

الجمهورية الجزائرية الديمقراطية الشعبية
وزارة التعليم العالي والبحث العلمي

UNIVERSITE BADJI MOKHTAR - ANNABA
BADJI MOKHTAR – ANNABA UNIVERSITY



جامعة باجي مختار – عنابة

Faculté : de TECHNOLOGIE

Département : Electronique

Domaine : Sciences et Techniques

Filière : Automatique

Spécialité : Automatique et systèmes

Mémoire

Présenté en vue de l'obtention du Diplôme de Master

Thème :

**Apprentissage Supervisé Automatique pour la Détection
des Défauts de Roulements d'un Moteur à Induction**

Présenté par : MESSADEG Abdelnour et BENSAYEH Islam

Encadrant : ARBAOUI Fayçal Prof. Université BADJI Mokhtar- ANNABA

Jury de Soutenance :

| | | | |
|----------------------|--------|-----------------------|-----------|
| LAFIFI Mourad | M.C.A. | BADJI Mokhtar- ANNABA | Président |
| ARBAOUI Fayçal | Prof. | BADJI Mokhtar- ANNABA | Encadrant |
| SAIDI Mohammed Larbi | Prof. | BADJI Mokhtar- ANNABA | Examineur |

Année Universitaire : 2021/2022

Dédicaces

Tout d'abord, je veux rendre grâce à Dieu,

C'est ainsi que je dédie ce travail à :

*A mes parents pour ses tendresses, ses patiences et encouragement
avec toute mon affection.*

*A tous mes amis ainsi qu'à toutes les personnes que j'ai connues, qui
m'ont aidé, soutenu et encouragé.*

*A tous les enseignants de la spécialité pour leurs soutiens. Avec
lesquels j'ai beaucoup appris.*

MESSADEG Abdelnour

*Aux personnes les plus chères et les plus proches de mon cœur, à ma
chère mère et à mon cher père, qui m'ont aidé et soutenu, et leurs prières
ont eu pour effet de gérer le navire de recherche jusqu'à ce qu'il se pose
sur cette image. À mes sœurs et à ma famille.*

*À mes professeurs et aux personnes qui m'ont comblé d'amour,
d'appréciation, de conseils, de direction et d'orientation*

*À tous, je dédie cet humble travail, demandant à Dieu le Tout-Puissant
de nous en faire bénéficier et de nous assurer le succès.*

BENSAYEH Islam

Remerciements

الحمد لله وكفى والصلاة على المصطفى وآله ومن تلا اما بعد

الحمد لله

Qui nous a permis par sa grâce d'apprécier cette étape de notre long chemin académique avec ce mémoire, fruit de beaucoup efforts et de réussites.

*Nous adressons nos sincères remerciements et notre gratitude au Professeur **ARBAOUI Fayçal** pour tous les conseils et les précieuses informations qu'il nous a fournis et qui ont contribué à compléter le sujet de notre étude dans ses divers aspects.*

Nous n'oublions pas de présenter nos respects et notre gratitude à nos enseignants respectueux...Merci beaucoup pour tous vos efforts.

ملخص

العنوان: التعلم الآلي الخاضع للإشراف لتصنيف عيوب المدرجة الكروية للآلة غير المتزامنة

الهدف من هذه الأطروحة هو التشخيص الآلي لعيوب المدرجة الكروية للآلة غير المتزامنة بناءً على تحليل المكونات الرئيسية APC.

يتم استخراج متجه من المعلمات (مؤشرات أو خصائص)، يسمى أيضاً متجه الشكل، من كل من إشارات وأطياف الاهتزاز الخام، ويتكون من مؤشرات إحصائية وطيفية للأداء الأمثل في البداية، ثم يتم استخراج المعلمات من الإشارات المعالجة باستخدام طريقة تحليل المكون الرئيسي لتحليل PCA.

أجريت الدراسة على قاعدة بيانات جامعة Case Western Reserve University، حيث تم الحصول على الإشارات في أوضاع وظروف تشغيل مختلفة (صحية وخاطئة، تغيرات السرعة، تغيرات الأحمال واختلاف شدة التقصير).

في مرحلة التصنيف، تم الاحتفاظ بفواصل الهوامش العريضة متعددة الفئات (SVM).

ثم أجريت دراسة مقارنة مع المصنفات بالاعتماد على الشبكات العصبية الاصطناعية (RNA). لوحظ وجود كفاءة أفضل من حيث الوقت ومعدل التصنيف لـ SVM المتعدد مقارنة بالشبكات RNA.

الكلمات المفتاحية: آلات المتجهات الداعمة (SVM)، المعلومات الإحصائية، تحليل المكونات الرئيسية (PCA)، خطأ المدرجة الكروية، إشارة الاهتزاز.

Résumé

Titre : *Apprentissage supervisé Automatique pour la Détection des Défauts de Roulements d'un Moteur à Induction*

Le défaut de roulement est l'une des causes dominantes de dysfonctionnement dans les machines asynchrones, entraînant une perte économique significative.

L'objectif de ce mémoire est le diagnostic automatisé des défauts de roulements basé sur l'analyse en composantes principales.

Un vecteur de paramètres (Indicateurs ou caractéristiques), appelé aussi vecteur forme, est extrait de chacun des signaux de vibration bruts et spectres. Il se compose d'indicateurs statistiques et spectraux pour une performance optimale dans un premier temps, ensuite les paramètres sont extraits des signaux traités en utilisant la décomposition par la méthode de l'analyse par les composantes principales ACP.

L'étude a été menée sur la base de données de la Case Western Reserve University, où les signaux ont été acquis dans différents modes et conditions de fonctionnement (sain et avec défauts, variations de vitesse, variation de charges et variation de la sévérité du défaut).

Dans la phase de classification, les séparateur à vaste marges (SVM) multi-classes ont été retenus.

Ensuite une étude comparative a été effectuée avec les classificateurs à base Réseaux de Neurones Artificiels (RNA). On a constaté une meilleure efficacité en termes de temps et taux de classification du multi-SVM par rapport aux RNA.

Mots clés : Machines à Vecteurs de Supports (SVM), Paramètres statistiques, L'analyse en composantes principales (APC), défaut roulement, signal vibratoire

Abstract

Title: *Automatic Supervised Learning for Bearing Fault Detection of an Induction Motor*

Bearing failure is one of the dominant causes of malfunctions in asynchronous machines, resulting in significant economic loss.

The objective of this thesis is the automated diagnosis of bearing faults based on principal component analysis.

A vector of parameters (Indicators or characteristics), also called shape vector, is extracted from each of the raw vibration signals and spectra, it consists of statistical and spectral indicators for optimal performance at first, then the parameters are extracted from signals processed using the APC method decomposition .

The study was conducted on the Case Western Reserve University database, where the signals were acquired in different operating modes and conditions (healthy and faulty, speed variations, load variations and the severity variation of the default).

In the classification phase, multi-class wide-margin separators (SVMs) were retained.

Then a comparative study was carried out with the classifiers based on Artificial Neural Networks (RNA). A better efficiency in terms of time and classification rate of the multi-SVM compared to the ANNs was observed.

Keywords: Support Vector Machines (SVM), Statistical Parameters, Principal Component Analysis (PCA), bearing fault, vibration signal.

Table des matières

| | |
|---|----|
| Dédicaces | |
| Remerciements | |
| Résumé / Abstract / ملخص | |
| Liste des figures | |
| Liste des tableaux | |
| Introduction générale | 1 |
| Chapitre 1. Défauts Roulements & Analyse Vibratoire | 3 |
| 1.1. Roulement | 4 |
| 1.2. Défauts roulements | 4 |
| 1.3. Type des défauts roulements | 5 |
| 1.3.1. Écaillage | 5 |
| 1.3.2. Grippage | 5 |
| 1.3.3. Coups, fissures, cassures | 5 |
| 1.3.4. Détérioration des cages | 5 |
| 1.4. Fréquences caractéristiques et défauts | 6 |
| 1.4.1. Les paramètres caractéristiques d'un roulement | 7 |
| 1.5. Définition d'une vibration | 8 |
| 1.5.1 Analyse vibratoire | 8 |
| 1.5.2. Objectifs analyse vibration | 8 |
| 1.5.3. Outils d'analyse des vibrations | 8 |
| 1.6. Les Méthodes d'analyse Vibratoire | 9 |
| 1.7. Sélection et réduction des caractéristiques | 11 |
| 1.7.1. Caractéristiques ou paramètres temporelles | 11 |
| 1.7.2. Caractéristiques ou paramètres fréquentielles | 12 |
| Références Bibliographiques | 13 |
| Chapitre 2. L'analyse en Composantes Principales | 14 |
| 2.1. Introduction | 15 |
| 2.2. Principe L'analyse en composantes principales (APC) | 15 |
| 2.3. Détermination d'une structure optimale du modèle ACP | 21 |

| | |
|---|----|
| 1. Pourcentage cumule de la variance (PCV) | 21 |
| 2. la méthode de validation cumulée (PRESS) | 21 |
| 3. le Scree test : | 22 |
| Références Bibliographiques | 23 |
| Chapitre 3. Multi classification avec les séparateurs à vaste marge | 24 |
| 3.1. Les algorithmes d'apprentissage automatique | 25 |
| 3.2. Séparateur à vaste marge (SVM) | 25 |
| 3.3. Notions de base : Hyperplan, marge et support vecteur | 25 |
| 3.4. Séparateur à vaste marge dans le cas linéaire | 27 |
| 3.4.1. Maximisation de marge | 27 |
| 3.4.2. Calcul de la marge | 28 |
| 3.4.3. Calcul de l'Hyperplan optimal | 28 |
| 3.5. Types multi-class des séparateurs à vaste marge | 30 |
| 3.5.1. Multi classification par l'approche un contre tous | 30 |
| 3.5.2. Multi classification par l'approche un contre un | 32 |
| Références Bibliographiques | 34 |
| Chapitre 4. Résultats de simulation | 35 |
| 4.1. Matériels et méthodes | 36 |
| 4.1.1. Présentation du Banc d'Essai de la CWRU | 36 |
| 4.1.2. Présentation des signaux et quelques-unes de leurs caractéristiques | 37 |
| 4.2. Méthodologie de diagnostic adoptée | 41 |
| 4.2.1 L'analyse en composantes principale | 42 |
| 4.2.2 Multi-classification SVM | 42 |
| 4.3. Configuration de l'expérience | 43 |
| 4.3.1. Les données de défaut de roulement | 43 |
| 4.3.2. Sélection des caractéristiques en utilisant l'analyse en composantes principales | 43 |
| 4.3.3. Traitement des données et diagnostic utilisant l'approche multi-classes SVM | 45 |
| 4.4 Discussion des résultats | 46 |
| Conclusion générale | 48 |

Liste des figures

Chapitre 1

| | |
|---|----|
| Figure 1.1 : Schéma d'un roulement billes..... | 4 |
| Figure 1.2 : (a) Ecaillage d'une bague intérieure, (b) Criques corrosion..... | 5 |
| Figure 1.3 : Photos représentant les différents défauts de roulements à billes. (a) sur la bague interne ;(b) sur la cage ; (c) sur une bille et (d) sur la bague externe..... | 5 |
| Figure 1.4 : Spectre théorique d'un défaut | 6 |
| Figure 1.5 : Fréquence caractéristique d'un défaut de type écaillage affectant la bague extérieure..... | 6 |
| Figure 1.6 : Fréquences caractéristiques du roulement à billes | 7 |
| Figure 1.7 : Techniques d'extraction des caractéristiques..... | 10 |

Chapitre 2

| | |
|--|----|
| Figure 2.1 : Représentation des étapes de la construction du modèle PCA..... | 16 |
| Figure 2.2 : Illustration graphique de l'effet du centrage et de réduction d'une distribution bi-variable, (a) Distribution d'origine, (b) Centrage et réduction de cette distribution :..... | 17 |

Chapitre 3

| | |
|--|----|
| Figure 3.1 : Exemple d'un hyperplan séparateur | 26 |
| Figure 3.2 : Exemple de vecteurs de support | 26 |
| Figure 3.3 : Exemple de marge maximal (hyperplan valide). | 27 |
| Figure 3.4 : a) Hyperplan avec faible marge, b) Meilleur hyperplan séparateur | 27 |
| Figure 3.5 : Exemple de classification d'un nouvel élément | 28 |
| Figure 3.6 : Classification SVM un contre tous (One Vs All)..... | 31 |
| Figure 3.7 : Schéma des hyperplans linéaires pour la classification un contre tous (One vs all) /n=4..... | 32 |
| Figure 3.8 : Classification SVM un contre un (One Vs One)..... | 32 |

Chapitre 4

| | |
|--|----|
| Figure 4.1 : Le Banc d'essai de la CWRU..... | 36 |
| Figure 4.2 : Signal original cas sain..... | 38 |
| Figure 4.3 : Auto corrélation du signal original cas sain..... | 38 |
| Figure 4.4 : Variation de quelques paramètres temporels et fréquentiels du signal sans défauts (sain)..... | 38 |
| Figure 4.5 : Signal original avec défaut bille..... | 39 |
| Figure 4.6 : Auto corrélation du signal ave défaut bille..... | 39 |
| Figure 4.7 : Variation de quelques paramètres temporels et fréquentiels du signal avec défaut bille..... | 39 |
| Figure 4.8 : Signal original avec défaut bague interne..... | 40 |
| Figure 4.9 : Auto corrélation du signal avec défaut bague interne..... | 40 |
| Figure 4.10 : Variation de quelques paramètres temporels et fréquentiels du signal avec défaut bague interne..... | 40 |
| Figure 4.11 : Signal original avec défaut bague externe..... | 41 |
| Figure 4.12 : Auto corrélation du signal avec défaut bague externe..... | 41 |
| Figure 4.13 : Variation de quelques paramètres temporels et fréquentiels du signal avec défaut bague externe..... | 41 |
| Figure 4.14 : Schéma présentant les étapes de diagnostic..... | 42 |

Liste des tableaux

Chapitre 4

| | |
|--|----|
| Tableau 4.1 : Données vibratoires des défauts avec une fréquence d'échantillonnage de 12K HZ /CWRU..... | 37 |
| Tableau 4.2 : Matrice de chargement des Composantes principales, L..... | 44 |
| Tableau 4.3 : Paramètres d'apprentissage | 45 |
| Tableau 4.4 : Récapitulatif des résultats obtenus..... | 46 |
| Tableau 4.5 : Résultats de diagnostic par multi-classification SVM..... | 46 |

Introduction Générale

Introduction Générale

Le moteur asynchrone occupe un domaine très important dans l'industrie et les transports et est la machine la plus utilisée dans le domaine des puissances supérieures à quelques kilowatts car il présente de nombreux avantages tels que sa puissance massique, sa robustesse, sa facilité de mise en œuvre, son faible coût d'achat et d'entretien. L'apparition dans les années 1980 des variateurs permettant de faire varier la fréquence de rotation dans une large gamme a grandement favorisé son développement.

