1K h)	À courte durée de vie (<1K h)	Niveau de pré-alarme	Niveau d'alarme d'urgence
Compresseurs				
Piston libre	10	32	32	56
Air HP, air cond.	4.5	10	10	18
Air BP	1.4	5.6	10	18
Réfrigération	0.56	5.6	10	18
Pompes				
plus de 5 hp.	1.4	5.6	10	18
moins de 5 hp.	0.79	3.2	5.6	10
Ventilateurs				
plus de 1800 RPM	1.0	3.2	5.6	10
moins de 1800 RPM	0.56	3.2	5.6	10
Moteurs électriques				
>5 hp. ou < 1200 RPM	0.25	1.8	3.2	5.6
< 5 hp ou >1200 RPM	0.14	1.8	3.2	5.6

(b) Norme canadienne CDA/MS/NVHS107

FIG. 1.7: Exemples de chartes de sévérité de vibration basées sur le peak et le rms, [Thomas, 2002]

En surveillance de boîtes d'engrenages, plusieurs indices de vibration définis à partir des moments statiques d'ordre 4, 6 et 8 sont utilisés. Stewart [Stewart, 1977] a développé plusieurs paramètres adimensionnels calculés à partir du signal synchronisé temporellement. Il les utilise pour définir une carte vibratoire du signal qu'il appelle « figure de mérite » (*Figure of Merit* en anglais). Forrester [Forrester, 1996, Lebold, 2000] expliquent en détail comment calculer certains paramètres utilisés en surveillance d'engrenages Fig. 1.8. Les plus utilisés sont :

- i) *FM0* proposé par Stewart [Stewart, 1977] : il permet de détecter des changements majeurs dans l'engrènement des dents. La valeur crête du signal synchronisé temporellement est divisée par la somme des amplitudes des harmoniques de la fréquence d'engrènement

$$FM0 = \frac{peak}{\sum_{i=1}^n A(f_i)} \quad (1.7)$$

- ii) *FM4* proposé par Stewart [Stewart, 1977] : il correspond au kurtosis du *différence signal*¹ qui est obtenu en filtrant les fréquences d'engrènement du signal synchronisé temporellement

$$FM4 = \frac{N \sum_{i=1}^N (d_i - \bar{d})^4}{\left[\sum_{i=1}^N (d_i - \bar{d})^2 \right]^2} \quad (1.8)$$

Le *FM4* est le paramètre de la figure de mérite de Stewart qui est le plus sensible aux défauts locaux sur les dents d'engrenage ;

¹Voir Fig. 1.8 pour sa définition

- iii) *NA4* proposé par Zakrajsek [Zakrajsek, 1993] : il correspond en fait à une sorte de kurtosis modifié du *residual signal*². La modification se situe au niveau du calcul de dénominateur : dans le kurtosis normal, le dénominateur correspond à la valeur rms du signal, alors que dans le *NA4*, on calcule la moyenne de la variance du signal résiduel dans le temps

$$NA4 = \frac{N \sum_{i=1}^N (r_i - \bar{r})^4}{\left\{ \frac{1}{m} \sum_{j=1}^m \left[\sum_{i=1}^N (r_{ij} - \bar{r}_j)^2 \right] \right\}^2} \quad (1.9)$$

Une version plus robuste du *NA4*, le *NA4** a été proposée par la suite par Decker [Decker, 1994] pour mieux suivre l'évolution des défauts. La modification apportée se situe au niveau du dénominateur qui est remplacé par la variance du signal résiduel d'une boîte d'engrenage en bonne condition ;

- iv) *NB4* proposé par Zakrajsek [Zakrajsek, 1994] : il correspond au kurtosis modifié de l'enveloppe du signal synchronisé temporellement et filtré autour de la fréquence d'engrènement. L'enveloppe est calculée à partir de la transformée de Hilbert

$$NB4 = \frac{N \sum_{i=1}^N (E_i - \bar{E})^4}{\left\{ \frac{1}{m} \sum_{j=1}^m \left[\sum_{i=1}^N (E_{ij} - \bar{E}_j)^2 \right] \right\}^2} \quad (1.10)$$

Comme ce fut le cas avec le *NA4*, une version plus robuste de ce paramètre, le *NB4** a été proposée par Decker [Decker, 1994] pour quantifier la sévérité du défaut par rapport à une référence ;

²Voir Fig. 1.8 pour sa définition

v) $M6A$ et $M8A$ qui sont les respectivement les 6ième et 8ième moments statistiques du *difference signal*³. Ils ont été proposés par Martin [Martin, 1989]

$$M6A = \frac{N^2 \sum_{i=1}^N (d_i - \bar{d})^6}{\left[\sum_{i=1}^N (d_i - \bar{d})^2 \right]^3} \quad (1.11)$$

$$M8A = \frac{N^3 \sum_{i=1}^N (d_i - \bar{d})^8}{\left[\sum_{i=1}^N (d_i - \bar{d})^2 \right]^4} \quad (1.12)$$

Tout comme le $FM4$, ces moments statistiques d'ordre supérieur sont plus sensibles à la présence d'impulsion dans le *difference signal*.

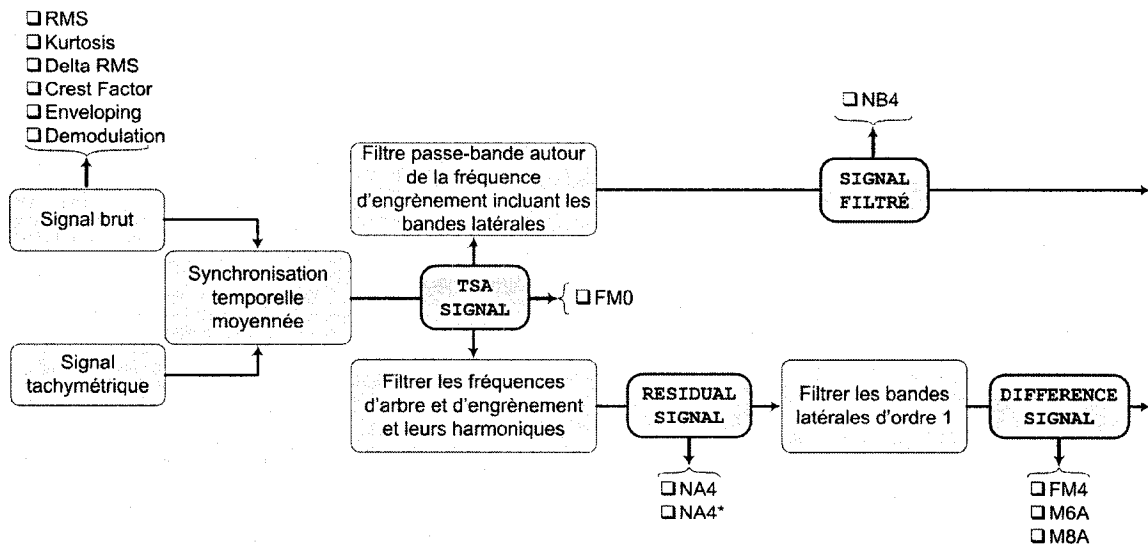


FIG. 1.8: Extraction des paramètres en surveillance d'engrenages [Lebold, 2000]

McClintic [McClintic, 2000] compare les performances des paramètres $NA4$, $NA4^*$, $M6A$, $M8A$ et $FM4$ pour le suivi de l'état de dégradation des engrenages dans des tests d'endurance. Ces résultats montrent que les paramètres extraits du *difference*

³Voir Fig. 1.8 pour sa définition

signal seront les premiers à indiquer un état de fonctionnement anormal. Le FM4 est le plus sensible au début de la dégradation.

1.2.2 Les méthodes d'analyse fréquentielles

Les méthodes d'analyse fréquentielles sont probablement les méthodes d'analyse les plus utilisées à l'heure actuelle en industrie. La majorité des analyseurs de vibration traitent le signal mesuré dans le domaine fréquentiel car cette représentation occupe moins d'espace mémoire et décrit mieux les phénomènes présents dans la machine.

1.2.2.1 Analyse fréquentielle en bande fine

Comme la plupart des machines rotatives opèrent à des vitesses de rotation constantes, les défauts se manifesteront à des fréquences caractéristiques bien définies. Ainsi un changement d'amplitude de vibration dans une bande de fréquence permet non seulement de détecter le changement d'état, mais aussi d'en diagnostiquer la cause.

En industrie, on utilise des gabarits pour fixer les seuils d'alarme dans chaque bande de fréquence et des investigations sont faites lorsque ces seuils sont dépassés. Au début, les bandes d'octave et d'1/3 d'octave étaient utilisées pour le suivi des vibrations [Glew, 1974, Carmody, 1972, Randall, 1981]. Le développement de la puissance




FIG. 1.9: Gabarit d'alarme rotor monté sur roulement

des ordinateurs a permis le raffinement des bandes [Alfredson, 1982, Odea, 1975, Osuagwu, 1982, Eshleman, 1980, B&K, 1980]. Selon la machine étudiée, certaines bandes de fréquence seront plus critiques que d'autres, d'où l'intérêt de pondérer les niveaux de gravité de chaque bande. Thomas [Thomas, 2002] propose la méthodologie suivante pour établir les seuils d'alarme :

- i) Déterminer la fréquence maximale d'analyse de la gamme : en vertu du Théorème de Nyquist, elle est bornée supérieurement par la moitié de la fréquence d'échantillonnage

choisie lors des mesures

- ii) Déterminer les niveaux d'alarme basé sur la vibration globale (Niveau d'Alarme Globaux, NAG) en utilisant une charte de sévérité.
- iii) Découper la gamme de fréquence en bandes : en général, la gamme de fréquence est divisée en 6 bandes. Il est préférable d'avoir des bandes d'inégale largeur, définies en fonction des défauts potentiels. Une bonne connaissance de la machine est nécessaire pour définir adéquatement les bandes de fréquences.
- iv) Établir les niveaux d'alarme (AL_i) pour chacune des bandes de fréquence.

$$AL_i = \alpha_i NAG \quad (1.13)$$

Le coefficient de pondération α_i de chaque bande est ajusté en fonction de la probabilité d'apparition du défaut.

Cette méthodologie simplifie la gestion des données car à chaque mesure, il n'y a que 6 alarmes à vérifier.

1.2.2.2 Indices fréquentiels de vibration

Les études de vibrations réalisées dans le domaine fréquentiel ont montré que le spectre de vibration est plus sensible aux changements d'état des machines rotatives [DeSilva, 2005]. Des indices basés sur le spectre du signal ont donc été proposés afin

de codifier l'information contenue dans les spectres. Quelques indices fréquentiels ont donc été proposés :

- La moyenne arithmétique, [Grove, 1979] : elle se calcule comme suit

$$AM = 20 \log \left\{ \left(\frac{1}{N} \sum_{i=1}^N A_i \right) / 10^{-5} \right\} \quad (1.14)$$

où A_i représente l'amplitude de la $i^{\text{ème}}$ composante fréquentielle et N le nombre totale de fréquences

- La moyenne géométrique, [Grove, 1979] : définie comme suit

$$GM = \frac{1}{N} \left\{ \sum_{i=1}^N 20 \log \left(\frac{A_i \cdot 10^5}{\sqrt{2}} \right) \right\} \quad (1.15)$$

- « Matched rms filter », [Mathew, 1984] : il pondère le second moment statistique du spectre par rapport aux fréquences d'un spectre de référence

$$Mrms = 10 \log \left\{ \sum_{i=1}^N \frac{1}{N} \left(\frac{A_i}{A_{i(ref)}} / 10^{-5} \right) \right\} \quad (1.16)$$

- Le rms de la différence de spectre, [Alfredson, 1982] : second moment statistique de la différences entre les composantes fréquentielles L_{ci} du spectre analysé et celles du spectre de référence L_{oi}

$$Drms = \sqrt{\frac{1}{N} \sum_{i=1}^N (L_{ci} - L_{oi})^2} \quad (1.17)$$

où L est l'amplitude en décibel.

- La somme des carrés des différences de fréquences, [Mathew, 1984]

$$\left\{ \frac{1}{N} \sum_{i=1}^N [(L_{ci} + L_{oi}) \times |L_{ci} - L_{oi}|]^{1/2} \right\} \quad (1.18)$$

De Silva rapporte que ces indices fréquentiels semblaient plus sensibles aux défauts de roulements que les indices temporels, [DeSilva, 2005].

1.2.2.3 High Frequency Resonance Technique - Démodulation - Analyse d'enveloppe

En général, la présence des défauts dans les machines rotatives aura pour effet d'exciter les résonances de la machine. Cela se manifestera par la présence de bandes latérales aux fréquences de résonance dans le spectre. En d'autres termes, les fréquences de résonance seront des fréquences porteuses, et les fréquences de modulation seront les fréquences caractéristiques des défauts. La méthode du « *High frequency resonance technique* », ou encore HFRT [McFadden, 1983, McFadden, 1984], consiste à démoduler le signal, i.e. à séparer la fréquence porteuse des fréquences caractéristiques du défaut. En général, cela est fait par analyse du signal enveloppe, qui contient toute l'information du signal en basse fréquence. Les étapes de la méthode HFRT sont illustrées à la figure 1.10.




FIG. 1.10: Étapes de la méthode HFRT

Dans cette méthode d'analyse, il y a plusieurs paramètres à choisir :

- La fréquence centrale du filtre passe-bande ainsi que sa largeur : il est dit de choisir une fréquence de résonance, mais rien n'est dit sur le critère du choix lorsqu'il y en a plusieurs qui sont modulées ;
- La méthode de démodulation : la plus simple est la transformée de Hilbert. Une méthode alternative (filtrage passe-haut, ensuite rectification, et enfin filtrage passe-bas) est proposée par Courrech [Courrech, 1985] ;
- La fréquence du filtre passe-bas.

Les résultats de cette méthode dépendent donc du choix des paramètres ci-haut mentionnés. Aussi, les filtrages successifs augmentent le niveau de bruit dans le signal. Ho [Ho, 2000] et Randall [Randall, 2000] rapportent que le fait de rectifier le signal (racine carrée de l'amplitude du signal analytique) pour le calcul du signal enveloppe entraîne l'apparition d'harmoniques *fantômes*. La rectification crée l'apparition de composantes fréquentielles qui sont supérieures à la fréquence de Nyquist. Ils proposent d'utiliser le carré signal enveloppe en lieu et place du signal enveloppe lui même. Dans certains cas, cela s'avère plus avantageux pour l'identification des fréquences de défauts dans le spectre du signal enveloppe [Antoni, 2006b,

Randall, 2000, Randall, 2001, Sawalhi, 2007].

1.2.2.4 La synchronisation temporelle moyennée

Il existe une certaine confusion dans la terminologie utilisée dans la littérature pour se référer à cette méthode d'analyse. Braun [Braun, 1975] et McFadden [McFadden, 1987] emploient les termes *time domain averaging*, Stewart [Stewart, 1977] parle de *synchronous averaging* alors que Forrester [Forrester, 1996] emploie les termes *synchronous signal averaging*. La synchronisation temporelle moyennée (*Time Synchronous Averaging*, TSA) consiste à moyenner le signal de vibration avec un signal de référence provenant de la machine. Cette méthode permet de réduire le niveau de bruit présent dans le signal en éliminant les composantes non synchrones à la fréquence de référence. En général, la fréquence de référence choisie est la fréquence de rotation de l'arbre. Le signal de référence provient d'un tachymètre relié à l'arbre d'intérêt.

Stander [Stander, 2005] décrit la procédure de synchronisation comme suit : le tachymètre envoie un signal pulsé à chaque tour d'arbre de sorte que le signal enregistré avant le prochain pulse représente la vibration de l'arbre pendant le cycle de rotation considéré ; ces signaux sont donc sommés et moyennés dans le temps pour plusieurs cycles de rotation d'arbre pour trouver le signal synchrone. Les composantes synchrones du signal auront toujours le même signe (positif ou négatif) à chaque tour

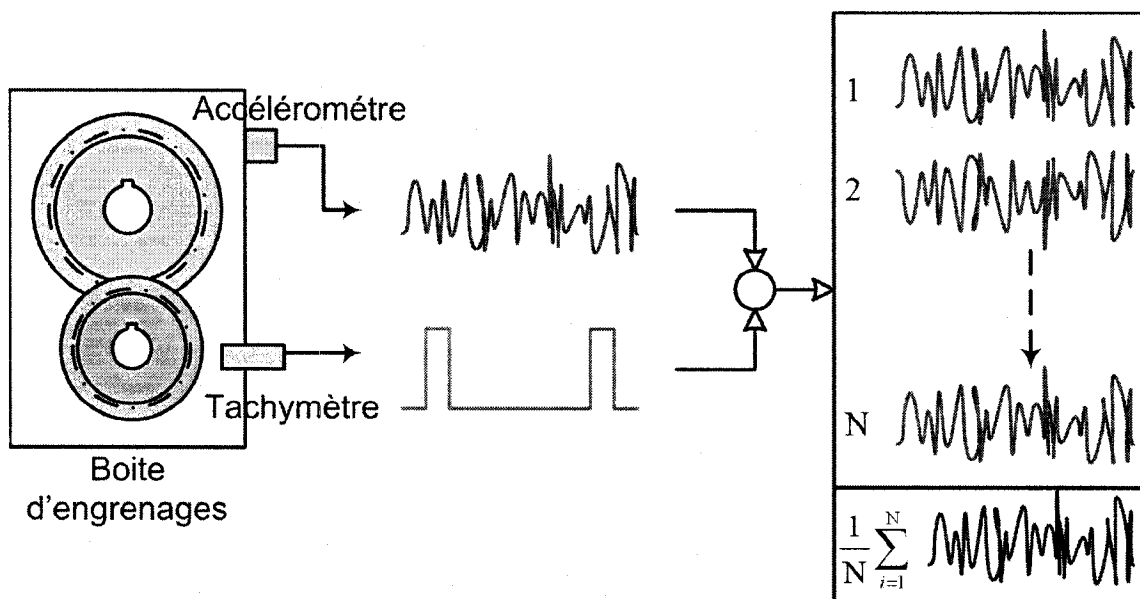


FIG. 1.11: Illustration de la synchronisation temporelle moyennée

l'arbre. Ainsi, l'addition des bandes de signal fait ressortir les composantes synchrones et atténue les composantes non synchrones. Cela équivaut à une convolution du signal avec un train d'impulsions qui possède un nombre fini d'impulsions. Le temps entre deux impulsions est égale à la période de rotation de l'arbre. Le problème avec cette procédure vient du déphasage et les différence d'amplitude introduites par la troncature du signal.

Dans le domaine fréquentiel, cela équivaut à multiplier le spectre par un filtre peigne fin. Seules les harmoniques de la fréquence du train d'impulsions seront retenues. Braun [Braun, 1975] rapporte que la multiplication fréquentielle est moins sujette à des erreurs que le moyennage temporel. McFadden [McFadden, 1987] a révisé le modèle proposé par Braun [Braun, 1975] en utilisant un nombre fini d'échantillons

de signaux pour obtenir un signal périodique grâce à l'application d'un fenêtrage rectangulaire au signal temporel et un échantillonnage fréquentiel.

L'acquisition des signaux peut aussi être faite en fonction du signal provenant du tachymètre : on parle de *synchronous sampling* [Forrester, 1996]. Cependant, cela complexifie l'acquisition des données : il faut convertir le signal du tachymètre en un signal d'horloge (*clock pulse*) qui va commander le système d'acquisition des données. Un filtre anti-repliement externe est requis lors de l'échantillonnage car même si tous les systèmes d'acquisition modernes possèdent des filtres anti-repliement, lorsqu'ils sont contrôlés par une horloge externe, leur efficacité est diminuée.

1.2.3 Les méthodes d'analyse temps-fréquence

L'utilisation de la transformée de Fourier suppose que les signaux de vibration des machines rotatives sont stationnaires, i.e. que les premiers et seconds moments statistiques ne varient pas dans le temps. Aucune indication sur une éventuelle variation des fréquences des défauts dans le temps n'est fournie par cette transformée. Les représentations temps-fréquence ont donc été introduites pour permettre de localiser les fréquences de défauts dans le signal temporel. Les méthodes d'analyse temps-fréquence les plus utilisées en diagnostic des machines rotatives sont résumées au tableau 1.1.

Noms	Expressions et Caractéristiques
Représentation linéaire	<p><i>Short Time Fourier Transform</i> :</p> $X(t, \omega) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} x(\tau) h^*(\tau - t) e^{-j\omega\tau} d\tau$ <p>Décomposition atomique [Auger, 1995] du signal par fenêtrage temporel. On ne peut obtenir simultanément une bonne résolution temporelle et fréquentielle : $B \times T = 1$. Un compromis doit être fait.</p>
Représentation temps-échelle	<p><i>Ondelettes</i> : $T_x(t, a; \Psi) = \int_{-\infty}^{+\infty} x(s) \Psi_{t,a}^*(s) ds$ avec</p> $\Psi(t, a) = a ^{1/2} \Psi\left(\frac{s-t}{a}\right)$ <p>Le facteur d'échelle a contrôle la durée et la bande passante de l'ondelette. Les résolutions temporelles et fréquentielles sont liées par $B/T = cste$</p>
Distributions d'énergie de Cohen, [Cohen, 1989]	<p>Il en existe plusieurs, la différence réside dans le choix du noyau $K(\xi, \tau)$. Expression générale :</p> $C_x(t, f; g) = \int \int \int e^{j2\pi\xi(s-t)} K(\xi, \tau) x(s + \tau/2) x^*(s - \tau/2) e^{-j2\pi f\tau} d\xi ds d\tau$ <hr/> <p><i>Wigner-Ville</i> : $K(\xi, \tau) = 1$. Représentation bi-linéaire quadratique, présence de terme d'interférences.</p> <hr/> <p><i>Pseudo Wigner-Ville</i> : $K(\xi, \tau) = H(\xi)$, lissage fréquentiel pour atténuer les termes d'interférence selon l'axe fréquentiel.</p> <hr/> <p><i>Pseudo Wigner-Ville lissée</i> : $K(\xi, \tau) = g(\tau) \cdot H(\xi)$, lissage temporel et fréquentiel, Atténuation en temps et en fréquence. Les résolutions temporelles et fréquentielles sont indépendantes.</p>

TAB. 1.1: Quelques représentations temps-fréquences

En raison de la nature bilinéaire des distributions d'énergie de Cohen, le signal doit être échantillonné à une période égale à $\frac{1}{2T_e}$ et non pas $\frac{1}{T_e}$ comme avec la transformée de Fourier. cela est parfois inadéquat en pratique à cause de la taille des signaux et une alternative consiste à utiliser le signal analytique $\bar{x}(t)$ en lieu et place de $x(t)$. Comme la bande passante du signal analytique est égale à la moitié de celle du signal réel, l'effet du repliement fréquentiel et des termes croisés ne seront pas présents dans la première moitié du spectre. Ce faisant, on réduit de moitié le nombre de composantes

dans le plan temps-fréquence, donc la mémoire requise pour stocker la distribution.

Boashash [Boashash, 1992] et Safizadeh [Safizadeh, 1999b] passent en revue les travaux effectués dans les méthodes temps-fréquence et présente leur application dans différents domaines. Safizadeh [Safizadeh, 1999a] montre l'efficacité du STFT pour l'identification des défauts de roulements. Peng [Peng, 2004] rapporte les travaux effectués en utilisant les ondelettes pour les diagnostic des défaillances des machines rotatives. Pan [Pan, 1996a, Pan, 1996b] compare le STFT, les ondelettes et la distribution de WV pour l'analyse des signaux vibratoires des boites d'engrenages.

Forrester [Forrester, 1989] a apporté une contribution significative à l'utilisation de la distribution de Wigner-Ville pour l'analyse des vibrations des transmissions d'engrenages dans les hélicoptères. Il a montré qu'il était possible de distinguer un défaut d'écaillage d'un bris de dents, ainsi que de quantifier leur sévérité. Polyshchuk [Polyshchuk, 2002] extrait des distributions de Wigner-Ville, le paramètre NP4 pour quantifier la sévérité d'un bris de dents d'engrenages. Yen [Yen, 2000] utilise les coefficients de la transformée en ondelette pour classer différents signaux simulés de vibrations.

L'utilisation des distributions temps-fréquences pour la détection et le diagnostic des défauts des machines rotatives en industrie se heurte aux problèmes de leur stockage en mémoire et de leur interprétation. Même auprès des chercheurs, elles sont encore

considérées comme des méthodes avancées de traitement de signal dans la mesure où leur interprétation n'est pas aussi facile que celle d'une spectre. L'utilisation des quelques logiciels temps-fréquence auquel on a eu accès au moment de rédiger ce mémoire [Auger, 1995, Safizadeh, 1999a], semblent limiter par la mémoire allouée par les plate-formes informatiques standard pour les calculs des distributions. Pour des signaux de 4096 points et moins, ces logiciels calculent aisément les distributions temps-fréquence, mais pour des signaux plus longs, des problèmes d'allocation de mémoire se produisent.

1.2.4 Les méthodes d'analyse cyclostationnaires

Les processus *cyclostationnaires* sont des processus non-stationnaires dont les premiers moments statistiques, i.e. la moyenne et la fonction d'autocorrelation (variance) sont périodiques i.e.

$$E \{ \mathbf{x}(t) \} = m_x(t) = m_x(t + T, \tau) \quad (1.19)$$

$$E \{ \mathbf{x}(t) \cdot \mathbf{x}(t + \tau) \} = R_x(t, \tau) = R_x(t + T, \tau) \quad (1.20)$$

Au départ, la théorie de la cyclostationnarité a été introduite pour l'analyse des signaux AM et FM qui sont cyclostationnaires. Récemment, Randall [Randall, 2001] et Antoni [Antoni, 2004a] ont démontré que les signaux des machines rotatives sont

cyclostationnaires avec cependant certaines particularités. De nouvelles méthodes d'analyse des signatures vibratoires qui tiennent compte de cette propriété ont été développées. Elles consistent à ajouter une variable discrète α qui est reliée à la rotation angulaire de la machine lors la transformation de Fourier.

1.2.4.1 La densité spectrale cyclique

La densité spectrale cyclique est calculée à partir de la transformée de Fourier de la fonction d'auto-corrélation d'un processus cyclostationnaire.

$$S_x(\alpha, f) = \lim_{t \rightarrow \infty} E\{X_T(f - \alpha/2)X^*(f + \alpha/2)\} \quad (1.21)$$

En d'autres termes, cela consiste à calculer la densité spectrale du signal pour chaque valeur de α , ce qui peut être lourd en pratique. On pourrait aussi calculer la fonction d'auto-corrélation cyclique $R_x^\alpha(\tau)$, trouver les valeurs de α où elle n'est pas nulle et ne calculer que la densité spectrale pour ces valeurs de α . Récemment, Antoni [Antoni, 2004a], a développé un algorithme de calcul où il faut spécifier un intervalle de valeur pour α où sera calculer la densité spectrale cyclique. La densité spectrale est continue en f et discrète en terme des fréquences cyclique $\alpha = \frac{k}{T}$ avec $k \in \mathbf{Z}$. $S_x^\alpha(f)$ est la densité spectrale de $x(t)$ à la fréquence cyclique α . Lorsque $\alpha = 0$, on

retrouve la densité spectrale obtenue par la transformée de Fourier

$$S_x(0, f) = S_x(f) \quad (1.22)$$

Donc si on a $S_x(0, f) \neq 0 \forall \alpha$, le signal est stationnaire. Par contre si il existe d'autres valeurs de α pour lesquelles $S_x(\alpha, f) \neq 0$ alors le signal est cyclostationnaire. Cette analyse permet de mettre en évidence les périodicités cachées (en α) du signal qui indiquent la présence d'un fonctionnement anormal de la machine. Cette méthode de traitement du signal conserve l'information de la phase du signal et renseigne sur les liens statistiques entre les composantes fréquentielles.

Depuis quelques temps, on observe un intérêt grandissant de la recherche pour l'utilisation des méthodes cyclostationnaires en diagnostic des machines. Randall [Randall, 2000] montrent que si les signaux des roulements défectueux sont cyclostationnaires, le fait que les fréquences cycliques soient confondues aux fréquences normales rend l'identification des défauts difficile. Antoni [Antoni, 2005b] utilisent les propriétés cyclostationnaires pour la déconvolution aveugle des signaux obtenus des analyses modales de type MIMO. Antoni [Antoni, 2007b] montre que le spectre de l'enveloppe au carré du signal et la cohérence cyclique spectrale donnent des résultats similaires dans le diagnostic des machines. Li et Qu [Li, 2003] proposent une méthode de démodulation basée sur la fonction d'auto-corrélation cyclique des signaux. Ils utilisent les modèles quasi-périodiques pour démontrer les propriétés cyclostationnaires

de signatures vibratoires des roulements défectueux. Ils comparent aussi leur approche avec celle obtenue des décompositions en ondelettes. Cependant, Antoni et Randanll [Antoni, 2005b] soutiennent qu'il est erroné de justifier les propriétés des ces signaux à partir des modèles quasi-périodiques. Ils les justifient par une approximation d'une cyclostationnarité *pure* de second ordre de ces signaux.

McCormick [McCormick, 1987] compare les performances des méthodes cyclostationnaires avec celles de la synchronisation temporelle et de la densité spectrale. Il montre que les défauts de bague interne des roulements sont très bien mis en évidence avec les méthodes cyclostationnaires alors que la synchronisation temporelle extrait la composante impulsive qui domine dans le signal. Cependant il souligne que les résultats de l'analyse cyclostationnaire, dépend du système étudié et qu'il n'y a pas une grande différence lorsque comparée avec la synchronisation temporelle.

Antoniadis [Antoni, 2001] introduit le degré de cyclostationnarité (DCS) de la fréquence cyclique α qui permet de quantifier le niveau de périodicité des moments

$$DCS^\alpha = \frac{\sum_f |S_x^\alpha(f)|^2}{\sum_f |S_x^0(f)|^2} \quad (1.23)$$

C'est un indice adimensionnel qui peut être utilisé pour caractériser le signal analysé. Comme la plupart des analyses cyclostationnaires, cet indice est particulièrement utile dans le cas d'un défaut sur la bague interne du roulement.

1.2.4.2 Le kurtosis spectral

Le kurtosis spectral est un descripteur fréquentiel calculé à partir de la densité spectrale cyclique. Dwyer [Dwyer, 1983] fut le premier à employer les termes *kurtosis spectral* pour désigner le quatrième moment statistique des parties réelle et imaginaire de la Short Time Fourier Transform (STFT). Il a montré que ce paramètre permettait de caractériser et de localiser les composantes non-gaussiennes des signaux dans le domaine fréquentiel. Il a démontré que le kurtosis spectral était plus efficace que la densité spectrale classique dans la détection des phénomènes transitoires dans les signaux bruités. Pagnan [Pagnan, 1994] et Ottonello [Ottonello, 1994] ont montré par la suite qu'en définissant le kurtosis spectral à partir du quatrième moment statistique de l'amplitude du signal complexe obtenu de la STFT, permettait de simplifier ses propriétés. Ils ont aussi montré que le kurtosis spectral pouvait être utilisé comme un filtre pour étudier les signaux transitoires aléatoires corrompus par du bruit. Capdevielle [Capdevielle, 1996] a proposé une définition du kurtosis spectral basée sur la théorie des méthodes spectrales d'ordre supérieure. Cependant, cette définition rencontre quelques difficultés pour l'étude des signaux non-stationnaires. Récemment, Antoni [Antoni, 2006a] a proposé une définition plus formelle du kurtosis spectral. Il le définit en utilisant la décomposition de Wold-Cramer des processus *conditionnellement non-stationnaires*, i.e. des processus qui génèrent des distributions non-gaussiennes et dont les moments statistiques sont périodiques.