Malgré ces qualités évoquées, il n'est pas rare que ces moteurs présentent quelques défaillances émanant d'un vieillissement prématuré. Comme ces machines sont soumises pendant leur fonctionnement à plusieurs contraintes électrique, magnétique, mécanique et thermique, elles provoquent des défauts dans les différentes parties du moteur, ce qui engendre des arrêts conduisant à des pertes de production et à des réparations coûteuses. Cependant, son utilisation génère des contraintes électriques et mécaniques, sources de défauts internes, amenant les scientifiques et les industriels à élaborer des méthodes de diagnostic des défauts de cette machine et à développer de nouvelles techniques pour obtenir un diagnostic automatique des défauts. Les défauts électriques peuvent apparaître au niveau du stator et/ou rotor. Les défauts mécaniques sont généralement les plus courants. Nous pouvons trouver dans la littérature de nombreuses publications traitant de divers problèmes comme les défauts de roulements ou de barres cassées dans les moteurs asynchrones.

L'objectif principal de ce mémoire est de mettre en œuvre un algorithme de surveillance de l'état des roulements par combinaison de l'analyse en composante principale et les machines à vecteurs de support pour la classification des défauts.

L'analyse en composantes principales (ACP) est une méthode statistique d'analyse des données multivariée et vise à transformer un certain nombre de variables corrélées en un plus petit nombre de variables décorrelées appelés composantes principales sans perte significative d'informations. Cette réduction de la dimensionnalité permet de réduire la complexité du traitement du signal. La méthode SVM est une technique de classification particulièrement bien adaptée pour la reconnaissance des formes et traite des données très diversifiées ayant plusieurs dimensions telles que les textes, les images, la voix, les diagnostics médicaux, la bio-informatique pour la reconnaissance de gènes ...etc. Le champ d'application des SVM est large et représente une méthode de classification intéressante.

Introduction Générale

Ce mémoire comporte principalement 4 chapitres. Le premier est consacré à la présentation des différents types de défauts des roulements ainsi que l'analyse vibratoire. Le deuxième chapitre, introduit la théorie de l'analyse en composante principales et son utilisation en diagnostic. Dans le troisième chapitre, nous détaillons la classification supervisée par les séparateurs à vaste marges.

Le dernier chapitre présente l'application expérimentale du système de diagnostic sur les données vibratoires non stationnaires issues du banc d'essai de la "Case Western Reserve University (CWRU)" avec la technique adoptée dans ce travail.

On achèvera, enfin par une conclusion générale et des perspectives.

Chapitre I

Défauts de Roulements & Analyse Vibratoire

1.1. Roulement :

Le roulement est un organe qui assure une liaison mobile entre deux éléments d'un mécanisme en rotation l'un par rapport à l'autre. Sa fonction est de permettre la liaison et généralement la rotation relative de ces éléments, sous charge, avec précision et avec un frottement minimal.

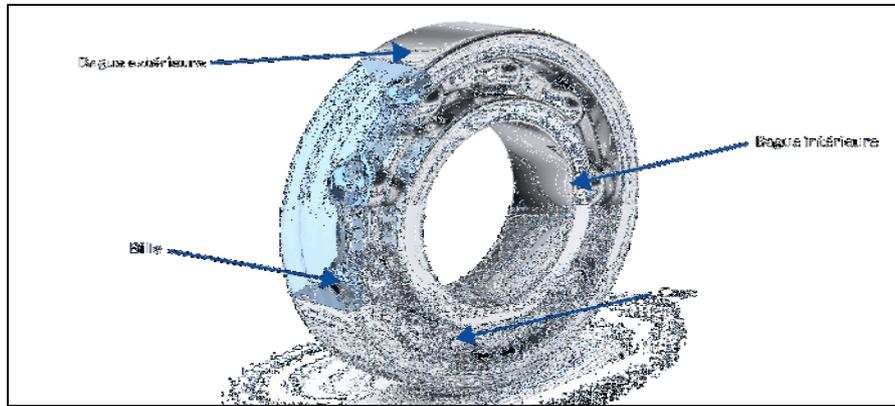


Figure 1.1 : Schéma d'un roulement à billes.

Un roulement à billes se compose de 4 éléments :

- Une bague extérieure.
- Une bague intérieure.
- Les billes.
- Une cage.

1.2. Défauts de Roulements :

Un roulement est composé des bagues interne et externe, d'une cage et de billes. Des vibrations sont produites quand les conditions de roulement ne sont pas parfaites, et qui peuvent être induites par des dommages extérieurs ou des forces agissant sur les roulements (déséquilibre, désalignement, etc.). Plus spécifiquement, les vibrations sont produites par les impacts qui se produisent quand la surface d'une composante heurte une autre surface. Comme le roulement tourne, les impulsions résultantes se produisent périodiquement. Les fréquences de ces impulsions sont uniquement déterminées par l'emplacement où le défaut se produit, soit sur la bague interne, sur la bague externe, ou sur les éléments de billes. La géométrie du roulement est aussi un paramètre très important.

1.3. Type des défauts de roulements :

1.3.1. Écaillage :

Se caractérise par des traces de fissuration et d'arrachement de fragments de matière.

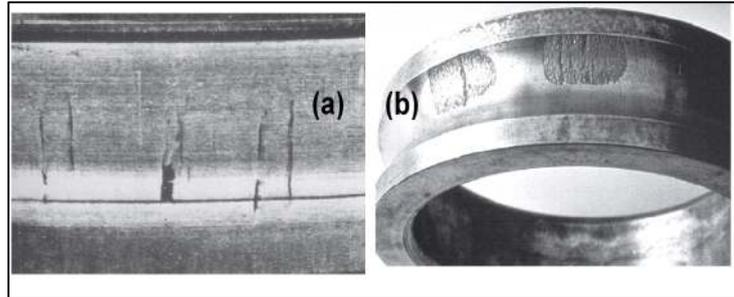


Figure 1.2 : (a) Ecaillage d'une bague intérieure, (b) Criques de corrosion.

1.3.2. Grippage :

En plus de l'arrachement de matière, des traces brunes dues à l'échauffement, des déformations de corps roulants, et des micros fusions peuvent apparaître.

1.3.3. Coups, fissures, cassures :

Se manifestant avec des traces visibles d'outils, et des ruptures des bagues.

1.3.4. Détérioration des cages :

Se manifestant sous plusieurs formes : déformation ; usure ou rupture des cages.

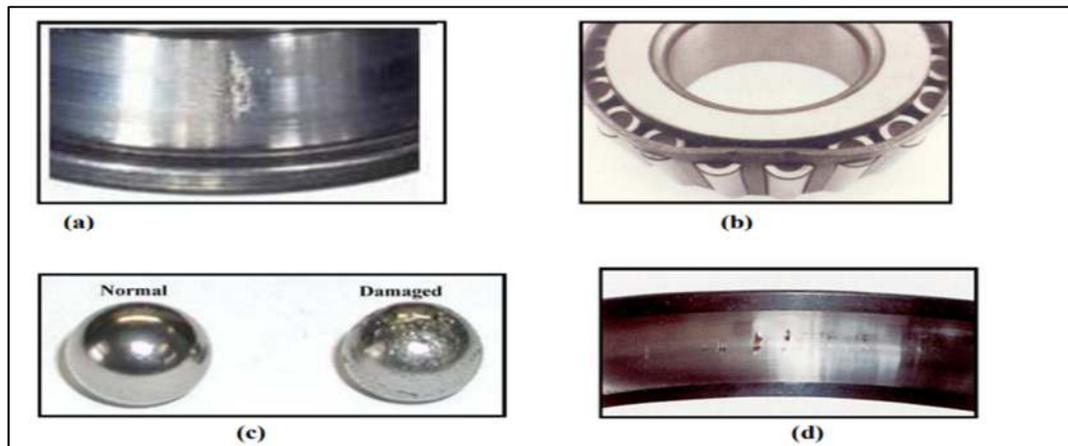


Figure 1.3 : Défauts des roulements à billes. (a) sur la bague interne ; (b) sur la cage ; (c) sur une bille et (d) sur la bague externe.

1.4. Fréquences caractéristiques de défaut des éléments d'un roulement :

La présence d'un défaut au niveau d'un roulement à un impact sur le spectre de son signal vibratoire tel qu'une augmentation de l'amplitude de la vibration aux fréquences du roulement, mais aussi la présence des vibrations aux harmoniques de ces fréquences ainsi qu'à des fréquences de modulation, le spectre va faire apparaître un peigne de raie à la fréquence du défaut et des bandes latérales à la fréquence de rotation de l'arbre (F_0).

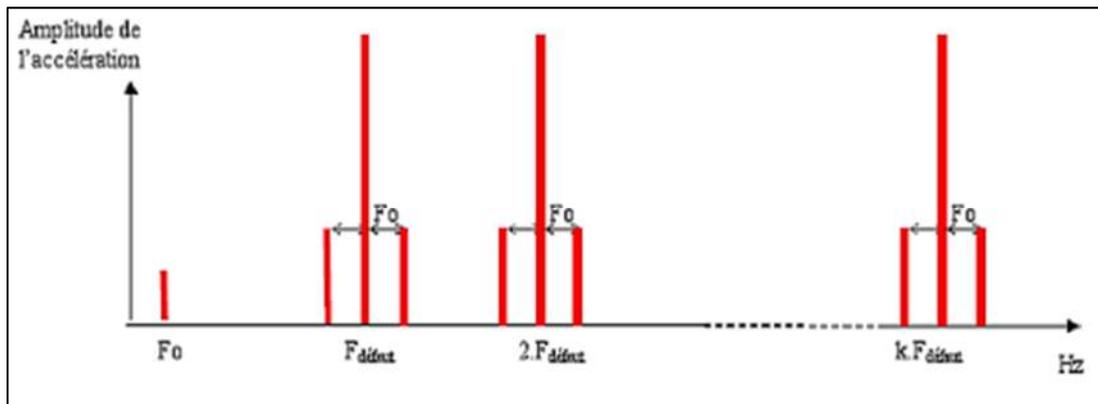


Figure 1.4 : Spectre théorique d'un défaut [1].

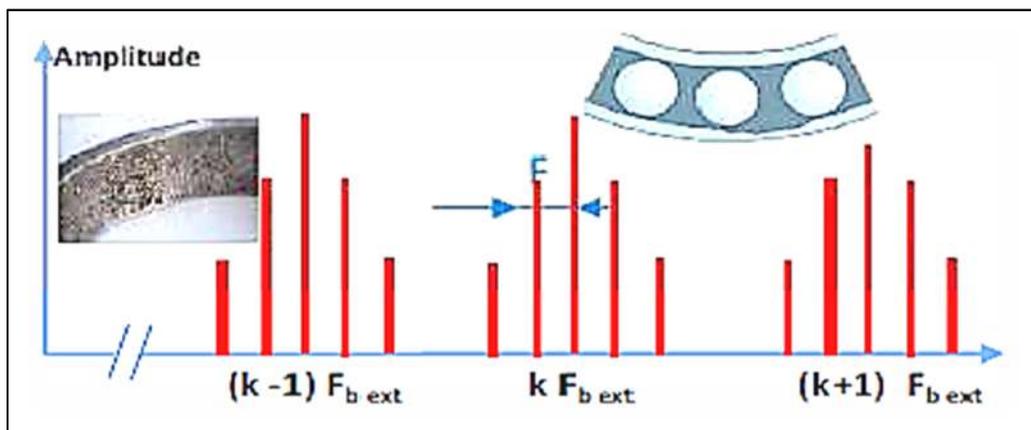


Figure 1.5 : Fréquence caractéristique d'un défaut de type écaillage affectant la bague extérieure [1].

Pour chaque type de roulement, et en fonction de ses cotes de fabrication, on peut considérer 4 fréquences caractéristiques [2] :

- La fréquence de passage d'un élément roulant sur un défaut de bague extérieure (Ball Passing Frequency Outer Race [BPFO]) :

$$BPFO = \frac{n \cdot f_0}{2} \left(1 - \frac{D_b}{D_p} \cos \theta \right) \quad (1.1)$$

- La fréquence de passage d'un élément roulant sur un défaut de bague intérieure (Ball Passing Frequency Inner Race [BPFI]) :

$$BPFI = \frac{n \cdot f_0}{2} \left(1 + \frac{D_b}{D_p} \cos \theta \right) \quad (1.2)$$

- La fréquence de passage d'un défaut de cage (Cage Frequency [CF]) :

$$CF = \frac{f_0}{2} \left(1 - \frac{D_b}{D_p} \cos \theta \right) \quad (1.3)$$

- La fréquence de passage d'un défaut de bille (Ball Frequency [BF]) :

$$BF = \frac{f_0 D_p}{2 D_b} \left(1 - \left(\frac{D_b}{D_p} \cos \theta \right)^2 \right) \quad (1.4)$$

1.4.1. Les paramètres caractéristiques d'un roulement :

Sont les suivantes (figure 1.6) :

- f_0 la fréquence de rotation en [HZ].
- n Le nombre de billes.
- D_b le diamètre de bille en [mm].
- D_p le diamètre moyen du roulement en [mm].
- θ l'angle de contact en [degré].

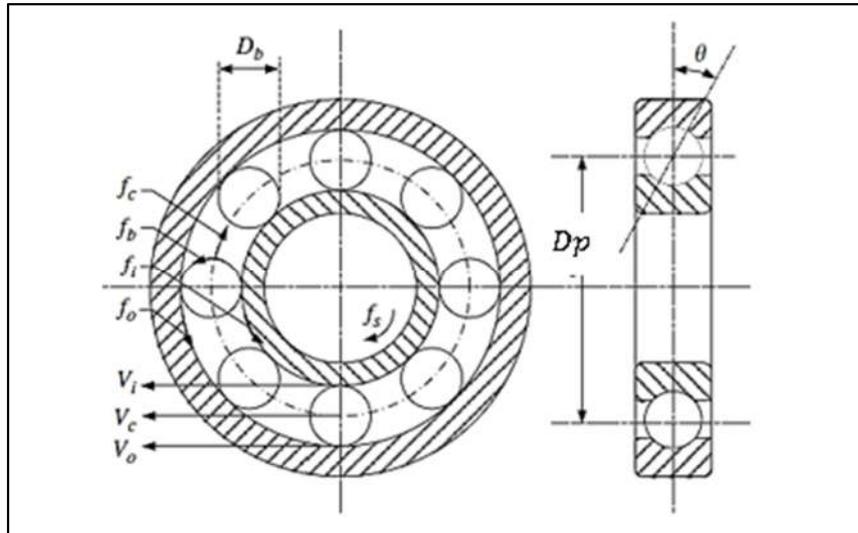


Figure 1.6 : Fréquences caractéristiques du roulement à billes [2].

1.5. Définition d'une vibration :

Un système mécanique est dit en vibration lorsqu'il est animé d'un mouvement de va-et-vient autour d'une position moyenne, dite position d'équilibre, si l'on observe le mouvement d'une masse suspendue à un ressort on constate qu'il se traduit par :

- Un déplacement : la position de la masse varie de part et d'autre du point d'équilibre ;
- Une vitesse de déplacement : variation du déplacement par rapport au temps ;
- Une accélération : variation de la vitesse par rapport au temps.

Une propriété fondamentale relie les trois représentations déplacement D , vitesse V et accélération a :

$$D = \frac{V}{2\pi f} = \frac{a}{(2\pi f)^2} \quad (1.5)$$

1.5.1. Analyse vibratoire :

La modification de la vibration d'une machine constitue souvent la première manifestation physique d'une anomalie, cause potentielle de dégradations, voire de pannes par effet de fatigue au sein de la matière.

La surveillance des vibrations peut permettre de déceler l'apparition d'efforts perturbateurs à un stade précoce. La facilité relative de son installation rend l'analyse des signaux vibratoires une des techniques les plus utilisées pour la surveillance et le diagnostic des défauts des machines tournantes, cela dit il existe d'autres techniques de surveillance tel que :

- La thermographie infrarouge.
- L'analyse des mesures ultrasonore.

1.5.2. Objectifs analyse vibration :

L'analyse vibratoire poursuit deux objectifs :

- L'analyse détaillée des défauts.
- La détection des défauts.

On utilise à cet effet des paramètres calculés :

- Soit dans le domaine temporel.
- Soit dans le domaine fréquentiel.
- Soit dans les deux à la fois.
-

1.5.3. Outils d'analyse des vibrations :

Les outils utilisés pour mesurer les vibrations se sont considérablement améliorés au cours des dernières années. Le capteur de choix pour la plupart des données de vibration sur les

machines industrielles est un accéléromètre : c'est un capteur qui convertit le mouvement mécanique en un signal électrique.

1.6. Les méthodes d'analyse vibratoire :

Les techniques du domaine temps-fréquence sont principalement utilisées pour traiter des signaux vibratoires non stationnaires. On y distingue la transformée de Fourier courte, la distribution de Wigner-Ville, l'analyse en ondelettes notamment la décomposition en paquets d'ondelettes (Wavelet Packet Decomposition : WPD), la décomposition modale empirique et la transformée de Hilbert-Huang.

L'une des Méthodes la plus efficace pour l'analyse des signaux non stationnaires est l'analyse en composante principale (ACP ou PCA en anglais pour Principal Component Analysis). C'est une méthode de la famille de l'analyse des données et plus généralement de la statistique multi variée, qui consiste à transformer des variables liées entre elles (dites « corrélées » en statistique) en nouvelles variables décorréelées les unes des autres. Ces nouvelles variables sont nommées « composantes principales », ou axes principaux. Elle permet de réduire le nombre de variables et de rendre l'information moins redondante.

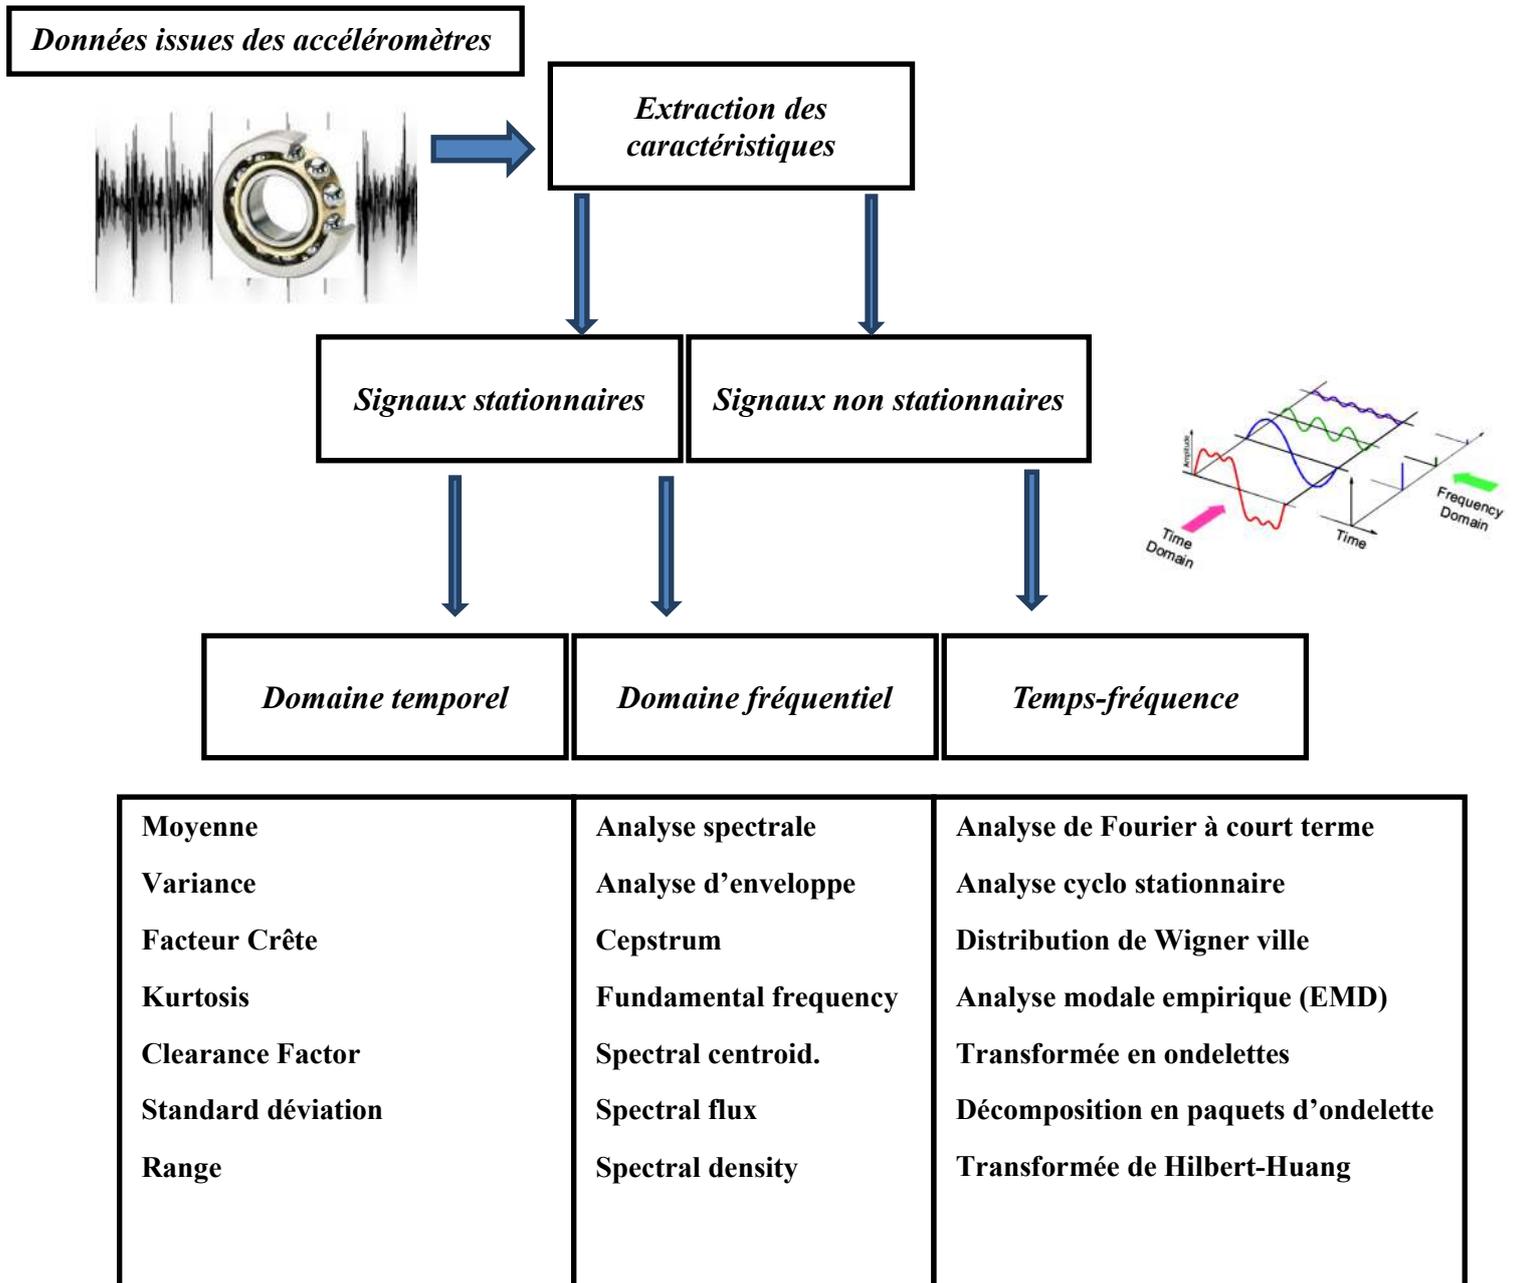


Figure 1.7 : Techniques d'extraction des caractéristiques [5]

1.7 .Sélection et réduction des caractéristiques :

Après l'étape d'extraction des paramètres, l'étape de sélection est cruciale pour trouver quels sont les paramètres les plus importants et les plus fiables pour la détection du défaut. En effet, si les paramètres sont sélectionnés avec peu de pouvoir de discrimination, la conception ultérieure d'un classificateur conduirait à de mauvaises performances.

D'autre part, si les paramètres avec des informations riches sont sélectionnés, la précision de la classification augmente et le temps de calcul est réduit.

Afin d'avoir un système de diagnostic performant, il est nécessaire d'employer un processus de sélection des indicateurs les plus pertinents, permettant d'améliorer les performances de la classification

1.7.1. Caractéristiques ou paramètres temporelles :

Elles concernent le calcul des paramètres statistiques du signal. Elles sont utilisées en classification, détection et diagnostic de défaillances où elles donnent des résultats acceptables.

Parmi les caractéristiques temporelles, on peut citer la moyenne, le carré de la moyenne quadratique (Root Mean Square : RMS) qui correspond à l'énergie moyenne du signal, la valeur de son pic qui peut renseigner sur la taille d'un défaut, le Kurtosis qui caractérise l'aspect impulsif du signal, le facteur de crête qui mesure les augmentations rapides des vibrations dans les roulements et le Skewness utilisé pour évaluer l'état de surface d'un composant [11].

$$\text{Moyenne : } x_m = \sum_{n=1}^N \frac{x(n)}{N} \quad (1.6)$$

$$\text{Variance : } x_{\text{var}} = \frac{\sum_{n=1}^N (x(n) - x_m)^2}{N} \quad (1.7)$$

$$\text{Kurtosis } x_{\text{kur}} = \frac{\sum_{n=1}^N (x(n) - x_m)^4}{(N-1)\sigma^4} \quad (1.8)$$

$$\text{Clearance factor : CLF} = \frac{x_{\text{max}}}{\left(\frac{1}{N} \sum_{n=1}^N \sqrt{|x(n)|}\right)^2} \quad (1.9)$$

$$\text{Mean absolute deviation : MAD} = \sum_{n=1}^N \frac{|\sum_{n=1}^N (x(n) - x_m)|}{N} \quad (1.10)$$

$$\text{Range : } x_{\text{range}} = |x_{\text{max}} - x_{\text{min}}| \quad (1.11)$$

$$\text{Standard deviation : STD} = \sqrt{\frac{\sum_{n=1}^N (x(n) - x_m)^2}{N}} \quad (1.12)$$

$$\text{Peak magnitude to RMS ratio: Crest factor} = \frac{x_{\max}}{\text{RMS}} \quad (1.13)$$

Où $x(n)$ / ($n= 1, \dots, N$) est l'amplitude au point d'échantillonnage n et N est le nombre de points d'échantillonnage. x_m est la moyenne de x , et σ son écart type.

1.7.2. Caractéristiques ou paramètres fréquentielles :

L'analyse fréquentielle consiste à visualiser l'énergie du signal à différentes fréquences. En connaissant les conditions critiques de fonctionnement du composant (vitesse, charge, géométrie des éléments constitutifs, ...etc.). On peut extraire des caractéristiques permettant d'isoler les défauts. Ces caractéristiques sont aussi appelées signatures fréquentielles.

La fréquence moyenne :

$$\text{Mean Frequency : } f_{\text{mean}} = \frac{\sum_{n=1}^N I_n \cdot f_n}{\sum_{n=1}^N I_n} \quad (1.14)$$

Où f_n et I_n sont les fréquences et les amplitudes au point n du spectre du signal

$$\text{Mean power frequency: MNF} = C_s = \frac{\sum_{n=1}^N P_n \cdot f_n}{\sum_{n=1}^N P_n} \quad (1.15)$$

Où P_n est la puissance spectrale du signal au point n [9].

$$\text{Densité spectrale de puissance DSP} = \frac{\sum_{n=1}^N P_n}{N} \quad (1.16)$$

$$\text{Spectral Entropy } E_{n_s} = - \sum_{n=1}^N P_n \log P_n \quad (1.17)$$

$$\text{Short time Energy} = \sum_{n=1}^N [x[m] W[nm]]^2 \quad (1.18)$$

Références Bibliographiques

[1] Ilyes, KHELFI. (2014) *Diagnostic des machines tournantes par les techniques de l'intelligence artificielle*. Thèse de doctorat. Université de BADJI Mokhtar Annaba.

[2] Morel, J. (1992). *Vibrations des machines et diagnostic de leur état mécanique*. Collection de la Direction des études et recherches d'électricité de France.

[3] Ishak T. (2012) *Extraction d'indicateurs robustes pour le diagnostic des défauts mécaniques : Comparaison de L'EMD et des ondelettes (WT)*. Thèse de Doctorat. Université Ferhat Abbas de Sétif 1.

[4] McInerny S.A. and Dai Y. (2003), Basic vibration signal processing for bearing fault detection, IEEE Transactions on Education, Vol.46, and No.1.

[5] W. Yan, H. Qiu, and N. Iyer, (2008). Feature extraction for bearing prognostics and health.

Chapitre II

L'Analyse en Composantes Principales

2.1. Introduction :

L'analyse en composantes principales (ACP) est une méthode statistique d'analyse des données multi variée qui fait la projection orthogonale linéaire, elle projette des observations multidimensionnelles représentées dans un espace de dimension m (où m étant le nombre des variables observées) sur un sous espace de dimension inférieure ($\ell < m$) tout en minimisant la perte des informations, aussi en maximisant la variance des projections et la minimisation de la distance quadratique moyenne entre les points de données et leurs projections. On obtient, alors, un nouvel espace de variables appelées les composantes principales d'une variance maximale et non corrélées entre eux. Ces derniers sont en combinaisons linéaires avec les variables originelles. Ces nouvelles variables sont ensuite utilisées à des fins de modélisation, d'estimation d'état, de diagnostic de fonctionnement de système.

La méthode ACP est fortement établie pour la réduction de dimensionnalité et l'analyse multi variée qui sont très importants dans des nombreux domaines comprennent la compression des données de grande dimension, le traitement d'image, la visualisation, l'analyse des données exploratoires, la reconnaissance des formes, et la prédiction de séries temporelles [1,2,5,6].

2.2. Principe de l'analyse en composantes principales :

L'ACP consiste à remplacer une famille de variables par de nouvelles variables appelées Composantes principales (CPs). Ces dernières sont de variances maximales et non corrélées deux à deux. Elles sont des combinaisons linéaires des variables originelles.