Plusieurs travaux [Antoni, 2004a, Antoni, 2005a, Antoni, 2005b, Antoni, 2006a, Antoni, 2006b, Antoni, 2007a, Antoni, 2007b, Randall, 2000, Randall, 2001] ont démontré l'utilité du kurtosis spectral dans l'identification et la localisation fréquentielle des composantes impulsives du signal. Récemment, on a montré qu'en utilisant la fréquence où le kurtosis spectral est maximal pour démoduler le signal, le spectre enveloppe résultant permettait de mettre en évidence les fréquences des défauts de roulement [Komgom, 2008].

1.2.5 Autres méthodes d'analyse des signatures vibratoires

Les méthodes d'analyse des signatures vibratoires que nous avons présentées ci-haut, ne sont pas les seules à avoir été utilisées dans la détection et l'identification des défaillances des machines rotatives. Dans cette section, on passe rapidement en revue d'autres méthodes qui sont souvent utilisées en surveillance des composantes rotatives.

1.2.5.1 Adaptive Noise Cancellation

L'Adaptive Noise Cancellation (ANC), consiste à retirer le bruit ou tout autre interférences contenus dans les signaux mesurés. On suppose que le signal mesuré contient le signal désiré plus du bruit provenant du chemin de transmission du signal ou de tout autre phénomène externe. L'ANC utilise une signal de référence sensé

contenir uniquement le bruit contenu dans le signal mesuré. Ce signal de référence est filtré et soustrait du signal mesuré en utilisant un algorithme de filtrage adaptatif. L'algorithme de filtrage adaptatif est composé d'un filtre dont les coefficients sont calculés par un algorithme d'optimisation. En d'autres termes, cela correspond à une méthode d'apprentissage, les coefficients du filtre étant mis à jour en fonction de l'erreur commise lorsque la sortie du filtre diffère du bruit de référence. À l'origine cette méthode fut utilisée en analyse des signaux de parole. Les livres de Widrow [Widrow, 1975, Widrow, 1985] et Haykin [Haykin, 1991] fournissent les fondements théoriques de cette méthode d'analyse.

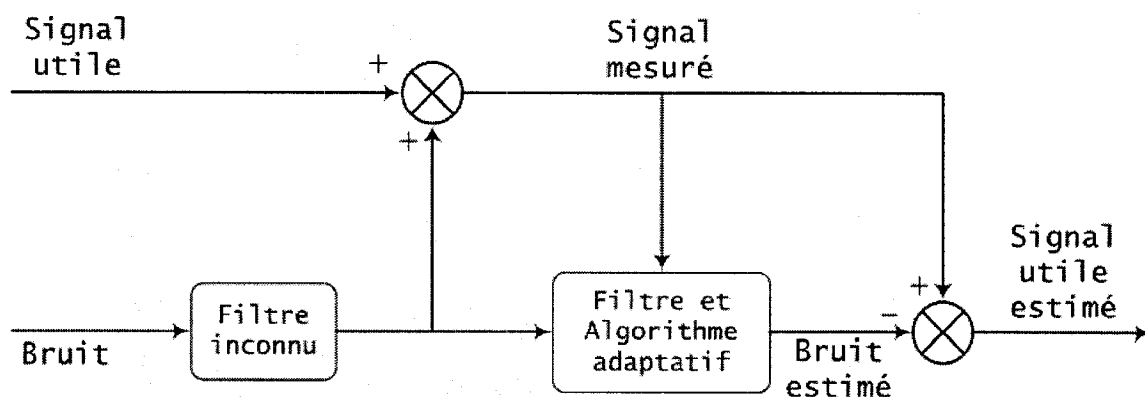


FIG. 1.12: Principe de l'Adaptive Noise Cancellation

Contrairement à la synchronisation temporelle moyennée qui est une méthode *déterministes* [Forrester, 1996], l'ANC permet de réduire le ratio bruit/signal utile des signatures vibratoires où les composantes fréquentielles d'intérêt ne sont pas des harmoniques de la fréquence de rotation de l'arbre. Un exemple typique est celui des défauts de roulements, qui se manifestent à des fréquences non synchrones de la vitesse de rotation

de l'arbre.

À l'origine, l'ANC était utilisé en suppression de bruit des signaux de parole. Chaturvedi & Thomas [Chaturvedi, 1981, Chaturvedi, 1982] furent parmi les premiers à l'appliquer en surveillance des roulements. Deux capteurs de vibration sont utilisés : le premier est proche du roulement étudié et le second mesure la référence de bruit provenant du système. L'ANC suppose que le bruit contenu dans les deux signaux provient d'une même source. Cela signifie que la différence entre les deux signaux sera l'effet du chemin de transmission du signal. Un filtre adaptatif est utilisé pour estimer le bruit du signal de référence qui se trouve dans le signal du roulement étudié. Une fois le processus d'optimisation terminé, on soustrait le bruit estimé du signal mesuré avec le premier capteur pour obtenir le signal utile mesuré avec le premier capteur.

L'inconvénient avec cette méthode vient du fait que l'on ne dispose pas toujours du signal de référence parfait. Il faut donc supposer que le bruit de référence est lui-même filtré suivant un processus inconnu (voir Fig. 1.12). Randall & Li [Randall, 1995] propose à cette effet, une version améliorée de l'ANC, la Self-Adaptive Noise Cancellation (SANC). Dans cette méthode, le signal de référence est remplacé par le signal mesuré auquel on a ajouté un délai, donc un seul capteur est nécessaire pour cette méthode. Le délai correspond à la période de temps pour que les signaux mesurés précédemment avec l'ANC soient semblables. La SANC peut être faite de deux manières dépendamment de la position du capteur. Si le capteur est proche du défaut,

le signal sera corrélé avec cette source et le bruit non corrélé. Par contre lorsque le capteur est loin du défaut, c'est le bruit qui sera corrélé et le signal ne le sera pas.

Randall [Randall, 2003] va plus loin en proposant une méthode de séparation aléatoire de sources de vibration, *Discrete Random Separation*(DRS), que Antoni explore [Antoni, 2004b, Antoni, 2004c]. Cette méthode combine la SANC et la corrélation spectrale pour séparer la signature des engrenages et des roulements à l'intérieur d'un signal mesuré sur une boîte d'engrenage d'hélicoptères. Il rapporte que la DRS requiert moins de calculs que le SANC. La DRS consiste à calculer la fonction de transfert linéaire entre le signal de référence et le signal qui est filtré par le chemin de transmission du signal. La fonction de transfert a une amplitude unitaire pour les fréquences discrètes du signal d'engrenages et se comporte comme un filtre peigne fin. Cependant, à la différence du filtre peigne fin, le filtre obtenu va filtrer toutes les composantes discrètes du signal, même celle qui ne sont pas des harmoniques d'une fréquence de référence donnée. La partie déterministe du signal est ensuite soustraite au signal total, et l'enveloppe du signal résultant permet de mettre en évidence le défaut d'engrenage.

1.2.5.2 L'analyse cepstrale

Le cepstre correspond au spectre du logarithme de la densité spectrale obtenue de la transformation de Fourier. En d'autres termes, c'est une analyse fréquentielle d'un

spectre. Ce qui correspond à des harmoniques d'une fréquence périodique dans le spectre sera identifié par une ligne dans le domaine des quéfrenes. L'échelle logarithmique est utilisée afin de maximiser la bande d'analyse. Randall [Randall, 1980] soutient que l'analyse cepstrale n'est pas affectée par le déphasage introduit par le chemin de transmission du signal. Il a montré que les signaux mesurés à différents endroits d'un boîtier d'engrenages défectueux avaient des spectres différents mais des cepstres identiques. Le spectre d'un signal mesuré sur le boîtier peut être exprimé comme le produit du spectre de la source de vibration source par celui du chemin de transmission du signal. L'avantage du cepstre réside dans le fait que dans le domaine logarithmique, cette multiplication devient une addition, ce qui simplifie les manipulations. Les quéfrenes du chemin qui correspondent au chemin de transmission du signal seront situées dans la partie inférieure du cepstre, alors que celles qui identifient la source de vibration seront dans la partie supérieure.

Cependant, Forrester [Forrester, 1996] rapporte que l'analyse cepstrale n'est pas vraiment utile pour les signaux synchrones comme ceux des engrenages. Il soutient que même si ces signaux sont périodiques en angle, cette périodicité est perdue dans le domaine des quéfrenes et les manipulations vont introduire des discontinuités. Par contre, dans le cas des roulements, comme les défauts vont produire des impulsions qui vont exciter les résonances du système, la périodicité de cette excitation sera évidente dans le domaine quéfrentiel, alors que dans le domaine fréquentiel, elle se

manifestera par une série de bandes latérales de faible amplitude souvent difficiles à identifier.

1.2.5.3 Les méthodes spectrales d'ordre supérieur

Les méthodes d'analyse conventionnelles sont en général basées sur la Transformée de Fourier, qui est une transformation linéaire, dans la mesure où elle suppose que les composantes fréquentielles du signal ont des phases indépendantes entre elles. En pratique, la non-linéarité inhérente aux systèmes mécaniques fait qu'il existe une corrélation entre les phases de ces fréquences, d'où l'intérêt accordé aux méthodes spectrales d'ordre supérieur. L'analyse bispectrale est très utilisée dans la littérature pour mettre en évidence le couplage quadratique entre les phases, *quadratic phase coupling*. Le couplage quadratique des phases est un phénomène physique qui se produit lorsque deux ondes interagissent ensemble pour former une nouvelle onde dont la fréquence et la phase sont égales à la somme de celles des deux sources. Le bispectre est calculé dans un plan dont les deux axes sont les fréquences et la bicohérence correspond au bispectre dont les amplitudes ont été normalisées entre 0 et 1. Si un point dans le plan a une bicohérence proche de 1, cela signifie que les deux fréquences qui forment ce point sont corrélées en phase. À l'inverse si ce point a une bicohérence proche de 0, cela signifie qu'il n'existe aucune corrélation de phase entre les deux fréquences. Ce concept a été appliqué en surveillance de boîtes d'engrenages pour

détecter les fréquences qui sont modulées entre elles. Li [Li, 1991, Li, 1996] a utilisé l'analyse bispectrale pour détecter les défauts de roulements dans un banc d'essai expérimental. Ces analyses ont montré qu'avec un défaut sur la bague externe du roulement, le bispectre met en évidence les points dont les fréquences sont de la forme

$$f_i = kBPFO \pm pf_r \quad (1.24)$$

où k et p sont des entiers naturels. Halim [Halim, 2006] a montré que l'analyse bispectrale combinée à la synchronisation temporelle moyennée permettait de déterminer la sévérité des défauts présents dans une boîte d'engrenages. La synchronisation temporelle moyennée permet de transformer le signal de vibration cyclostationnaire en un signal ayant une seule période. La présence de crête dans le domaine bispectrale montre que le signal est non-linéaire, permettant ainsi de mettre en évidence la présence des défauts.

1.3 Les méthodes de reconnaissance de forme comme outils d'aide au diagnostic

Parmi toutes les méthodes d'analyse des signatures vibratoires ci-haut présentées, aucune ne s'est encore imposée comme un standard en matière de détection de défaut. Cela est en grande partie dû au fait que les résultats de chacune d'elles varient en

fonction du système étudié. Toutefois, même si ces méthodes ne sont pas toujours efficaces dans l'identification des défaillances, chacune à son niveau fournit une information (extraction des paramètres) plus ou moins pertinente sur l'état de la machine. D'où l'intérêt accordé aux méthodes de reconnaissance de forme comme outil d'aide au diagnostic : elles devraient permettre de mettre en évidence l'information cachée et utile au diagnostic qui n'est pas toujours bien mis en évidence par les méthodes d'analyse de signatures vibratoires.

1.3.1 Historique générale

Le plus ancien algorithme en reconnaissance de forme est probablement le *perceptron* introduit par Rosenblatt en 1962 pour résoudre du XOR. Le perceptron est schématisé par un neurone ayant n entrées qui sont pondérées par un coefficient w_n . Le neurone possède une fonction d'activation et une sortie qui représente en fait une probabilité à posteriori d'un évènement donné. Cela équivaut à une fonction discriminante linéaire. Depuis, de nouveaux algorithmes d'apprentissage plus performants ont été développés pour résoudre les problèmes de classification non-linéaires. On cite entre autres les réseaux de neurones, les réseaux bayésiens et les séparateurs à vaste marge (*Support Vector Machine en anglais*, SVM). L'utilisation des algorithmes d'apprentissage comme outils d'aide au diagnostic a fait l'objet de nombreuses études. Jardine [Jardine, 2005] passe en revue les méthodes d'analyse actuellement utilisées

en surveillance des machines rotatives. Il divise ces méthodes en deux catégories : les méthodes statistiques et les méthodes d'intelligence artificielle. Dans la première catégorie, il regroupe les méthodes basées sur la minimisation des distances entre les données comme l'analyse des *clusters* (e.g. les plus proches voisins), les réseaux cachés de Markov et les SVM. Dans la seconde catégorie, on retrouve les méthodes de logique floue (*fuzzy logic*), les réseaux de neurones, les réseaux de neurones à logique floue (*fuzzy neural network*), et les algorithmes évolutionnaires (*evolutionary algorithms*).

Cependant, cette classification n'est peut être pas appropriée pour bien décrire le principe de ces méthodes. Il est préférable de les classer en terme du principe d'apprentissage sur lequel elles sont basées. On distingue actuellement deux grands principes d'apprentissage : l'apprentissage *supervisé* et l'apprentissage *non supervisé*. Le premier type d'apprentissage consiste à ajuster les paramètres du classificateur pour minimiser son erreur de classification sur des données dont les classes associées sont connues. En apprentissage non supervisé, on a aucune idée de la classe des données que l'on a et on cherche à les regrouper selon leurs ressemblances. L'apprentissage est particulièrement utile pour l'analyse des systèmes dont les modes de défaillance sont inconnus. Dans le cas, des machines rotatives, les modes de défaillance sont assez bien connus, et cela explique pourquoi les méthodes d'apprentissage supervisé sont plus populaires auprès des chercheurs.

Depuis les premiers travaux effectués avec le perceptron, les réseaux de neurones sont probablement les méthodes d'apprentissage les plus utilisées à ce jour en reconnaissance de forme. Le livre de Haykin [Haykin, 1999] constitue une bonne référence sur les fondements théoriques de ces algorithmes ainsi que leur application dans les problèmes pratiques. L'avantage des réseaux de neurones se situe dans le fait qu'ils sont capables d'effectuer les deux types d'apprentissage. En apprentissage supervisé, on peut utiliser les réseaux à base radiale et le perceptron multi-couches, alors qu'en apprentissage non-supervisé on a le choix entre les cartes auto-organisatrices de Kohonen (*Self-Organized Map*, SOM), les réseaux de Hopfield, les machines de Boltzmann etc. L'inconvénient majeur avec les réseaux de neurones réside dans le fait qu'ils nécessitent un nombre élevé de données pour réaliser un bon apprentissage. Cela explique l'intérêt de plus en plus croissant des chercheurs pour les Support Vector Machines (SVM). Bien qu'introduits dans les années 1960 par Vapnik [Vapnik, 1964] comme application de son principe d'apprentissage statistique, ce n'est qu'au début des années 1990 que les chercheurs s'y sont vraiment intéressés, avec les progrès de l'informatique [Vapnik, 1995, Burges, 1998].

1.3.2 Principe d'apprentissage statistique

La notion d'apprentissage statistique, *Statistical Learning Theory*, est sous-jacente au principe d'*induction* qui consiste à proposer des lois générales à partir de l'observation

des cas particuliers, i.e. de *généraliser*. On classe les algorithmes d'apprentissage en deux grandes catégories :

- L'apprentissage *non-supervisé* : étant donné l'échantillon d'apprentissage $S = \{\mathbf{x}_i\}_{i=1}^l$, on cherche à les regrouper selon leurs ressemblances ou à les séparer selon leur différences. Les régularités sous-jacente que l'on recherche peuvent être des fonctions (problème de régression), des nuages de points (mélanges gaussiennes) ou des modèles complexes (réseau bayésien).
- L'apprentissage *supervisé* : à partir d'un échantillon de la forme $S = \{\mathbf{x}_i, y_i\}_{i=1}^l$, on cherche des classes de fonctions $\phi : \mathbf{x} \rightarrow h(\mathbf{x})$ de telle manière que la fonction $h(\mathbf{x})$ approxime le mieux possible la vraie fonction $f(\mathbf{x})$ qui relie \mathbf{x}_i à sa classe y_i .

Dans le cadre de ce mémoire, on s'intéresse aux cas d'apprentissage supervisé car les modes de défaillances des machines rotatives sont assez bien connus de nos jours. Cependant, la vraie relation $f(\mathbf{x})$ entre le type de défaillance y_i et la signature vibratoire mesurée \mathbf{x}_i nous est inconnue. L'apprentissage statistique consiste donc à supposer des fonctions $h(\mathbf{x})$ et à minimiser le risque que l'on commet en faisant cette approximation. Le risque est définie par

$$R = \int \frac{1}{2} |y - f(\mathbf{x})| dP(\mathbf{x}, y) \quad (1.25)$$

où $P(\mathbf{x}, y)$ représente la probabilité que la donnée \mathbf{x} appartienne à la classe de défaillance y . Or comme on ne connaît pas la vraie relation entre \mathbf{x} et la classe y , le

risque est lui aussi inconnu. C'est à ce niveau que naissent les différences entre les algorithmes d'apprentissage. Les algorithmes classiques comme les réseaux de neurones vont chercher à minimiser le risque *empirique* défini par

$$R_{emp} = \frac{1}{l} \sum_{i=1}^l \frac{1}{2} |f(\mathbf{x}_i) - y_i| \quad (1.26)$$

La différence fondamentale entre les réseaux de neurones et les SVM réside dans le principe de minimisation du risque. Les réseaux de neurones vont chercher à minimiser le risque *empirique* alors que les SVM minimisent la borne supérieure du risque structurel grâce à la dimension de Vapnik-Chervonenkis [Vapnik, 1964, Vapnik, 1995]. Les algorithmes d'apprentissage basé sur le risque empirique ne permettent pas de contrôler efficacement la capacité à généraliser des fonctions discriminantes. On se heurte très souvent aux problèmes de *mémorisation* ou *sur-apprentissage* et de *sous-apprentissage*. Dans ces méthodes, le seul paramètre qui contrôle la capacité à généraliser est le nombre de données d'apprentissage. Il faut en général un grand nombre de données d'apprentissage pour obtenir une faible erreur de classification. Cependant, plus le nombre de données est élevé, plus les chances de faire une mémorisation sont élevées. L'idéal serait donc de trouver une fonction discriminante qui réalise un bon compromis entre l'obtention d'un risque empirique faible et d'une bonne capacité à généraliser. C'est dans cette optique que s'inscrit la *dimension de Vapnik-Chervonenkis* qui découle de la théorie d'apprentissage statistique de

Vapnik.

1.3.3 La dimension de Vapnik-Chervonenkis

Considérons le cas d'une classification binaire où on doit répartir l données entre deux classes $y = \pm 1$. Il y a 2^l manières possibles de séparer les données. La classe de fonctions idéale est donc celle qui permettrait d'accomplir les 2^l séparations. La dimension de *Vapnik-Chervonenkis* (VC) notée h correspond au plus grand nombre de points qu'une classe de fonction peut séparer. Dans le cas d'une classification linéaire (la frontière est une droite), il est facile de montrer que la dimension VC dans un espace de dimension p est égale à $p + 1$.




FIG. 1.13: Dimension de Vapnik-Chervonenkis dans un espace de dimension 2

La dimension de Vapnik-Chervonenkis joue un rôle central dans la minimisation du risque défini à l'équation (1.25). En lieu et place de minimiser le risque, Vapnik cherche plutôt à minimiser sa borne supérieure. Il a montré que si $h < l$ est la dimension VC d'une classe de fonction dans l'espace d'apprentissage, alors avec une probabilité d'au moins $1 - \eta$, le risque est borné par

$$R \leq R_{emp} + \sqrt{\frac{1}{l} \left[h \left(\ln \left(\frac{2l}{h} \right) + 1 \right) - \ln \left(\frac{\eta}{4} \right) \right]} \quad (1.27)$$

Le membre de droite de l'équation (1.27) représente la borne du risque (*risk bound*) et est la somme du risque empirique et du terme de *confiance de Vapnik-Chervonenkis*. Notons que cette équation ne fait pas intervenir $P(\mathbf{x}, y)$ qui est inconnu. Cependant connaissant h il est facile de calculer cette probabilité. Si η est suffisamment petit et qu'une classe de fonctions qui minimise le membre de droite est trouvé, alors cette classe de fonction est celle qui minimise la borne supérieure du risque. Ce principe représente la base de la Minimisation du Risque Structurel de Vapnik. Il est résumé par Vapnik [Vapnik, 1998] comme suit

The explanation by the machine with the smallest capacity, i.e. VC dimension, is the best

Les figures 1.14 et 1.15 montrent la variation du terme de confiance VC en fonction du nombre des données d'apprentissage et de la dimension VC respectivement. On remarque que le terme de confiance de VC augmente lorsque la dimension de VC

augmente (Fig. 1.14) et diminue lorsque le nombre de données augmente (Fig. 1.15). Cela signifie que pour les frontières de classification linéaires, plus la dimension de l'espace de représentation est grande, plus il faut de données d'apprentissage pour obtenir une bonne capacité de généralisation.




FIG. 1.14: Variation de la confiance VC en fonction du nombre de points

Cependant, le fait de disposer d'un espace de représentation de grande dimension alourdit les calculs, et fait augmenter le terme de confiance, cf. Fig. 1.15 ; ce phénomène est connu sous le nom de *curse of dimensionality*. Un compromis entre la dimension de l'espace de représentation et le nombre de données d'apprentissage est donc nécessaire.




FIG. 1.15: Variation de la confiance VC en fonction de la dimension VC

1.3.4 Application des SVM en surveillance des machines rotatives

Il a été rapporté à maintes reprises dans la littérature que les SVM avaient une meilleure capacité de généralisation que les réseaux de neurones pour un nombre limité de données d'apprentissage [Nandi, 2002, Samanta, 2003, Samanta, 2004a, Zhang, 2006].

La popularité des SVM auprès des chercheurs est mise en évidence par Widodo [Widodo, 2007a]. Il rapporte qu'une recherche avec les termes *support vector machine* comme mots-clés donne pas moins de 5000 articles publiés entre 1996 et 2006 sur les principales bases de données d'articles scientifiques⁴. Il passe aussi en revue les travaux effectués avec les SVM en surveillance des machines rotatives : roulements,

⁴IEEEExplore, Elsevier ScienceDirect, WileyInterscience, Springer, Igenta

moteurs à induction, machines à outils, pompes, compresseurs, turbines, engrenages, moteurs à combustions etc.

Étant donné que les algorithmes d'apprentissage supervisés, font intervenir des processus d'optimisation et de sélection de paramètres, il est possible de les combiner avec les algorithmes génétiques afin d'améliorer leurs performances. Samanta [Samanta, 2003, Samanta, 2004a, Samanta, 2004b] et Nandi [Nandi, 2002] comparent les performances des réseaux de neurones et des SVMs lorsque les deux sont couplés avec des algorithmes génétiques pour la détection des défauts d'engrenages et de roulements. Ils utilisent l'algorithme génétique pour sélectionner les paramètres les plus importants dans les données d'apprentissage. Rojas [Rojas, 2005, Rojas, 2006] propose une procédure pour choisir adéquatement les paramètres de l'algorithmes d'apprentissage. Il teste cette procédure sur la classification des défauts de roulements. Il extrait 90 paramètres statistiques du signal temporel et 66 paramètres du spectre obtenu par la transformation de Fourier pour construire le classificateur. Guo [Guo, 2005] propose une *programmation génétique* (*Genetic Programming* en anglais) pour la génération ou l'extraction des paramètres des signaux bruts de vibration. Elle montre qu'on obtient de meilleurs taux de généralisation lorsque l'apprentissage est réalisé avec ces paramètres. Cependant, le problème avec une telle approche se situe dans l'interprétation physique des paramètres qui seront trouvés par l'algorithme de programmation génétique.

CHAPITRE 2

FONDEMENTS THÉORIQUES DES MÉTHODES D'ANALYSE

Dans ce chapitre, on présente les fondements théoriques des méthodes d'analyses vibratoires et statistiques que nous avons utilisées pour construire notre procédure de diagnostic.

2.1 Méthode d'analyse des signatures vibratoires

La complexité grandissante des systèmes mécaniques a rendu difficile, voire impossible, l'identification des fréquences de défaut de roulement dans les spectres des signaux bruts de vibration. Les méthodes HFRT et d'analyse d'enveloppe introduites à cet effet, ne donnent pas toujours des résultats satisfaisants, surtout lorsque le ratio bruit/signal est élevé. Il devient donc impératif d'utiliser une méthode d'extraction de la composante impulsive du signal brut de vibration mesuré. D'où l'intérêt que l'on porte à la synchronisation temporelle moyennée et au kurtosis spectral.

2.1.1 La synchronisation temporelle moyennée

À l'origine, la synchronisation temporelle moyennée (STM) a été introduite pour localiser les défauts d'engrenages à chaque cycle de rotation des roues dentées. Cette méthode est considérée *déterministe* [Forrester, 1996], car elle est basée sur le nombre de chocs entre les roues dentées, qui peut être prédit avec exactitude. Par contre, dans le cas des roulements, la lubrification engendre du glissement entre les composantes en mouvement, introduisant ainsi une incertitude dans le calcul des fréquences de défaut¹. L'exemple typique est celui d'un défaut sur une bille. En plus de tourner autour de l'axe de rotation de l'arbre, la bille tourne aussi autour d'elle-même. Puisque le sens de cette dernière rotation ne peut être prédit, il est possible que la partie de la bille où se trouve le défaut ne rentre pas en contact avec une des deux cages (interne ou externe) au cours d'un cycle de rotation d'arbre. L'impulsion caractéristique du défaut ne sera pas produite au cours de ce cycle, et cela va influencer la valeur de la fréquence du défaut dans le spectre.

Malgré cela, on a montré dans nos travaux précédents [Komgom, 2007a, Komgom, 2007b, Komgom, 2008] qu'il était possible de l'utiliser pour mettre en évidence les défauts de roulements dans les signaux bruts de vibration. En se servant du modèle de synchronisation temporelle moyennée proposé par McFadden et Toozhy, on a été en mesure d'identifier les fréquences de défaut dans le spectre du signal enveloppe.

¹Voir Annexe I pour le calcul des fréquences théoriques de défaut de roulement

2.1.1.1 Modèle de McFadden & Toozhy

Au départ [McFadden, 2000], ce modèle a été développé pour les défauts de bague interne. On propose ici une généralisation de ce modèle aux autres défauts i.e. bague externe et défaut de bille. Le modèle de McFadden & Toozhy suppose que le spectre enveloppe d'intérêt est celui dont les fréquences prédominantes sont celles qui sont harmoniques de la fréquence théorique du défaut modulées par la fréquence de rotation de l'arbre. De manière générale, elles sont de la forme

$$f = m f_{\text{defaut}} \pm n f_r \quad (2.1)$$

où m et n sont des entiers naturels. En remplaçant la fréquence de défaut f_{defaut} par sa valeur théorique, on obtient une expression générale des fréquences attendues dans le spectre enveloppe.

i) Pour un défaut de bague interne, $f_{\text{defaut}} = B P F I$

$$f = m \frac{z}{2} f_i \left(1 + \frac{B_d \cos \alpha}{P_d} \right) \pm n f_r \quad (2.2)$$

En se servant de la fréquence théorique d'un défaut de cage, Eq.(I.6), il vient que

$$\frac{B_d \cos \alpha}{P_d} = 1 - 2 \frac{f_c}{f_r} \quad (2.3)$$

En insérant (2.3) dans (2.2), et en simplifiant les termes, on trouve

$$f = mz(f_r - f_c) \pm nf_r \quad (2.4)$$

On obtient ainsi les fréquences que McFadden & Toozhy considèrent comme les fréquences prédominantes du spectre enveloppe dans leur modèle.

- ii) Pour un défaut de bague externe, en procédant de la même façon que précédemment, on arrive à

$$f = mzf_c \pm nf_r \quad (2.5)$$

- iii) Pour un défaut sur une bille, le résultat final est plus complexe

$$f = m \frac{P_d}{B_d} \left(f_r - 2f_c + 2\frac{f_c^2}{f_r} \right) \pm nf_r \quad (2.6)$$

Selon les équations (2.4), (2.5) et (2.6), les fréquences prédominantes du spectre enveloppe sont des combinaisons linéaires de la fréquence relative de l'arbre par rapport à la cage dans le cas d'un défaut de bague interne, et de celle de la cage et de l'arbre dans le cas d'un défaut de bague externe. Dans le cas d'une bille défectueuse, la relation est non linéaire.

En se basant sur ces équations, McFadden & Toozhy proposent d'effectuer la synchronisation temporelle moyennée par convolution du signal brut de vibration avec un filtre peigne. Ce dernier correspond à un train de N impulsions d'amplitude $1/N$

et de période T_t . Soit

$$\text{TSA}[x(t)] = y(t) = c(t) * x(t) \quad (2.7)$$

avec $c(t)$ défini par

$$c(t) = \frac{1}{N} \sum_{n=0}^{N-1} \delta(t + nT_t) \quad (2.8)$$

Dans le domaine fréquentiel, cela équivaut au produit du spectre du filtre peigne et de celui du signal brut

$$Y(f) = C(f) \cdot X(f) \quad (2.9)$$

avec

$$C(f) = \frac{1}{N} \frac{\sin(\pi N T_t f)}{\sin(\pi T_t f)} \quad (2.10)$$

Pour de grandes valeurs de N , i.e. un grand nombre d'impulsions, seulement les multiples **entiers** de la fréquence $f_t = 1/T_t$ du filtre peigne seront retenues. McFadden & Toozhy choisissent alors comme fréquence du filtre peigne, la fréquence d'apparition des impacts dans le cas d'un défaut de bague interne, soit

$$f_t = z(f_r - f_c) \quad (2.11)$$

Ils ont utilisé ce modèle pour localiser les *mini-cratères* (spalls) sur la surface d'une bague interne. Cependant, comme ils le soulignent eux même, ce modèle présente quelques inconvénients lors d'une implémentation directe en industrie. Premièrement, un grand nombre d'impulsions est requis pour filtrer les fréquences non harmoniques

de la fréquence du filtre. Il faut donc faire un compromis entre la taille du signal et le nombre d'impulsions. Ensuite, il est nécessaire de connaître avec exactitude la fréquence de rotation de la cage f_c , ce qui est quasiment impossible en industrie. Face à ces difficultés, on propose donc de simplifier la procédure de synchronisation pour obtenir de bonnes approximations du signal synchrone moyenné.

2.1.1.2 Modèle de synchronisation proposé

Le modèle de McFadden & Toozhy repose sur le principe fondamental suivant : en synchronisant le signal de vibration avec une séquence qui se répète à une fréquence donnée, seulement les multiples entiers de cette fréquence seront présentes dans le spectre enveloppe si le nombre de moyennes N est assez élevé. En d'autres termes, les facteurs le plus importants dans ce modèle sont la fréquence du train d'impulsions et le nombre d'impulsions. Au cours des travaux entrepris dans le cadre de ce mémoire [Kongom, 2007a, Kongom, 2007b, Kongom, 2008], on a montré qu'en lieu et place d'utiliser la fréquence relative entre l'arbre et la cage, la fréquence de rotation de l'arbre seule serait suffisante pour faire apparaître les fréquences de défaut de roulement dans le spectre enveloppe. On justifie cela par le raisonnement suivant :

- a) Les roulements à billes sont conçus telle manière que leurs fréquences de défaut ne soient pas des harmoniques de la fréquence de rotation de l'arbre afin de faciliter

leur identification dans le spectre. Donc si on utilise la fréquence de rotation de l'arbre comme fréquence fondamentale du train d'impulsions, alors en théorie, les fréquences de défaut de roulement ne devraient pas être retenues par le filtre peigne.

- b) Cependant, on sait que si on n'a pas assez d'impulsions, alors le spectre enveloppe contiendra aussi des composantes fréquentielles non-harmoniques de la fréquence du filtre peigne, les fréquences de défaut roulement en font partie.

La procédure de convolution du signal que nous avons utilisé a été implémenté dans un modèle Simulink. On utilise le block 'Repeating Sequence' pour simuler le train d'impulsions, et le bloc 'CONV' pour effectuer la convolution du signal brut et du train d'impulsions.




FIG. 2.1: Modèle simulink pour la synchronisation temporelle moyennée

En fixant la fréquence de la séquence de répétition à f_r , le nombre d'impulsions est donné par

$$N = f_r \times \text{durée du signal} \quad (2.12)$$

Pour ce qui est de la méthode de calcul du signal enveloppe, on n'a pas noté une grande différence entre les résultats obtenus avec la transformée de Hilbert et celle de Courrech. Notre choix s'est porté sur la méthode de Hilbert car elle est plus facile à implémenter.

2.1.2 Analyse cyclostationnaire : le kurtosis spectral

On montre dans cette section comment on peut tirer profit de la propriété de cyclostationnarité des signatures vibratoires des machines rotatives pour détecter et diagnostiquer un fonctionnement anormal. L'emphase est mise sur l'utilisation du kurtosis spectral. Premièrement, une brève présentation des fondements théoriques du kurtosis spectral est faite, une analyse plus détaillée se trouvant dans l'article d'Antoni [Antoni, 2006a].

Au départ, Antoni [Antoni, 2006a] cherche à caractériser les signatures vibratoires aléatoires et non-stationnaires en utilisant une représentation stochastique qui préserve la signification physique du phénomène observé. Pour un processus stationnaire, la décomposition de Wold seule, est suffisante pour décrire tout phénomène stationnaire stochastique comme la réponse d'un système causal linéaire et invariant dans le temps

$h(s)$ excité par du bruit blanc

$$y(t) = \int_{-\infty}^t h(t - \tau)X(\tau) d\tau \quad (2.13)$$

Cette décomposition n'est valide que si $X(t)$ a une densité spectrale *plate* sur toute sa gamme de fréquence. Dans ce qui suit, on suppose aussi que $X(t)$ a une fonction de densité de probabilité symétrique. Dans le domaine fréquentiel, la décomposition de Cramer est l'équivalent de celle de Wold

$$y(t) = \int_{-\infty}^{+\infty} e^{j2\pi ft} H(f) dX(f) \quad (2.14)$$

où $H(f)$ et $X(f)$ représentent les transformées de Fourier de $h(s)$ et de $x(t)$ respectivement. Pour étendre ces définitions au cas d'un processus non stationnaire, une solution serait de remplacer la fonction de transfert du système invariant $h(s)$ par celle d'un système qui varie dans le temps, i.e. $h(t, s)$. Les équations (2.13) et (2.14) deviennent respectivement

$$y(t) = \int_{-\infty}^t h(t, t - \tau)X(\tau) d\tau \quad (2.15)$$

$$y(t) = \int_{-\infty}^{+\infty} e^{j2\pi ft} H(t, f) dX(f) \quad (2.16)$$

où $H(t, f)$ est la transformée de Fourier de la fonction impulsionnelle variante $h(t, s)$, en d'autres termes la fonction de transfert du système variant. On pourrait aussi

interpréter $H(t, f)$ comme l'enveloppe complexe d'un processus $y(t)$ à la fréquence f . Ce faisant, l'expression à l'intérieur de l'intégrale correspondrait à la réponse au temps t , d'un filtre à bande infiniment étroite centré à la fréquence f .

Dans le développement fait jusqu'à présent, il est supposé que $H(t, f)$ représente un phénomène *déterminé*. Pour tenir compte de la nature stochastique du processus analysé, on suppose que la forme de l'enveloppe complexe $H(t, f)$ dépend aussi de la variable aléatoire ϖ , i.e. $H(t, f, \varpi)$. Ce faisant, le processus $y(t)$ est doublement stochastique : en $H(t, f)$ et en $dX(f)$. Dans ce qui suit, on suppose que $H(t, f, \varpi)$ est stationnaire dans le temps ² et indépendant du processus spectral $dX(f)$: Antoni les définit par les termes de processus *conditionnellement non-stationnaires*. Ces processus ont la propriété fondamentale d'être caractérisés par des fonctions de densité de probabilité non-gaussiennes.

La décomposition de Wold-Cramer confère à l'enveloppe complexe $H(t, f)$ un rôle central dans la description des processus non-stationnaires. Cette description est faite en considérant ses moments statistiques. Soit $S_{2ny}(t, f)$ le moment statistique instantané d'ordre $2n$ qui mesure l'énergie de l'enveloppe au temps t et à la fréquence f

$$S_{2ny}(t, f) \equiv E\{|H(t, f)dX(f)|_{\varpi}^{2n}\}/df = |H(t, f)|_{\varpi}^{2n} \cdot S_{2nx} \quad (2.17)$$

²De ce fait, on omettra la variable ϖ dans $H(t, f, \varpi)$, pour simplifier la notation

Notons que l'on ne considère que les moments pairs car $x(t)$ est stationnaire, ce qui signifie que $dX(f)$ est *circulaire* et que ses moments impairs sont nuls. Les moments spectraux permettent d'étudier le comportement de $H(t, f, \varpi)$ sur un intervalle de valeurs moyennes de ϖ

$$S_{2ny}(f) \equiv E\{S_{2ny}(t, f)\} = E\{|H(t, f)dX(f)|^{2n}\} \cdot S_{2nx} \quad (2.18)$$

Dans l'équation (2.18) on suppose que $H(t, f)$ est un processus aléatoire stationnaire, indépendant de $dX(f)$ et que $X(t)$ correspond à un bruit blanc d'ordre $p \geq 2n$. Pour $n = 1$, l'équation (2.18) correspond à la densité spectrale de $y(t)$. En pratique, les moments spectraux sont évalués en moyennant les moments instantanés dans le temps. Les moments moyennés d'ordre $2n$ sont alors définis comme

$$\langle S_{2ny}(t, f) \rangle_t = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-T/2}^{T/2} S_{2ny}(t, f) dt \quad (2.19)$$

Les moments d'ordre supérieur, i.e. $2n \geq 4$, ont la propriété intéressante d'être non-nuls pour des processus non-gaussiens. Le kurtosis spectral est donc le quatrième cumulant normalisé de l'enveloppe complexe $H(n, f)$ du signal x à la fréquence f

$$K_x(f) = \frac{E\{|H(n, f)|^4\}}{E\{|H^2(n, f)|^2\}} - 2 \quad (2.20)$$

Dans la définition (2.20), on a -2 en lieu et place de -3 que l'on retrouve dans la

définition du kurtosis temporel classique. Cela est dû au fait que $dX(f)$ est une variable *circulaire* aléatoire. Physiquement parlant, le kurtosis spectral peut être considéré comme une mesure de la dispersion temporelle de la distribution d'énergie temps-fréquence, i.e. la quantité d'énergie de l'enveloppe complexe à la fréquence f qui varie dans le temps. Antoni [Antoni, 2004a, Antoni, 2006a, Antoni, 2007a] a développé le *kurtogram*, un algorithme de calcul de la distribution spectrale du kurtosis. Le calcul du kurtosis spectral permet d'identifier la bande de fréquence où le signal a une impulsivité maximale. Cette information peut être utilisée en séparation de sources ou pour débruiter le signal [Antoni, 2005a, Sawalhi, 2007]. On peut montrer que le kurtosis spectral d'un signal bruité est de la forme

$$K_{x+b}(f) = \frac{K_x(f)}{[1 + \rho(f)]^2} \quad (2.21)$$

où $\rho(f)$ est le ratio signal/bruit à la fréquence f . Cette bande de fréquence peut aussi servir au calcul du spectre du signal enveloppe : en lieu et place de filtrer le signal autour d'une fréquence de résonance tel que le suggère la méthode du HFRT, il est plus avantageux d'utiliser la bande de fréquence où le kurtosis spectral est maximal [Antoni, 2004a, Antoni, 2005a, Antoni, 2005b, Antoni, 2006a, Antoni, 2006b, Antoni, 2007a, Antoni, 2007b, Randall, 2000, Randall, 2001].

2.2 Méthode de reconnaissance de formes : les Support Vector Machines

Les méthodes d'analyse des signatures vibratoires ne sont pas toujours efficaces pour mettre en évidence les défauts des machines rotatives. Il a été rapporté à maintes reprises que leurs performances dépendaient des caractéristiques du système mécanique étudié (niveau de bruit, conditions d'opération ...). C'est dans cette optique que s'inscrit notre intérêt pour les méthodes d'apprentissage statistique dans le but de fiabiliser le diagnostic posé par la procédure de diagnostic. Ces méthodes permettent de représenter deux états de fonctionnement de la machine apparemment semblables dans un espace de grande dimension où leurs différences seront plus visibles. En d'autres termes, on quantifie l'information cachée contenue dans la signature vibratoire et qui serait utile à la détection et au diagnostic de la défaillance. On présentera dans cette section les principaux fondements théoriques des Support Vector Machines comme algorithme d'apprentissage.

2.2.1 Introduction aux Support Vector Machines

Les *Support Vector Machines* sont des algorithmes d'apprentissage qui découlent de la théorie de minimisation du risque structurel de Vapnik et qui permettent d'obtenir un bon compromis entre la dimension de l'espace de représentation des données et la capacité de généralisation des frontières. Leurs fondements théoriques sont présentés en

détail dans les références suivantes [Burges, 1998, Cristianini, 2000, Scholkopf, 2002, Shawe-Taylor, 2004]. On se présentera ici les notions de base de ces algorithmes de classification.

2.2.1.1 Formulation du problème de classification

Considérons un ensemble de données $S = \{\mathbf{x}_i, y_i\}_{i=1}^N$ que l'on doit répartir entre deux classes de défaillance A et B selon la règle suivante

$$y = \begin{cases} +1 & \text{si } \mathbf{x}_i \in \text{classe A} \\ -1 & \text{si } \mathbf{x}_i \in \text{classe B} \end{cases} \quad (2.22)$$

Les données \mathbf{x}_i sont de dimension n . Dans le cas où les données sont linéairement séparables, alors la frontière entre les deux classes sera un hyperplan de la forme

$$f(\mathbf{x}) = \mathbf{w} \cdot \mathbf{x} + b = \sum_{j=1}^N w_j \cdot x_j + b \quad (2.23)$$

où $\mathbf{w} \in \mathbb{R}^n$ représente le vecteur normal à l'hyperplan et b la distance de l'hyperplan à l'origine de l'espace. Ainsi, la règle de classification devient

$$y = \begin{cases} +1 & \text{si } f(\mathbf{x}) \geq \Delta \\ -1 & \text{si } f(\mathbf{x}) < \Delta \end{cases} \quad (2.24)$$

où Δ représente la marge du classificateur. Vapnik [Vapnik, 1998] a montré que si les éléments de S sont inclus dans une sphère de rayon R , alors la dimension VC d'un hyperplan ayant une marge Δ est bornée par

$$d \leq \min\left(\frac{R^2}{\Delta^2}, n\right) + 1 \quad (2.25)$$

Cet important résultat démontre que la dimension VC d'un hyperplan dont la marge est Δ peut être inférieure à $n + 1$, si la marge est assez large. Cela signifie que la confiance VC de la borne supérieure du risque décroît lorsque Δ augmente. La *marge fonctionnelle* γ_i du point (\mathbf{x}_i, y_i) représente la distance de ce point à l'hyperplan optimal

$$\gamma_i = y_i(\mathbf{w} \cdot \mathbf{x} + b) \quad (2.26)$$

Les classificateurs à marge maximale sont ceux qui sont obtenus en posant $\Delta = \frac{1}{\|\mathbf{w}\|}$. On définit la *marge géométrique* γ de l'hyperplan optimal comme la moitié de la distance entre les points qui se trouvent sur les hyperplans canoniques $\mathbf{w} \cdot \mathbf{x} + b = \pm 1$, soit

$$\gamma = \frac{1}{2\|\mathbf{w}\|} [f(\mathbf{x}^+) - f(\mathbf{x}^-)] = \frac{1}{\|\mathbf{w}\|} \quad (2.27)$$

L'équation (2.27) montre que pour maximiser la marge géométrique de l'hyperplan, il faut minimiser $\|\mathbf{w}\|$. Cela équivaut donc à résoudre le problème quadratique convexe

suivant

$$\begin{aligned} & \text{minimiser } \frac{1}{2} \|\mathbf{w}\|^2 \\ & \text{sujet à } y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 \end{aligned} \quad (2.28)$$

Puisque ce problème d'optimisation est convexe, alors sa solution est unique et globale. si le nombre de données d'apprentissage est grand, alors il est préférable de travailler avec la version duale du problème. Le problème dual de Lagrange est

$$\begin{aligned} & \text{maximiser } L(\mathbf{w}, b, \alpha) = \frac{1}{2}(\mathbf{w} \cdot \mathbf{w}) - \sum_{i=1}^N y_i (\mathbf{w} \cdot \mathbf{x}_i + b) - 1 \\ & \text{sujet à } \alpha_i \geq 0, \quad i = 1 \dots N \end{aligned} \quad (2.29)$$

où $\alpha = (\alpha_1, \dots, \alpha_n)$ sont les multiplicateurs de Lagrange associés à chaque donnée.

Les points stationnaires du problème dual sont donnés par

$$\begin{aligned} \mathbf{w} - \sum_{i=1}^N y_i \alpha_i \mathbf{x}_i &= \mathbf{0} \\ \sum_{i=1}^N y_i \alpha_i &= 0 \end{aligned} \quad (2.30)$$

Le problème dual se réécrit donc sous la forme suivante

$$\begin{aligned} & \text{maximiser } W(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,k=1}^N y_i y_k \alpha_i \alpha_k (\mathbf{x}_i \cdot \mathbf{x}_k) \\ & \text{sujet à } \sum_{i=1}^N y_i \alpha_i = 0 \\ & \alpha_i \geq 0, \quad i = 1 \dots N \end{aligned} \quad (2.31)$$

Soient α^* et b^* les solutions optimales du problème dual. Selon le théorème de Karush-Kuhn-Tucker (KKT), l'égalité dans la contrainte du problème (2.28) aura lieu si

et seulement si le multiplicateur de Lagrange α_i associé à la paire (\mathbf{x}_i, y_i) est *non nulle*. Dans ce cas, \mathbf{x}_i est appelé *support vector*. Graphiquement, les supports vectors correspondent aux points qui se trouvent à l'intérieur de la marge. Seuls ces points sont importants pour définir la frontière optimale. Tous les points se trouvant à l'extérieur de la marge auront un multiplicateur de Lagrange associé $\alpha_i = 0$. La solution optimale du problème dual est donc creuse.




FIG. 2.2: Illustration des support vectors

Vapnik a démontré que si N données sont classées par le classificateur à marge maximale, alors une bonne approximation de la borne supérieure de l'espérance de la

probabilité d'erreur de classification est donnée par

$$E[P_{\text{erreur}}] \leq \frac{\text{nombre sv}}{N} \quad (2.32)$$

Dans le cas où les données ne sont pas non linéairement séparables, mais qu'on veut les classer avec une frontière linéaire, alors on introduit des variables d'écart $\xi > 0$ associées à chaque donnée \mathbf{x}_i et le paramètre de pénalisation C pour forcer le classificateur à faire le moins d'erreur possible. Le problème primal est de la forme

$$\begin{aligned} \text{minimiser } & \mathbf{w} \cdot \mathbf{w} + C \sum_{i=1}^N \xi_i^\sigma \\ \text{sujet à } & y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 - \xi_i \\ & \xi_i \geq 0 \end{aligned} \quad (2.33)$$

Ce problème est connu sous le nom de *Soft Margin Optimal Hyperplane*. Il existe deux variantes : le 1-Norm soft margin où $\sigma = 1$ et le 2-Norm soft margin où $\sigma = 2$. La constante C représente le paramètre de pénalité et elle permet de faire un compromis entre la maximisation de la marge et les erreurs de classification lors de l'apprentissage. Si $C \rightarrow \infty$, alors on force le classificateur à ne pas commettre d'erreur lors de l'apprentissage, et cela aura pour effet de diminuer sa capacité à généraliser. À l'inverse une faible valeur de C ne favorise pas un bon apprentissage. Dans la formulation duale, C agit aussi comme borne supérieure de la valeur de α_i , i.e. $0 \leq \alpha_i \leq C \forall i = 1 \dots N$. Il n'y a pas de règle générale pour choisir la valeur de

C , Scholkopf [Scholkopf, 2002] utilise une valeur heuristique tel que $C/N = 10$.

Une alternative consiste à changer l'espace de représentation des données. En effet, il a été démontré qu'il existe toujours un espace de dimension $l \gg n$ où des données non linéairement séparables dans l'espace de dimension n seront linéairement séparables. L'astuce consiste donc à projeter les données dans un espace de plus grande dimension où elles ont plus de chance d'être linéairement séparables et d'y résoudre le problème de classification. La projection vers l'espace de dimension $l \gg n$ est faite grâce à une fonction non linéaire $\psi : \mathbb{R}^n \rightarrow \mathbb{F}$. Dans l'espace de projection, l'hyperplan optimal est défini par

$$f(\mathbf{x}) = \sum_{j=1}^N \alpha_j y_j (\psi(\mathbf{x}_i) \cdot \psi(\mathbf{x}_j)) + b \quad (2.34)$$

Travailler dans des espaces de grandes dimensions permet d'obtenir des frontières de classification qui ont une forme complexe, mais cela engendre aussi des problèmes de calculs et sur-apprentissage. Les premiers viennent du fait que l'expression de ψ peut être très complexe dans certains cas, ce qui aura pour effet d'alourdir les calculs ou de nuire à la convergence du processus d'optimisation.

Dans l'équation (2.34), seule la valeur du produit scalaire $\psi(\mathbf{x}_i) \cdot \psi(\mathbf{x}_j)$ est important pour le calcul de la fonction de décision. Une solution serait donc de calculer ce produit scalaire sans avoir à connaître explicitement l'expression de la fonction $\psi(\cdot)$. Il a été démontré [Cristianini, 2000] que toute fonction de transformation ψ admet

au moins une *fonction noyau* K tel que

$$K(\mathbf{x}_i, \mathbf{x}_j) = \psi(\mathbf{x}_i) \cdot \psi(\mathbf{x}_j) \quad (2.35)$$

Ce ne sont pas toutes les fonctions qui peuvent être choisies comme fonction noyau d'une transformation. Les fonctions noyau admissibles sont celles qui satisfont les conditions de Mercer [Cristianini, 2000], i.e. la matrice définie par $[K] = [K(\mathbf{x}_i, \mathbf{x}_j)]_{i,j=1}^N$ soit *semi définie positive*. Les fonctions noyau les plus utilisées sont

– les fonctions polynomiales d'ordre p

$$K(\mathbf{x}_i, \mathbf{x}_j) = [(\mathbf{x}_i \cdot \mathbf{x}_j) + 1]^p \quad (2.36)$$

– les fonctions à base radiale

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right) \quad (2.37)$$

– les fonctions linéaires

$$K(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i \cdot \mathbf{x}_j) \quad (2.38)$$

La capacité à généraliser du classificateur dépendra donc du choix de la fonction noyau. En général, les fonctions à base radiales sont préférées aux fonctions polynomiales car elles ne sont pas influencées par les données aberrantes et ne requièrent pas que les deux classes de données aient la même variance. Le choix des paramètres

de l'algorithme d'apprentissage (C , type de fonction noyau et la dimension associée d ou σ) dépend des problèmes. Il est conseillé de tester plusieurs possibilités avant de faire un choix définitif.

2.2.1.2 Autres formulations

La formulation du problème de classification présentée à la section précédente est la formulation initiale proposée par Vapnik [Vapnik, 1995, Vapnik, 1998]. Elle est essentiellement basée sur un problème d'optimisation d'une fonction quadratique convexe, cf. équation (2.28). Plusieurs algorithmes ont été proposés pour ce type problèmes d'optimisation.

Nu-soft Margin

C'est une variante des problèmes de type *Soft Margin* proposée par Scholkopf [Scholkopf, 2000, Scholkopf, 2002]. Dans cette formulation, le paramètre C est remplacé par le paramètre ν tel que $\nu \in (0, 1]$ qui va contrôler le nombre de support vectors et d'erreurs de classification. Le problème primal est formulé comme suit

$$\begin{aligned}
 &\text{minimiser } \tau(\mathbf{w}, \boldsymbol{\xi}, \rho) = \frac{1}{2} \|\mathbf{w}\|^2 - \nu \rho + \frac{1}{m} \sum_{i=1}^N \xi_i \\
 &\text{sujet à } y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq \rho - \xi_i \\
 &\quad \xi_i \geq 0, \quad \rho \geq 0
 \end{aligned} \tag{2.39}$$

où ρ est un paramètre qui permet de garantir que si $\boldsymbol{\xi} = 0$, alors la contrainte du problème (2.39) signifie que la marge géométrique entre les deux classes est $2\rho/||\mathbf{w}'||$.

Le problème dual associé à (2.39) est

$$\begin{aligned} \text{maximiser } W(\boldsymbol{\alpha}) &= -\frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) \\ \text{sujet à } 0 &\leq \alpha_i \leq \frac{1}{N} \\ \sum_{i=1}^N \alpha_i y_i &= 0 \\ \sum_{i=1}^N \alpha_i &= \nu \end{aligned} \tag{2.40}$$

Comme avec le paramètre C , il n'y a pas de formules précises pour le choix de la valeur de ν . Mais l'avantage est que l'intervalle de choix est beaucoup plus restreint, ce qui facilite les tests préliminaires. Dans les publications [Komgom, 2007a, Komgom, 2007b, Komgom, 2008], on a utilisé une valeur de $\nu = 0.2$ et nous avons obtenus des résultats satisfaisants.

Chunking & Sequential Minimal Optimization

En utilisant la fonction noyau pour projeter les données dans un espace de grande dimension, le problème quadratique (2.31) fait intervenir la matrice $[K(\mathbf{x}_i, \mathbf{x}_j)]_{i,j=1}^N$ qui est de dimension N^2 . Pour de très grandes valeurs de N , l'algorithme d'optimisation devient lourd car il faut stocker la matrice $[K]$ en mémoire à chaque itération. Vapnik a proposé un algorithme de décomposition (*chunking*) qui consiste à diviser l'échantillon initial S en plusieurs sous-échantillons $\hat{S} \subset S$ et à résoudre le problème

quadratique sur \hat{S} . Cet algorithme suit le principe selon lequel les lignes et les colonnes de la matrice $[K]$ dont les multiplicateurs de Lagrange associés sont nuls, n'ont aucune influence sur la solution du problème d'optimisation. On commence l'optimisation avec un sous échantillon initial et on résout le problème quadratique. À l'itération suivante, on met à jour le sous-échantillon : on retire tous les points dont les multiplicateurs de Lagrange associés sont nuls, et on ajoute de nouveaux points au sous-échantillon. Le choix des points entrants dans le sous-échantillon est arbitraire, et le nombre de points ajoutés est fixe à chaque itération. Ainsi la taille de la matrice $[K]$ va augmenter à chaque itération, ce qui peut générer les mêmes problèmes de stockage que l'on voulait éviter. Le fait de ne pas contrôler les points qui entrent dans le sous-échantillon actif peut nuire à la convergence de l'algorithme. Osuna [Osuna, 1997] a démontré qu'en ajoutant uniquement les points qui violent les conditions de KKT, on garantit la convergence de l'algorithme à chaque itération. La taille de la matrice $[K]$ est gardée constante : on ajoute autant de points qu'on en retire.

L'optimisation séquentielle minimale (Sequential Minimal Optimisation, SMO) est un algorithme simple introduit par Platt [Platt, 1998] qui résout le problème quadratique sans utiliser un algorithme de résolution quadratique. Contrairement aux autres méthodes de décomposition, le SMO résout le plus petit problème d'optimisation possible. À chaque itération, le SMO trouve la valeur optimale de deux multiplicateurs de

Lagrange soumises à des contraintes d'égalité linéaires. L'avantage de cet algorithme est qu'il ne requiert pas d'espace mémoire pour stocker la matrice $[K]$ et que chaque sous problème possède une solution analytique. Le SMO comprend deux composantes essentielles : une méthode analytique pour résoudre le sous problème ayant deux multiplicateurs de Lagrange et une méthode heuristique pour choisir les multiplicateurs de Lagrange à optimiser. À priori, on pourrait penser que le temps d'optimisation augmente de manière significative dû au fait qu'on trouve uniquement la valeur de deux multiplicateurs de Lagrange à chaque itération, mais Platt [Platt, 1998] a rapporté que dans certains problèmes, cet algorithme était plus rapide que les autres méthodes de décomposition.

Lagrangian, Active set & Least square SVM

Mangasarian reformule le problème quadratique de classification linéaire pour proposer une formulation lagrangienne [Mangasarian, 2000b] et une formulation d'ensemble actif [Mangasarian, 2000a]. Dans le premier cas, il transforme le problème dual avec contrainte en un problème de minimisation sans contraintes dans un espace de dimension égal au nombre de points. Cette formulation est semblable à celle d'un problème de Lagrangien augmenté. La méthode d'ensemble actif consiste à diviser les variables duales en deux catégories : les variables en base, i.e. celles dont les multiplicateurs de Lagrange associés sont non-nuls et les variables hors-base, i.e. celles dont les multiplicateurs sont nuls. Les variables en base sont déterminées en utilisant l'algorithme

du gradient projeté.

Suykens [Suykens, 2002] reformule le problème de classification en utilisant une fonction des moindres carrés comme fonction objectif et des contraintes d'égalité linéaires. La résolution du nouveau problème correspond donc à un système KKT d'équations linéaires qui est résolu en utilisant l'algorithme du gradient conjugué. L'inconvénient majeur de cette formulation est qu'elle la solution optimale n'est pas nécessairement creuse.

2.2.2 Multi-classification

Les algorithmes des SVM ont été développés sur la base d'un problème de classification entre deux classes. En pratique, il arrive très souvent que les données soient à classer entre plusieurs classes. Il faut alors adapter la formulation initiale du problème dans ces cas. La multi-classification avec SVM en est encore à ses débuts. À ce jour, plusieurs méthodes ont été proposées mais chacune d'elles a ses avantages et ses inconvénients. Dans ce mémoire, on s'intéressera uniquement aux méthodes *One-Against-One*, OAO et *One-Against-All*, OAA, qui sont les méthodes les plus utilisées actuellement. Ces deux méthodes consistent à diviser le problème de multi-classification en une série de problèmes de classification binaire. La différence entre elles se situe au niveau de la règle de décision.

Dans la méthode OAA, pour un problème de classification entre k classes, on construit k classificateurs binaires. Dans chaque cas, on effectue une classification entre la i ème classe et le reste des données de l'échantillon. La règle de décision finale s'énonce comme suit

$$\text{classe de } \mathbf{x} = \max_{i=1..k} (\mathbf{w}_i \cdot \mathbf{x} + b_i) \quad (2.41)$$

où \mathbf{w}_i et b_i sont les paramètres du i ème classificateur. Même si cette méthode est simple et intuitive, il se pose cependant des problèmes lorsque pour le i ème problème de classification, le nombre de données dans une classe sera beaucoup plus élevé que dans l'autre.

Dans la méthode OAO, on construit $\frac{k(k-1)}{2}$ classificateurs binaires et chaque classificateur va voter pour sa classe préférée. La règle de décision est donc basée sur le nombre de vote recueillis par une classe ; celle qui obtient le plus grand nombre de votes est celle à laquelle on assigne la donnée. Cependant, dans ce principe de classification tout les votes ont la même importance même si ils ne sont pas vraiment significatif. Par exemple, si le classificateur binaire A vs. B doit voter pour une donnée dont la classe réelle est C, alors ce vote ne doit pas avoir la même importance que celui du classificateur A vs. C. De plus, on a aucun moyen de sélectionner les classificateurs qui doivent participer au vote car on n'est pas supposé connaître la vraie classe à l'avance.

2.3 Sélection des paramètres par Algorithme Génétique

Parmi les paramètres utilisés pour représenter l'état de la machine dans un espace de grande dimension, on se doute bien qu'il y en a certains qui sont plus utiles que d'autres pour définir des frontières de classification. L'identification de ces paramètres permettrait de réduire le nombre de paramètres à calculer pour représenter l'état de la machine, ce qui a pour effet d'accélérer le diagnostic une fois le signal de vibration enregistré. L'utilisation d'un algorithme génétique (AG) est le moyen le plus simple et le plus rapide pour identifier la (ou les) combinaison(s) de paramètres qui sont les plus utiles à la classification.

De plus, l'AG permet aussi de déterminer les valeurs optimales de certains paramètres d'apprentissage pour lesquels il n'existe pas de règles de choix prédéfinies. Par exemple, la dimension de l'espace de projection (d dans le cas d'une fonction polynomiale, σ dans le cas d'une fonction à base radiale), le type de fonction de projection (polynomiale ou radiale), la valeur du paramètre ν , le nombre minimal de données d'apprentissage, sont autant de paramètres qu'il faut fixer par essai-erreur lors de l'apprentissage. En général, ces choix sont faits par essai-erreur, et étant donné le nombre de paramètres à varier et le nombre de combinaisons possibles, cette approche devient très vite fastidieuse.

Dans le cadre de ce travail, on s'intéresse uniquement à l'utilisation de l'algorithme

génétique pour la sélection efficace des paramètres les plus importants pour la classification. La fonction que l'on cherche à minimiser est l'erreur de classification des classificateurs construits à partir des vecteurs d'apprentissage formés à partir des gènes d'un individu de la population.

2.3.1 Plan général de l'AG

La première étape de l'AG consiste à définir les fonctions de codage et de décodage. Elles permettent de convertir les variables de la fonction à optimiser en variables binaires qui constitueront les gènes de chaque individu de la population.

La figure 2.3 montre les principales étapes d'un algorithme génétique. L'initialisation de la population est probablement l'étape la plus importante dans l'algorithme génétique. En effet, le choix de la population initiale ainsi que le nombre d'individus qui la constitue vont influencer les performances de l'algorithme. Si plusieurs individus ont une valeur élevée de la fonction-objectif à la première génération, alors l'algorithme va vite converger vers cette valeur. Cependant rien ne nous garantit que la solution trouvée soit optimale. En général, on génère aléatoirement les gènes de chaque individus de la population.