Les différentes étapes pour la construction du modèle ACP sont hiérarchisées comme suit :

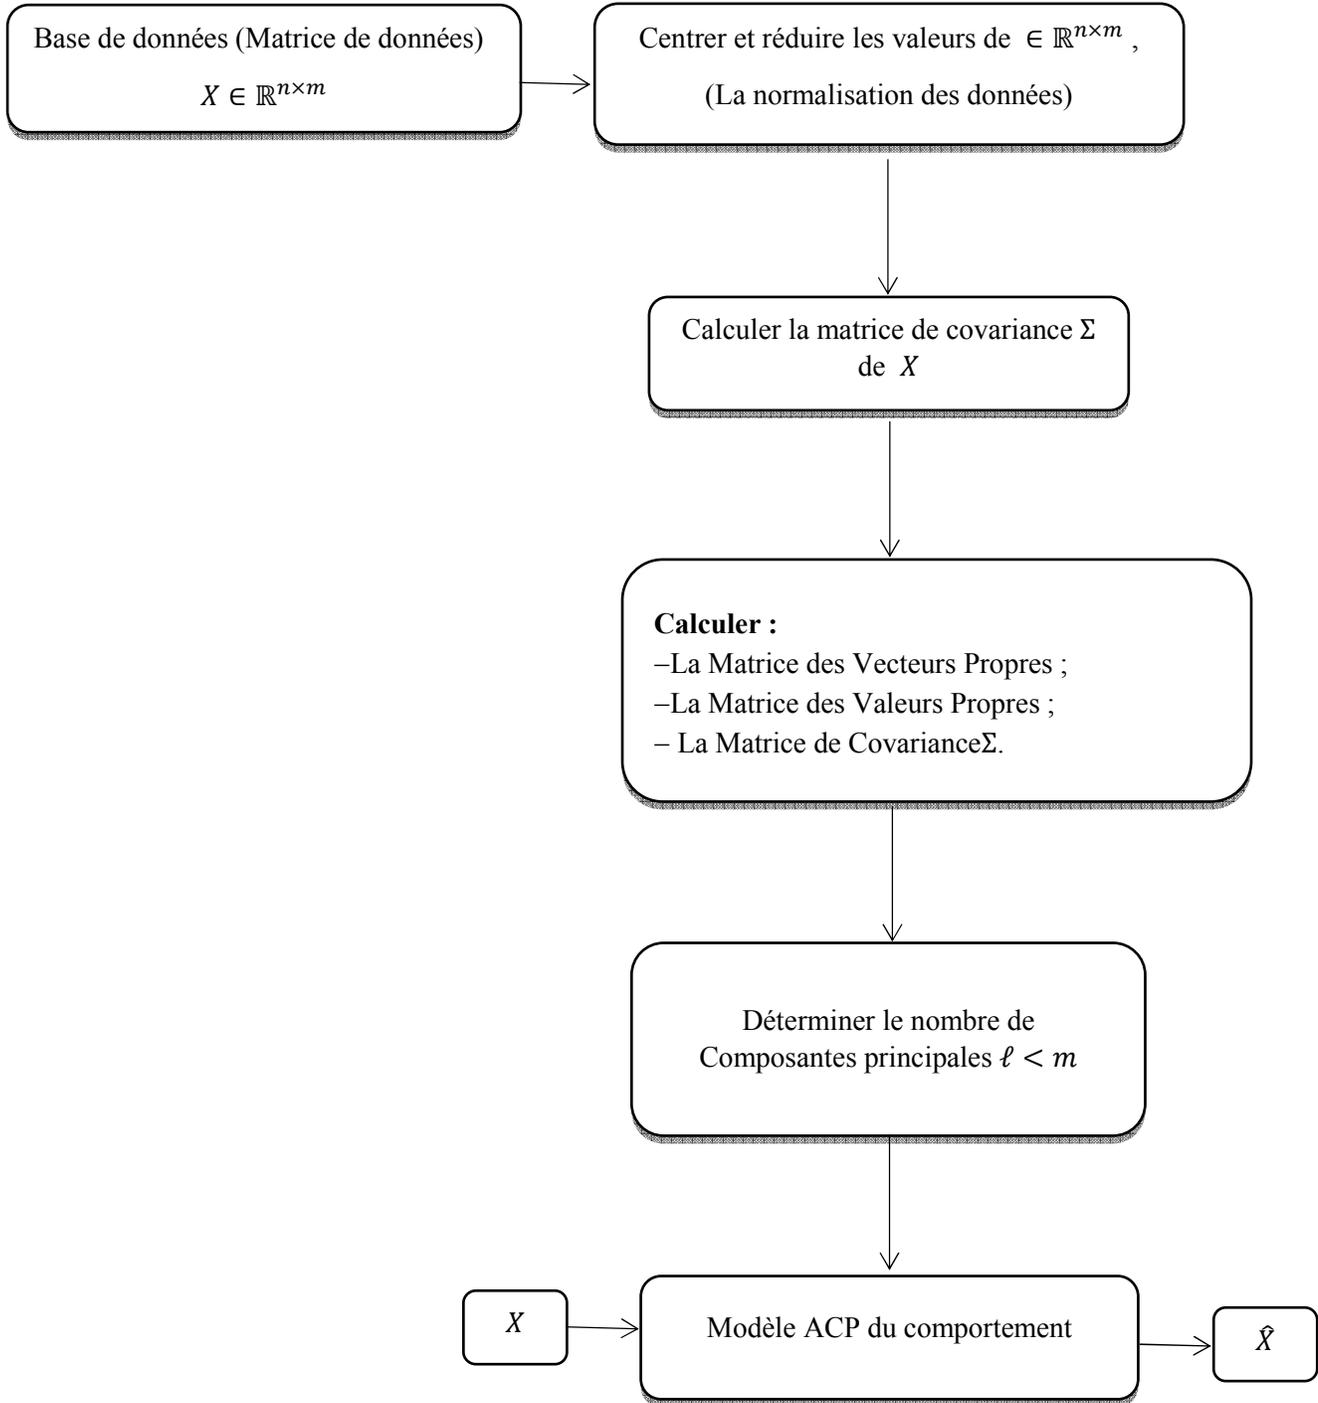


Figure 2.1 : Représentation des Etapes de la construction du modèle ACP.

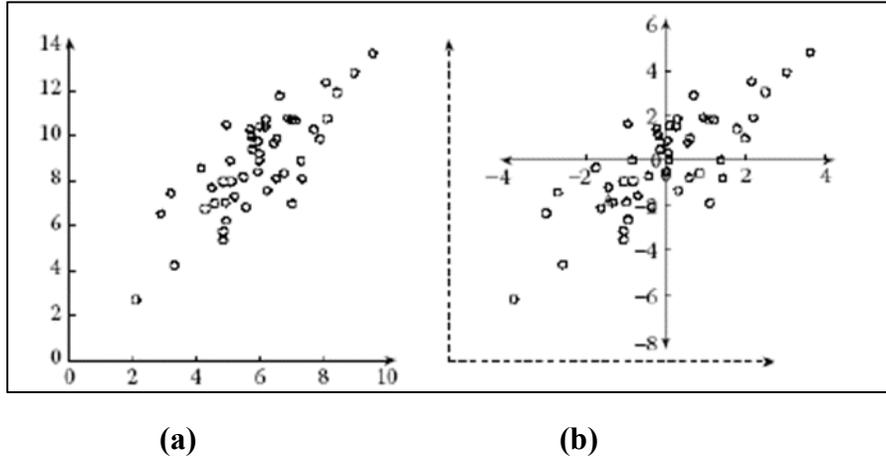


Figure 2.2 : Illustration graphique de l'effet du centrage et de réduction d'une distribution bi variable, **(a)** Distribution d'origine, **(b)** Centrage et réduction de cette distribution.

Considérons un ensemble de données collectées lors d'un fonctionnement normal du système étudié. Ces données peuvent être représentées par une matrice

$$X = [x(1), \dots, x(N)]^T \in \mathbb{R}^{N \times m} \quad (2.1)$$

Où N représente le nombre des observations et m représente le nombre des variables mesurées. Chaque ligne de la matrice de données X représente une observation sous forme d'un vecteur de mesures collectées à un instant k , généralement centrées

$$x(k) = [x_1(k), \dots, x_m(k)]^T \in \mathbb{R}^m \quad (2.2)$$

Où $x_j(k)$ ($j = \{1, \dots, m\}$) est la mesure de la variable j à l'instant k ,

Par définition, la matrice de covariance est donnée par :

$$\Sigma = E\{XX^T\} = \frac{1}{N}XX^T \in \mathbb{R}^{m \times m} \quad (2.3)$$

Selon le principe de l'ACP, on suppose qu'un vecteur de composantes $\hat{t} \in \mathbb{R}^\ell$ est associé à chaque vecteur d'observation dont il optimise la représentation au sens de la minimisation de l'erreur d'estimation de x ou la maximisation de la variance de \hat{t} . A chaque instant k , les vecteurs \hat{t} et x sont liés par une transformation linéaire de type $\hat{t}(k) = \hat{P}^T x(k)$ telle que la matrice de transformation $\hat{P} \in \mathbb{R}^{m \times \ell}$ vérifie la condition d'orthogonalité $\hat{P}^T \hat{P} = I_\ell \in \mathbb{R}^{\ell \times \ell}$.

Chapitre II : L'Analyse en Composantes Principales

L'optimisation de la représentation en se basant sur la matrice de projection \hat{P} est obtenue par la minimisation de l'erreur quadratique d'estimation de x . Notons par \hat{P} la matrice optimale de représentation, celle-ci peut être donnée par :

$$\hat{P} = \underbrace{\arg \min}_{\hat{P}} \{J_e(\hat{P})\} \quad (2.4)$$

Où J_e étant le critère d'erreur d'estimation de PCA qui devrait être minimisé.

Sous la contrainte d'orthogonalité de la matrice de projection, on peut écrire [1,2] :

$$\begin{aligned} J_e(\hat{P}) &= E\{\|x - \hat{x}\|^2\} = E\{\|x - \hat{P} \hat{P}^T x\|^2\} \\ &= E\{(x - \hat{P} \hat{t}^T)(x - \hat{P} \hat{t}^T)\} = E\{x^T x - \hat{t}^T \hat{t}\} \quad (2.5) \\ &= E\{\text{trace}(xx^T) - \hat{t}^T \hat{t}\} = \text{trace}\{\Sigma\} - E\{\hat{t}^T \hat{t}\} \\ &= \text{trace}\{\Sigma\} - J_v(\hat{P}) \end{aligned}$$

La minimisation du critère d'erreur d'estimation de PCA J_e est équivalent à la maximisation de J_v , alors [1] :

$$J_v(\hat{P}) = E\{\hat{t}^T \hat{t}\} = E\{\sum_{j=1}^{\ell} t_j^2\} = \sum_{j=1}^{\ell} E\{t_j^2\} = \sum_{j=1}^{\ell} \text{Var}\{t_j\} \quad (2.6)$$

D'après l'équation précédente, la maximisation du critère J_v est équivalente à une maximisation de la variance de la composante t_j . Le problème d'optimisation est donc reformulé comme suit :

$$\hat{P} = \underbrace{\arg \min}_{\hat{P}} \{J_e(\hat{P})\} = \underbrace{\arg \max}_{\hat{P}} \{J_v(\hat{P})\} \quad (2.7)$$

Soit $t \in \mathbb{R}$ la projection du vecteur de données x le long d'une direction représentée par un vecteur unitaire $p \in \mathbb{R}^m$. La composante t est donné par $t = x^T p = p^T x$, sous la contrainte $\|p\|^2 = p^T p = 1$. Elle représente une nouvelle variable ayant une moyenne et une variance qui dépendent des propriétés statistiques de x comme suit :

$$\begin{aligned} E\{t\} &= E\{p^T x\} = p^T E\{x\} = 0 \\ \text{Var}\{t\} &= E\{(t - E\{t\})^2\} = E\{t^2\} \\ E\{(p^T x)(x^T p)\} &= p^T E\{xx^T\} p = p^T \Sigma p \end{aligned} \quad (2.8)$$

L'expression précédente est un problème d'optimisation sous contrainte qui admet une solution par l'application de la méthode de multiplicateur de Lagrange, donc l'expression de la résolution est formulée par la fonction de Lagrange suivante [1,2] :

Chapitre II : L'Analyse en Composantes Principales

$$\mathcal{L}(p, \lambda) = J_v(p) - \lambda(p^T p - 1) = p^T \Sigma p - \lambda(p^T p - 1) \quad (2.9)$$

Où λ est le multiplicateur de Lagrange et le vecteur p maximisant le critère d'optimisation J_v , est solution du système d'équations suivant :

$$\begin{cases} \partial \mathcal{L}(p, \lambda) / \partial p = \Sigma p - \lambda p = 0 \\ \partial \mathcal{L}(p, \lambda) / \partial \lambda = p^T p - 1 = 0 \end{cases} \quad (2.10)$$

Un tel système d'équations admet des solutions réelles de la variable λ . Par la résolution directe de l'équation caractéristique [1,7] :

$$\text{Det}\{\Sigma - \lambda I_m\} = 0 \quad (2.11)$$

Ces solutions sont les m valeurs propres λ_i de la matrice de covariance Σ et qui sont associées au m vecteurs propres p_i [1,2] :

$$(\Sigma - \lambda_i I_m)p_i = 0 \Rightarrow \Sigma p_i = \lambda_i p_i \quad (2.12)$$

Elle est donnée aussi sous forme matricielle comme suit [1,2] : $\Sigma P = P \Lambda$

Avec $P = [P_1, \dots, P_m] \in \mathbb{R}^{m \times m}$: la matrice de projection des données, et

$\Lambda = \text{diag}\{\lambda_1, \dots, \lambda_m\} \in \mathbb{R}^{m \times m}$: La matrice diagonale des valeurs propres de Σ .

Alors nous avons les propriétés suivantes :

- la matrice de covariance Σ est symétrique,
- les m valeurs propres λ_i sont réelles et les m vecteurs propres p_i sont orthogonaux, alors les vecteurs propres p_i forment une base orthonormée [1,2] :

$$P^T P = P P^T = I_m \in \mathbb{R}^{m \times m} \quad (2.13)$$

Avec I_m la matrice d'identité d'ordre m .