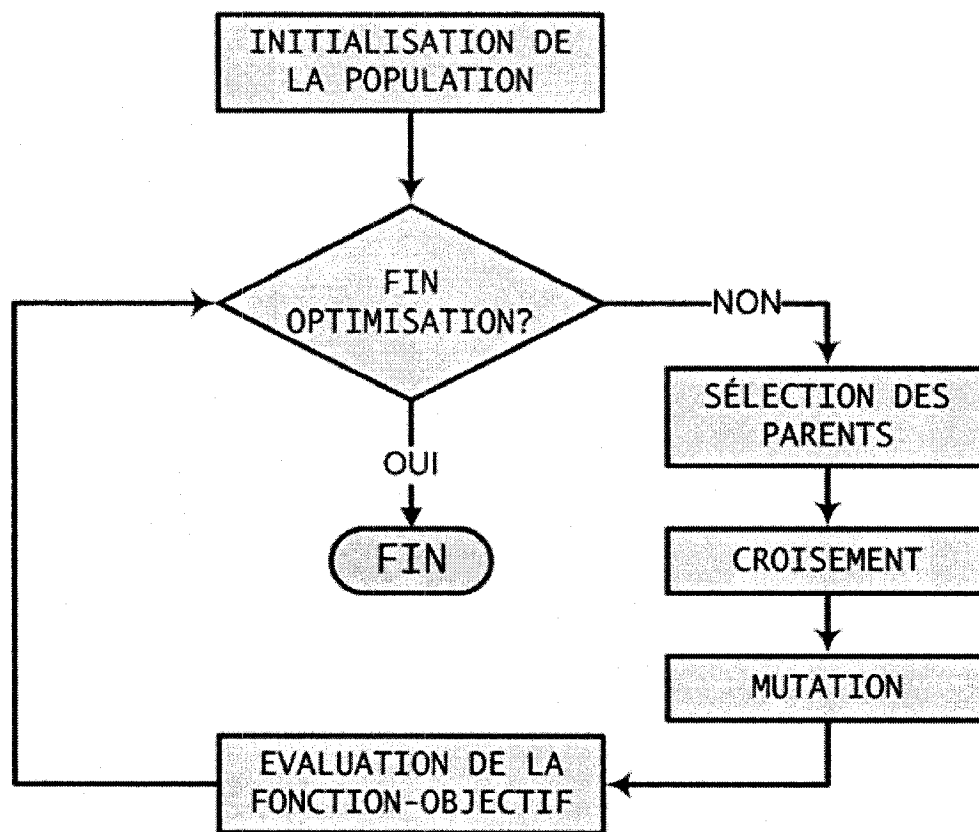


FIG. 2.3: Plan de l'algorithme génétique

2.3.2 Évaluation de la fonction objectif & Condition d'arrêt

Ici, on cherche à minimiser l'erreur de classification des frontières SVM lorsque les données d'apprentissage et de classification n'ont pas été enregistrées avec le même accéléromètre. La fonction objectif (ou fonction de survie) de l'algorithme génétique est donc de la forme

$$f(x) = \frac{1}{1 + \text{erreur de classification}} \quad (2.42)$$

Pour chaque individu de la population, i.e. chaque combinaison de paramètres, on trouve l'erreur de classification commise par les frontières SVM sur les données de validation. Si l'erreur est nulle, la fonction objectif vaudra 1, ce qui signifie qu'une combinaison optimale a été trouvée pour classer les données de validation. Par contre, plus la valeur de l'erreur de classification est grande, plus la valeur de la fonction objectif diminue, ce qui pénalise le chromosome associé à cette erreur de classification. Notons qu'on ne cherche pas à minimiser le nombre des paramètres qui sont retenus lors de la procédure de sélection. On s'attend à ce que l'AG nous identifie moins de 40 paramètres lors de la procédure de sélection.

L'algorithme se termine lorsque le nombre maximal de générations a été atteint ou lorsque la valeur de la fonction objectif remplit une ou plusieurs conditions.

2.3.3 Sélection des parents, croisement & mutation

À chaque génération de l'algorithme génétique, on doit choisir des *parents* parmi les individus de la population courante qui seront amenés à se reproduire et à survivre. Le processus de sélection des parents influence aussi la convergence de l'algorithme vers une solution optimale. Plusieurs opérateurs de sélection existe et on les classe en deux catégories : la sélection *proportionnelle* et la sélection *ordinale*. Dans la première catégorie, la sélection des parents est basée sur la valeur normalisée de la fonction de

survie des chromosomes alors que dans le second cas, les chromosomes sont choisis en fonction de la valeur de leur fonction de survie. La vitesse de convergence de l'AG dépend largement du processus de *sélection naturelle*, i.e. le degré auquel les individus les plus forts sont favorisés lors de la sélection. Si le degré de sélection naturelle est faible, alors l'algorithme mettra beaucoup de temps avant de converger, alors qu'un degré trop fort entraîne souvent une convergence prématurée vers un minimum local. Les opérateurs de sélection les plus utilisés sont la *roulette* (*roulette wheel selection*), le *tournoi* (*tournament selection*), le *Stochastic universal sampling* (SUS), et le *ranking*. Goldberg compare les performances de ces méthodes de sélection dans l'article [Goldberg, 1989].

Les opérateurs de croisement et de mutation simulent la reproduction entre les parents. Il existe plusieurs opérateurs de croisement dans la littérature [Spears, 1991, Syswerda, 1989], mais tous suivent le même principe : les portions de deux chromosomes sélectionnés au hasard sont mises ensemble pour former un nouveau chromosome. Selon les opérateurs, il existe un ou plusieurs points (sites) de croisement. L'opération de croisement à un seul point est celle qui maximise la transmission des gènes des parents aux enfants. Cela est souhaitable dans la plupart des cas, car les parents choisis pour la reproduction sont supposé être de *bons* chromosomes. Par contre, cet opérateur de sélection ne favorise pas la diversification du génotype d'une génération à l'autre. À l'autre extrême, l'opérateur de croisement uniforme préserve peu d'infor-

mation entre les générations et favorise l'exploration de l'espace de recherche. Si les nouveaux chromosomes sont moins forts que leurs parents, alors ils ne survivront pas à la prochaine génération. En général, la probabilité de croisement p_c fixe le pourcentage d'individus qui participeront au croisement tandis que $100(1-p_c)\%$ des individus seront tous simplement choisis aléatoirement pour compléter la nouvelle population.

L'opération de mutation simule l'influence de l'environnement sur les individus de la population. Elle consiste à changer la valeur d'un gène de 0 à 1 selon une probabilité prédéfinie p_m . Dans une moindre mesure par rapport à l'opération de croisement, elle permet de diversifier la population. Elle permet une recherche locale de la solution optimale. Dans certains cas, la mutation aide l'algorithme à s'éloigner d'une solution locale, alors que dans d'autres elle peut retarder la convergence vers la solution optimale. Il est conseillé de choisir une faible probabilité de mutation, pour éviter une recherche aléatoire et une convergence lente. Bien qu'il n'existe pas de règles prédéfinies pour le choix des paramètres p_m et p_c , en général on choisit leurs valeurs tel que suit : $0.6 \leq p_c \leq 1$ pour la probabilité de croisement et $0.001 \leq p_m \leq 0.005$ pour la probabilité de mutation.

2.3.4 Modèle d'algorithme génétique proposé

Dans notre cas, la fonction de codage traduit la sélection ou la non-sélection d'un paramètre pour former les vecteurs. Les gènes des chromosomes sont formés comme suit : à chacun des 40 paramètres de notre vecteur d'apprentissage, on associe une variable binaire a_i qui vaut 0 ou 1 selon que le paramètre associé n'est pas retenu ou est retenu lors de la procédure de sélection. Chaque chromosome correspond donc à une combinaison possible des paramètres pour former les vecteurs représentant l'état de la machine. Par exemple, en se basant sur la procédure d'extraction de la figure 4.21, si $a_4 = 0$, cela signifie que le Kurtosis n'est pas utilisé pour former les vecteurs d'apprentissage, si $a_{10} = 1$, alors le paramètre NB4 est utilisé dans la définition des vecteurs. Ainsi, on construit des chromosomes de taille égale à celle des vecteurs d'apprentissage et on alloue la valeur de 0 ou 1 selon que le i ème paramètre est retenu ou non lors du processus de sélection. Une fois le chromosome optimal trouvé, la fonction de décodage permet d'identifier la combinaison de paramètres qui permet de maximiser la capacité à généraliser des frontières de classification.

Les données d'apprentissage sont choisies aléatoirement pendant l'initialisation de l'AG et elles sont les mêmes à chaque génération. La taille minimale de la population est fixée à 100 et on ne dépasse pas 100 générations lors de chaque test. L'algorithme se termine lorsque le nombre maximal de générations est atteint ou lorsque les deux conditions suivantes sont remplies : la valeur maximale de la fonction de survie est

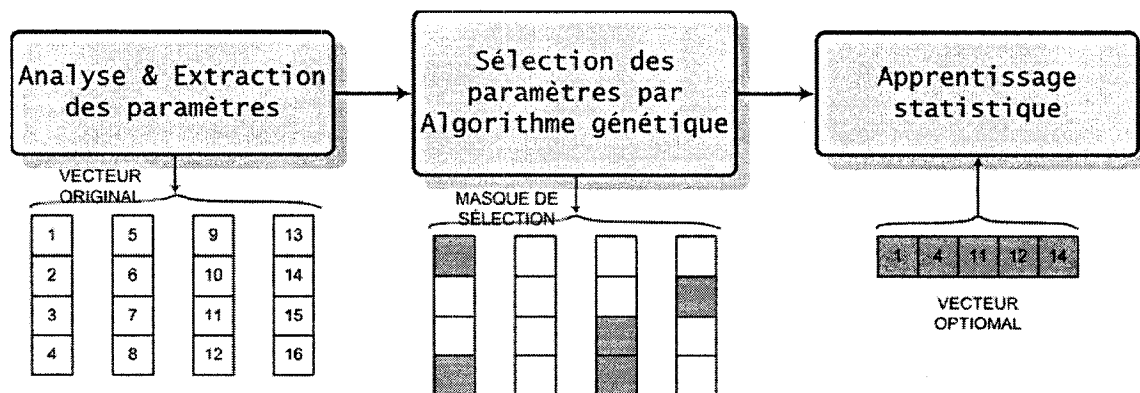


FIG. 2.4: Modèle de sélection des paramètres par Algorithme génétique

de 1 (i.e. le meilleur chromosome donne une erreur de classification nulle sur les données de validation) et la valeur moyenne de la fonction de survie des individus de la population est supérieure ou égale à 0.95 (i.e. une erreur de classification moyenne inférieure ou égale à 5%). On a implémenté 4 opérateurs de sélection de parents : la roulette, le tournoi, le SUS et le ranking.

Lors des tests préliminaires, on a varié les opérateurs de sélection des parents choisis pour la reproduction, de même que les routines utilisées pour générer la population initiale, i.e. *randint(.)*, *randerr(.)*, et *zeros(.)*. Ces tests montrent qu'il est difficile de mesurer l'influence de l'opérateur de sélection sur la convergence de l'AG. Par contre, la convergence de l'AG vers une ou plusieurs solutions optimales dépend fortement de la population initiale. Avec la fonction *randint(.)*, les individus de la population initiale sont en général *denses*, i.e. il y a plus de gènes ayant une valeur de 1 que ceux ayant une valeur de 0. On remarque l'algorithme converge plus rapidement vers une solution optimale, ce qui ne permet pas d'apprécier l'influence des autres paramètres

(population initiale) et opérateurs de l'AG. À l'inverse en choisissant une matrice nulle comme population initiale, la vitesse de convergence de l'algorithme diminue considérablement et dans la plupart des cas, l'AG se termine sans qu'aucune des deux conditions sur la valeur de la fonction-objectif ne soit satisfaite.

La routine *randerr* s'avère être un bon compromis. Elle permet de générer des chromosomes dont le nombre de gènes non-nuls varie entre deux nombres que l'on passe en argument. Cela permet de contrôler implicitement la densité des individus de la population finale. Dans notre cas, chaque chromosome de la population initiale a soit 2 ou 3 gènes non nuls, pour permettre au minimum une représentation dans le plan ou dans l'espace. Ce faisant, on a noté que les meilleurs chromosomes de la population finale étaient peu denses, i.e. beaucoup plus de 0 que de 1, ce qui signifie qu'on a peu de paramètres dans la combinaison optimale. Par contre dans certains cas, étant donnée la faible valeur de la probabilité de mutation et le nombre relativement élevé d'individus copiés entre deux générations successives, la convergence de l'AG avec une telle population initiale est très lente. Dans certains cas, l'AG se termine sans avoir trouvé une combinaison qui donne un taux de classification acceptable. Pour remédier à cela, on utilise la routine *round(rand(.))* pour générer la population initiale. Avec cette dernière, on génère des chromosomes qui ont en général autant de 0 que de 1.

La taille de la population semble aussi avoir une influence sur la population. Dans les cas, où l'AG a de la difficulté à converger, on augmente progressivement la taille de

la population par paliers de 100 jusqu'à 500 individus. Cela a pour effet d'alourdir les calculs, i.e. le temps d'évaluation de toutes les combinaisons à chaque génération. Par contre, cela favorise la diversité des individus dans la population initiale dans la mesure où on a plus de combinaisons différentes à tester. On a aussi constaté que la valeur de la probabilité de mutation semblait avoir une influence sur la convergence de l'AG vers une solution optimale en particuliers. Nombreux sont les cas où l'AG identifie une solution optimale, i.e. la valeur de la fonction de survie est égale à 1, mais par contre la valeur moyenne de la fonction des individus de la population ne dépasse pas 0.95. La valeur élevée de la probabilité de mutation semble être un des facteurs qui favorisent ces cas, dans la mesure où l'opérateur de sélection choisi est celui du *Tournoi* qui est sensé favoriser les meilleurs individus même si les individus sélectionnés pour participer au tournoi sont choisis de manière aléatoire.

CHAPITRE 3

MESURES ET PROCÉDURE EXPÉRIMENTALES

Les signatures vibratoires utilisées dans ce travail de mémoire proviennent de deux bancs d'essai différents :

- le premier montage utilisé est celui de l'université Case Western. Les signaux téléchargés de cette base de données ont été utilisés pour développer et valider les méthodes d'analyse des signatures vibratoires implémentés dans ce mémoire ;
- le second montage se trouve au laboratoire IFS de l'École Polytechnique de Montréal. Étant donné que le nombre de données disponibles sur la base de données de Case Western est insuffisant pour tester la fiabilité de la procédure de diagnostic, un montage temporaire a été emménagé pour permettre le test des roulements défectueux.

3.1 Base de données de l'Université Case Western

Les signaux utilisés dans cette section sont ceux qui proviennent de la base de données de l'université Case Western (Case Western Reserve University, CWRU). Les signaux disponibles dans cette base de données proviennent d'un banc d'essai expérimental composé d'un moteur électrique de 2 Hp chargé radialement par un dynamomètre

(voir Fig. 3.1a). Les roulements défectueux sont ceux qui supportent l'arbre principal à l'intérieur du moteur : un du côté du ventilateur (Fan End, FE) et l'autre du côté de l'accouplement (Drive End, DE).




FIG. 3.1: Banc d'essai expérimental utiliser à CWRU

Il est à noter que les roulements du côté DE et du côté FE ne sont pas identiques. Des défauts de différents diamètres (7, 14 et 21 mils) ont été introduits sur les bagues internes et externes ainsi que sur une des billes respectivement. Chaque mesure a été effectuée avec un seul roulement défectueux et un seul type de défaut. Au cours de chaque test des signaux d'accélération du moteur ont été mesurés aux deux extrémités de l'arbre. Les accéléromètres sont montés sur la boîtier externe du moteur. Les tests ont été menés avec le moteur tournant à différentes vitesses : 1797, 1772, 1750 et 1730 rpm. Des signaux ont été échantillonnés à une fréquence de 12 kHz pendant 10 secs.

	$BPFO/f_r$	$BPFI/f_r$	BSF/f_r
SKF 6205-2RS JEM (DE)	3.5848	5.4152	4.7135
SKF 6203-2RS JEM (FE)	3.0530	4.9469	3.9874

TAB. 3.1: Fréquences théoriques des défauts de roulement du montage CWRU

3.2 Banc d'essai du laboratoire IFS

Le banc d'essai utilisé est une adaptation du *Squeeze Film Damper*, SFD, qui se trouve au laboratoire de la chaire industrielle CRNSG/EACL/BWC en Interaction Fluide-structure de l'École Polytechnique de Montréal. Le design original du SFD conçu par Turgeon [Turgeon, 2007] a été modifié pour permettre le test d'un roulement défectueux. On a remplacé l'amortisseur avec film d'huile par un palier à semelles dans lequel est monté le roulement testé.

3.2.1 Description du banc d'essai

Le banc d'essai est composé d'un arbre conique en acier, supporté à ses extrémités par deux paliers de roulement. L'arbre est connecté au moteur par un accouplement rigide. Le roulement proche de l'accouplement est auto-alignant et il est monté libre, i.e. il peut *suivre* le désalignement angulaire permis par l'accouplement rigide. Le palier opposé contient le roulement testé et ce dernier est monté fixe. Le banc d'essai comprend aussi un roulement magnétique SKF qui permet d'appliquer une force radiale pouvant aller jusqu'à 5000N @ 1800 rpm sur l'arbre conique.




FIG. 3.2: Banc d'essai expérimental

Composantes	Spécifications techniques	Caractéristiques
Moteur	1 Hp 1750 rpm 60 Hz 1.2 amp	Moteur à induction à trois phases, TEFC
Accouplement	7/8 po à 1 ^{1/4} po	2 mâchoires + 1 élément flexible
Roulement coté moteur	SKF 2310 E2RS1TN9	Auto-alignant et auto-lubrifié, double rangée de billes, scellé
Roulement testé	SKF 1211 EKTN9	Auto-alignant, double rangée de billes, non-scellé

TAB. 3.2: Caractéristiques des composantes du montage expérimental

Le roulement magnétique est aussi muni de deux capteurs de déplacement positionnés à 90 deg l'un de l'autre. Ces capteurs sont utilisés lors du montage des roulements afin de contrôler le désalignement entre les deux paliers de roulements. De cette manière, on a pu maintenir un désalignement inférieur à $200\mu m$ dans les deux axes du roulement magnétique lors de tous les essais effectués. La vitesse du moteur est contrôlée par un variateur de fréquence qui règle la fréquence du réseau que reçoit le moteur. Le tableau 3.3 résume les fréquences de défauts des roulements du dispositif expérimental.

	$BPFO/f_r$	$BPFI/f_r$	BSF/f_r
SKF 2310 E2RS1TN9	5.36	7.64	5.47
SKF 1211 EKTN9	8.68	11.3	7.39

TAB. 3.3: Fréquences théoriques des défauts de roulement du montage SFD

3.2.2 Description des essais expérimentaux

Pour les essais expérimentaux, on dispose de quatre roulements skf 1211 pour chacune des quatre classes suivantes :

- normal, *no* : le roulement testé est en bon état, aucun défaut n'est présent sur ces composantes ;
- inner race, *ir* : un défaut local a été pratiqué sur la surface de la bague interne qui est en contact avec une rangée de billes, Fig. 3.4 ;
- outer race, *or* : un défaut local a été introduit sur la surface de la bague externe

qui est en contact avec une rangée de billes, Fig. 3.3 ;

– ball, *bl* : un défaut local a été introduit sur une des billes du roulement, Fig. 3.5.

Les campagnes de mesures expérimentales ont été menées séparément pour chaque type de défaut de roulement.




FIG. 3.3: Simulation des défaut sur le roulement SKF 1211 - Défaut de bague externe

La taille, la forme et la profondeur des défauts pratiqués sur les composantes du roulement n'ont pu être contrôlées adéquatement. L'approche adoptée à cet effet est celle par essai erreur : la composante est endommagée jusqu'à ce que l'on puisse distinguer clairement la fréquence caractéristique du défaut. Dans le cas du défaut de bague externe, un seul essai fut nécessaire. Même si le défaut pratiqué est de petite




FIG. 3.4: Simulation des défaut sur le roulement SKF 1211 - Défaut de bague interne taille, le fait de le positionner dans la zone de chargement du roulement est suffisant pour générer des impulsions dans la signature vibratoire. Par contre pour les défaut de bague interne et de bille, on a du augmenter graduellement la taille du défaut pratiqué afin d'obtenir un signal satisfaisant.

3.3 Acquisition des données

Les signatures vibratoires ont été mesurées à l'aide de deux accéléromètres PCB 353B33 ICP/IEPE. Ils sont positionnés au dessus de chaque palier de roulement.




FIG. 3.5: Simulation des défaut sur le roulement SKF 1211 - Défaut de bille

Les accéléromètres sont fixes au palier en utilisant de la cire d'abeille. On a utilisé le système d'acquisition OROS de la chaire pour échantillonner les signaux à une fréquence de 32.768 kHz pendant 20 secs, avec une précision de 24 bits par canal et une bande passante de 12.8 kHz. Les mesures expérimentales ont été faites à différentes vitesses : 1800 rpm, 1500 rpm, 1200rpm, 900 rpm, 600 rpm. Pour chaque vitesse, on a enregistré 20 signaux différents, soit un total de 500 signaux disponibles (100 signaux par classe *ir*, *no*, *bl*, *or@6h* et *or@3h*) pour tester la fiabilité de la procédure de diagnostic.

Durant les essais expérimentaux, nous n'avons pas utilisé les capteurs de déplacement qui se trouvent à l'intérieur du roulement magnétique. Nous n'avons pas non plus appliqué de force radiale à l'arbre, car nos essais préliminaires ont montré que seul le poids de l'arbre, env. 321 N, était suffisant pour mettre en évidence la présence d'un défaut sur chaque composante du roulement. Comme dans le cas des signaux de la base de données Case Western, chaque mesure vibratoire a été effectuée en utilisant deux accéléromètres : un positionné à 12 h sur le palier du roulement SKF 2310 (canal 1), un sur le palier du roulement SKF 1211 (canal 2). On pourra ainsi étudier l'impact du chemin de transmission du signal sur la classification.

3.4 Analyse modale expérimentale

Avant de débiter les campagnes de mesures, on a procédé à l'analyse modale du banc d'essai expérimental pour trouver les fréquences naturelles du banc d'essai. On pourra ainsi les identifier dans les spectres de vibration dont on se servira plus tard. En théorie, ces fréquences seront modulées par les fréquences de défaut de roulement dans les spectres. L'analyse modale expérimentale a été faite en utilisant un marteau choc à embout dur, 10 points d'impédance ont été positionnés sur l'arbre conique. Les résultats détaillés de l'analyse de la réponse impulsionnelle à chaque point de mesure sont présentés à l'annexe II. En résumé, on a localisé une fréquence naturelle dans les intervalles suivants dans la majorité des points de mesure : entre 133 et 137.9 Hz,

199.9 et 200.7 Hz, 6347 et 6367 Hz. On s'abstient ici de citer les autres fréquences rapportées au tableau II.1 car elles n'apparaissent pas dans la majorité des points de mesure. On les considère comme des fréquences de résonance locales.

CHAPITRE 4

APPLICATION DES MÉTHODES D'ANALYSE & RÉSULTATS

On présente dans ce chapitre l'application des méthodes d'analyse traitées au chapitre 2 sur les mesures expérimentales rapportées au chapitre 3. Premièrement, une analyse préliminaire des signatures vibratoires du banc d'essai SFD est présentée afin de s'assurer que ces signaux mettent en évidence les défauts de roulement que l'on tente d'identifier. Ensuite, vient le développement de la procédure de diagnostic : on montre comment les méthodes d'analyse de signatures vibratoires, i.e. la synchronisation temporelle moyennée et le kurtosis spectral, permettent de mettre en évidence les défauts de roulement. À cet effet, on présentera quelques résultats précédemment obtenus pour justifier l'utilisation de ces méthodes dans la procédure de diagnostic. On étudie par la suite l'impact de la dimension de l'espace de représentation des données et du chemin de transmission du signal sur les performances de la méthode de reconnaissance de formes.

4.1 Analyse préliminaire des signatures vibratoires du SFD

On présente dans cette section, l'analyse spectrale des signatures vibratoires mesurées sur le banc d'essai. Sauf indication contraire, on calcule la densité spectrale des signatures vibratoires en utilisant la méthode du périodogramme moyenné de Welch : fenêtre de Hanning de longueur égale au 1/20 de la longueur totale du signal et un recouvrement de 75%.

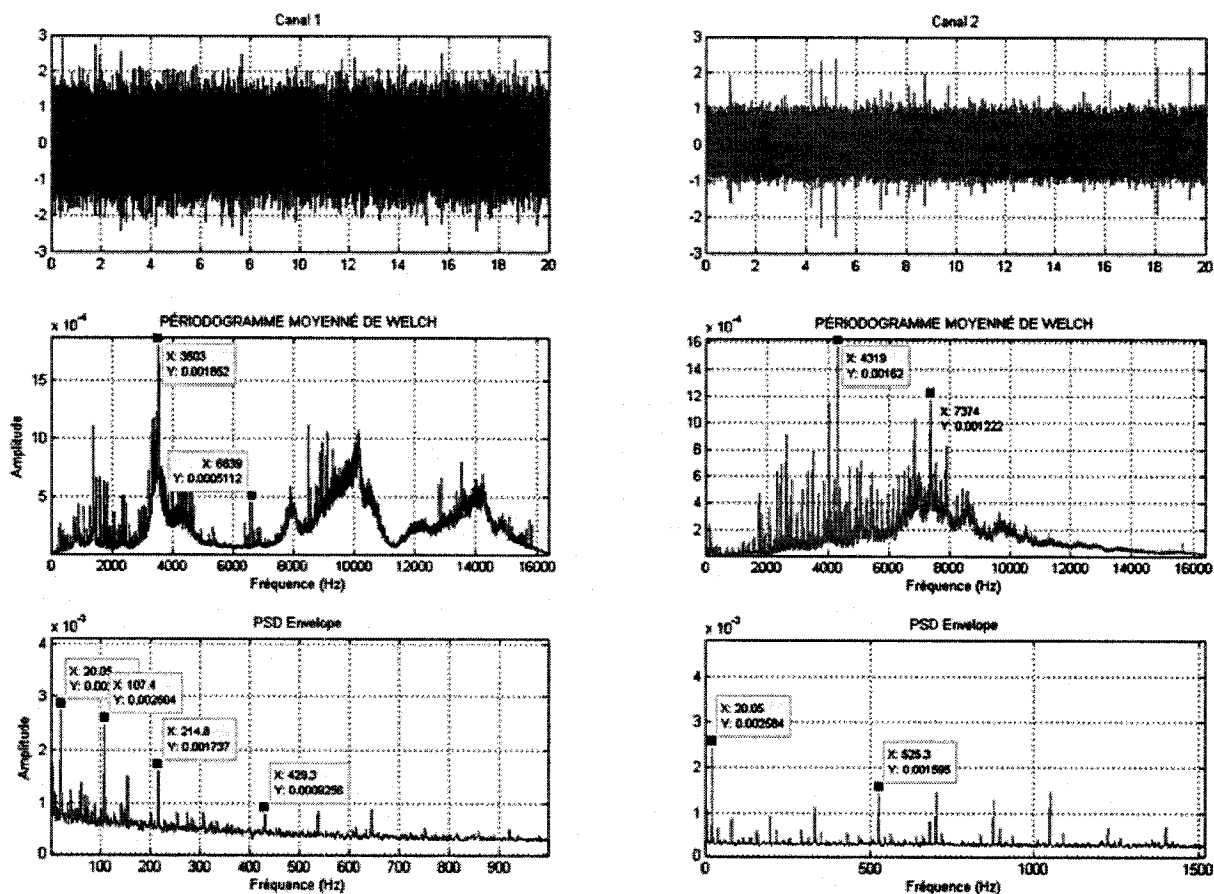


FIG. 4.1: Roulement SKF 1211 sans défaut, 1200 rpm

La figure 4.1 montre les résultats de l'analyse spectrale des signatures vibratoires

mesurées avec le roulement SKF 1211 en bon état. Dans les deux spectres enveloppe, on distingue la fréquence de rotation de l'arbre à 20.05 Hz. Dans le spectre du signal enveloppe du canal 1, on observe aussi la présence de la fréquence 107.4 Hz et de ses harmoniques (214.8 Hz, 429.3 Hz, etc.). Si on se réfère au tableau 3.3, on se rend compte que 107.4 Hz correspond au *BPFO* du roulement SKF 2310. Cela indique qu'il semble exister un défaut sur la bague externe de ce roulement. Il serait risqué d'affirmer ici qu'il existe effectivement un défaut de bague externe sur le roulement SKF 2310 sur la base de ces observations. Le roulement SKF 2310 est supposé être en bon état, étant donné que le SFD est un banc expérimental *neuf* qui venait tout juste d'être monté. Les expériences sur les défauts de roulement sont les premières à avoir été faites sur ce banc d'essai. Cette incertitude confirme la difficulté liée à l'interprétation des résultats des analyses des signatures vibratoires. Avec l'apparition du BPFO dans le spectre enveloppe du canal 1, nous sommes dans l'une des situations suivantes :

- soit le roulement SKF 2310 est effectivement défectueux
- soit l'apparition du BPFO est fortuite. Cela est peut être due à une configuration particulière au niveau du montage ou de l'interaction entre les composantes du banc d'essai. Une des sources possibles est le battement entre les lèvres de l'accouplement et l'élastomère rigide.

Une inspection visuelle de la bague externe de ce roulement, doit donc être faite avant de se prononcer définitivement. Elle n'a pu être faite au cours de notre étude car le

SKF 2310 est un roulement scellé, on ne peut séparer ses composantes sans le détruire.