Par conséquent :

$$p^T \Sigma p = \Lambda \quad (2.14)$$

Cela montre que les éléments diagonaux de Λ sont arrangés dans l'ordre décroissant [1]

$$\lambda_1 \geq \dots \geq \lambda_m$$

Le vecteur de données $x(k)$ peut se transformer sans aucune perte d'informations en un vecteur de composantes principales contenant de nouvelles variables non corrélées, qui sont des

Chapitre II : L'Analyse en Composantes Principales

combinaisons linéaires des variables originelles. Ce nouveau vecteur des variables (vecteur des composantes principales) est exprimé par la relation suivante [1] :

$$t(k) = [t_1(k), \dots, t_m(k)]^T = P^T x(k) \in \mathbb{R}^m \quad (2.15)$$

Avec t_j ($j = \{1, \dots, m\}$) sont les composantes principales projeté dans le sous espace [1,7] :

$$t_j(k) = P_j^T x(k) = x^T P_j \quad (2.16)$$

Ces composantes non corrélées sont définies par [1] :

$$E\{t_i t_j\} = E\{p_i^T x x^T p_j\} = p_i^T \Sigma p_j = 0 \quad i \neq j \quad (2.17)$$

Aussi on peut représenter la matrice des composantes sous forme matricielle suivante [1] :

$$T = [t(1), \dots, t(N)]^T = X P \in \mathbb{R}^{N \times m} \quad (2.18)$$

Le vecteur de données $x(k)$ est défini par le vecteur de composantes principales associées avec le vecteur P [1] : $x(k) = P t(k) = \sum_{j=1}^m p_j t_j(k)$

L'estimation $\hat{x}(k)$ du vecteur de données $x(k)$ dans l'espace réduit qui est formé par les l premières valeurs propres est donnée par [1] :

$$\hat{x}(k) = \hat{P} \hat{t}(k) = \hat{P} \hat{P}^T x(k) = \hat{C} x(k) \quad (2.19)$$

Où $\hat{C} \in \mathbb{R}^{m \times m}$ est la matrice qui caractérise le modèle PCA et dont la matrice optimale de représentation est exprimée par [1] :

$$\hat{P} = [p_1, \dots, p_\ell] \in \mathbb{R}^{m \times \ell}$$

Ainsi le vecteur des l composantes est exprimé par [1] :

$$\hat{t}(k) = \hat{P}^T x(k) \in \mathbb{R}^\ell \quad (2.20)$$

Les pertes des informations pendant la réduction peuvent être récupérées à partir du vecteur résiduel comme suit [1] :

$$\tilde{x}(k) = \tilde{P} \tilde{t}(k) = \tilde{P} \tilde{P}^T x(k) = \tilde{C} x(k) \quad (2.21)$$

Avec $\tilde{P} = [p_{\ell+1}, \dots, p_m] \in \mathbb{R}^{m \times (m-\ell)}$

Chapitre II : L'Analyse en Composantes Principales

Et
$$\tilde{C} = \tilde{P}\tilde{P}^T = I_m - \hat{C} \in \mathbb{R}^{m \times m}$$

La notion de la modélisation par PCA est divisée en deux parties, la réduction en un sous-espace principale, et un sous-espace résiduel, donc la décomposition du vecteur de mesures est donné par [1] :

$$x(k) = \hat{x}(k) + \tilde{x}(k) \quad (2.22)$$

2.3. Détermination d'une structure optimale du modèle ACP :

Le choix du nombre de CPs joue un rôle crucial dans la détermination des relations de redondance entre les variables. Un tel nombre est difficile à déterminer. Pour assurer une meilleure estimation du modèle PCA, des méthodes sont présentées pour aider dans son choix. Pour cela, il existe des nombreux critères permettent de la détermination optimale des nombres des composantes retenues. Parmi ces critères, on peut citer la méthode du pourcentage cumulée de la variance totale, la méthode validation cumulée (PRESS), la méthode de la variance de l'erreur de reconstruction VER, et le Scree test [1,4].

1. Pourcentage cumule de la variance (PCV) :

Les valeurs propres de la matrice de corrélation représentent les variances des CPs. Par conséquent, elles ont été utilisées pour définir un critère PCV dans le but est la détermination de la structure optimale d'un modèle ACP. Ce critère représente le pourcentage de la variance expliquée par les CPs retenues comme suit :

$$PCV(\ell) = 100 \left(\frac{\sum_{a=1}^{\ell} \lambda_a}{\sum_{a=1}^m \lambda_a} \right) \% \quad (2.23)$$

Généralement, on essaie de retenir avec ce critère un nombre de CPs ayant un PCV compris entre 90% et 95% ou 99% de la variance totale.

2. la méthode de validation cumulée (PRESS) :

L'idée de la validation croisée est basée principalement sur la prédiction à travers un modèle ACP d'une mesure $x_i(k)$ de la matrice de données X. Le nombre des CPs retenues est optimal si la moyenne de la prédiction globale d'une telle mesure n'est plus significativement améliorée par l'ajout de CPs supplémentaires.

Chapitre II : L'Analyse en Composantes Principales

L'approche de la validation cumulée présente un critère qui est appelé PRESS, et le principe général de ce dernier est la minimisation de la somme des carrés des erreurs des prédictions, et qui est donné par la formule suivante :

$$PRESS(\ell) = \frac{1}{Nm} \sum_{k=1}^N \sum_{i=1}^m (\hat{x}_i^\ell(k) - x_i(k))^2 \quad (2.24)$$

Où $\hat{x}_i^\ell(k)$ est la prédiction de $x_i(k)$, N étant la taille du jeu de validation.

Il existe un algorithme simplifié de ce critère qui permet de calculer les composantes principales comme suit :

3. le Scree test :

Le Scree Test ou test du coude est une approche empirique proposée principalement pour la sélection du nombre optimal des CPs. Elle est basée sur un test du coude de la courbe du pourcentage de la variance résiduelle dont l'expression est la suivante :

$$PVR(\ell) = 100 \left(\frac{\sum_{a=\ell+1}^m \lambda_a}{\sum_{a=1}^m \lambda_a} \right) \% \quad (2.25)$$

Références Bibliographiques

- [1] Baligh MNASSRI .2012. Surveillance des processus industriels par analyse en composantes principales. Thèse de doctorat, Université d'Aix-Marseille.
- [2] Chaouch Alima. 2013. Surveillance de l'état de fonctionnement d'un procédé biologique de dépollution. Mémoire de magister, Université 20 Aout 1955 – Skikda
- [3] Anissa Ben Aicha. . Détection et localisation de défauts par Analyse en Composantes Principales certaine ou incertaine de type intervalle. Thèse de doctorat, l'Ecole Nationale d'Ingénieurs de Monastir.
- [4] Bergoug Aicha. 2016/2017. Détection et Localisation de Défauts par Analyse en Composantes Principale (ACP). Mémoire de Master.
- [5] Baligh Mnassri. Diagnostic de Défauts par Analyse en Composantes Principales, Laboratoire des Sciences de l'Information et des Systèmes – UMR CNRS 6168, Université de Saint-Jérôme.
- [7] Mohamed-Faouzi Harkat. 2003. Détection et Localisation de défauts par Analyse en Composantes Principales, thèse de doctorat, Institut National Polytechnique de Lorraine

Chapitre III

Multi-Classification par les Séparateurs À Vastes Marges

3.1. Les algorithmes d'apprentissage automatique :

Les algorithmes d'apprentissage automatique ont pour objet d'extraire de la connaissance à partir de données. Les algorithmes d'apprentissage automatique dit supervisés construisent un modèle de prédiction en utilisant un ensemble d'objets préalablement étiquetés, dit ensemble d'apprentissage.

À partir de l'ensemble d'apprentissage, ou base d'exemples, l'algorithme estime les paramètres du modèle de prédiction les plus performants possible, c'est-à-dire qui produisent le moins d'erreurs en prédiction.

À partir de ce modèle qui a été construit avec les paramètres optimaux, il sera possible de prédire la classe ou la catégorie d'un nouvel objet qui lui est soumis.

Un de ces algorithmes d'apprentissage automatique supervisé est le Séparateur à Vaste Marge (SVM) ou machines à vecteurs de support.

3.2. Séparateur à vaste marge (SVM) :

Les séparateurs à vastes marges reposent sur deux idées clés : la notion de marge maximale et la notion de fonction noyau.

L'idée des hyperplans à marge maximale a été explorée dès 1963 par Vladimir Vapnik et A. Lerner, et en 1973 par Richard Duda et Peter Hart dans leur livre Pattern Classification.

Un SVM appartient à un ensemble de techniques d'apprentissage comme un perceptron, il trouve un séparateur linéaire entre les points de données de deux classes différentes,

En général, il peut y avoir plusieurs séparateurs possibles entre les classes (en supposant le problème linéairement séparable) et qu'un perceptron n'a pas de préférence parmi celles-ci, dans les SVMs, cependant, nous faisons un choix particulier parmi tous les séparateurs possibles : nous voulons celui avec la "marge" maximale.

3.3. Notions de base : Hyperplan, marge et support vecteur :

Pour deux classes d'exemples donnés, le but des SVMs est de trouver un classificateur qui va séparer les données et maximiser la distance entre ces deux classes. Avec SVM, ce classificateur est un classificateur linéaire appelé hyperplan. Dans le schéma qui suit, on détermine un hyperplan qui sépare les deux ensembles de points [1].

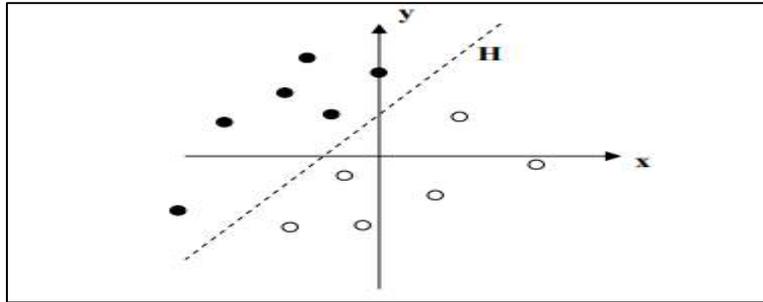


Figure 3.1 : Exemple d'un hyperplan séparateur [1].

Les points les plus proches, qui seuls sont utilisés pour la détermination de l'hyperplan, sont appelés vecteurs de support.

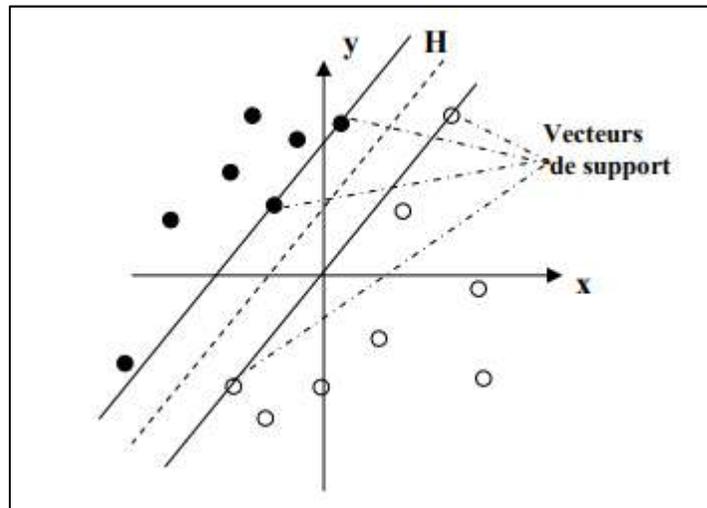


Figure 3.2 : Exemple de vecteurs de support [1].

Il est évident qu'il existe une multitude d'hyperplans valides, mais la propriété remarquable des SVMs est que cet hyperplan doit être optimal. Nous allons donc en plus chercher parmi les hyperplans valides, celui qui passe « au milieu » des points des deux classes d'exemples. Intuitivement, cela revient à chercher l'hyperplan le « plus sûr » [2]. En effet, supposons qu'un exemple n'ait pas été décrit parfaitement, une petite variation ne modifiera pas sa classification si sa distance à l'hyperplan est grande. Formellement, cela revient à chercher un hyperplan dont la distance minimale aux exemples d'apprentissage est maximale [2]. On appelle cette distance « marge » entre l'hyperplan et les exemples. L'hyperplan séparateur optimal est celui qui maximise la marge. Comme on cherche à maximiser cette marge, on parlera de séparateurs à vastes marges [2].

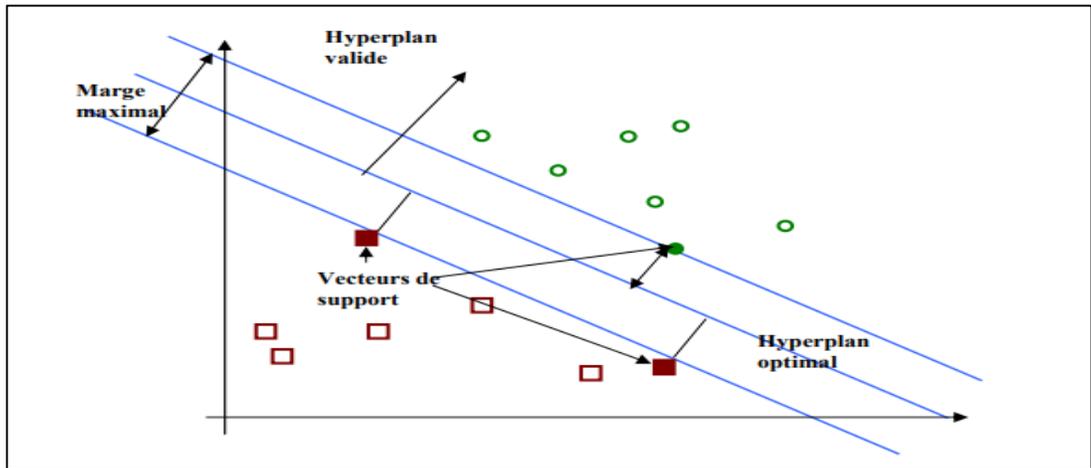


Figure 3.3 : Exemple de marge maximale (hyperplan valide).

3.4. Séparateur à vaste marge dans le cas linéaire :

3.4.1. Maximisation de la marge :

Intuitivement, le fait d'avoir une marge plus large procure plus de sécurité lorsque l'on classe un nouvel exemple. De plus, si l'on trouve le classificateur qui se comporte le mieux vis-à-vis des données d'apprentissage, il est clair qu'il sera aussi celui qui permettra au mieux de classer les nouveaux exemples. Dans le schéma qui suit, la partie droite nous montre qu'avec un hyperplan optimal, un nouvel exemple reste bien classé alors qu'il tombe dans la marge. On constate sur la partie gauche qu'avec une plus petite marge, l'exemple se voit mal classé [1].

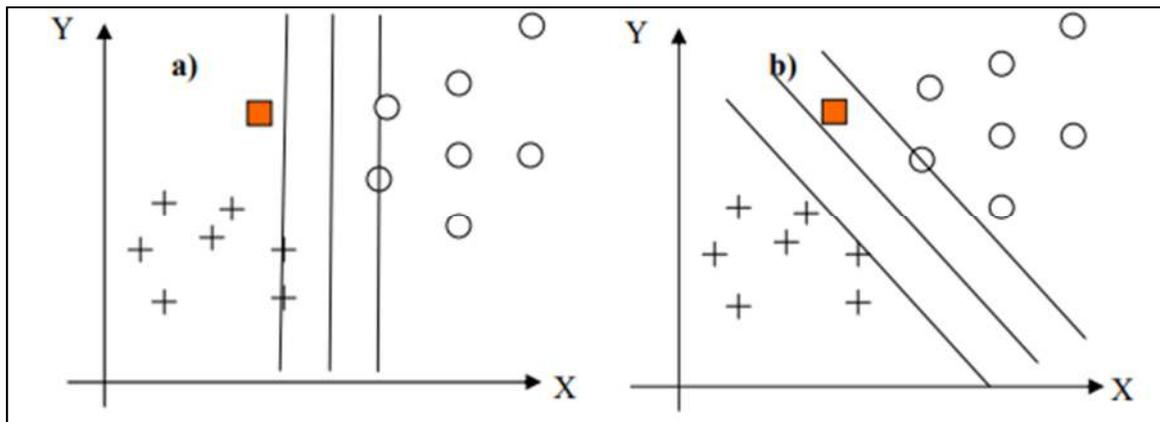


Figure 3.4 : a) Hyperplan avec faible marge, b) Meilleur hyperplan séparateur [1].

En général, la classification d'un nouvel exemple inconnu est donnée par sa position par rapport à l'hyperplan optimal. Dans le schéma suivant, le nouvel élément sera classé dans la catégorie des « + ».