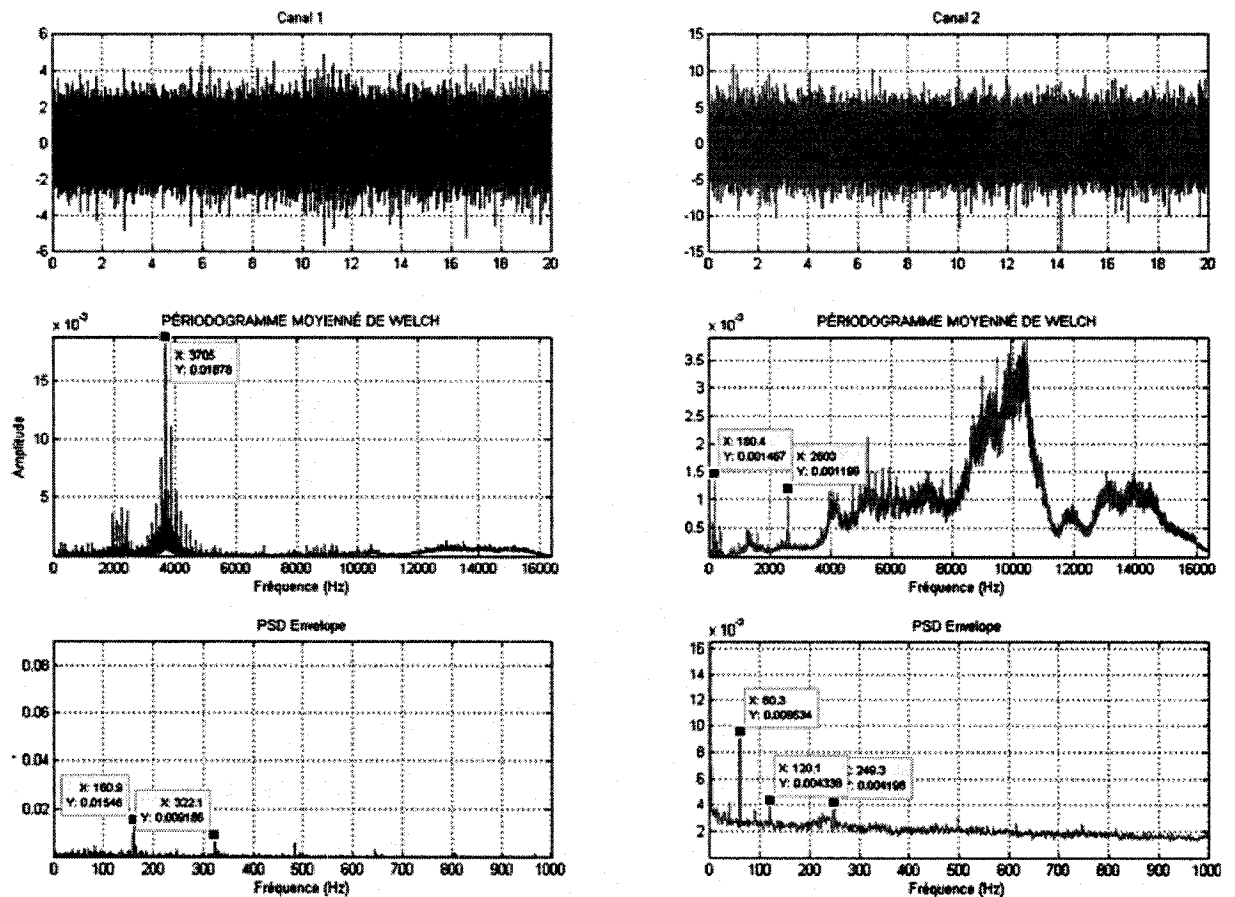


FIG. 4.2: Roulement avec bille défectueuse, 1800 rpm

La figure 4.2 montre les résultats de l'analyse spectrale des signatures vibratoires mesurées avec le roulement SKF 1211 dont une des billes est défectueuse. Dans le spectre enveloppe du canal 2, la seconde harmonique (60 Hz) de la vitesse de rotation (30 Hz) est la fréquence maximale. On explique cela par le désalignement (de 200 μm max.) permanent qui existe entre les deux paliers de roulement. Cela se confirme avec la présence de la quatrième harmonique de la fréquence de rotation. Le *BSF* théorique est de 221.7 Hz, mais il se manifeste ici à 249.3 Hz, probablement à cause

de la nature aléatoire du phénomène. Rappelons que la valeur théorique du *BSF* ne tient pas compte du glissement dû la lubrification ni du fait que le mouvement de la bille autour de son axe n'est pas contrôlé. Dans le spectre enveloppe du canal 1, on note toujours la présence du *BPFO* théorique du roulement SKF 2310, i.e. 160.9 Hz et sa seconde harmonique 322.1 Hz. La présence d'un défaut de bille du roulement SKF 1211 n'y est pas décelable.

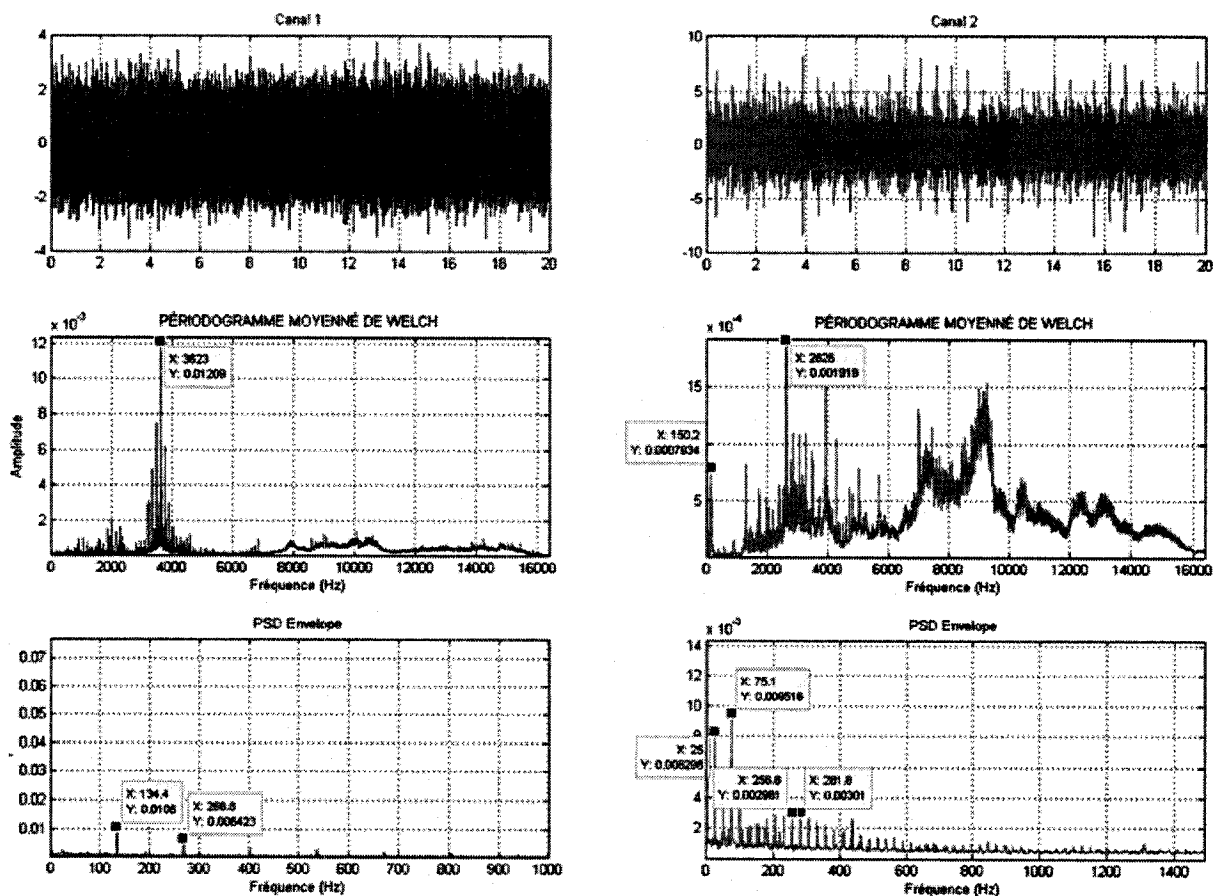


FIG. 4.3: Roulement avec bague interne défectueuse, 1500 rpm

Dans le cas d'un défaut de bague interne dans le roulement SKF 1211, le spectre enveloppe du canal 2 de la figure 4.3 contient beaucoup plus de lignes de fréquences

que dans les cas précédents. On observe la fréquence de rotation de l'arbre i.e. 25 Hz et ses quatre premières harmoniques. Le *BPFI* se manifeste à la fréquence 281.3 Hz, la valeur théorique étant 282.5 Hz. Le phénomène de modulation est bien visible dans le spectre enveloppe, où on observe des fréquences qui sont espacées régulièrement selon un écart égal à la vitesse de rotation de l'arbre. Dans le spectre enveloppe du canal 1, le *BPFO* du roulement SKF 2310 est encore bien présent, 134.4 Hz et sa seconde harmonique 268.8 Hz. Ce spectre enveloppe ne permet pas de mettre en évidence la présence d'un défaut de bague interne sur le roulement SKF 1211.

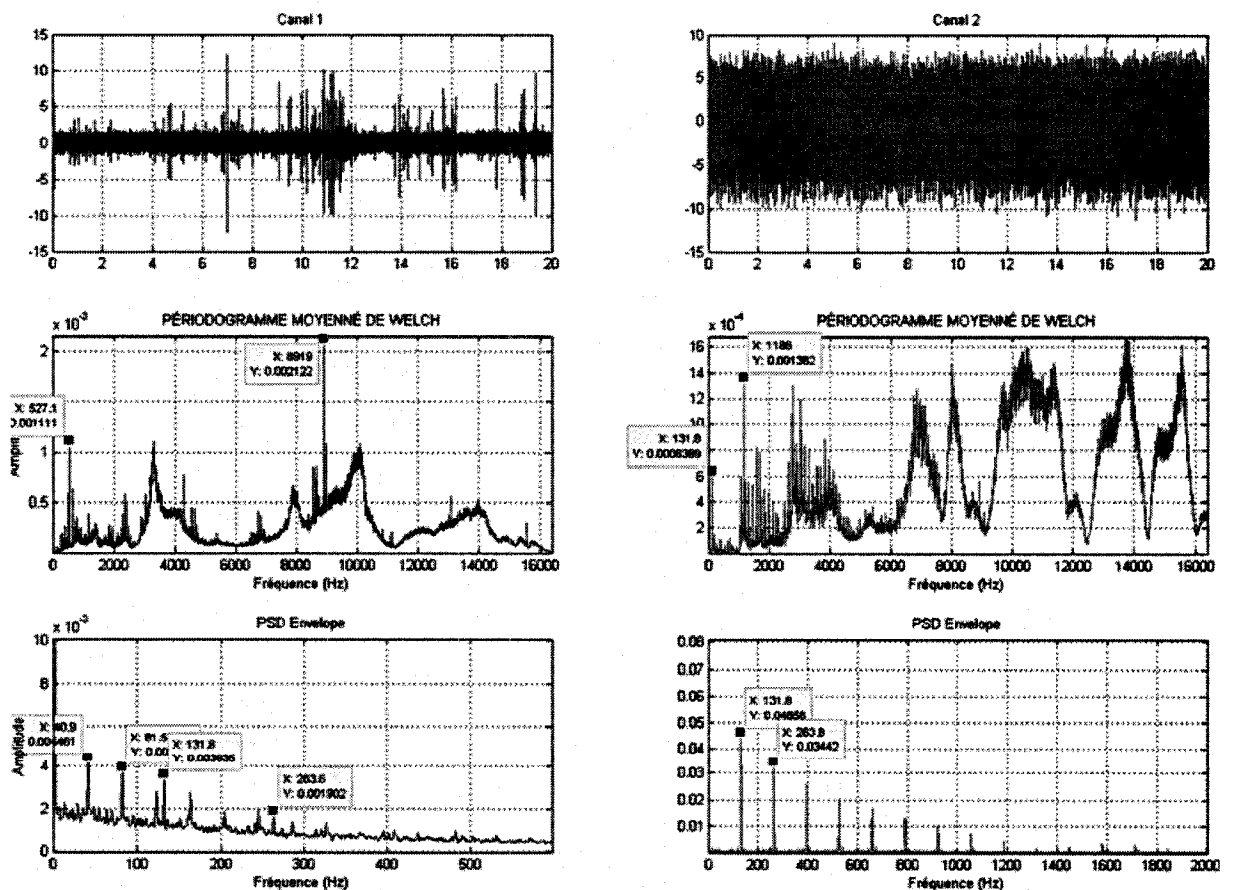


FIG. 4.4: Roulement avec une bague externe défectueuse, défaut positionné à 6h, 900 rpm

Dans le cas d'un défaut de bague externe positionné à $6h$ dans le roulement SKF 1211, le spectre enveloppe du canal 2 de la figure 4.4 met en évidence le *BPFO* du roulement SKF 1211, i.e. 131.8 Hz ainsi que ses 6 premières harmoniques. Dans le spectre enveloppe du canal 1, le *BPFO* du roulement SKF 2310, i.e. 81.5 Hz apparaît une fois de plus. Cependant, contrairement aux cas précédents, on observe aussi la présence du *BPFO* du roulement SKF 1211. La figure 4.5 montre les résultats obtenus avec l'analyse des signatures vibratoires pour un défaut de bague externe positionné à $3h$ par rapport à la zone de chargement. Dans ce cas, le *BPFO* du roulement SKF 1211 n'est plus visible dans le spectre enveloppe du signal mesuré par l'accéléromètre du canal 1. Aussi, même si les vitesses de rotation diffèrent entre les deux signatures vibratoires présentées, on note quand même une forte différence en amplitude crête à crête dans la réponse mesurée au canal 2. Cela met en évidence l'impact de la zone de chargement du roulement sur la signature vibratoire d'un roulement avec bague externe défectueuse. On verra plus loin si la zone de chargement a une influence sur la capacité à généraliser des frontières de classification.

4.2 Application des méthodes d'analyse des signatures vibratoires

Dans cette section, on présente l'application des méthodes d'analyse des signatures vibratoires sur les signaux provenant des deux bancs d'essai présentés au chapitre précédent.

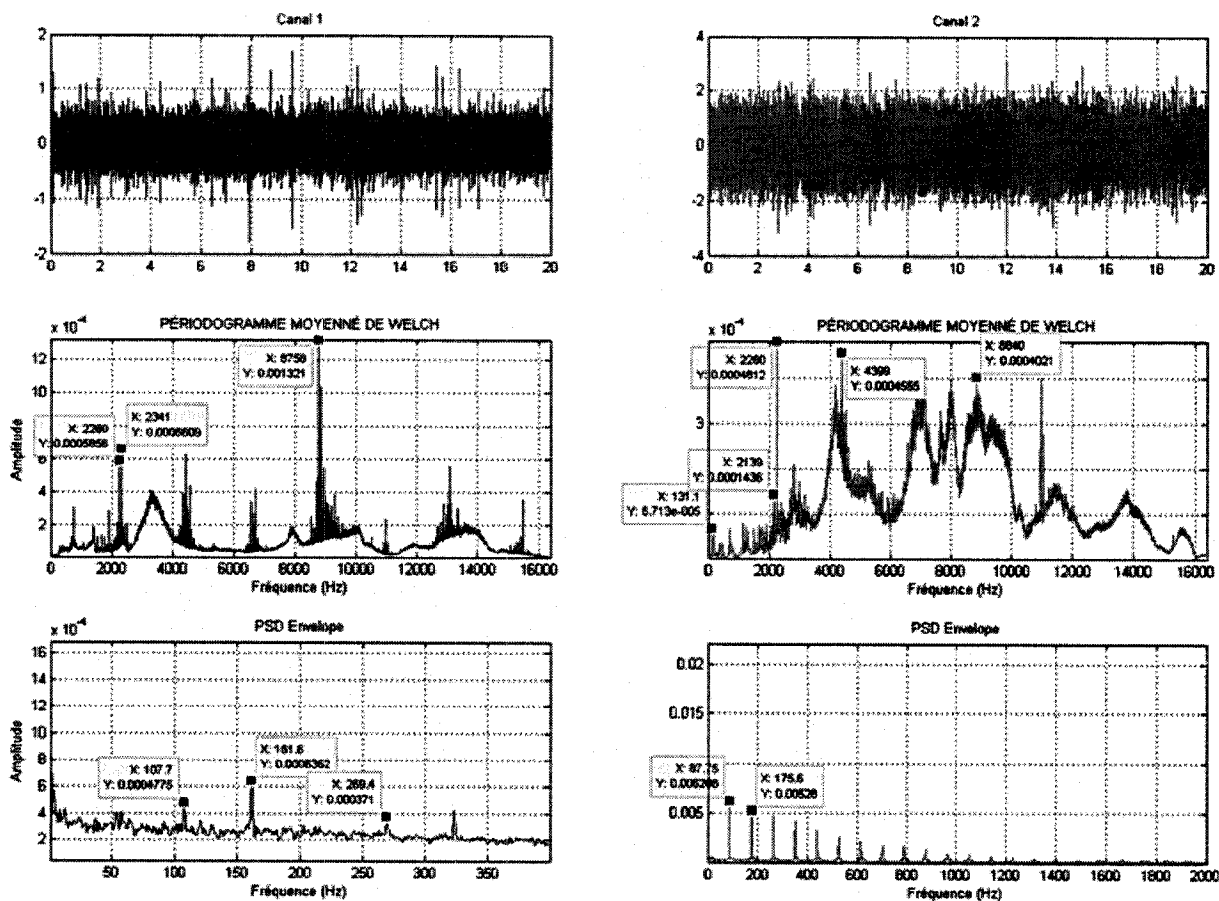


FIG. 4.5: Roulement avec une bague externe défectueuse, défaut positionné à 3h, 600 rpm

4.2.1 Application du modèle de synchronisation temporelle proposé

La procédure de synchronisation temporelle moyennée proposée au chapitre 2 est testée avec les signaux téléchargés de la base de données CWRU. La figure 4.6 montre le périodogramme moyenné de Welch du signal DEirde021¹ ainsi que le spectre enveloppe calculé par la méthode de Hilbert. On note que les impulsions dues au défaut sont assez bien définies dans le signal temporel et le spectre enveloppe est suffisant

¹Voir Fig. 3.1b pour la signification

pour mettre en évidence le *BPMI* du roulement, soit 161.9 Hz. Notons que le *BPMI* est la fréquence prédominante du spectre enveloppe, suivi de la fréquence de rotation de l'arbre, 29.97 Hz. La figure 4.7 montre l'effet de la synchronisation temporelle moyennée sur le signal de vibration original. On note tout de suite la différence d'amplitude entre le TSA signal et le signal original. Cela provient du facteur $1/N$ dans l'équation du train d'impulsion (2.8). Pour rendre la comparaison plus facile, on a modifié ce facteur pour que le TSA-signal soit de même amplitude que le signal original.

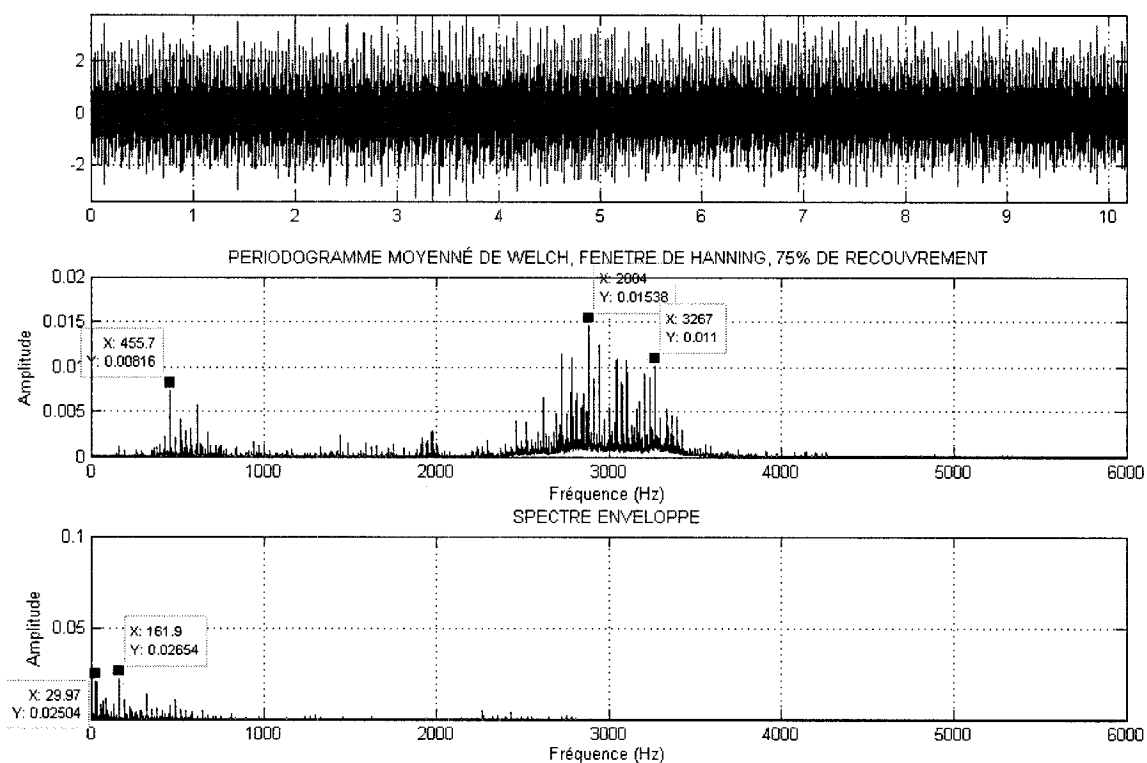


FIG. 4.6: Signal original, défaut de 21mils sur la bague interne du roulement DE, 1797 rpm

En comparant les figures et 4.6 et 4.8, on note une différence entre les signaux tem-




FIG. 4.7: TSA-Signal, défaut de 21mils sur la bague interne du roulement DE, 1797 rpm

porels. Si on suppose que le signal prafit serait composé d'impulsions espacées à la fréquence du défaut, alors la zone délimitée par les traits interrompus correspondrait à du bruit. Ainsi cette zone a une plus faible largeur dans la figure 4.6 que dans la figure 4.8. En d'autres termes, les impulsions sont encore mieux définies dans le TSA-signal qu'elles ne le sont dans le signal original. De plus, les contenus fréquentiels des deux signaux sont presque identiques, preuve que la STM ne change pas la nature du signal original. La seule différence entre les deux signaux vient de l'amplitude de la fréquence de rotation (29.97 Hz) de l'arbre dans le spectre enveloppe. Dans le spectre enveloppe du TSA-signal, 29.97 Hz est la fréquence maximale du signal, suivie de

161.8 Hz le BPFI du roulement. Cette augmentation d'amplitude est causée par le train d'impulsions avec lequel on a synchronisé le signal original.

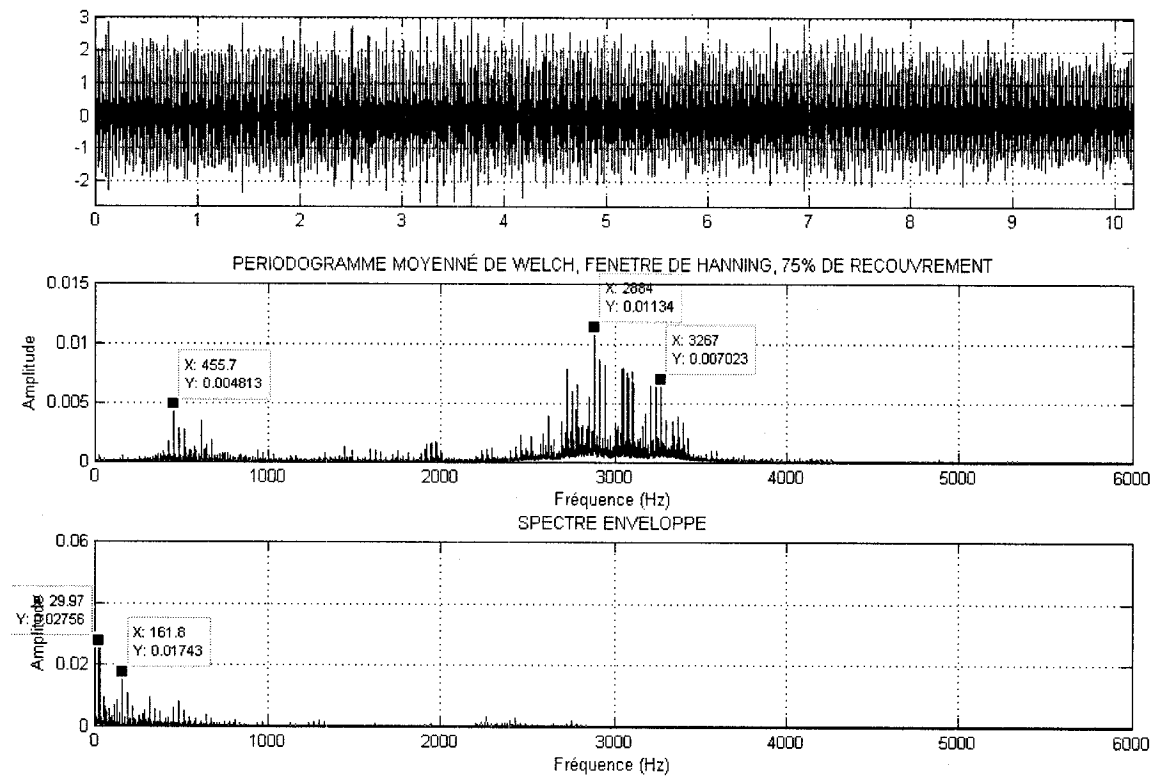


FIG. 4.8: TSA-Signal de même amplitude que le signal original

La figure 4.9 montre les résultats de la STM en utilisant la fréquence relative de l'arbre par rapport à la cage comme fréquence fondamentale du train d'impulsion. On note que le signal temporel de la figure 4.9 contient moins d'impulsions que celui de la figure 4.8, et que ces impulsions y sont mieux définies. Cependant, le problème avec un tel choix de fréquence de synchronisation se trouve dans le spectre enveloppe. La fréquence relative de la rotation de l'arbre par rapport à la cage, 17.96 Hz y est présente avec une amplitude non-négligeable. Elle provient essentiellement du

train d'impulsions qui a été défini à cette fréquence. Cependant, cette fréquence est d'amplitude négligeable dans le spectre du signal original. Cela signifie qu'on a modifié le signal original avec ce choix de fréquence de synchronisation. Or notre but est d'extraire la composante impulsive du signal, sans modifier son contenu fréquentiel.




FIG. 4.9: TSA-Signal, synchronisation selon le modèle de McFadden & Toozhy

Ces résultats montrent qu'en choisissant la fréquence de rotation de l'arbre comme fréquence de synchronisation, le contenu fréquentiel du signal reste inchangé. Cependant comme cette fréquence est définie à la fois dans le signal original et le train d'impulsions, son amplitude dans le spectre enveloppe sera modifiée. Par contre, en choisissant la fréquence de l'arbre par rapport à la cage comme fréquence de synchro-

nisation, le contenu fréquentiel du signal change. Cela montre l'importance de vérifier le contenu fréquentiel du signal avant de calculer le TSA-signal avec la procédure de synchronisation temporelle moyennée proposée dans ce mémoire.

4.2.2 Utilisation du kurtosis spectral pour l'identification des défauts de roulements

Dans cette section, on présente les résultats de l'analyse des signaux de vibration de la base de données CWRU par la méthode du kurtosis spectral. On utilise à cet effet le *kurtogram*, un algorithme de calcul proposé par Antoni [Antoni, 2007a]. Cette routine *Fast-Kurtogram* permet de calculer la distribution du kurtosis spectral en utilisant la STFT ou une décomposition en filtre d'ondelettes. Contrairement aux structures arborescentes de décomposition qui divisent le plan en utilisant une grille dyadique, l'algorithme de calcul d'Antoni repose sur une structure arborescente d'échelle 1/3 pour une meilleure résolution.

La figure 4.10 montre la distribution du kurtosis spectral du signal FEirfe014. Elle montre que pour ce signal, la partie impulsive du signal se trouve autour de 3375 Hz, où le kurtosis spectral est maximal $SK_{max} = 0.5$.

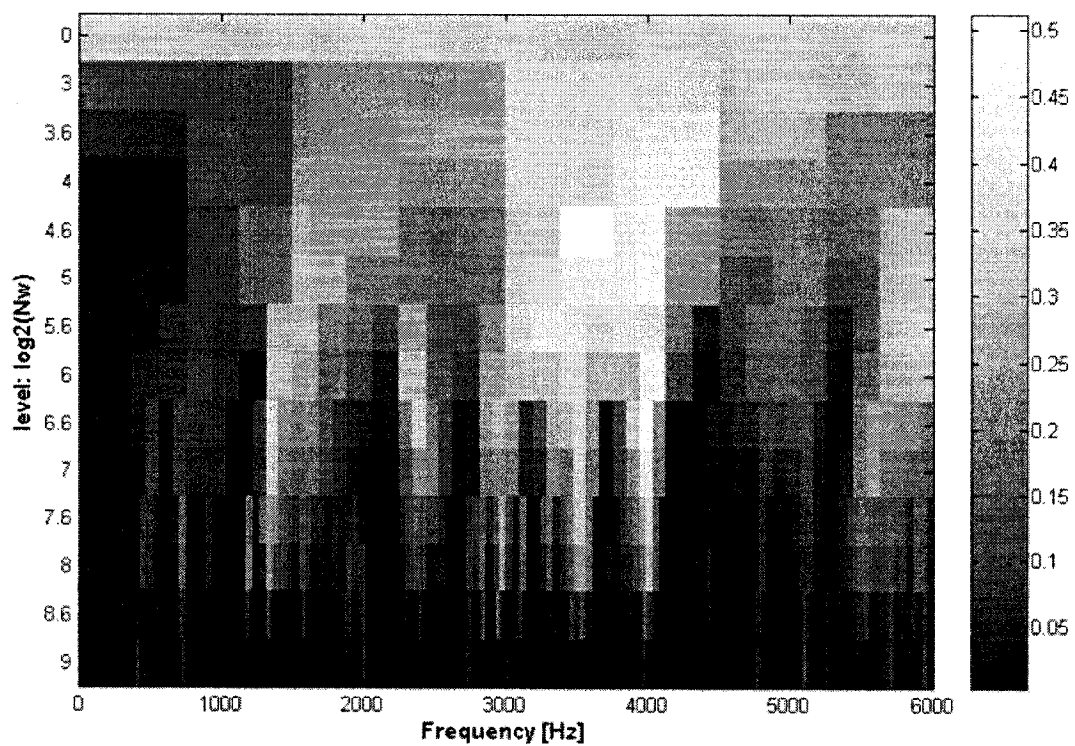


FIG. 4.10: Distribution du kurtosis spectral du signal FEirfe014, 1772 rpm




FIG. 4.11: Spectre enveloppe de FEirfe014 filtre passe-bande de largeur $2^{4.5}$ centré à 3375 Hz

Cette distribution indique aussi la largeur du filtre passe-bande pour effectuer une démodulation appropriée. Ainsi la figure 4.11 montre les résultats de la démodulation autour de 3375 Hz avec un filtre de largeur $2^{4.5}$. On voit clairement le *BPFI* du roulement défectueux (145.8 Hz) ainsi que ses harmoniques. L'effet de la modulation de la fréquence, i.e. bandes latérales espacées à la fréquence de rotation de l'arbre, de rotation de l'arbre est aussi visible dans le spectre enveloppe. La modulation observée ici vient du fait que la bague interne tourne à la même vitesse de rotation que l'arbre. La fréquence de rotation de l'arbre joue donc le rôle de fréquence porteuse et elle se manifestera dans le spectre enveloppe par des bandes latérales autour du BPFI, i.e. présence de fréquence du type $m * BPFI \pm n * f_r$.

On obtient des résultats similaires en analysant le signal SKenvFEorde014 de la même manière. La figure 4.13 montre que la partie impulsive du signal se trouve autour de la fréquence 4875 Hz, et en filtrant le signal avec un filtre passe-bande de largeur $2^{4.5}$, on met en évidence le *BPFO* (91.82Hz), ses bandes latérales et ses harmoniques dans le spectre enveloppe. La modulation observée dans ce cas vient de la variation de la zone de chargement du roulement. Cette variation se fait en fonction de la fréquence de rotation de l'arbre.




FIG. 4.12: Distribution du kurtosis spectral du signal FEorde014, 1797 rpm




FIG. 4.13: Spectre enveloppe FEorde014 filtre passe-bande de largeur $2^{4.5}$ centré à 4875 Hz

Les résultats présentés jusqu'à présent démontrent l'efficacité de l'analyse du kurtosis spectral pour étudier les signatures vibratoires des roulements ayant des défauts sur une bague interne ou externe respectivement. Cependant, il en est tout autrement pour les roulements dont les défauts sont sur les billes. La figure 4.14 montre la distribution du kurtosis spectral du signal DEblde007.




FIG. 4.14: Distribution du kurtosis spectral du signal DEblde007, 1797 rpm

Cette figure montre que le kurtosis spectral est maximal autour de la fréquence 3281 Hz et qu'un filtre passe-bande de largeur 2^8 serait suffisant pour mettre en évidence cette composante impulsive. Mais comme on peut le constater à la figure 4.15, le spectre enveloppe ne contient pas une valeur proche du *BPFR* théorique du roulement étudié. On y observe plutôt la fréquence de rotation de l'arbre et ses harmoniques.