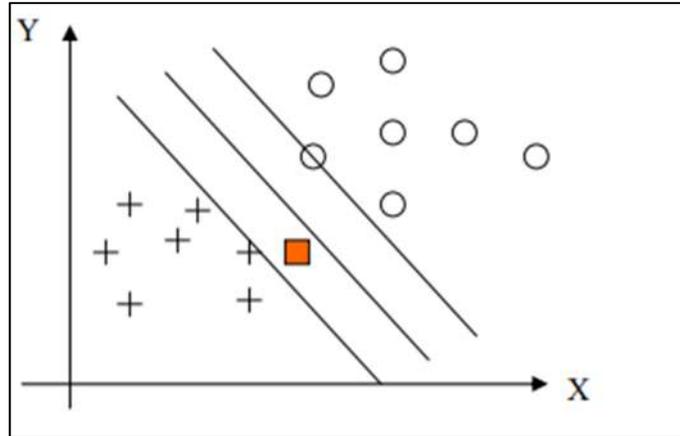


Figure 3.5 : Exemple de classification d'un nouvel élément.

3.4.2. Calcul de la marge :

Rappelons qu'en deux dimensions la distance entre un point (x_0, y_0) et une droite.

$Ax + By + c = 0$, est donnée par la relation suivante :

$$\frac{|Ax_0 + By_0 + c|}{\sqrt{A^2 + B^2}} \quad (3.1)$$

De façon similaire, dans un modèle linéaire (voir figure (3.1)), la distance entre un point et le hyperplan séparateur qui a pour équation $wx + b = 0$ est donnée par :

$$d(x) = \frac{|wx + b|}{\|w\|} \quad (3.2)$$

3.4.3. Calcul de l'Hyperplan optimal :

L'hyperplan optimal est celui pour lequel la distance aux points les plus proches (Marge) est maximale. L'équation générale de l'hyperplan est $H : wx + b = 0$ où :

- w est le vecteur orthogonal à l'hyperplan.
- x un vecteur de l'hyperplan.
- $b/\|w\|$ est la distance entre l'hyperplan et l'origine.

Doit satisfaire les conditions suivantes pour une classification binaire :

$$\begin{cases} Si \ y_i = +1 ; w x_i + b \geq 1 \\ Si \ y_i = -1 ; w x_i + b \leq -1 \\ Pour \ tous \ \{x_i, y_i\} ; y_i (w x_i + b) \geq 1 \end{cases} \quad (3.3)$$

Soient $f(x) = w \cdot x + b$ tel que x_1 et x_2 deux points de classes différentes :

$$(f(x_1) = +1 \text{ et } f(x_2) = -1).$$

Chapitre III : Multi-Classification par les Séparateurs À Vastes Marges

$$(w \cdot x_1) + b = +1 \text{ et } (w \cdot x_2) + b = -1 \text{ donc } (w \cdot (x_1 - x_2)) = 2$$

$$\text{D'où : } (w \cdot (x_1 - x_2)) / \|w\| = 2 / \|w\|.$$

On peut donc en déduire que maximiser la marge revient à minimiser son inverse $\|w\|/2$ sous la contrainte $y_i(w \cdot x + b) \geq +1$.

$$\min \frac{1}{2} \|w\|^2 = \min \frac{1}{2} w^T w \quad (3.4)$$

$$\text{On a } \begin{cases} \min \frac{1}{2} w^T w \\ \text{sous la contrainte} \\ y_i(w \cdot x + b) \geq +1 \end{cases} \quad (3.5)$$

Ce genre de problème d'optimisation peut être résolu en associant un multiplicateur de Lagrange $\alpha_i \geq 0$.

Le Lagrangien est donné par :

$$L(w, s, \alpha) = \frac{1}{2} w^T w - \sum_{i=1}^N \alpha_i y_i (w \cdot x_i + b) + \sum_{i=1}^N \alpha_i \quad (3.6)$$

Pour trouver la solution du problème primal, il faut minimiser le lagrangien par rapport à w et le maximiser par rapport aux α_i . Pour cette solution, les dérivées partielles du lagrangien s'annulent, selon les conditions de Kuhn-Tucker, on obtient :

$$\frac{\partial L(w, b, \alpha)}{\partial w} = 0, \frac{\partial L(w, b, \alpha)}{\partial b} = 0 \text{ et } \alpha_i \geq 0 \quad (3.7)$$

Cela revient à trouver les α_i et w qui annulent ses dérivées partielles :

On trouve :

$$w = \sum_{i=1}^N \alpha_i y_i x_i \text{ et } \sum_{i=1}^N \alpha_i y_i = 0 \quad (3.8)$$

Et en les réinjectant dans le Lagrangien on obtient le Lagrangien dual qui doit être maximisé

$$L(w, b, \alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j x_i \cdot x_j \quad (3.9)$$

Si les α_i^* sont solutions de ce problème c.à.d. les multiplicateurs optimaux correspondant aux points les plus proches et sont non-nuls. Alors les points x_i sont appelés **vecteurs de supports**.

Et on a le w^* optimal :

$$w^* = \sum_{i=1}^n \alpha_i^* y_i x_i \quad (3.10)$$

En le remplaçant dans l'équation de l'hyperplan séparateur on obtient l'hyperplan optimal

$$h(x) = \sum_{i=1}^n \alpha_i^* y_i x_i \cdot x + b \quad (3.11)$$

La fonction de décision associée est donc :

$$f(x) = \text{sign}(\sum_{i=1}^n \alpha_i^* y_i x_i \cdot x + b) \quad (3.12)$$

$$K(x, z) = x \cdot x' \quad (3.13)$$

3.5. Types de multi-classification des séparateurs à vaste marge

On discute dans la suite deux méthodes utilisées dans les vecteurs de support traitant des problèmes multi classes.

- Un Contre Tous.
- Un Contre Un.

Dans la méthode "*un contre tous*", un problème de classification de n classes est converti en n classificateurs binaires et pour le classificateur 'i' binaire, la classe i est séparé des autres classes.

L'approche "*un contre un*" transforme le problème de n classes en n (n-1) / 2 classificateurs binaire qui couvrent tous les paires de classe.

3.5.1. Multi-classification par l'approche "Un Contre Tous" :

Pour un problème de N classes, la classificatrice multi-classe établit d'abord N classificateurs bi-classe, chacun d'eux est responsable de chaque classe respectivement.

Pour le nième classificateur bi-classe, toutes les données d'entraînement ont besoin d'être impliqué ; le résultat positif est le point de données dans la classe N, et le résultat négatif est le point de données dans les autres classes N-1.

Chacun des N classificateurs bi-classes, est formé pour trouver la fonction de décision, et alors toutes les fonctions de décision sont combinées pour obtenir la fonction finale de décision pour le problème de classification multi-classes figure (3.7).

Considérons un problème de n classes, pour l'approche "un contre tous", on détermine n fonctions de décision discrètes qui séparent une classe des autres classes avec une marge maximale :

$$D_i(x) = w_i^T \phi(x) + b_i \quad (3.14)$$

Si on a pour un vecteur d'entrée x :

$$D_i(x) > 0 \quad (3.15)$$

Les vecteurs de support doivent satisfaire :

$$y_i D_i(x) = 1$$

Le $i^{\text{ème}}$ SVM est formé avec tous les exemples dans la $i^{\text{ème}}$ classe avec des étiquettes positives et tous les autres exemples avec des étiquettes négatives, ainsi, l'hyperplan $D_i(x) = 0$ forme l'hyperplan de séparation optimal avec $D_i(x) \geq 1$ pour la $i^{\text{ème}}$ classe et ceux qui appartiennent aux classes restantes satisfont $D_i(x) \leq 1$.

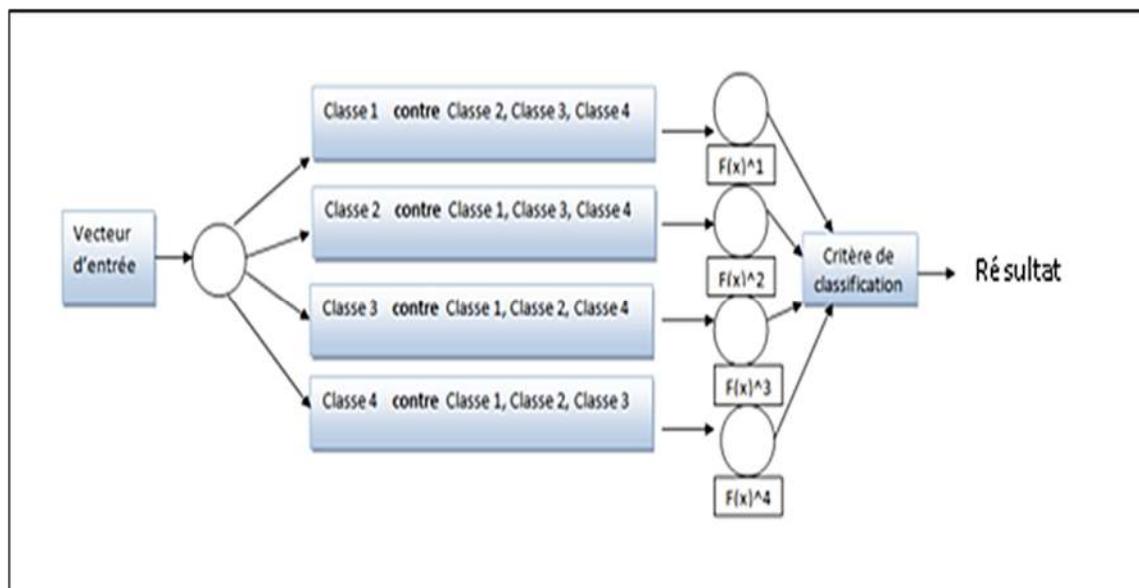


Figure 3.6 : Classification SVM un contre tous (One Vs All)

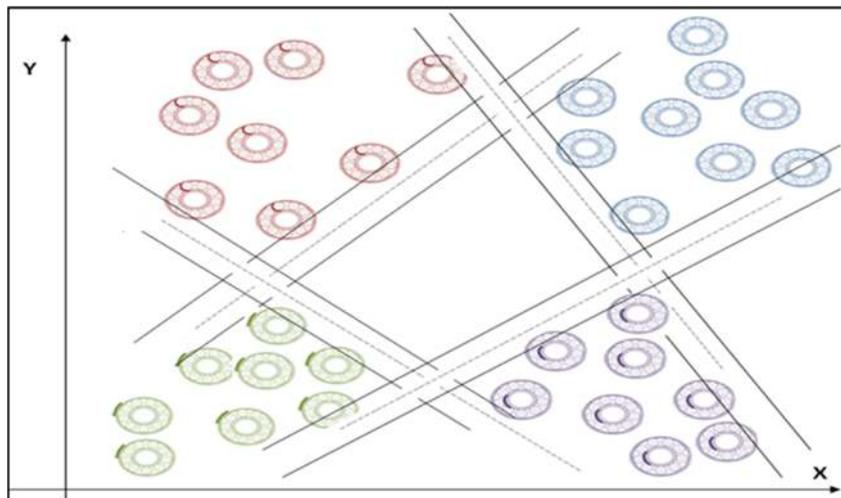


Figure 3.7 : Schéma des hyperplans linéaires pour la classification un contre tous (One vs all) /n=4

3.5.2. Multi-Classification par l'approche "Un Contre Un" :

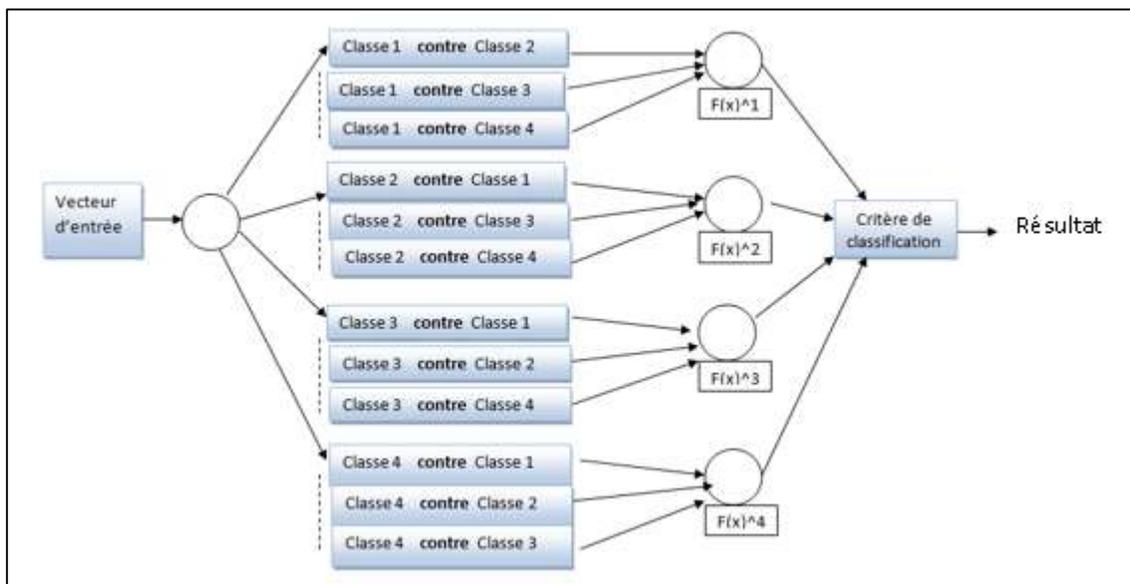


Figure 3.8 : Classification SVM un contre un (One Vs One)

Dans l'approche "un contre un", les fonctions de décision sont déterminées à partir des combinaisons des deux classes. Pour déterminer une fonction de décision pour une classe paire, nous utilisons les données d'apprentissage pour les deux classes correspondant. Ainsi, dans

Chapitre III : Multi-Classification par les Séparateurs À Vastes Marges

chaque session d'apprentissage, le nombre de données d'apprentissage est considérablement réduit par rapport l'approche "un contre tous", qui utilisent tous les données d'apprentissage. Mais le nombre de fonctions de décision est $n(n-1)/2$ comparativement avec n , où n est le nombre de classes. Soit la fonction de décision pour la classe i contre la classe j est [3] :

$$D_{ij}(x) = w_{ij}\phi(x) + \lambda_{ij} \quad (3.16)$$

Avec $D_{ij} = -D_{ji}$.

Les régions :

$$R_i = \{x \mid D_{ij}(x) > 0, j=1, \dots, n, j \neq i\} \quad (3.17)$$

Ne se chevauchent pas, et si $x \in R_i$, nous classons x dans la classe i [3].

Références Bibliographiques

- [1] Mohamadally Hasan, omani Boris : " SVM machine à vecteurs de support ou séparateur à vaste marge ". BD Web, ISTY3, Versailles St Quentin, France, janvier 2006.
- [2] A. Cornuéjols : " Une nouvelle méthode d'apprentissage : Les SVM. Séparateurs à vaste marge". Université de Paris-Sud, Orsay, France, Juin 2002.
- [3] A. Shigeo. Support vector machines for pattern classification. Springer-Verlag (2005).

Chapitre IV

Résultats de Simulation

Chapitre 4. Résultats de simulation

4.1. Matériels et méthodes :

4.1.1. Présentation du Banc d'Essai de la CWRU :

Comme représenté sur la figure 4.1, le banc d'essai se compose principalement d'un moteur (à gauche), d'un accouplement « transducteur/encodeur » (au centre), d'un dynamomètre (à droite) et d'un module d'acquisition des données.