Notons aussi que le spectre est plat et avec une amplitude non négligeable autour de la fréquence de défaut de la cage. Cependant, si on change la fréquence autour de laquelle la démodulation sera faite, on trouve qu'autour de 1687 Hz, avec un filtre de largeur 2^5 , on observerait 137.3 Hz qui est une valeur proche du *BPFR* théorique. Cet exemple est l'un des rares cas où l'on est parvenu à identifier une fréquence proche du *BPFR* théorique dans le spectre enveloppe.




FIG. 4.15: Spectre enveloppe DEblde007 filtre passe-bande de largeur 2^8 centré à 3281 Hz




FIG. 4.16: Spectre enveloppe de DEblde007 : filtre passe-bande de largeur 2^8 centré à 1687 Hz

En général, on a observé que l'analyse par le kurtosis spectral n'était pas toujours efficace pour mettre en évidence les défauts de billes. On explique cela par le fait que les signatures vibratoires des défauts de billes sont beaucoup plus aléatoires, que cyclostationnaire. L'effet combiné du glissement dû à la lubrification du roulement et

du sens de rotation arbitraire de la bille autour d'elle même engendre un mouvement qui est difficilement périodique.

4.2.3 Utilisation de l'ANC en détection des défauts de roulement

Les résultats des analyses précédentes montrent qu'il est difficile de détecter le défaut du roulement SKF 1211 en se basant sur l'analyse du signal mesuré au canal 1 du banc d'essai SFD. Une conclusion similaire peut aussi être faite en analysant les signaux de Case Western. Ces observations peuvent être expliquées par l'effet du chemin de transmission du signal de la source de vibration au point de mesure. En effet, les composantes du banc d'essai par lesquelles le signal de vibration est transmis agissent comme un filtre qui dans ce cas atténue l'amplitude des fréquences de défaut de roulement. Cependant, dans nos analyses, on a vu que ces fréquences n'étaient pas du tout visibles dans les spectres enveloppe, ce qui veut dire qu'elles sont *noyées* dans le bruit du système. Le but de l'ANC est donc d'enlever ce bruit qui corrompt le signal afin de mettre en évidence l'impact réel du chemin de transmission du signal.

Il existe plusieurs algorithmes de filtrage adaptatif en suppression de bruit. Notre modèle se base sur les définitions suivantes

- signal de référence, *refsig* : signal qui correspond à la source de vibration (signal 2)
- signal mesuré, *mesig* : signal de référence + bruit (signal 1)

- signal désiré, *desig* : signal que l'on devrait théoriquement obtenir au point de mesure 1 si on ne tenait compte que du chemin de transmission du signal. Il correspond à la convolution entre le signal 2 et la fonction de transfert entre les points de mesure 1 et 2.

D'après ces définitions, le bruit du système correspond à la différence entre le signal mesuré et le signal désiré. On a donc utilisé ces définition pour implémenter la méthode ANC sous Matlab en utilisant un algorithme de logique floue (fuzzy logic) pour calculer les coefficients du filtre adaptatif. On utilise la fonction *genfis* pour générer le modèle de logique floue à deux règles et un *pas* (step size) de 0.2. La fonction *anfis* permet faire l'apprentissage des coefficients du filtre de manière à ce que le bruit calculé par l'algorithme approxime bien la différence entre le signal mesuré et le signal désiré.

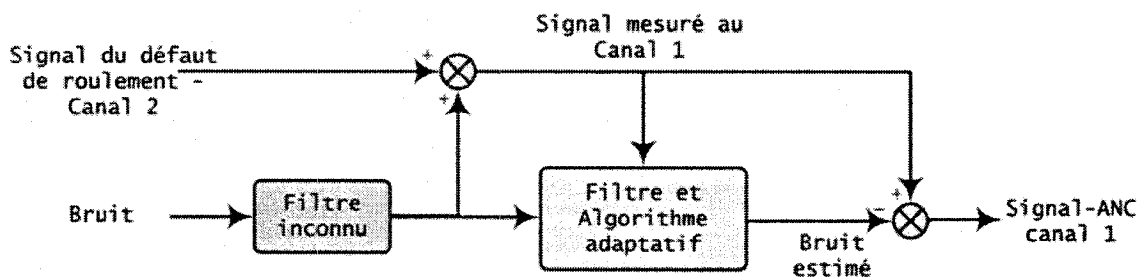


FIG. 4.17: Modèle proposé pour l'Adaptive Noise Cancellation

La figure 4.18 montre un exemple d'application du modèle de filtrage adaptatif de bruit proposé à la figure 4.17 et décrit ci-haut. Dans la première colonne (celle de gauche), on montre les analyses (signal temporel, spectre de puissance et spectre-enveloppe) du signal original mesuré au canal 1. Dans la troisième colonne (celle

de droite), on montre les résultats des analyses de ce signal après traitement par la méthode ANC proposée.

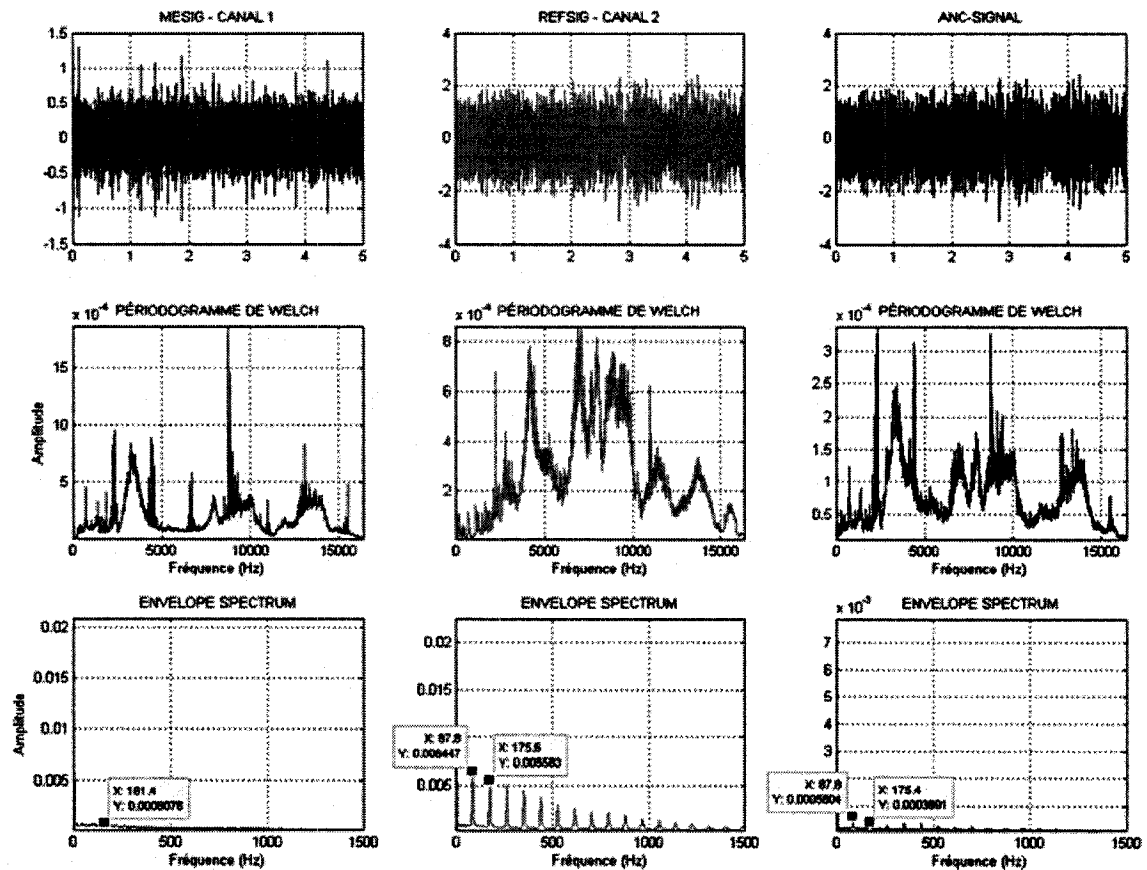


FIG. 4.18: Résultats de l'ANC sur le signal rpm0600or3h05

On observe que les contenus fréquentiels du signal mesurés aux capteurs 1 et 2 sont différents l'un de l'autre. Cette différence est clairement visible dans les spectres enveloppe où on observe le *BPFO* et ses harmoniques dans le signal 2, mais pas dans le signal 1. On note un étalement du spectre dans cette région, ce qui montre que ces fréquences sont confondues avec le bruit du système.

Par contre dans le spectre enveloppe du signal-ANC, le *BPFO* et ses harmoniques

sont visibles mais sont de plus faible amplitude. Cela est dû à l'effet du filtrage du signal par son chemin de transmission du canal 1 au canal 2. Dans le montage SFD, l'arbre conique est la composante principale par laquelle le signal est transmis. Ces résultats démontrent qu'il est possible d'*isoler* l'impact du chemin de transmission du signal du bruit environnant du système. Nous verrons plus loin si cela a un impact sur la capacité à généraliser des frontières de classification.

4.3 Développement de la procédure de diagnostic

Suite aux résultats obtenus en utilisant les méthodes d'analyse des signaux de vibration, on étudie dans cette section à la combinaison entre ces méthodes d'analyse et les méthodes d'apprentissage statistique pour rendre plus fiable la détection des défauts de roulement.

Il est évident qu'on ne peut utiliser les signaux bruts de vibration comme vecteurs d'apprentissage, étant donnée leur grande taille. L'utilisation d'une méthode d'extraction de paramètres s'impose. C'est donc à ce niveau qu'apparaît la combinaison entre les méthodes d'analyse de signatures vibratoires et les méthodes d'apprentissage statistiques. On utilise les premières pour extraire des paramètres qui quantifient le niveau et la sévérité des vibrations. Ces paramètres permettent de représenter l'état de la machine dans un espace de grande dimension, dans lequel l'algorithme

d'apprentissage sera implémenté. La difficulté à ce niveau réside dans le choix des indices de vibration et dans celui des paramètres de l'algorithme d'apprentissage. On a étudié trois procédures d'extraction de paramètres. Les principaux résultats de chacune d'elles sont présentés dans cette section.

Notre but est de combiner des méthodes d'analyse de signatures vibratoires, d'extraction de paramètres et d'apprentissage statistiques pour développer notre procédure de diagnostic. L'amélioration de cette procédure a été continue. On présente ici ses étapes principales. Les signaux utilisés proviennent de la base de données de l'université Case Western.

4.3.1 Description de la procédure d'apprentissage

La procédure d'apprentissage consiste essentiellement à trouver la frontière optimale pour chaque cas de classification. Dans ce mémoire, l'algorithme de classification utilisé est le *nu-soft margin* avec $\nu = 0.2$ et on utilise une fonction à noyau polynomial de degré 2 pour projeter les données dans un espace de plus grande dimension. Pour éviter les cas de sous- ou de sur-apprentissage, on adopte une procédure pour le choix des données d'apprentissage et de test.

Signaux mesurés sur banc d'essai de Polytechnique. On divise les données (100 données par classe pour le montage SFD) en trois groupes distincts :

- les données d'apprentissage (25% des données par classe) : elles sont utilisées pour résoudre le problème d'optimisation. Sur 100 données disponibles, on utilise au maximum 25 données par classe pour construire la frontière. À chaque fois qu'on augmente le nombre de données d'apprentissage, on choisit aléatoirement les données qui seront utilisées lors de l'apprentissage ;
- les données de validation (25% des données par classe) : afin d'éviter les problèmes de sur-apprentissage sur les données d'apprentissage, chaque frontière sera testée avec des données qui n'ont pas été utilisées pendant le processus d'apprentissage. Cela permet d'améliorer la capacité à généraliser des frontières construites. La frontière optimale est celle qui aura le meilleur pourcentage de classification sur les données de validation ;
- les données test (50% des données par classe) : elles servent à tester la capacité à généraliser des frontières optimales trouvées avec les données de validation. Ce sont ces résultats de classification que l'on utilise pour évaluer la capacité à généraliser des frontières.

Signaux provenant de la base de donnée CWRU. La base de données de Case Western ne contient pas assez de signaux pour permettre une telle répartition. Dans ces cas, on n'effectue pas de validation pendant l'apprentissage. Le nombre maximal de données par classes retenues pour l'apprentissage est fixé à 25.

Dans les deux cas, l'apprentissage est composé d'une boucle *for* primaire et d'une

autre boucle *for* secondaire. Dans la boucle primaire, on itère sur le nombre de données par classe, i.e. $k = 1 \dots 25$ données, alors que dans la boucle secondaire, on réalise plusieurs fois l'apprentissage en faisant varier les données retenues. Cette deuxième boucle est implémentée en référence à la logique des méthodes des ensembles actifs : on sait qu'il existe une combinaison de données d'apprentissage qui permettent de minimiser l'erreur sur les données de validation. On fait 100 tests dans la seconde boucle. L'apprentissage prend fin dès qu'on atteint un résultat de classification de 100% sur les données de validation. Dans le cas contraire, on arrête l'apprentissage lorsqu'on atteint le nombre maximal de données par classe.

4.3.2 Combinaison de la Synchronisation Temporelle Moyennée avec les Support Vector Machine

Dans l'article [Komgom, 2007a], on a combiné la synchronisation temporelle moyennée et les support vector machines pour l'identification de la défaillance des roulements à billes. La figure 4.19 décrit la procédure d'extraction des paramètres qui a été utilisée pour construire les données d'apprentissage.

On a utilisé l'algorithme *nu-svm*, avec $\nu = 0.2$ pour construire les frontières. On utilise une fonction polynomiale de degré 2 comme noyau de la transformation vers l'espace de grande dimension. Afin d'avoir plus de signaux pour l'apprentissage et les tests,




FIG. 4.19: Extraction des paramètres implémentée dans l'article de conférence [Komgom, 2007a]

on a divisé chaque signal de 10 secs de la base de données CWRU en trois signaux de durée identiques. Cela nous a permis de disposer de 33 signaux avec un défaut de bague interne et de bille, et 69 signaux pour un défaut de bague externe². On utilise au maximum 20 signaux par classe de défaut lors du processus d'apprentissage. On adopte la nomenclature suivante pour définir les frontières de classification

- *blirBound* : frontière de classification entre un défaut de bille défectueuse (bl) et un défaut de bague interne (ir) ;
- *blorBound* : frontière de classification entre un défaut de bille défectueuse (bl) et un défaut de bague externe (or) ;
- *irorBound* : frontière de classification entre un défaut de bague interne (ir) et un défaut de bague externe (or).

Étant donné la configuration des signaux de la base de données Case Western, on a eu la possibilité de tester l'impact du chemin de transmission du signal sur la capacité

²Dans ce cas, on a considéré les signaux pris lorsque le défaut sur la bague externe est positionné à 3h, 6h et 12h dans la même classe

à généraliser des frontières de classification. On rapporte au tableau 4.1 quelques résultats de classification obtenus.

	DE...de	DE...fe		FE...de	FE...fe
DE...de	98.3%	56.9%	FE...de	97.5%	87.7%
De...fe	47.3%	100%	Fe...fe	75.8%	100%
(a) blurBound, DE défectueux			(b) blurBound, FE défectueux		
	DE...de	DE...fe		FE...de	FE...fe
DE...de	95.5%	58.3%	FE...de	94.9%	88.6%
De...fe	65.8%	100%	Fe...fe	86%	98.65%
(c) blurBound, DE défectueux			(d) blurBound, FE défectueux		
	DE...de	DE...fe		FE...de	FE...fe
DE...de	95.24%	68.3%	FE...de	100%	63.2%
De...fe	69.2%	98.8%	Fe...fe	71%	98.4%
(e) irorBound, DE défectueux			(f) irorBound, FE défectueux		

TAB. 4.1: Impact du chemin de transmission du signal sur la généralisation des frontières SVM, [Komgom, 2007a]

Le tableau 4.1a montre les résultats de classification obtenus avec la frontière de classification entre les signaux ayant une bille défectueuse et une bague interne défectueuse. La première colonne identifie l'origine des signaux utilisés pendant l'apprentissage, et la première ligne, ceux utilisés pour tester la frontière. Ainsi dans la diagonale principale, les signaux utilisés pendant l'apprentissage et pendant les tests proviennent du même accéléromètre, alors que dans la diagonale opposée les signaux d'apprentissage et de test sont enregistrés avec un accéléromètre différent. On observe que la capacité à généraliser des classificateurs est supérieure à 95% dans tous les cas où

les signaux test et d'apprentissage sont mesurés avec le même capteur, i.e. le chemin de transmission est le même. Par contre lorsque le chemin de transmission du signal varie, la capacité à généraliser des frontières décroît et est même inférieure à 50% dans certains cas.

4.3.3 Combinaison de la Synchronisation Temporelle Moyennée avec l'analyse en composantes Indépendantes et les Support Vector Machine

Suite aux résultats précédents, on a tenté par la suite d'améliorer les résultats de classification lorsque les chemins de transmission des signaux d'apprentissage et de test diffèrent. Notre but principal est de trouver un moyen de mettre en évidence l'information de la défaillance qui est contenue dans les signaux mais qui est atténuée par le chemin de transmission du signal. Suite aux résultats infructueux obtenus avec l'analyse en composantes principales, on a opté pour l'analyse en composantes indépendantes [Hyvarinen, 2000, Hyvarinen, 2001]. On utilise la même procédure d'extraction des paramètres que précédemment Fig. 4.19. Ensuite, on projette les vecteurs de données dans un espace de dimension 16 formés des composantes indépendantes calculés en utilisant l'algorithme *FastICA* développé par Hyvarinen [Hyvarinen, 2000]. Les résultats de l'analyse ont été présentés dans l'article de conférence [Komgom, 2007b].

En comparant les résultats des tableaux 4.2 avec ceux obtenus précédemment (Tab.

	DE...de	DE...fe		FE...de	FE...fe
DE...de	97.2%	50%	FE...de	100%	50%
De...fe	50%	98.6%	Fe...fe	50%	100%
(a) blurBound, DE défectueux			(b) blurBound, FE défectueux		

	DE...de	DE...fe		FE...de	FE...fe
DE...de	95.8%	70%	FE...de	95.7%	34.7%
De...fe	70%	99.2%	Fe...fe	64.5%	96.8%
(c) blurBound, DE défectueux			(d) blurBound, FE défectueux		

	DE...de	DE...fe		FE...de	FE...fe
DE...de	98.3%	70%	FE...de	99%	65.2%
De...fe	70%	98.3%	Fe...fe	64.5%	99%
(e) irorBound, DE défectueux			(f) irorBound, FE défectueux		

TAB. 4.2: Impact du chemin de transmission du signal sur la généralisation des frontières SVM, [Kongom, 2007b]

4.1), on remarque une légère amélioration de la capacité à généraliser des frontières lorsque le chemin de transmission des signaux test et d'apprentissage est différent. Les taux de classification des frontières varient entre 50% et 70%. Cependant ces résultats de classification ne permettent pas de conclure que l'effet du chemin transmission est mieux contrôlé par l'ajout de l'analyse en composantes indépendantes.

4.3.4 Combinaison de la Synchronisation Temporelle Moyennée avec le kurtosis spectral et les Support Vector Machine

À la suite de ces deux résultats insatisfaisants, on a émis l'hypothèse selon laquelle la synchronisation temporelle moyennée seule était insuffisante pour mettre en évidence la partie impulsive du signal que l'on recherche. C'est la raison pour laquelle on s'est intéressé aux méthodes d'analyse cyclostationnaire. Dans l'article de conférence [Kongom, 2008], on cherche à mettre en évidence la composante impulsive du signal en ajoutant l'analyse du kurtosis spectral à la procédure d'extraction de paramètres. On insère cette étape après la synchronisation temporelle moyennée du signal, Fig. 4.20. Les vecteurs de paramètres sont maintenant de dimension 22. On a aussi redéfini les bandes d'énergie pour mieux encadrer les fréquences de défaut de roulement sur un modèle semblable à celui de la figure 1.9. Les bandes sont définies de telle sorte que chaque intervalle contienne une des trois fréquences de défaut de roulement, en plus du balourd, du désalignement et des autres phénomènes présents dans le système. Encore une fois, on a utilisé les signaux provenant de la base de données Case Western pour tester la fiabilité des frontières calculées.

Les tableaux 4.3a à 4.3f montrent que la capacité à généraliser des frontières lorsque le chemin de transmission du signal est différent a été légèrement améliorée (par comparaison avec les tableaux 4.1) dans certains cas. Par exemple, pour les frontières *blorBound* du roulement DE, on obtient un taux de succès supérieur à 80%. Cepen-

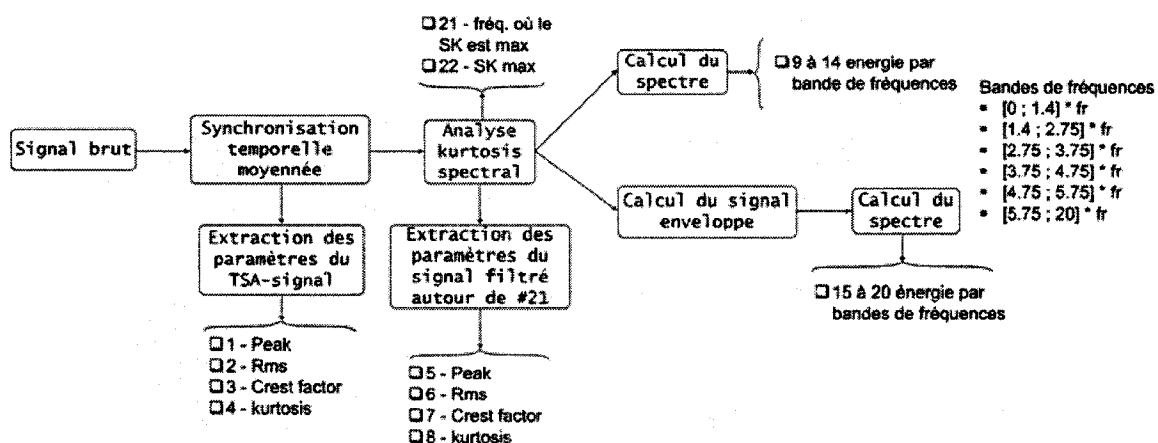


FIG. 4.20: Extraction des paramètres implémentée dans l'article de conférence [Kongom, 2008]

dant, il existe encore des cas où le taux de succès de classification est inférieur à 40%, e.g la frontière *irorbound* dans le cas du roulement FE défectueux, ce qui est loin d'être satisfaisant. Cependant, on peut considérer ces résultats comme encourageant car, malgré la perte d'information liée au filtrage du signal lors de l'analyse du kurtosis spectral et par la synchronisation temporelle moyennée, la capacité à généraliser des frontières varie peu. Cela montre que ces deux méthodes d'analyse préservent les composantes du signal utiles lors de l'apprentissage.

À partir de ces résultats, on se propose d'explorer plusieurs pistes pour diminuer l'impact du chemin de transmission du signal lors de l'apprentissage. Les méthodes de filtrage adaptatif de bruit, l'augmentation du nombre de paramètres des vecteurs, ou l'utilisation des algorithmes évolués de SVM (SMO) sont autant de pistes à explorer.

	DE...de	DE...fe		FE...de	FE...fe
DE...de	100%	59.7%	FE...de	98.5%	59.7%
DE...fe	87.5%	100 %	FE...fe	54.5%	97 %
(a) blurBound - DE défectueux			(b) blurBound - FE défectueux		

	DE...de	DE...fe		FE...de	FE...fe
DE...de	98.3%	80.3%	FE...de	94.8 %	73 %
De...fe	82.5%	95 %	FE...fe	67.7%	93.8 %
(c) blurBound - DE défectueux			(d) blurBound - FE défectueux		

	DE...de	DE...fe		FE...de	FE...fe
DE...de	95.8%	52.5%	FE...de	94.8%	63.5%
De...fe	58.3%	92.5 %	FE...fe	39.6%	96.8 %
(e) irorBound - DE défectueux			(f) irorBound - FE défectueux		

TAB. 4.3: Impact du chemin de transmission du signal sur la généralisation des frontières SVM, [Komgom, 2008]

4.4 Diminution de l'impact du chemin de transmission du signal sur la classification

Les résultats de classification obtenus jusqu'à présent montrent que les signatures vibratoires mesurées avec un capteur positionné loin de la source de vibration contiennent très peu d'informations utiles au diagnostic. Deux explications sont possibles : soit le chemin de transmission se comporte comme un filtre et atténue l'amplitude des fréquences sources au point où elles seront confondues avec le bruit dans le signal ; soit on a pas extrait assez de paramètres des signaux de vibration pour représenter l'état de la machine. Dans cette section on étudie donc l'influence de l'augmentation

du nombre de paramètres et l'utilisation de l'ANC pour améliorer les résultats de classification.

4.4.1 Augmentation du nombre de paramètres

On ajoute 18 nouveaux paramètres aux 22 déjà sélectionnés à la figure 4.20, pour un total de 40 paramètres par signal. Les 18 nouveaux paramètres sont choisis parmi ceux que l'on a présentés au chapitre de revue de littérature. Dans certains cas, on a modifié la formule de certains paramètres pour avoir des vecteurs dont les éléments ont le même ordre de grandeur. Cela permet d'éviter les problèmes de mauvais conditionnement dans l'algorithme d'apprentissage. On classe les 40 paramètres retenus en deux catégories :

- i) les paramètres temporels : on y regroupe les moments statistiques d'ordre 2 (rms), 4 (kurtosis), 6 (M6) et 8 (M8), ainsi que la valeur crête et le facteur crête. On a aussi adapté la définition des paramètres FM2, FM4B, NA4 et NB4 à notre cas d'analyse :
 - FM2 [Forrester, 1996] : rapport entre le kurtosis du signal enveloppe et celui du signal obtenu après la synchronisation temporelle moyenné ;
 - FM4B [Forrester, 1996] : rapport entre la valeur rms du signal enveloppe et celle du signal-TSA ;

- NA4 : on utilise la formule de l'équation (1.9), en remplaçant le signal résiduel par le signal-TSA ;
 - NB4 : calculé tel que défini à l'équation (1.10), en remplaçant l'enveloppe signal filtré autour de la fréquence d'engrènement par celle du signal-TSA ;
- ii) les paramètres fréquentiels : à partir des bandes de fréquences définies en fonction des fréquences cinématiques du montage, on calcule les paramètres suivants par bande de fréquence : FMO, AM et GM.

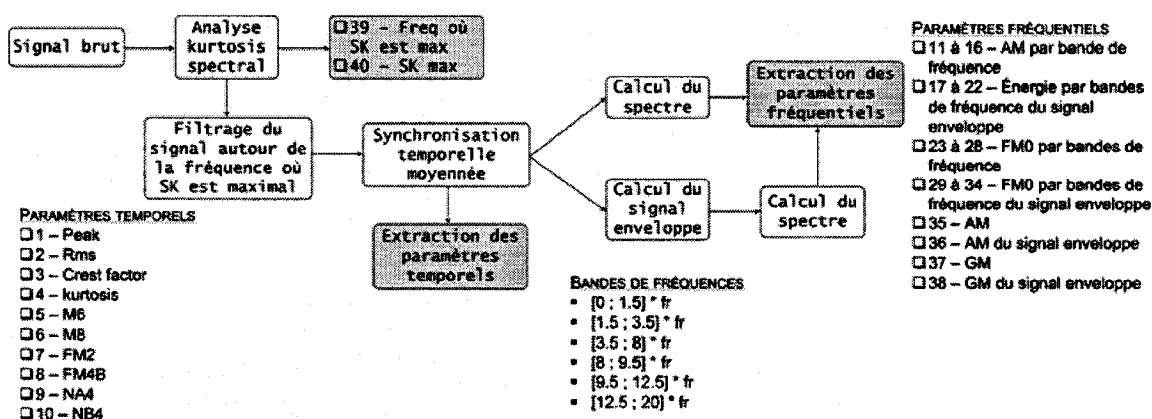


FIG. 4.21: Procédure de diagnostic : extraction de 40 paramètres

La méthode d'extraction des paramètres est présentée en détail à la figure 4.21. Sachant que plus l'espace représentation est grand, plus il faut augmenter le nombre de données d'apprentissage pour obtenir une bonne capacité à généraliser, on a donc utilisé les signaux provenant de notre banc d'essai pour tester l'impact de la dimension de l'espace de représentation.

Les tableaux 4.4 et 4.5 présentent les résultats de classification des frontières SVM. Pour chaque frontière, on présente les résultats de classification obtenus pendant

l'apprentissage et pendant les tests. Par exemple la première frontière du tableau 4.4 réalise la classification entre les données appartenant à la classe *normal* et celles construites à partir des signatures vibratoires mesurées lorsqu'il y a un défaut de bague externe positionné à 6h par rapport à la zone de chargement du roulement SKF 1211. Deux frontières sont calculées : la première est obtenue à partir des données obtenues des signatures vibratoires mesurées au canal 1 et la seconde à partir des données obtenues des signatures vibratoires du canal 2. Les résultats d'apprentissage montrent que l'algorithme d'apprentissage a identifié 2 *support vector* dans chaque cas pour obtenir une classification parfaite sur les données de validation. La capacité à généraliser de chaque frontière est évaluée avec les données test.

Frontières	Apprentissage			Test		
Normal vs. Outerace@6h		Nbre de sv	Validation		ch1	ch2
	ch1	2	100%	ch1	91%	55%
	ch2	2	100%	ch2	51%	100%
Normal vs. Innerace		Nbre de sv	Validation		ch1	ch2
	ch1	17	96%	ch1	86%	52%
	ch2	4	100%	ch2	50%	99%
Normal vs. Ball		Nbre de sv	Validation		ch1	ch2
	ch1	7	100%	ch1	98%	40%
	ch2	2	100%	ch2	56%	100%
Ball vs. Innerace		Nbre de sv	Validation		ch1	ch2
	ch1	12	100%	ch1	98%	38%
	ch2	6	100%	ch2	57%	100%
Ball vs. Outerace@6h		Nbre de sv	Validation		ch1	ch2
	ch1	7	100%	ch1	93%	76%
	ch2	4	100%	ch2	61%	99%
Innerace vs. Outerace@6h		Nbre de sv	Validation		ch1	ch2
	ch1	12	100%	ch1	96%	90%
	ch2	2	100%	ch2	54%	100%
Normal vs. Outerace@3h		Nbre de sv	Validation		ch1	ch2
	ch1	16	98.2%	ch1	86%	72%
	ch2	4	100%	ch2	48%	98%
Ball vs. Outerace@3h		Nbre de sv	Validation		ch1	ch2
	ch1	5	100%	ch1	91%	66%
	ch2	5	100%	ch2	50%	99%
Innerace vs. Outerace@3h		Nbre de sv	Validation		ch1	ch2
	ch1	16	96.3%	ch1	90%	32%
	ch2	2	100%	ch2	56%	98%

TAB. 4.4: Généralisation des frontières SVM, extraction de 22 paramètres des signaux SFD

Comme dans le cas des données de Case Western, le tableau 4.4 montre que le chemin de transmission du signal a un impact sur la capacité à généraliser des frontières. En général lorsque les données test et d'apprentissage proviennent du même canal de mesure, la capacité à généraliser des frontières est supérieur à 95 %. Par contre lorsque les données obtenues des signatures vibratoires mesurées au canal 1 sont utilisées pour tester les frontières construite à partir des données obtenue des sgnatures vibratoires mesurées au canal 2, la capacité à généraliser des frontières diminue très fortement. Elle est inférieure à 50% dans certains cas.