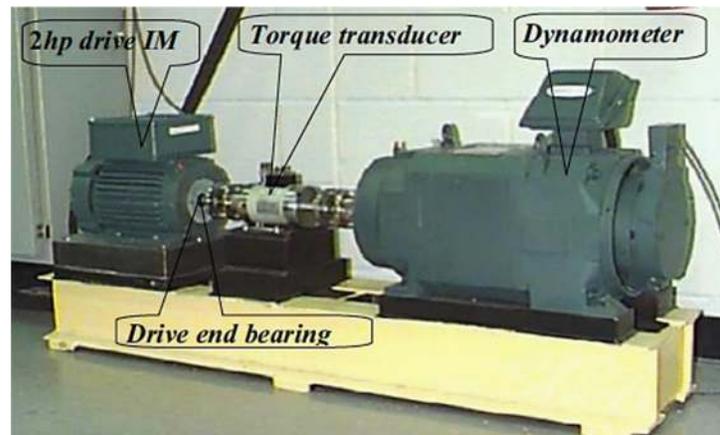


Figure 4.1 : Le Banc d'essai de la CWRU

Les signaux ont été enregistrés à l'aide des accéléromètres, qui ont été fixés à la cage du moteur par aimant. Pour différents couples résistants (donc différentes vitesses de rotations).

Les couples sont respectivement 0, 1, 2, 3 Hp dont des vitesses respectives sont 1797,1772, 1750, 1730 tr/min.

Les capteurs ont été placés à la position 12 heures verticale des deux côtés accouplement et ventilateur de la cage du moteur en plus de deux autres capteurs à 6 et 3 heures.

La fréquence d'échantillonnage est $f_e = 12$ KHz et le nombre de points total est de

$N_p = 243938$ pts.

Les données ont été enregistrées pour :

- Les roulements sans défaut.
- Les défauts uniques du cotés accouplement (12.000 et 48.000 points/second).
- Les défauts uniques du cotés ventilateur (12.000 points/second.)

Chapitre IV : Résultats de Simulation

Dans ce travail, les roulements que nous avons considérés, sont le roulement du côté accouplement pour l'apprentissage et les tests. Les fréquences sont :

- Fréquence de la bague intérieure : $f_{bi} = 5.415 \times f_r$
- Fréquence de la bague extérieure : $f_{be} = 3.584 \times f_r$
- Fréquence de la cage : $f_c = 0.3982 \times f_r$
- Fréquence de la bille : $f_b = 4.7135 \times f_r$

4.1.2. Présentation des signaux et quelques-unes de leurs caractéristiques :

| Fault Diameter (inches) | Motor Speed (rpm) | Inner Race | Ball | Outer Race Position Relative to Load Zone (Load Zone Centered at 6:00) | | |
|-------------------------|-------------------|------------|-------|---|------------------|-----------------|
| | | | | Centered @6:00 | Orthogonal @3:00 | Opposite @12:00 |
| 0.007" | 1797 | I07_0 | B07_0 | O07@6_0 | O07@3_0 | O07@12_0 |
| | 1772 | I07_1 | B07_1 | O07@6_1 | O07@3_1 | O07@12_1 |
| | 1750 | I07_2 | B07_2 | O07@6_2 | O07@3_2 | O07@12_2 |
| | 1730 | I07_3 | B07_3 | O07@6_3 | O07@3_3 | O07@12_3 |
| 0.014" | 1797 | I14_0 | B14_0 | O14@6_0 | | |
| | 1772 | I14_1 | B14_1 | O14@6_1 | | |
| | 1750 | I14_2 | B14_2 | O14@6_2 | | |
| | 1730 | I14_3 | B14_3 | O14@6_3 | | |
| 0.021" | 1797 | I21_0 | B21_0 | O21@6_0 | O21@3_0 | O21@12_0 |
| | 1772 | I21_1 | B21_1 | O21@6_1 | O21@3_1 | O21@12_1 |
| | 1750 | I21_2 | B21_2 | O21@6_2 | O21@3_2 | O21@12_2 |
| | 1730 | I21_3 | B21_3 | O21@6_3 | O21@3_3 | O21@12_3 |
| 0.028" | 1797 | I28_0 | B28_0 | | | |
| | 1772 | I28_1 | B28_1 | | | |

Tableau 4.1 : Données vibratoires des défauts avec une fréquence d'échantillonnage de 12K HZ /CWRU

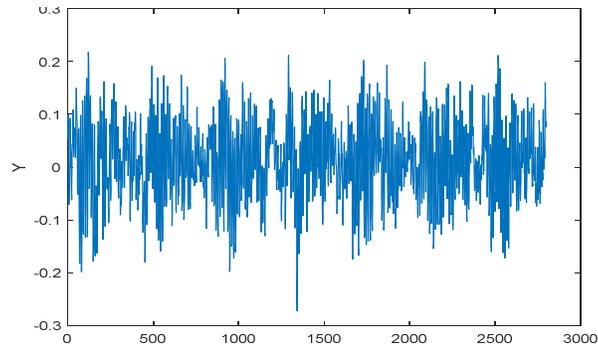


Figure 4.2 : Signal original cas sain

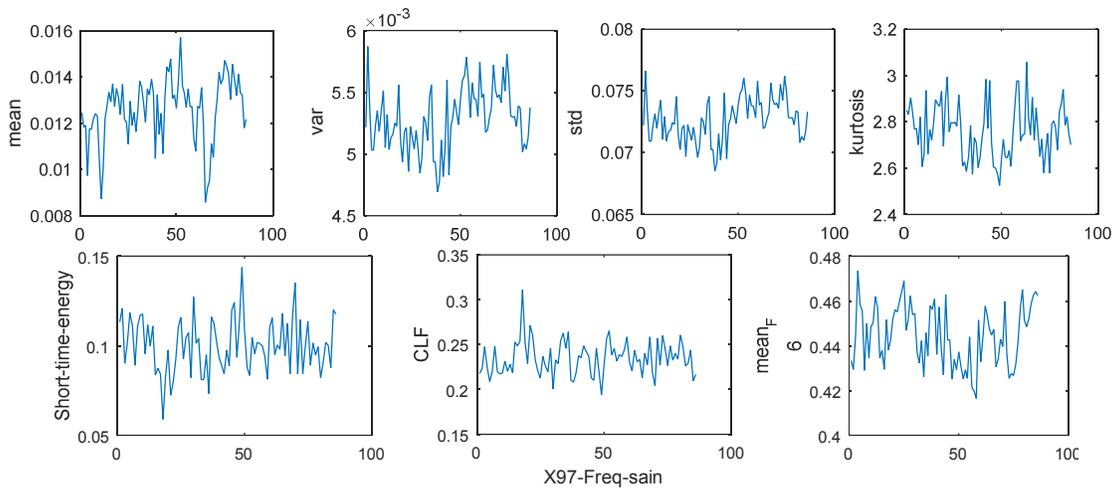


Figure 4.3 : Auto corrélation du signal original cas sain

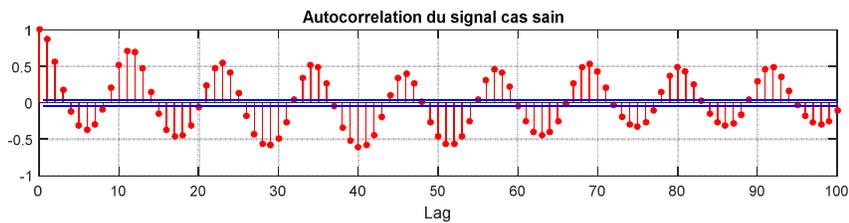


Figure 4.4 : Variation de quelques paramètres temporels et fréquentiels du signal sans défauts (sain)

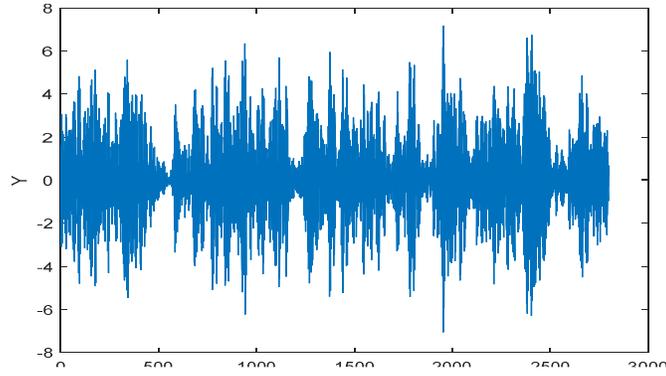


Figure 4.5 : Signal original avec défaut bille

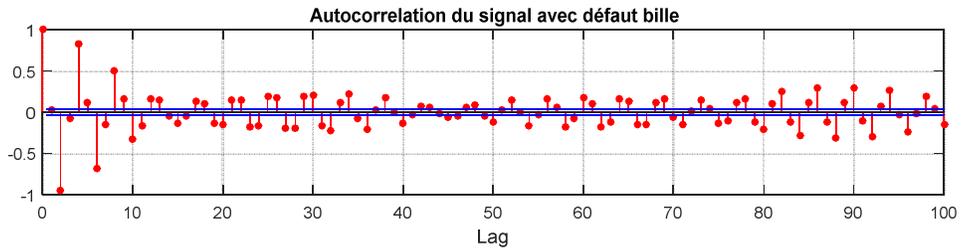


Figure 4.6 : Auto corrélation du signal avec défaut bille

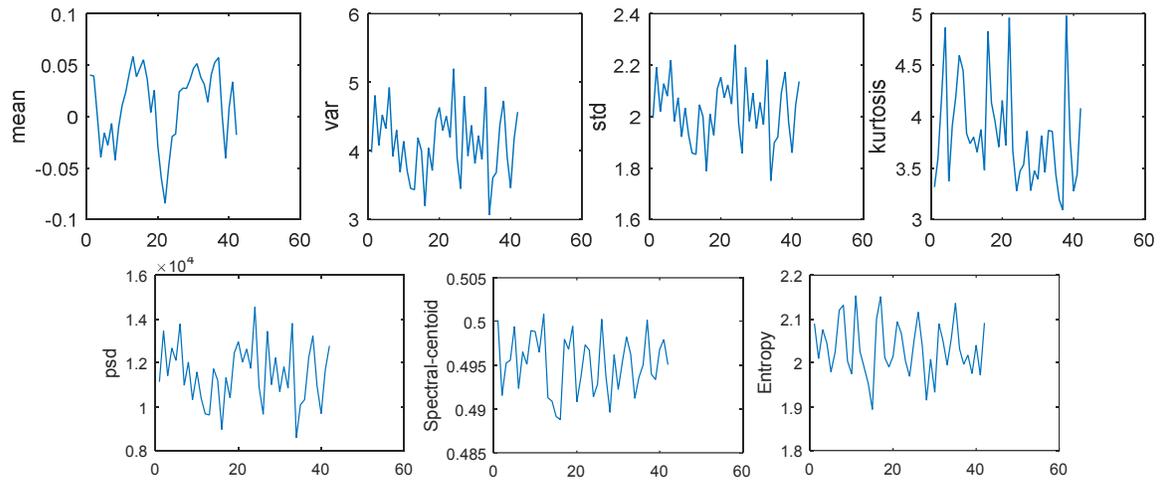


Figure 4.7 : Variation de quelques paramètres temporels et fréquentiels du signal avec défaut bille

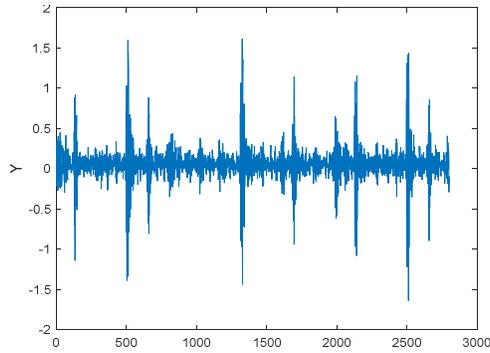


Figure 4.8 : Signal original avec défaut bague interne

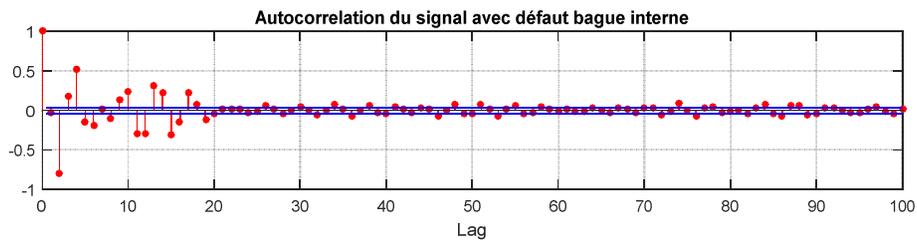


Figure 4.9 : Auto corrélation du signal avec défaut bague interne

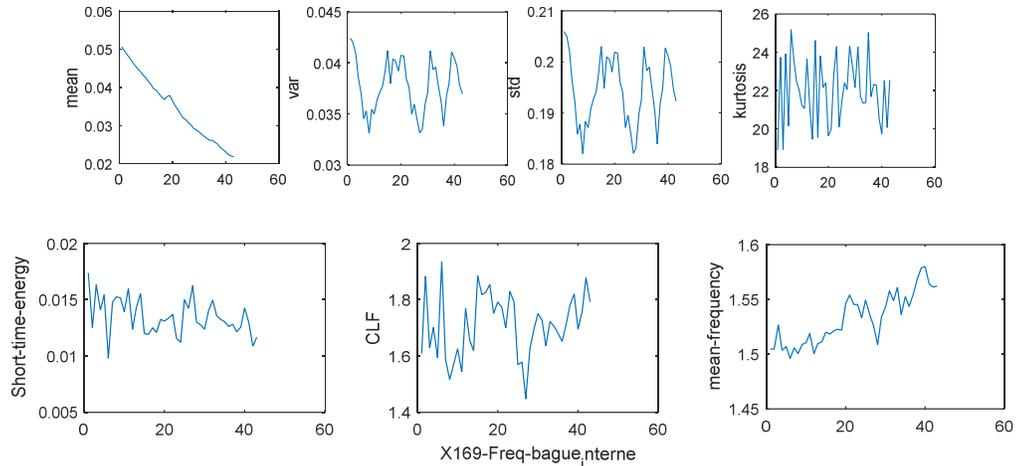


Figure 4.10 : Variation de quelques paramètres temporels et fréquentiels du signal avec

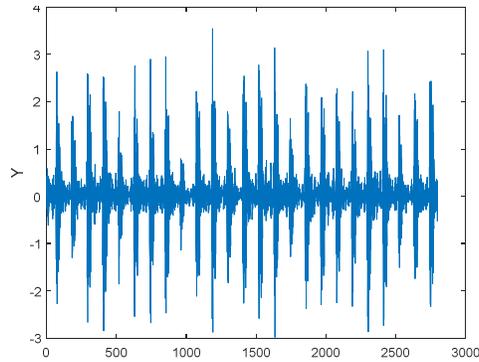


Figure 4.11 : Signal original avec défaut bague externe

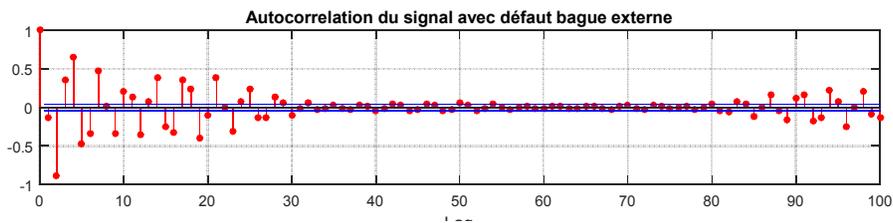


Figure 4.12 : Auto corrélation du signal avec défaut bague externe.

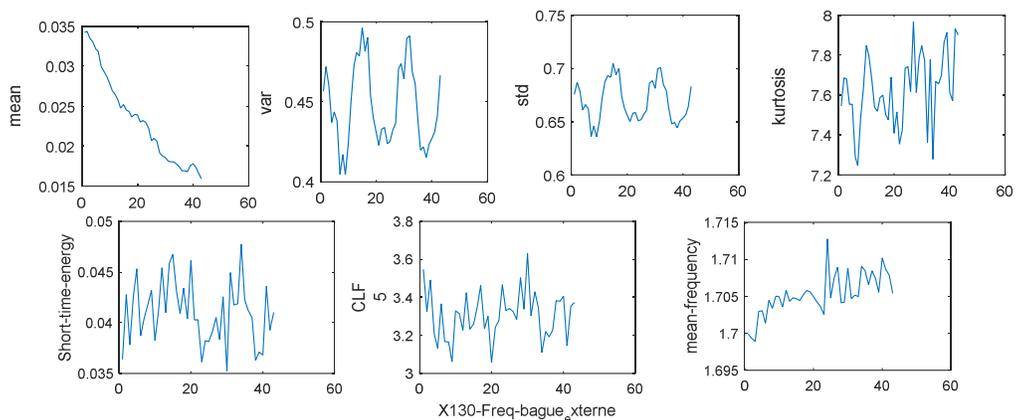


Figure 4.13 : Variation de quelques paramètres temporels et fréquentiels du signal avec défaut bague externe

4.2. Méthodologie de diagnostic adoptée :

La méthode utilisée dans notre travail peut être résumée comme le montre la figure 4.14 :

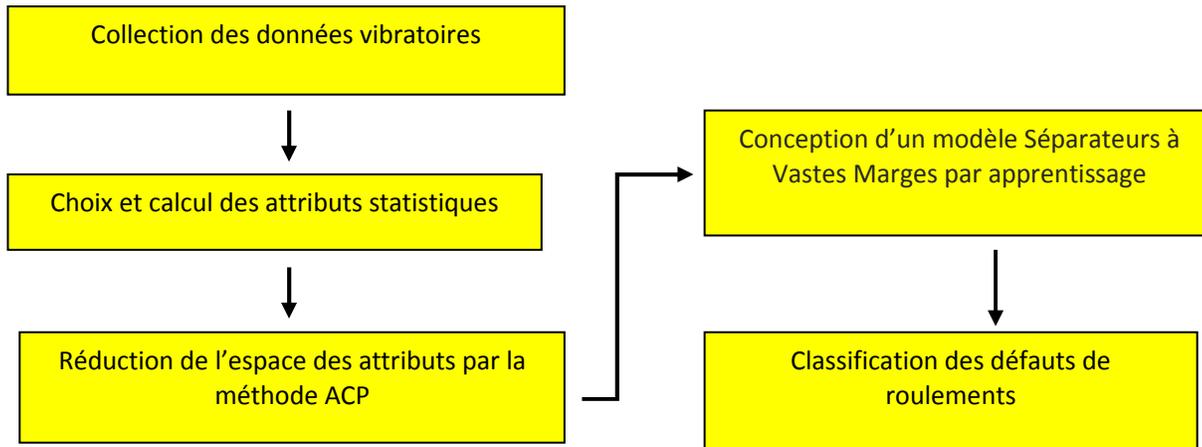


Figure 4.14 : Schéma présentant les étapes de diagnostic

4.2.1 L'analyse en composantes principales :

L'analyse en composantes principales (ACP) vise à transformer un certain nombre de variables corrélées en un plus petit nombre de variables décorrélées appelées composantes principales. Cette réduction de la dimensionnalité permet de réduire la complexité du traitement du signal. Les étapes de l'ACP s'opèrent comme suit :

- 1) Normalisation de la matrice d'observation X pour obtenir une matrice normalisée X^* .
- 2) Calcul de la matrice de covariance R .
- 3) Calcul des vecteurs propres et des valeurs propres de la matrice de covariance R .
- 4) Choix des composants et la formation d'un vecteur caractéristique.
- 5) Obtenir le nouvel ensemble de données.

4.2.2 Multi-classification SVM

L'origine de l'algorithme SVM est une classification binaire où la classe étiquettes peut prendre deux valeurs : 1 et -1, mais en fait, les problèmes de classification comprennent plus de deux classes. Par exemple, l'implémentation de l'algorithme SVM binaire pour le diagnostic des défauts de roulement d'une machine asynchrone, où il y a le défaut de la bague intérieure, le défaut de la bague extérieure, et le défaut de billes ne peut être utilisée. Par conséquent, on adoptera la stratégie de classification par multi-classe SVM multiples pour le diagnostic de ces

Chapitre IV : Résultats de Simulation

défauts de roulements. Plus précisément, on choisit la multi-classification SVM un contre tous (One Against All : OAA).

4.3. Configuration de l'expérience :

4.3.1. Les données de défaut de roulement du moteur :

La série temporelle des signaux de vibration ont été obtenues suite à une série d'expériences du banc d'essai de l'université CWRU via son centre de données pour les cas suivants : fonctionnement sans défaut du roulement, défaut de bague intérieure, défaut de bague extérieur, et défaut de bille. Nous avons choisi les données prélevés à 12 000 échantillons par seconde ($f_e = 12\text{Khz}$). Le type de roulement utilisé dans l'expérience est le 6205-2RS JEM, SKF qui est un roulement à billes à gorge profonde. Des exemples de signaux présentant le cas sain et les trois défauts sont représentés dans les figures 4.2, 4.5, 4.8 et 4.11.

4.3.2. Sélection des caractéristiques en utilisant l'analyse en composantes principales :

Les caractéristiques statistiques originales choisies et calculées sont : *kurtosis, skewness, valeur moyenne, écart-type, variance, max, et rms*. Le schéma de l'expérience est décrit comme suit : extraire cinquante échantillons de chaque signal vibratoire des trois défauts (y compris le cas sain) avec une longueur d'échantillon égale à 12000 pts (donc sur une durée de 1seconde). Par conséquent, on obtient donc $4 \times 50 = 200$ échantillons au total. On a Calculé les paramètres (attributs statistiques) pour chaque échantillon à l'aide des formules des équations (1.6) à (1.18) pour réaliser enfin une matrice observée X. Cette matrice observée X est transformée selon les étapes de l'analyse en composantes principales.

$$X^* = \frac{X - X_p}{S} \quad (4.1)$$

X^* étant la matrice normalisé (centrée réduite), X_p étant la moyenne du signal vibratoire et S son écart type.

Premièrement, la matrice X observée nécessite une normalisation selon la formule (4.1). Puis, on calcule le coefficient de corrélation R ainsi que ses valeurs propres et vecteurs propres. Les composantes principales obtenues sont présentées dans le tableau suivant :

| <i>Composantes Principales</i> | <i>Echantillons à 12000 points</i> | | | |
|------------------------------------|------------------------------------|-----------|-----------|-----------|
| | <i>P1</i> | <i>P2</i> | <i>P3</i> | <i>P4</i> |
| X1 | 0.4838 | -0.7661 | -0.4170 | 0.0424 |
| X2 | -0.9329 | -0.3373 | -0.0649 | -0.0407 |
| X3 | -0.9315 | -0.3276 | -0.0383 | 0.0883 |
| X4 | 0.8877 | -0.3105 | -0.3271 | 0.0035 |
| X5 | 0.0548 | 0.8350 | -0.5362 | -0.0346 |
| X6 | -0.9214 | -0.1459 | -0.2230 | -0.2597 |
| X7 | 0.9149 | -0.1680 | 0.2402 | -0.2368 |
| <i>Taux Contribution</i> | 0.6356 | 0.2359 | 0.0974 | 0.0194 |
| <i>Taux Contribution cumulatif</i> | 0.6356 | 0.8715 | 0.9688 | 0.9883 |

Tableau 4.2 : Matrice de chargement des Composantes principales, L.

Selon le tableau précédent, on peut voir qu'il y a quatre composantes principales qu'on nomme P1, P2, P3 et P4. Le rapport de contribution cumulatif des composantes principales est de 0.9883, contient pratiquement l'information des caractéristiques d'origine.

La dernière étape est le calcul du résultat final, la matrice de la composante principale Z, qui contient un pourcentage de 98,8 des paramètres originels. Cette dernière a été calculée par multiplication de matrice de chargement gauche L selon la formule suivante :

$$Z = X * L$$

Enfin, l'analyse en composantes principales a été l'étape de prétraitement qui précède la multi classification par les classificateurs SVMs.

4.3.3. Traitement des données et diagnostic utilisant l'approche multi-classes SVM :

Le diagnostic des défauts à l'aide de l'algorithme multi-classe SVM est basé sur la sélection des caractéristiques de trois types de défauts de roulement et du cas sain, de plus la méthode un contre tous (OAO), est la stratégie de l'algorithme SVM multi-classe utilisée dans cette expérience. Dans ce cadre, quatre paramètres sélectionnés par l'analyse en composantes principales, ont été utilisés pour la classification multi-SVM, et chaque type défaut contenait 50 échantillons. Par conséquent, il y avait $4 \times 50 = 200$ échantillons utilisés lors de l'étape de formation.

$$Z = [P_1 P_2 P_3 P_4]^T$$

La matrice Z de dimension 200×4 , contient les informations pour l'apprentissage. Le tableau suivant présente l'établissement de formation SVM pour l'entraînement.

Le tableau 4.3 représente les paramètres de l'apprentissage par les SVMs.

| | |
|---|----------|
| Type de fonction Noyau | Linéaire |
| Nombre de caractéristiques utilisées | 7 |
| Nombre d'échantillons | 200 |

Tableau 4.3 : Paramètres d'apprentissage

Le tableau suivant dresse le résultat de traitement par ACP et multi-classification SVM en précisant le taux de bonne classification, le temps de classification ainsi que la matrice de confusion.

Le résultat a montré que l'OAO multi-classe SVM était approprié pour le diagnostic du défaut où les fonctions « Kernel » ou noyaux *linéaire* (utilisée dans cette simulation), *quadratique* et *polynomiale* ont donné les meilleurs résultats contrairement à la fonction *RBF*.

Le réseau de neurones utilisé pour la classification (pour des fins de comparaison avec la classification SVM) est un réseau multicouche possédant une couche cachée à 20 neurones et

Chapitre IV : Résultats de Simulation

trois sorties binaires (0 0 0 pour reconnaître le cas sain, 1 0 0, 0 1 0 et 0 0 1 pour les défauts bague interne, bague externe et défauts billes respectivement).

| | ACP + SVM | | | ACP + RNA | | |
|---|---------------------------|-------------------------|--|---------------------------|-------------------------|--|
| | Taux bonne classification | Temps de classification | Matrice de confusion | Taux bonne classification | Temps de classification | Matrice de confusion |
| 4X50échantillons de 12000 pts (1sec /échantillon) | 97.5% | 2.05 s | $\begin{bmatrix} 50 & 0 & 0 & 0 \\ 0 & 49 & 1 & 0 \\ 0 & 0 & 50 & 0 \\ 0 & 2 & 2 & 46 \end{bmatrix}$ | 90% | 4.3 s | $\begin{bmatrix} 35 & 7 & 6 & 3 \\ 0 & 50 & 0 & 0 \\ 0 & 1 & 45 & 4 \\ 0 & 0 & 0 & 50 \end{bmatrix}$ |

Tableau 4.4 : Récapitulatif des résultats obtenus.

| Type de Défaut | Nombre d'échantillons classés corrects | Nombre d'échantillons classés incorrects | Précision |
|-----------------------------|--|--|-----------|
| Défaut bague interne | 49 | 1 | 98% |
| Défaut bague externe | 50 | 0 | 100% |
| Défaut billes | 46 | 4 | 92% |

Tableau 4.5 : Résultats de diagnostic par multi-classification SVM

4.4. Discussion des Résultats :

D'après le tableau 4.4, on voit bien que la méthode de diagnostic utilisant la classification par SVM avec un prétraitement par ACP donne un meilleur résultat que celle impliquant les réseaux de neurones. Ceci est évident en comparant les taux de bonne classification et les temps de classification obtenus.

Néanmoins, l'utilisation d'un nombre de points élevé dans un échantillon donne un meilleur taux de bonne classification au détriment d'un temps de classification plus lent. Donc, si on veut se rapprocher du diagnostic temps réel il faut opter pour les petits échantillons à condition de savoir bien choisir le vecteur de caractéristiques qui devrait comporter des détails temporels et

Chapitre IV : Résultats de Simulation

fréquentiels sur le signal vibratoire originel. Le prétraitement et la réduction de la taille de la matrice d'observation devrait être aussi bien examiné dans le but d'avoir une espace de données pouvant donner une bonne classification.

D'après le tableau 4.5, le rapport correct de classification est très satisfaisant. Ceci prouve bien que les performances de la reconnaissance des multi-classes les algorithmes SVMs sont améliorées par l'étape de prétraitement utilisant l'analyse et la réduction de la taille des données par les ACPs.

Conclusion Générale

En reconnaissance de formes, plusieurs méthodes ont été introduites pour le diagnostic mécanique des pannes, parmi lesquelles et les plus couramment utilisées sont les réseaux neuronaux artificiels, le séparateur à vastes marges et les réseaux de neurones flous.

Les séparateurs vastes marges qui sont basés sur la théorie de l'apprentissage statistique sont réputés pour l'utilisation d'un nombre d'échantillons réduit et ont une meilleure généralisation que les fameux réseaux de neurones artificiels et c'est l'utilisation de noyaux qui permet cette généralisation. Cependant la précision d'une machine vectorielle de support est hautement déterminée par la sélection des paramètres optimaux.

La plus grande différence entre le SVM et le RNA est dans la méthode d'optimisation des paramètres du modèle, le RNA utilise la retro propagation du gradient qui ne garantit pas l'obtention d'une solution optimale par contre l'implémentation du SVM trouvera les paramètres optimaux.

Cependant, ils peuvent être complémentaire avec des combinaisons SVM et RNA. Par exemple, on peut utiliser plusieurs couches RNA et avoir la dernière classification via SVM à la couche de sortie.

L'algorithme développé dans cette étude peut être étendu à plusieurs types de défauts (composants, actionneurs, capteurs, ...etc.) sur les machines jusqu'à la conception d'un système d'avertissement adapté dans lequel l'apparition des défauts est rapportée à l'utilisateur sur l'écran de commande de la machine pour un diagnostic en temps réel.

Une autre idée est d'utiliser les informations existantes sur les machines et les exploiter avec cet algorithme pour en tirer un diagnostic fiable, sans pour autant déployer un matériel supplémentaire (capteurs et interfaces de calculs).

Comme perspectives, on voudrait explorer plusieurs méthodes de prétraitement en plus de l'ACP et plus de méthodes de classification dans un but de comparaison en premier, puis essayer de combiner celles ayant donné de meilleurs résultats jusqu'à obtenir une méthode présentant un temps de classification temps réel et une précision proche du 100%.