Le tableau 4.5 présente les résultats de classification avec la procédure d'extraction de 40 paramètres. À l'exception des frontières *Ball vs. Outerace@3h*, toutes les autres frontières ont une meilleure à généraliser lorsque le chemin de transmission du signal est différent. Dans certains cas, la capacité à généraliser est très satisfaisante, e.g. 90% pour la frontière *Normal vs. Outerace@6h* construite à partir des données du canal 1, ainsi que pour la frontière *Ball vs. Innerace* construite à partir des données du canal 2. Dans d'autres cas, on dépasse 70% de succès de classification, e.g. frontière ch1 *Normal vs. Innerace* ; frontière ch1 *Normal vs. Ball* ; frontière ch1 *Ball vs. Innerace* ; frontières ch1 et ch2 *Innerace vs. Outerace@6h* ; frontière ch1 *Normal vs. Outerace@3h*.

Ces résultats montrent que l'augmentation de l'espace de représentation améliore légèrement la capacité à généraliser des frontières SVM. Cependant, les résultats de classification obtenus ne sont pas toujours assez fiables pour une implémentation

en industrie. Il existe encore certaines frontières qui ont une très faible capacité de généralisation.

Frontières	Apprentissage			Test		
Normal vs. Outerace@6h		Nbre de sv	Validation		ch1	ch2
	ch1	9	100%	ch1	97%	90%
	ch2	4	100%	ch2	30%	100%
Normal vs. Innerace		Nbre de sv	Validation		ch1	ch2
	ch1	14	100%	ch1	98%	77%
	ch2	4	100%	ch2	60%	100%
Normal vs. Ball		Nbre de sv	Validation		ch1	ch2
	ch1	3	100%	ch1	97%	80%
	ch2	3	100%	ch2	56%	100%
Ball vs. Innerace		Nbre de sv	Validation		ch1	ch2
	ch1	3	100%	ch1	100%	77%
	ch2	4	100%	ch2	90%	100%
Ball vs. Outerace@6h		Nbre de sv	Validation		ch1	ch2
	ch1	3	100%	ch1	98%	60%
	ch2	5	100%	ch2	40%	91%
Innerace vs. Outerace@6h		Nbre de sv	Validation		ch1	ch2
	ch1	5	100%	ch1	99%	79%
	ch2	2	100%	ch2	80%	100%
Normal vs. Outerace@3h		Nbre de sv	Validation		ch1	ch2
	ch1	8	100%	ch1	96%	84%
	ch2	4	100%	ch2	45%	98%
Ball vs. Outerace@3h		Nbre de sv	Validation		ch1	ch2
	ch1	4	100%	ch1	20%	20%
	ch2	6	100%	ch2	30%	100%
Innerace vs. Outerace@3h		Nbre de sv	Validation		ch1	ch2
	ch1	7	100%	ch1	93%	65%
	ch2	3	100%	ch2	56%	100%

TAB. 4.5: Généralisation des frontières SVM, extraction de 40 paramètres des signaux SFD

4.4.2 Intégration de l'ANC dans la procédure de diagnostic

On présente dans cette section les résultats obtenus en utilisant la méthode de filtrage de bruit adaptatif pour approximer l'impact du chemin de transmission du signal sur les signatures vibratoires mesurées au canal 1. Les signatures vibratoires mesurées au canal 1 sont donc traitées selon la procédure de filtrage adaptatif présentée au chapitre 2. On extrait ensuite les 40 paramètres retenus des signaux-ANC. Notons que les données correspondant au canal 2 demeurent inchangées.

En comparant les résultats du tableau 4.6 avec ceux du tableau précédent, i.e. Tab. 4.5, il est clair que la capacité à généraliser des frontières s'est considérablement améliorée lorsque le chemin de transmission du signal est différent. Dans certains cas, on atteint même un résultat de classification parfait de 100%, i.e. frontière *ch2*, *Normal vs. Innerace*. Comme précédemment, les frontières *Ball vs. Outerace@3h* ont toujours la plus faible capacité à généraliser lorsque le chemin de transmission du signal varie.

Ces résultats montrent qu'en isolant l'effet du chemin de transmission du signal du bruit environnant, et en augmentant le nombre de paramètres extraits du signal de vibration, il est possible d'obtenir une bonne capacité de généralisation des frontières SVM. En comparant les résultats des procédures d'extraction des paramètres avec et sans ANC comme méthode d'analyse, on ne peut conclure que l'ANC constitue donc

une méthode importante dans l'établissement de la procédure de diagnostic. Cela était prévisible étant donné les observations faites à partir des spectres enveloppes de la figure 4.18. Ces résultats restent à être confirmés avec d'autres modèles de filtrage adaptatif. Il faudrait notamment comparer les résultats obtenus par la procédure implémentée dans ce mémoire avec celle proposée par Randall³.

³Il fut impossible d'avoir accès au code de Randall afin de pouvoir comparer nos résultats.

Frontières	Apprentissage			Test		
		Nbre de sv	Validation		ch1-ANC	ch2
Normal vs. Outerace@6h	ch1-ANC	4	100%	ch1-ANC	100%	90%
	ch2	4	100%	ch2	96%	100%
Normal vs. Innerace	ch1-ANC	4	100%	ch1-ANC	98%	88%
	ch2	4	100%	ch2	100%	100%
Normal vs. Ball	ch1-ANC	3	100%	ch1-ANC	100%	90%
	ch2	3	100%	ch2	75%	100%
Ball vs. Innerace	ch1-ANC	3	100%	ch1-ANC	98%	71%
	ch2	4	100%	ch2	80%	100%
Ball vs. Outerace@6h	ch1-ANC	5	100%	ch1-ANC	98%	96%
	ch2	5	100%	ch2	69%	91%
Innerace vs. Outerace@6h	ch1-ANC	3	100%	ch1-ANC	100%	92%
	ch2	2	100%	ch2	81%	100%
Normal vs. Outerace@3h	ch1-ANC	3	100%	ch1-ANC	100%	80%
	ch2	4	100%	ch2	70%	98%
Ball vs. Outerace@3h	ch1-ANC	9	100%	ch1-ANC	96%	46%
	ch2	6	100%	ch2	67%	100%
Innerace vs. Outerace@3h	ch1-ANC	2	100%	ch1-ANC	100%	86%
	ch2	3	100%	ch2	76%	100%

TAB. 4.6: Généralisation des frontières SVM, 40 paramètres , signaux ch1 traités par ANC

4.4.3 Sélection des paramètres par Algorithme Génétique

On a implémenté le modèle d'AG présenté au chapitre 2, pour trouver la combinaison optimale de paramètres pour chaque frontière étudiée. On s'intéresse aux cas où les données d'apprentissage et les données de test n'ont pas le même chemin de transmission. On utilise les données d'apprentissage de chaque état de machine pour trouver la combinaison optimale de paramètres. Une fois cette combinaison optimale trouvée, on utilise les données test pour tester sa fiabilité. Par exemple pour la frontière ch1-NO vs IR et un apprentissage basé sur les données extraites des signaux mesurés au canal 1, la méthode de sélection est implémentée comme suit : pour chaque chromosome, on utilise les données *ch1nolearn* et *ch1irlearn* pour construire le classificateur. La valeur de la fonction de survie de ce chromosome sera évaluée en utilisant les données *ch2nolearn* et *ch2irlearn*. Si la combinaison dictée par ce chromosome est optimale, alors on utilise cette combinaison pour construire des classificateurs avec les données *ch1nolearn* et *ch1irlearn* et on évalue leur capacité à généraliser avec les données *ch2notest* et *ch2irtest*. Notons qu'on a pas utilisé les données extraites des signaux traités par filtrage adaptatif de bruit dans nos tests avec l'AG. Mentionnons aussi que l'apprentissage des frontières se fait avec 25 données par classe, et qu'on ne varie plus les données d'apprentissage comme précédemment. Ce choix a été fait dans le but de simplifier le plus possible l'évaluation des chromosomes.

Étant donné que l'AG a identifié plus d'une combinaison optimale dans presque tous

les cas testés, on se limitera à présenter les plus intéressantes dans cette section. Pour chaque frontière, les combinaisons optimales intéressantes correspondent à celle qui ont le plus petit nombre de paramètres d'apprentissage et qui ont une capacité de généralisation supérieure ou égale à 85% sur les données test, i.e. Different Path-Learn (DP-L) et -Test(DP-T).

Frontières	Nb. Par.	Combinaison	SP-L	SP-T	DP-L	DP-T
ch1 - BL vs. OR@3h	6	0000000100000100111100	98%	97%	100%	100%
ch1 - BL vs. OR@6h	7	1000001100101100010000	98.2%	97%	90%	90%
	8	1000001101101101000000	97.1%	97%	100%	100%
	8	0010001100110100000011	100%	98%	100%	100%
ch1 - IR vs. OR@3h	9	0100000110101101101000	91.9%	91%	100%	100%
	9	0100000110100111000011	94.2%	91%	100%	100%
	10	0100000111100101101001	98.4%	95%	100%	100%
ch1 - IR vs. OR@6h	9	0101000111100000100101	100%	94%	100%	100%
	10	0111000010100100111001	100%	98%	100%	100%
ch1 - NO vs. BL	2	1001000000000000000000	78%	73%	90%	89%
	8	0001010000101100110010	98.6 %	96%	39%	40%
ch1 - NO vs. OR@3h	7	1101000100000000110010	74.1%	52%	99%	100%
ch1 - NO vs. OR@6h	11	0101000111101001110100	96%	98%	99%	100%
	11	0101000100100111011110	93%	98%	100%	100%
	12	1100101001110011110001	100%	96%	100%	100%

TAB. 4.7: Résultats de classification des frontière basées sur les signaux provenant du canal 1 après sélection de paramètres SK22 par AG

Le tableau 4.7 montre les résultats pour certaines frontières de classification basée sur les vecteurs à 22 paramètres obtenus après analyse par kurtosis spectral uniquement, i.e. la procédure d'extraction de la figure 4.20 sans l'étape de la synchronisation temporelle moyennée. De manière générale, ces résultats montrent qu'il existe effectivement une combinaison de paramètres qui permet de réduire l'influence du chemin

de transmission sur la capacité à généraliser des frontières, et ce même si la synchronisation temporelle moyennée et le filtrage adaptatif de bruit n'ont pas été utilisés pour analyser le signal. Cependant, les combinaisons optimales de paramètres varient beaucoup selon la frontière étudiée et il est difficile d'identifier les paramètres qui reviennent dans toutes les combinaisons.

On remarque aussi que certaines combinaisons jugées optimales par l'AG ne donnent pas une capacité de généralisation satisfaisante dans tous les cas testés. Par exemple dans le cas de la frontière NO vs. BL, la combinaison à 2 paramètres, i.e. le peak et le kustosis, performe très bien lorsque le chemin de transmission du signal diffère (DP-L : 90% et DP-T : 89%), mais donne des résultats peu satisfaisant lorsqu'il est le même (SP-L : 78%, SP-T : 73%). Par contre, pour la combinaison à 8 paramètres de la même frontière, c'est l'inverse qui se produit : bonne capacité à généraliser lorsque le chemin de transmission est le même, mais piètre performance lorsqu'il diffère. On peut expliquer ces cas particuliers par le fait que la fonction complexe que l'on veut optimiser contient plusieurs minimums locaux dans l'espace de représentation. Les résultats de la frontière NO vs. OR@3h sont similaires à ceux de la combinaison à deux paramètres de la frontière NO vs. BL : la classification est presque parfaite lorsque le chemin de transmission diffère, mais peu satisfaisant lorsqu'il est le même.

Le tableau 4.8 montre les résultats de classification pour les frontières basées sur les paramètres extraits des signaux mesurés au canal 1 selon la procédure de la figure

4.21. Encore une fois, ces signaux n'ont pas été traités par la méthode de filtrage adaptatif de bruit avant l'extraction des paramètres. Dans tous les cas présentés, on remarque que moins de la moitié des paramètres extraits sont retenues pour former des combinaisons optimales. Comme précédemment, il est difficile d'identifier à vue d'oeil, les paramètres qui reviennent souvent dans les combinaisons optimales trouvées. Le fait que ces combinaisons diffèrent selon les frontières rend ce processus difficile. D'un autre côté, le nombre de paramètres par combinaison est relativement élevé dans le meilleur des cas, i.e. 10 paramètres. Même si cela équivaut à extraire 4 fois moins de paramètre que la procédure d'extraction initiale, il y a de fortes chances qu'on puisse encore réduire ce nombre si on avait utilisé la fonction *randerr()* en lieu et place de la fonction *round(rand())*. Ce choix a été fait dans le but d'accélérer les calculs.

Finalement, notons que l'on n'a pas présenté de résultats de classification des frontières basées sur les signaux mesurés au canal 2. On justifie cela par le fait que dans les majorité des cas testés, l'AG ne parvenait pas à trouver une combinaison qui avait une erreur de classification acceptable, au contraire, la valeur de la fonction de survie stagne à une faible valeur, et ce, malgré les opérations de croisement et de mutation à chaque génération.

Frontières					
Nb. Par.	Combinaison	SP-L	SP-T	DP-L	DP-T
ch1 - IR vs. OR@3h					
15	0000100101100001010101001001010000111100	100%	98%	88%	91%
16	0000101011111000000101001101010000101100	100%	96%	100%	100%
16	0000100000111101001101001001010000111100	100%	97%	100%	98%
16	0100111101011000000001001000001010111100	100%	95%	99%	98%
ch1 - IR vs. OR@6h					
17	1001101011100010000111101000010010100100	100%	95%	100%	100%
18	100101000110000101011111011001010100000	100%	98%	100%	100%
18	0011111101010100101000001011010100100100	100%	95%	100%	100%
18	0001010101010111000101111100010000100101	100%	98%	100%	100%
ch1 - NO vs. BL					
13	1000111000111000000000000001011010010100	100%	93%	80%	82%
14	1100010100110001000100100000001011010100	100%	91%	92%	86%
15	1000010000111100101100100000001011010100	100%	90%	100%	100%
17	1100010110110101001000101000001011010100	100%	94%	100%	100%
ch1 - NO vs. OR@3h					
10	0100000100100000010100000100100000010101	98.2%	94%	99%	100%
11	0000000000100010111101000100100000010100	100%	93%	98%	95%
12	1000000110100000011100000110100000010100	100%	95%	97%	95%
ch1 - NO vs. OR@3h					
17	1110000010100111100101000001110100010100	100%	98%	100%	100%
17	0011110010101011100000001010001000110011	100%	99%	97%	90%
19	0111110010010010110111011010000011010000	100%	96%	94%	96%
20	1110010101111011001001001110010010000101	100%	98%	98%	100%
20	1100100010001000111111001101111000010101	100%	92%	100%	100%

TAB. 4.8: Résultats de classification des frontière basées sur les signaux provenant du canal 1 après sélection de paramètres SKTSA40 par AG

DISCUSSIONS & RECOMMANDATIONS

Les résultats présentés dans ce travail de mémoire montre qu'il est possible de réduire l'influence du chemin de transmission du signal sur la fiabilité du diagnostic posé par les méthodes d'apprentissage statistique. Dans cette section, un retour critique, sur certains points jugés importants et qui méritent une attention particulière dans la perspective d'une continuité de ce sujet de recherche, est fait.

Implémentation de la synchronisation temporelle moyennée

Dans la revue de littérature, on a rapporté l'existence de plusieurs méthodes de synchronisation temporelle moyennée. Dans le cadre de ce travail de recherche, toutes ces méthodes n'ont pas été testées, seul le modèle de McFadden & Toozhy a été comparé avec la méthode implémentée. Tout comme le modèle de McFadden & Toozhy, la méthode implémentée est une méthode *off-line* dans la mesure où le signal de vibration est d'abord enregistré avant que la procédure de synchronisation ne soit appliquée par convolution. Cependant, il existe des méthodes de synchronisation en *temps réel*, où la synchronisation est faite juste après l'échantillonnage du signal, cf. Fig. 1.11. Il serait avisé de comparer ces méthodes de synchronisation entre elles afin de trouver celle qui est la mieux adaptée à nos besoins.

Aussi, le signal de synchronisation utilisé pour la convolution est un signal simulé,

non pas mesuré directement du banc d'essai expérimental. Il faudrait envisager l'utilisation d'un tachymètre afin d'obtenir la séquence de répétition directement à partir de l'arbre du montage. Le choix de la fréquence de répétition est très importante dans l'utilisation de la synchronisation temporelle moyennée tel qu'implémentée dans ce travail de recherche. Si l'utilisation de la fréquence de défaut de roulement comme fréquence de la séquence de synchronisation en lieu et place de la fréquence de rotation de l'arbre, semble avantageux dans la mesure où on veut que le spectre enveloppe ne contiennent que les fréquences de défauts de roulement et leurs harmoniques, cela peut avoir des effets pervers dans la mesure où il est possible que les fréquences du spectre enveloppe proviennent non pas du signal de vibration original, mais plutôt de la séquence de synchronisation. De plus d'un point de vue expérimental, il est impossible d'obtenir un tel signal de synchronisation, ce qui n'est pas le cas pour le signal de rotation de l'arbre.

D'un point de vue plus général, l'utilisation de la synchronisation temporelle moyennée pour analyser les signaux de vibration de roulements reste à être démontrée plus clairement. La synchronisation temporelle moyennée est considérée comme étant une méthode *déterministe* qui est adaptée pour les signaux de vibration bien définis en par rapport à une fréquence de référence comme les signaux d'engrenages. Dans ces signaux, les composantes fréquentielles du signal sont en majorité les harmoniques de la fréquence d'engrènement des dents. Par contre dans le cas des roulement, la

présence de glissement entre les billes et les surfaces des bagues, ainsi que le fait que les fréquences de défaut de roulement soient non-harmoniques par rapport à la fréquence de rotation de l'arbre, rend plusieurs experts critiques quand à l'utilisation de cette méthode en analyse des vibrations des roulements.

Analyse cyclostationnaire & Filtrage adaptatif de bruit

Le potentiel offert par les méthodes d'analyse cyclostationnaire a été très peu exploité dans ce travail de recherche. Seuls le spectre enveloppe du signal filtré autour de la fréquence où le kurtosis spectral est maximal, ladite fréquence et la valeur maximale du kurtosis spectral, ont été utilisés pour caractériser le signal de vibration. Il faudrait trouver un moyen d'extraire des paramètres de la densité spectrale cyclique qui aideraient à l'identification du signal de vibration. Tout comme les représentations temps-fréquence, des méthodes d'extraction des paramètres de ces représentations bidimensionnelles restent à être développées.

Pour ce qui est de la méthode de filtrage adaptatif, la méthode utilisée dans ce mémoire est une adaptation de l'algorithme proposé dans le Toolbox de Matlab. Il faudrait comparer les résultats de cette méthode avec ceux que l'on obtiendrait si on utilisait l'algorithme implémenté par Randall. Il fut impossible d'avoir accès à cet algorithme à temps afin de faire cette étude. La SANC reste aussi une méthode à être testée, dans la mesure où elle permettrait de diminuer le nombre de capteurs

nécessaires pour l'identification du défaut de roulement.

Support Vector Machine & Algorithme génétique

Un seul algorithme d'optimisation a été testé dans ce travail pour résoudre le problème d'apprentissage. La routine quadratique *quadprog* a été employé dans toutes les optimisations faites. Cette algorithme est bien adapté aux problèmes d'optimisation ayant un nombre de variables moyen. Si dans un travail futur, on augmente considérablement le nombre de signaux mesurés sur le banc d'essai (environ un millier), il serait préférable d'utiliser des algorithmes d'optimisation plus évoluées tel que le SMO, ou les méthodes d'ensemble actifs. Cela permettrait de réduire le temps d'exécution de l'AG.

L'AG implémenté dans ce mémoire est un algorithme de base. Plusieurs améliorations restent à faire dans son implémentation. Notamment, il faudrait considérer les paramètres choisis par essai erreur pendant l'apprentissage, i.e. taille de l'espace de représentation, fonction de projection vers l'espace grande dimension, valeur du paramètre ν , nombre de données d'apprentissage, nombre de paramètres pour représenter l'état de la machine ... etc., comme étant des variables qui ont une influence sur l'optimisation de la fonction-objectif. De plus, une étude comparative doit être faite entre les opérateurs de sélection, de croisement et de mutation afin de déterminer lesquels sont les mieux adaptés à notre problème d'optimisation.

Aussi, une analyse plus rigoureuse des paramètres qui reviennent souvent dans les combinaisons optimales trouvées reste à être effectuée. Les résultats de classification basés sur une sélection de paramètres par AG, semblent montrés qu'il est plus facile de reconnaître les signaux provenant du canal 2 pour les frontières construites avec les signaux du canal 1. Il est fort possible que les signaux mesurés au canal 1 contiennent très peu d'informations pour pouvoir être correctement identifié par les frontières construites avec les signaux du canal 2. Dans le cas inverse, étant donné que les signaux du canal 1 sont similaires à des signaux ayant un défaut naissant, les classificateurs sont entraînés pour détecter ces différences minimales. Lorsque les signaux avec les défauts bien définis comme ceux du canal 2 leur sont présentés, ils ont une très bonne capacité de généralisation. Cette hypothèse reste à être confirmée dans des travaux futurs.

Les résultats de classification des frontières montrent aussi que la position du défaut de bague externe, i.e. à 3h ou à 6h par rapport à la zone de chargement, a peu d'impact sur leur capacité à généraliser. Il reste cependant à étudier le cas où le défaut est positionné à 12h par rapport à la zone de chargement. Il est possible que les impulsions soient moins bien définies dans le signal de bague externe, rendant la distinction avec un signal de roulement normal difficile. La combinaison de plusieurs types de défaut sur le même roulement ou la présence d'un même type de défaut à différents endroits des composantes reste aussi à être étudié. Il serait intéressant de

tester les classificateurs issus de la procédure de diagnostic avec des signaux provenant des roulements ayant plusieurs composantes défectueuses ou ayant plusieurs défauts sur une même composante.

Enfin, dans cette étude, les paramètres extraits des signaux de vibration ne sont pas tous adimensionnels. De plus, la matrice du noyau de projection vers l'espace de grande dimension est souvent mal conditionnée, en raison du grand écart entre les valeurs des paramètres. La matrice de noyau de projection vers l'espace de grande dimension sera ainsi sujette à des problèmes de mauvais conditionnement, et la convergence de l'algorithme d'optimisation en sera affectée. La recherche de paramètres adimensionnels qui permettent de caractériser l'état de fonctionnement d'une machine peu importe ses conditions d'opération et qui sont sensibles à son état de dégradation est donc la prochaine étape dans l'utilisation de l'AG. Les méthodes de *genetic programming* qui permettent de trouver de nouveaux paramètres en utilisant un AG constituent à cet effet un bon point de départ. Cependant, l'utilisation de ces méthodes de *genetic programming* doit être faite avec attention dans la mesure où les paramètres proposés par la méthode ne contiennent pas toujours une signification physique.

CONCLUSION

Les défaillances de roulements occupent une place importante dans la problématique récurrente à la surveillance des machines rotatives. Le suivi de l'état de ses composantes critiques est le principal objectif de tout programme de maintenance implémenté dans l'industrie. En plus de ce suivi permanent, le programme de maintenance prédictive permet de détecter et de diagnostiquer toute défaillance le plus rapidement possible. Cela a pour conséquence d'augmenter la disponibilité des équipements et de réduire les coûts associés à la planification et à l'exécution des activités de maintenance. C'est dans cette optique que s'inscrit l'intérêt porté aux méthodes de reconnaissance de formes pour *fiabiliser* le diagnostic des méthodes traditionnelles d'analyse de signaux de vibration. De nombreux travaux de recherche ont démontré que la combinaison entre les méthodes d'analyse de signatures vibratoires et les méthodes de reconnaissance de forme permettaient d'augmenter la fiabilité du diagnostic posé. Cependant, l'impact du chemin de transmission du signal sur la fiabilité du diagnostic n'a été l'objet d'aucune étude sérieuse avant ce travail de recherche, et ce, même si tous les chercheurs reconnaissent son influence sur les résultats de méthodes d'analyses des signaux de vibration.

L'objectif de ce mémoire est donc double : montrer que le chemin de transmission du signal a effectivement une influence sur la capacité à généraliser des frontières issues

des méthodes d'apprentissages, peu importe la dimension de l'espace de représentation, et proposer une procédure de d'analyse des signaux de vibration pour diminuer cette influence. Pour se faire, on se sert des méthodes avancées de traitements de signaux de vibration que sont la synchronisation temporelle moyennée (Time Synchronous Averaging), le kurtosis spectral (méthode d'analyse cyclostationnaire) et les méthodes de filtrage adaptatif de bruit (Adaptive Noise Cancellation) pour identifier et isoler la composante du signal de vibration associée aux défauts de roulement.

Premièrement, on a justifié l'utilisation de la synchronisation temporelle moyennée comme une méthode de filtration de bruit dans le but de mettre en évidence les impulsions liées au défaut de roulement dans le signal temporel. L'importance du choix de la fréquence de répétition de la séquence a été clairement démontrée et la fréquence de rotation de l'arbre s'est avéré être un choix simple et efficace. Cependant, la procédure de synchronisation temporelle moyennée implémentée a peu d'influence sur la représentation spectrale du signal, d'où l'utilité des méthodes d'analyse cyclostationnaire afin de mettre en évidence les composantes fréquentielles liées aux défauts de roulement. En effet, ces composantes fréquentielles ont été mises en évidence dans le spectre enveloppe des signaux obtenus suite à l'application d'un filtre passe bande autour de la fréquence où le kurtosis spectral est maximal. Cependant, on a montré qu'à elles seules ces deux méthodes ne suffisent pas à contrer l'impact du chemin de transmission du signal sur la classification. Par contre, une fois le filtrage adaptatif de

bruit ajouté à la procédure de diagnostic, les résultats se sont nettement améliorés, atteignant 100% dans certains cas (80% en moyenne).

Dans ce travail on a aussi montré que la dimension de l'espace de représentation avait une légère influence sur la capacité à généraliser des classificateurs, bien qu'elle ne permet de résoudre entièrement le problème posé par le chemin de transmission du signal. L'utilisation d'un algorithme génétique pour la sélection des paramètres a aussi été abordée. On a montré qu'il était possible d'utiliser notre modèle d'algorithme génétique proposé pour identifier des combinaisons de paramètres qui permettent d'augmenter la capacité de généralisation des classificateurs malgré le chemin de transmission du signal. Des combinaisons à 17, 6 et voire même 2 paramètres, qui permettent d'obtenir des résultats de classification supérieurs à 90%, ont été trouvées. Cependant, les combinaisons identifiées varient selon les frontières, et il est difficile d'identifier à priori les paramètres qui apparaissent régulièrement dans les combinaisons. Une étude plus exhaustive reste à être effectuée à cet effet.

Les résultats obtenus dans cette étude montrent donc que si le chemin de transmission du signal influence la fiabilité des méthodes de reconnaissances de forme, il est possible de réduire ladite influence en utilisant les méthodes avancées de traitement de signal et en augmentant la dimension de l'espace de représentation de l'état de la machine.

Perspectives

Ce travail de recherche explore de nouveaux horizons dans la surveillance des machines rotatives. Dans de nombreuses applications industrielles, il est quasiment impossible de placer des capteurs de vibration aux endroits appropriés d'un point de vue dynamique. Les signaux de vibration qui seront mesurés par les capteurs positionnés aux endroits accessibles proviennent donc de plusieurs sources de vibration et cela complexifie considérablement la détection et l'identification d'une éventuelle panne. Si l'identification de chaque source de vibration est possible (méthode aveugles de séparation de sources, *Blind Source Separation*), l'influence du chemin de transmission du signal demeure. Une méthode d'analyse des signatures vibratoires a été proposée afin de réduire cette influence, et son perfectionnement reste à être mené à terme.

RÉFÉRENCES

- [Alfredson, 1982] Alfredson R.J., 1982. *A computer based system for condition monitoring*, Symposium on reliability of large machinery, I.E. Sydney : 39-42.
- [Antoni, 2004a] Antoni J., Bonnardot F., Raad A. and El Badaoui M., 2004. *Cyclostationary modelling of Rotating Machine Vibration Signals*, Mechanical Systems and Signal Processing, vol. 18 : 1285-1314.
- [Antoni, 2004b] Antoni J., Randall R.B., 2004. *Unsupervised noise cancellation for vibration signals : Part I - Evaluation of adaptive algorithms*, Mechanical Systems and Signal Processing, vol. 18(1) : 89-101.
- [Antoni, 2004c] Antoni J., Randall R.B., 2004. *Unsupervised noise cancellation for vibration signals : Part II - A novel frequency-domain algorithm*, Mechanical Systems and Signal Processing, vol. 18(1) : 103-117.
- [Antoni, 2005a] Antoni J., Guillet F., El Badaoui M., Bonnardot F. , 2005. *Blind separation of convolved cyclostationary processes*, Signal Processing, vol. 85 : 51-66.

- [Antoni, 2005b] Antoni J., Randall R.B., 2005. *On the use of the cyclic power spectrum in rolling element bearings diagnosis*, Journal of Sound and Vibration, vol. 281 : 463-468.
- [Antoni, 2006a] Antoni J., 2006. *The spectral kurtosis : a useful tool for characterizing non-stationary signals*, Mechanical Systems and Signal Processing, vol. 20(2) : 282-307
- [Antoni, 2006b] Antoni J., Randall, R.B., 2006. *The spectral kurtosis : application to the vibratory surveillance and diagnostics of rotating machines*, Mechanical Systems and Signal Processing, vol. 20 : 308-331.
- [Antoni, 2007a] Antoni J., 2007. *Fast computation of the kurtogram for the detection of transient faults*, Mechanical Systems and Signal Processing, vol. 21 : 108-124. Voir le site suivant pour les programmes utilisés : <http://www.utc.fr/~antoni/>
- [Antoni, 2007b] Antoni J., 2007. *Cyclic spectral analysis of rolling element bearing signals : Facts and fictions*, Journal of Sound and Vibration, vol. 304 : 497-527
- [Antoni, 2001] Antoniadis I., Glossiotis G. 2001. *Cyclostationary analysis of rolling element bearing vibration signals*, Journal of Sound and Vibration, vol. 248(5) : 829-845

- [Auger, 1995] Auger F., Flandrin P., Goncalvès P., Lemoine O., 1995-1996. *Time-Frequency toolbox*, Tutoriel du logiciel, Collaboration entre le CNRS (France) et Rice University (USA).
- [Badri, 2007a] Badri B., Thomas M., Sassi S., Lakis A., 2007. *Combination of bearing defect simulator and artificial neural network for the diagnosis of damaged bearings*, Proceedings of the 20th conference of Condition Monitoring and Diagnostic Engineering Management, COMADEM.
- [Badri, 2007b] Badri B., Hamelin P., Thomas M., 2007. *Analyse des mesures vibratoires effectuées sur la machine outil Ecospeed*, Rapport interne, Projet CRIAQ 1.18.
- [Bazarsuren, 2004] Bazarsuren U., Filbert D., 2004. *Motor fault detection using support vector machines*, Surveillance, CETIM senlis.
- [B&K, 1980] Bruel & Kjaer, 1980. *Condition monitoring of industrial machinery using mechanical vibration as a machine health indicator*, Bruel & Kjaer, Denmark.
- [Boashash, 1992] Boashash B., 1992. *Time frequency signal analysis*, John Wiley & Sons.
- [Braun, 1975] Braun S.G., 1975. *The extraction of periodic waveforms by time domain averaging*, Acustica, vol.32(2) : 69-77.

- [Braun, 1979] Braun S.G., Seth B.B., 1979. *On the extraction and filtering of signals acquired from rotating machines*, Journal of Sound and Vibration, vol.65(1) : 37-50.
- [Bremer, 1990] Bremer P.G., 1990. *adaptive noise cancellation applied to machine condition monitoring*, Mémoire présenté en vue de l'obtention du diplôme de Maîtrise Es Sciences Appliquées, University of Cap Town, Afrique du Sud.
- [Burgess, 1998] Burgess C.J., 1998. *A tutorial on support vector machines for pattern recognition*, Data mining and Knowledge Discovery
- [Capdevielle, 1996] Capdevielle V., Servière C., Lacoume J.L., 1996. *Blind separation of wide-band sources : application to rotating machine signals*, Proceedings of the 8th European Signal Processing Conference, vol. 3 : 2085-2088.
- [Carmody, 1972] Carmody T., 1972. *The measurement of vibration as a diagnostic tool*, Trans.I.Mar.E., vol. 84 : 147-159.
- [CETIM91] CEntre Technique des Industries Mécaniques, 1991, *Les besoins des entreprises mécaniciennes en fiabilité et maintenance*.
- [Chaturvedi, 1981] Chaturvedi G.K., Thomas D.W., 1981. *Adaptive noise cancelling and condition monitoring*, Journal of Sound and Vibration, vol. 76(3) :391-405.

- [Chaturvedi, 1982] Chaturvedi G.K., Thomas D.W., 1982. *Bearing fault detection using adaptive noise cancelling*, Transactions of the ASME Journal of Mechanical Design, vol. 104 :280-289.
- [Cohen, 1989] Cohen L., 1989. *Time-frequencies distributions - A review*, Proceedings of the IEEE, vol.77(7) :941-980.
- [Courrech, 1985] Courrech J., 1985. *New techniques for fault diagnostics in rolling element bearings*, Proceedings of the 40th meeting of the Mechanical Failure Prevention Group, National Bureau of standards :47-54.
- [Cristianini, 2000] Cristianini N., Shawe-Taylor J., 2000. *An introduction to Support Vector Machines and other kernel-based learning methods*, Cambridge University Press.
- [Decker, 1994] Decker H.J., Handschuh R.F., Zakrajsek J.J., 1994. *An enhancement to the NA4 gear vibration diagnostic parameter*, 18th Annual Meeting of the Vibration Institute, NASA Glenn Research Center, U.S. Army research Laboratory, NASA TM 1063553 ARL-TR-389
- [DeSilva, 2005] De Silva C.W. , 2005. *Vibration and shock handbook*, Boca Raton, FL : Taylor & Francis.
- [Downham, 1980] Downham E., 1980. *Vibration monitoring and wear prediction*, Second International Conference on vibrations in rotating ma-

chinery, Cambridge : 29-33.

- [Dyer, 1978] Dyer D., Stewart R.M., 1978. *Detection of rolling element bearing damage by statistical vibration analysis*, ASME Journal of Mechanical Design, vol. 100 : 229-235.
- [Dwyer, 1983] Dyer R.F., 1983. *Detection of non-Gaussian signals by frequency domain kurtosis estimation*, International Conference on Acoustic, Speech, and Signal Processing : 607-610.
- [Halim, 2006] Halim E.B., Choudhury S., Shah S.L., Zuo M.J., 2006. *Fault Detection of Rotating Machinery from Bicoherence Analysis of Vibration Data* presented at the SAFEPROCESS 2006 Beijing, China.
- [Eshleman, 1980] Eshleman R.L., 1980. *The role of sum and difference frequencies in rotating machinery fault diagnosis*, Second international conference on vibration in rotating machinery, I. Mech.E. Cambridge : 145-149.
- [Forrester, 1989] Forrester B.D., 1989. *Use of Wigner-Ville distribution in helicopter fault detection*, Proceedings of the Australian Symposium on Signal Processing and Applications, ASSPA89 :78-82.
- [Forrester, 1996] Forrester B.D., 1996, *Advanced vibration analysis techniques for fault detection and diagnosis in geared transmission systems*, Thèse de

- doctorat, <http://adt.lib.swin.edu.au/public/adt-VSWT20050715.092623>
- [Gasch, 1993] Gasch R., 1993. *a survey of the dynamic behaviour of a simplerotating shaft with transverse crack*, Journal of Sound and Vibration, vol. 160 : 313-332.
- [Glew, 1974] Glew C.W.A., 1974. *The effectiveness of vibration analysis as a maintenance tool*, Trans.I.Mar.E., vol. 86 : 29-50.
- [Goldberg, 1989] Goldberg D.E., 1989. *Genetic algorithms in search, optimization, and machine learning*, New-York, Addison-Wiley.
- [Goldberg, 1991] Goldberg D.E., Deb K., 1991. *A comparison of selection schemes used in genetic algorithms*, Fondation of Genetic Algorithms, edited by Rawlins G.J.E. : 69-93.
- [Grove, 1979] Grove R.C., 1979. *An investigation of advanced prognostic analysis techniques*, Paper USARTL-TR-79-10, Northrup Research and Technology Center, Palos Verdes, CA.
- [Guo, 2005] Guo H., Jack L.B., Nandi A.K., 2005. *feature generation using genetic programing for fault calssification*, IEEE Transactions on Systems, Man and Cybernetics - Part B : Cybernetics, vol. 35 (1) : 89-99.
- [Hyvarinen, 2000] Hyvarinen A., Oja E., 2000. *Independent component analysis : algorithms and applications*, Neural Networks, vol. 13 (4-5) :

411-430.

- [Hyvarinen, 2001] Hyvarinen A., Karhunen J., Oja E., 2001. *Independent component analysis*, John Wiley & Sons.
- [Haykin, 1991] Haykin S., 1991 *Adaptive filter theory*, Prentice Hall.
- [Haykin, 1999] Haykin S., 1999 *Neural Networks : a comprehensive foundation*, 2nd edition, Prentice Hall
- [Ho, 2000] Ho D. Randall R.B., 2000. *Optimisation of bearing diagnostic techniques using simulated and actual bearing fault signals*, Mechanical Systems and Signal Processing, vol. 14 : 763-788.
- [ISO2372] International standard ISO-2372-1974(E), *Mechanical vibration of machines with operating speeds from 10 to 200 rev/s - Basis for specifying Evaluation standards*
- [Jardine, 2005] Jardine A.K.S., Lin D., Banjevic D., 2005. *A review on machinery diagnostics and prognostics implementing condition-based maintenance*, Mechanical systems and signal processing, vol. 20 : 1483-1510.
- [Kongom, 2007a] Kongom N.C., Mureithi N., Lakis A. and Thomas M., 2007. *Bearing Fault Detection using Pattern recognition methods applied to The Case Western Reserve University Bearing data*, Proceedings of the 25th annual seminar of the Canadian Machinery Vibration Association, CMVA 2007.

- [Komgom, 2007b] Komgom N.C., Mureithi N., Lakis A. and Thomas M., 2007. *On the use of Time synchronous averaging, independent component analysis and support vector machine for bearing fault diagnosis*, Proceedings of the 1st International Conference on Industrial Risk Engineering, CIRI 2007.
- [Komgom, 2007c] Komgom N.C., Mureithi N., Lakis A., Safizadeh M.S., 2007. *Analyse des signatures vibratoires de l'écospeed - Mesures du 20 Août et du 17 Septembre 2007*, Rapport interne, Projet CRIAQ 1.18.
- [Komgom, 2008] Komgom N.C., Mureithi N., Lakis A., 2008. *Application of Time Synchronous Averaging, Spectral Kurtosis and Support Vector Machines for bearing fault identification*, To be presented at the ASME 2008 Pressure Vessels & Piping conference, Chicago.
- [Li, 1991] Li C.J., Ma J., Hwang B., 1991. *Bispectral analysis of vibration for bearing condition monitoring*, Proceedings of the 3rd International Machinery Monitoring and Diagnostics Conference : 225-231.
- [Li, 1996] Li C.J., Ma J., Hwang B., 1996. *Bearing condition monitoring by pattern recognition based on bicoherence analysis*,

Proceedings of the Institutions of Mechanical Engineers, vol. 210(3) :277-285.

- [Li, 2003] Li L., Qu L., 2003. *Cyclic statistics in rolling bearing diagnosis*, Journal of Sound and Vibration, vol. 267 :253-265.
- [Lebold, 2000] Lebold M., McClintic K., Campbell R., 2000. *Review of vibration analysis methods for gearbox diagnostics and prognostics*, Proceedings of the 54th meeting of the Society for Machinery Failure Prevention Technology, 623-634.
- [Mangasarian, 2000a] Mangasarian O.L., Musicant D.R., 2000 Active Support Vector Machine Classification, Technical report 00-04, Data Mining Institute, Computer Sciences Department, University of Wisconsin : <http://www.cs.wisc.edu/dmi/asvm/>.
- [Mangasarian, 2000b] Mangasarian O.L., Musicant D.R., 2000 Lagrangian Support Vector Machine Classification, Technical report 00-06, Data Mining Institute, Computer Sciences Department, University of Wisconsin : <http://www.cs.wisc.edu/dmi/lsvm/>.
- [Martin, 1989] Martin H.R., 1989. *Statistical moment analysis as a means of surface damage detection*, Proceedings of the 7th International Modal Analysis Conference, Society for Experimental mechanics, 1016-1021.

- [Mathew, 1984] Mathew J., Alfredson R.J., 1984. *Condition monitoring of rolling element bearings using vibration analysis*, Journal of Vibration, Acoustics, Stress, and Reliability in design, vol. 106 : 447 -453
- [McCormick, 1987] McCormick A.C., Nandi A.K., 1998. *Cyclostationarity in rotating machine vibration*, Mechanical system and Signal Processing, vol. 12(2) : 225-242.
- [McFadden, 1983] McFadden P.D., Smith J.D, 1983. *Implementing the High Frequency resonance technique for the vibration monitoring of rolling element bearings*, Cambridge University, Engineering Department, Technical report.
- [McFadden, 1984] McFadden P.D., Smith J.D, 1984. *Vibration monitoring of rolling element bearings by the high-frequency resonance technique - a review*, Tribology international, vol. 17 : 2-10.
- [McFadden, 1987] McFadden P.D., 1987. *A revised model for the extraction of periodic waveforms by time domain averaging*, Mechanical System and Signal Processing, vol. 1 : 83-95.
- [McFadden, 1991] McFadden P.D., 1991. *Technique for calculating the time domain averages of the vibration of the individual planet gears and the sun gear in an epicyclic gearbox*, Journal of Sound and Vibration, vol. 144 : 163-172.

- [McFadden, 2000] McFadden P.D. and Toozhy M., 2000, *Application of synchronous averaging to vibration monitoring of rolling element bearings*, Mechanical Systems and Signal Processing, vol. 14 : 891-906.
- [McClintic, 2000] McClintic, K.; Lebold, M.; Maynard, K.; Byington, C.; Campbell, R., 2000. *Residual and Difference Feature Analysis with Transitional Gearbox Data*, Proceedings of the 54th Meeting of the Society for Machinery Failure Prevention Technology : 635-645.
- [Meng, 1991] Meng Q., Qu. L., 1991. *Rotating machinery fault diagnosis using Wigner distribution*, Mechanical Systems and Signal Processing, vol. 5(3) :155-166
- [Monk, 1972] Monk R., 1974. *Vibration measurement gives early warning of mechanical faults*, Process Engineering :135-137
- [Nandi, 2002] Nandi A.K., Jack L.B.,2002. *Fault detection using support vector machines and artificial neural networks augmented by genetic algorithms*, Mechanical System and Signal Processing, vol. 16 : 373-390.
- [Odea, 1975] O'Dea D.M., 1975. *Computerised machinery vibration analysis improves reliability*, The Oil and Gas journal : 50-54.

- [Osuagwu, 1982] Osuagwu C.C., Thomas D.W., 1982. *Effect of inter-modulation and quasi-periodic instability in the diagnosis of rolling element incipient defect*, ASME Journal of Mechanical Design : 296-302.
- [Osuna, 1997] Osuna E., Freund R., Girosi F., 1997. *Improved training algorithm for Support Vector Machines*, Proceedings of the IEEE Neural Networks for Signal Processing : 276 - 285.
- [Ottonello, 1994] Ottonello C., Pagnan S., 1994 *Modified frequency domain kurtosis for signal processing*, Electronics letters vol. 30(14) : 1117 -1118.
- [Pagnan, 1994] Pagnan S., 1994 *Filtering of randomly occurring signals by kurtosis in the frequency domain*, Proceedings of the 12th International Conference on Pattern Recognition, vol. 3 : 131 -133.
- [Pan, 1996a] Pan M.C., Sas P., 1996. *Transient Analysis on Machinery Condition Monitoring*, Proceedings of ICSP96
- [Pan, 1996b] Pan M.C., Sas P., Van-Brussel H., 1996. *Non-Stationary Time-Frequency analysis for machine condition monitoring*, Proceedings of the IEEE-SP International Symposium on Time-Frequency and Time-Scale Analysis : 477-480
- [Peng, 2004] Peng Z.K., Chu F.L., 2004. *Application of the wavelet transform in machine condition monitoring and fault diagnostics : a*

review with bibliography, Mechanical Systems and Signal Processing, vol.18 : 199-221

- [Platt, 1998] Platt J.C., 1998. *Sequential Minimal optimisation : A fast algorithm for training Support Vector Machines*, Microsoft research, Technical report MSR-TR-98-14.
- [Polyshchuk, 2002] Polyshchuk V., Choy F.K. , Braun M.J., 2002. *Gear fault detection with Time-Frequency based parameter NP4*, International Journal of Rotating Machinery, vol.8(1) : 57-70
- [Randall, 1980] Randall R.B., 1980. *Advances in the application of cepstrum analysis to gearbox diagnostic*, Proceedings of the 2nd international conference on rotating machinery, Cambridge : 169-174.
- [Randall, 1981] Randall R.B., 1981. *Computer assisted incipient fault detection on rotating and reciprocating machines*, Noise and Vibration control Worldwide : 230-234.
- [Randall, 1995] Randall R.B., Li L, 1995. *Diagnostics of planetary gear bearings in the presence of gear vibrations*, Second International Conference on Gearbox Vibration and Diagnostics, London : 73-80.
- [Randall, 2000] Randall R.B., Antoni J., Chobsaard S., 2000. *A comparison of cyclostationary and envelope analysis in the diagnosis of rolling element bearings*, Proceedings of IEEE International Confe-

rence on Acoustics Speech and Signal Processing, ICASSP, vol.6 : 3882-3885.

- [Randall, 2001] Randall R.B., Antoni J., Chobsaard S., 2001. *The relationship between spectral correlation and envelope analysis in the diagnostics of bearing faults and other cyclostationary machine signals bearing*, Mechanical Systems and Signal Processing, vol.15 : 945-962.
- [Randall, 2003] Randall R.B., 2003. *Detection and diagnosis of incipient bearing failure in helicopter gearboxes* Mechanical Systems and Signal Processing, vol.11 : 177-190.
- [Ray, 1980] Ray A.G., 1980. *Monitoring rolling contact bearings under adverse conditions*, Second International Conference on vibrations in rotating machinery, Cambridge : 169-174.
- [Robichaud, 2007] Robichaud J.M., 2007. *Reference standards for vibration monitoring and analysis*, Proceedings of the 25th annual seminar of the Canadian Machinery Vibration Association, CMVA 2007.
- [Rojas, 2005] Rojas A., Nandi A.K., 2005. *Detection and Classification of Rolling-Element Bearing Faults using Support Vector Machines*, IEEE Workshop on machine learning for signal processing, vol.12 :153 -158 .

- [Rojas, 2006] Rojas A., Nandi A.K., 2006. *Practical scheme for fast detection and classification of rolling-element bearing faults using support vector machines*, Mechanical systems and signal processing, vol.20(6) :1523 -1536 .
- [Safizadeh, 1999a] Safizadeh M.S., Lakis L.L., Thomas M., 1999. *Application of Short Time Fourier Transform in machine fault detection*, Département de Génie Mécanique, École Polytechnique de Montréal, no :EPM/RT-99/5
- [Safizadeh, 1999b] Safizadeh M.S., Lakis L.L., Thomas M., 1999. *Fault detection and identification using Wigner-Ville distribution*, Département de Génie Mécanique, École Polytechnique de Montréal, no :EPM/RT-99/6
- [Samanta, 2003] Samanta B., Al-Balushi K.R., Al-Araimi S.A., 2003. *Artificial neural networks and support vector machines with genetic algorithm for bearing fault detection*, Engineering Applications of Artificial intelligence vol. 16 : 657-665.
- [Samanta, 2004a] Samanta B., 2004. *Gear fault detection using artificial neural networks and support vector machines with genetic algorithms*, Mechanical Systems and Signal Processing, vol. 18(3) : 625-644.

- [Samanta, 2004b] Samanta B., Al-Balushi K.R., Al-Araimi S.A., 2004. *Bearing fault detection using artificial neural networks and genetic algorithm*, EURASIP Journal on Applied Signal Processing vol. 3 :366-377.
- [Sawalhi, 2007] Sawalhi N., Randall R.B., Endo H., 2007. *The enhancement of fault detection and diagnosis in rolling elements bearings using minimum entropy deconvolution combined with spectral kurtosis*, Mechanical Systems and Signal Processing, vol. 21 : 2616-2633.
- [Scholkopf, 2000] Scholkopf B., Smola A.J., Williamson R.C., Bartlett P.L., 2000. *New support vector algorithms*, Neural computation, vol.12 : 1207-1245.
- [Scholkopf, 2002] Scholkopf B., Smola A.J., 2002. *Learnings with kernels : Support vector machines, regularization, optimization, and beyond*, Cambridge, MIT Press.
- [Shawe-Taylor, 2004] Shawe-Taylor J., Cristianini N., 2004. *An introduction to Support Vector Machines and other kernel-based learning methods*, Cambridge University Press.
- [Spears, 1991] Spears W.M., De Jong K.A., 1991. *An analysis of multi-point cross-over*, Fondation of Genetic Algorithms, edited by Rawlins G.J.E. : 310-315.

- [Stander, 2005] Stander C.J., 2005. *Condition monitoring of gearboxes operating under fluctuating load condition*, Thèse de doctorat, <http://upetd.up.ac.za/UPeTD.htm>.
- [Stewart, 1977] Stewart R.M., 1977. *Some useful data analysis techniques for gearbox diagnostics*, Université de Southampton, rapport MHM/R/10/77.
- [Suykens, 2002] Suykens J., Van Gestel T., De Brabanter J., De Moor B., Vandewalle J., 2000. *Least Squares Support Vector Machines*, World Scientific, Singapore.
- [Swansson, 1980] Swansson N.S., 1980. *Application of vibration signal analysis techniques to signal monitoring*, Conference on Friction and Wear in Engineering., 262-267.
- [Swansson, 1984] Swansson N.S., Favalro S.C., 1984. *Application of vibration analysis techniques to the condition monitoring of rolling element bearings*, Aero propulsion report 163, Department of Defence, Aeronautical Research Laboratory.
- [Syswerda, 1989] Syswerda G., 1989. *Uniform crossover in genetic algorithms*, Proceedings of the 3rd international conference on Genetic Algorithms : 2-9.
- [Tandon, 1999] Tandon N., Chouldhury A., 1999. *A Review of vibration and acoustics measurements methods for the detection of defects in*

- rolling element bearing*, Tribology Int. Eng., 32 : 469-480.
- [Thomas, 2002] Thomas M., 2002. *Fiabilité, Maintenance prédictive et Vibrations des machines* École de Technologie supérieure.
- [Turgeon, 2007] Turgeon F., 2007. *Design d'un Squeeze Film Damper*, rapport technique, Chaire industrielle CRNSG/EACL/BWC, Ecole Polytechnique de Montreal.
- [Uli, 1993] Ulieru D., 1993. *Diagnosis by measurement of internal vibration and vibration analysis on maintenance of rotating machinery as turbochillers*, Institute of environmental sciences annual technical meeting preceedings, vol. 2 : 525 -530.
- [Vapnik, 1964] Vapnik V., Chervonenkis, 1964. *A note on one class of perceptrons*, Automation and Remote Control.
- [Vapnik, 1995] Vapnik V., 1995. *The nature of statistical learning theory*, Springer verlag.
- [Vapnik, 1998] Vapnik V., 1998. *Statistical Learning Theory*, John Wiley & Sons.
- [Widodo, 2007a] Widodo A., Yang B., 2007. *Support vector machine in machine condition monitoring and fault diagnosis*, Mechanical systems and signal processing, vol. 21 : 2560-2574.

- [Widodo, 2007b] Widodo A., Yang B., Han T., 2007. *Combination of independent component analysis and support vector machines for intelligent faults diagnosis of induction motors*, Expert systems with application, vol. 32 : 299-312.
- [Widodo, 2007c] Widodo A., Yang B., 2007. *Application of non-linear feature extraction and support vector machines for fault diagnosis of induction motors*, Mechanical Systems and Signal Processing, vol. 33 : 241-250.
- [Widrow, 1975] Widrow B., McCool J.M., Larimore M.G., Johnson C.R., 1975. *Adaptive noise cancelling : Principles and Applications*, Proceedings of the IEEE, vol. 63(12) :1692-1716.
- [Widrow, 1985] Widrow B., Stearns B., 1985. *Adaptive signal processing*, Prentice Hall.
- [Yang, 2004] Yang B., Han T., An J.L., 2004. *ART Kohonen neural network for fault diagnosis of rotating machinery*, Mechanical Systems and Signal Processing, vol. 18 : 645-657.
- [Yen, 2000] Yen G., Lin K.C., 2000. *Wavelet packet feature extraction for vibration monitoring*, IEEE Transactions on Industrial Electronics, vol. 47(3) :650-667
- [Zakrajsek, 1993] Zakrajsek J.J., Townsend D.P., Decker H.J., 1993. *An analysis of gear fault detection method as applied to pitting fa-*

tigue failure data, 47th Mechanical failure Prevention Group, NASA Lewis Research Center, U.S. Army Aviation Systems Command, NASA TM 105950 AVSCOM TR 92-C035.

[Zakrajsek, 1994] Zakrajsek J.J., Handschuh R.F., Decker H.J., 1994. *Application of fault detection techniques to spiral bevel gear fatigue data*, 48th Mechanical failure Prevention Group, NASA Lewis Research Center, U.S. Army research Laboratory, NASA TM 106467 ARL-TR-345

[Zhang, 2006] Zhang L., Nandi A.K., 2006. *Fault classification using genetic programming*, Mechanical Systems and Signal Processing, vol. 21 : 1273-1284.

ANNEXE I

CALCUL DES FRÉQUENCES DE DÉFAUT D'UN ROULEMENT À BILLES

La détermination des fréquences de défaut de roulement est basée sur une analyse de la cinématique du roulement : elle consiste à calculer le nombre théorique d'impact engendré par la présence d'un défaut sur une des composantes du roulement. Ce modèle ne tient pas compte du glissement entre les composantes causé par la lubrification. Les fréquences caractéristiques des défauts qui en découlent sont donc des approximations plus ou moins justes des fréquences réelles de défauts.

Ici on s'intéresse aux fréquences de rotation des composantes du roulement : la bague interne, la bague externe, les billes et la cage. Les fréquences de rotation des bagues internes et externes sont en général connues car ses parties sont soit attachées aux composantes en rotation, soit fixes. Dans la majorité des configurations, le roulement est monté avec une bague interne tournante et une bague externe fixe. La bague interne tourne donc à la vitesse de rotation de l'arbre alors que la bague externe est immobile. Cependant, le développement théorique qui suit est général et suppose que la bague interne et la bague externe tournent.

I.1 Fréquence d'un défaut de cage

La cage qui retient les billes assure la transition de vitesse entre la bague interne et la bague externe. Comme elle est située au diamètre moyen du roulement, on peut donc approximer sa vitesse V_c par la moyenne des vitesses des bagues internes et externes, V_i et V_o respectivement.

$$V_c = \frac{V_i + V_o}{2} \quad (\text{I.1})$$




FIG. I.1: Géométrie et vitesse cinématique du roulement

La relation entre les vitesses tangentielles de l'équation (I.1) peut être réécrite en terme des fréquences comme suit

$$f_c = \frac{f_i D_i + f_o D_o}{2D} \quad (\text{I.2})$$

D'un autre côté, la relation entre les diamètres des bagues internes D_i et externes D_o ,

des billes B_d et le diamètre moyen P_d est donnée par

$$D_i = P_d - B_d \cos \alpha \quad (\text{I.3})$$

$$D_o = P_d + B_d \cos \alpha \quad (\text{I.4})$$

En insérant les relations (I.3) et (I.4) dans l'équation (I.2), il vient

$$f_c = \frac{\left(1 - \frac{B_d}{P_d} \cos \alpha\right) f_i + \left(1 + \frac{B_d}{P_d} \cos \alpha\right) f_o}{2} \quad (\text{I.5})$$

Ainsi, si il existe un défaut quelconque sur la cage du roulement, cela se manifestera à sa fréquence de rotation f_c . Dans le cas où la bague interne est tourne à la fréquence de rotation de l'arbre f_s et que la bague interne est fixe, on a que

$$f_c = \frac{f_s}{2} \left(1 - \frac{B_d \cos \alpha}{P_d}\right) \quad (\text{I.6})$$

I.2 Fréquence d'un défaut sur les bagues

Lorsqu'il existe un défaut sur une des bague du roulement, il se crée des impulsions lorsque chaque bille passe sur le défaut. C'est donc la fréquences de passage des billes sur la défaut de la bague interne/externe qui sera la fréquence caractéristique du défaut. Ces fréquences sont fonction de la vitesse de rotation de la cage, de la bague

défectueuse et du nombre de billes z présent dans le roulement.

La fréquence de passage des billes sur un défaut sur la bague interne, BPFI (Ball Pass Frequency on Inner race) se calcule comme suit

$$BPFI = z(f_c - f_i) = \frac{z}{2}|f_o - f_i| \left(1 + \frac{B_d \cos \alpha}{P_d} \right) \quad (\text{I.7})$$

Si la bague externe est fixe, il vient

$$BPFI = \frac{z}{2}f_i \left(1 + \frac{B_d \cos \alpha}{P_d} \right) \quad (\text{I.8})$$

La fréquence de passage des billes sur un défaut sur la bague externe, BPFO (Ball Pass Frequency on Outer race) se calcule comme suit

$$BPFO = z(f_o - f_c) = \frac{z}{2}|f_o - f_i| \left(1 - \frac{B_d \cos \alpha}{P_d} \right) \quad (\text{I.9})$$

Si la bague externe est fixe, il vient

$$BPFO = \frac{z}{2}f_i \left(1 - \frac{B_d \cos \alpha}{P_d} \right) \quad (\text{I.10})$$

I.3 Fréquence d'un défaut sur la bille

Lorsqu'il existe un défaut sur une bille, il se créera des impulsions entre la bille et les bagues lorsque contact se fera à cet endroit. En plus de tourner autour de l'axe du roulement, la bille tourne aussi sur elle-même, donc le point de contact entre la bille défectueuse et une des bagues varie et ne coïncidera pas toujours avec le point où se trouve le défaut sur la bille. C'est pourquoi le phénomène résultant est *aléatoire*, car il ne peut être prédit avec exactitude comme dans les cas précédents. Cependant, dans une configuration parfaite, la fréquence de contact (communément appelé Ball Spin Frequency, BSF, à ne pas confondre avec la fréquence de rotation de la bille autour de son axe) sera l'inverse du temps mis par la bille pour parcourir une distance égale à son diamètre le long d'une des bagues.

$$BSF = (f_c - f_i) \frac{\pi(P_d - B_d \cos \alpha)}{\pi B_d} = (f_o - f_c) \frac{\pi(P_d + B_d \cos \alpha)}{\pi B_d} \quad (\text{I.11})$$

Peu importe la bague considérée, interne ou externe, on aboutira au même résultat, soit

$$BSF = \frac{1}{2} |f_o - f_i| \left(\frac{P_d}{B_d} - \frac{B_d \cos^2 \alpha}{P_d} \right) \quad (\text{I.12})$$

$$BSF = \frac{P_d}{2B_d} |f_o - f_i| \left[1 - \left(\frac{B_d \cos \alpha}{P_d} \right)^2 \right] \quad (\text{I.13})$$

Si la bague interne du roulement tourne avec l'arbre, et la bague externe est fixe, alors on a

$$BSF = \frac{P_d}{2B_d} f_i \left[1 - \left(\frac{B_d \cos \alpha}{P_d} \right)^2 \right] \quad (\text{I.14})$$

Très souvent, il arrive que la fréquence caractéristique d'un défaut de bille apparaît non pas à la fréquence BSF , mais à sa seconde harmonique, i.e. $2 \times BSF$. Cela s'explique par le fait qu'en un tour, le point de contact entre la bille et les bagues interne et externe respectivement coïncide avec le point où se trouve le défaut.

ANNEXE II

ANALYSE MODALE DU SFD

On présente dans cette annexe les résultats de l'analyse modale expérimentale du SFD. Cette analyse a été menée dans le but d'identifier les fréquences de résonance du montage dans la plage de fréquences que nous allons couvrir. Nous avons effectué les tests d'analyse modale selon la méthode Single Input Single Output, SISO. On excite la structure à l'aide d'un marteau choc à embout dur (PCB 086C04) et on déplace l'accéléromètre (PCB 353B33) le long de l'arbre pour mesurer la réponse impulsionnelle.




FIG. II.1: Disposition des points de mesures lors de l'analyse modale

La fréquence d'échantillonnage est fixée à 32.768 kHz et le temps d'échantillonnage à 30 secs, avec une bande passante de 12.8 kHz. On génère environ 10 chocs par point de mesure. La figure II.2 montre que la gamme de fréquence excitée par le marteau à embout dur s'étend de 0 à 5 kHz environ.




FIG. II.2: Bande passante typique du signal d'impulsion, marteau choc à embout dur

On a estimé la fonction de transfert avec la fonction *tfestimate* de MATLAB. On utilise une fenêtre de Hanning pour découper le signal et le spectre est calculé avec un chevauchement de 75% entre les blocs de signal. On se sert de la partie réelle et de la partie imaginaire de la fonction de transfert (signal d'inertance) pour estimer les fréquences naturelles du banc d'essai. On applique le principe suivant : le système est en résonance lorsque la partie réelle du signal d'inertance est nulle et sa partie imaginaire passe par un optimum local. On vérifie aussi que la phase des fréquences naturelles est de ± 90 deg.




FIG. II.3: Fonction de transfert au point A, partie réelle et imaginaire




FIG. II.4: Fonction de transfert au point A, amplitude et phase

Points de mesure	Fréquences observées (Hz)
A	135.8 ; 199.9 ; 1573 ; 2169 ; 6347 ; 10810
B	136.2 ; 199.9 ; 1487 ; 1567 ; 2170 ; 3785 ; 6370
C	136.4 ; 199.9 ; 475 ; 1475 ; 1563 ; 4756 ; 6363
D	136.9 ; 200.3 ; 478.8 ; 1471 ; 1560 ; 4755 ; 6382
E	137.3 ; 200.2 ; 477.9 ; 2299 ; 6370
F	137.9 ; 199.9 ; 477.4 ; 6368 ; 10140
G	200 ; 476.4 ; 1578 ; 2171 ; 2287 ; 4772 ; 6268
H	199.9 ; 475.4 ; 1572 ; 4779 ; 6367
I	199.7 ; 475.9 ; 1567 ; 4786 ; 10180
SKF 2310	133 ; 199.9 ; 650.8 ; 810.4 ; 2179 ; 6375 ; 9105 ; 11800
SKF 1211	133.1 ; 200.7 ; 1585 ; 2158 ; 4783 ; 6358

TAB. II.1: Fréquences naturelles du banc d'essai expérimental