



الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي والبحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

جامعة وهران 2 محمد بن أحمد
Université d'Oran 2 Mohamed Ben Ahmed

معهد الصيانة و الأمن الصناعي
Institut de Maintenance et de Sécurité Industrielle

Département de Maintenance en Instrumentation MÉMOIRE

Pour l'obtention du diplôme de Master

Filière : Génie Industriel

Spécialité : Maintenance de L'automatisme et L'instrumentation

Thème

Application des méthodes Root-MUSIC et SVM pour la classification des défauts rotoriques dans un moteur asynchrone.

Présenté et soutenu publiquement par :

SAHNOUN Abderrahmen & SADJI Hadjer

Devant le jury composé de :

Nom et Prénom	Grade	Etablissement	Qualité
Mme Rahyel Haimour	MCB	Univ. Oran-2, IMSI	Président
M.Nekrouf Djilali	MCB	Univ. Oran-2, IMSI	Encadreur
Mme Chouitek Mama	Professeur	Univ. Oran-2, IMSI	Examineur

Remerciements

Al hamdoulah, en premier lieu, nous remercions Dieu Tout-Puissant de nous avoir accordé la santé, la patience et la volonté nécessaires pour mener à bien ce travail.

Nous tenons à exprimer nos sincères remerciements à notre encadrant, Monsieur **Nekrouf Djilali**, pour son accompagnement, ses conseils précieux, sa disponibilité et le temps qu'il nous a accordé tout au long de ce projet. Son encadrement a été d'une grande importance pour la réalisation de ce travail.

Nous adressons également nos remerciements à tous les enseignants de l'Institut de Maintenance et Sécurité Industrielle de l'Université d'Oran 2, pour la qualité de la formation et les connaissances qu'ils nous ont transmises durant notre parcours universitaire.

Nous remercions aussi les membres du jury qui ont accepté d'évaluer ce travail et de consacrer du temps à son étude.

Enfin, nous exprimons notre profonde gratitude à nos familles, qui nous ont toujours soutenus, encouragés et accompagnés tout au long de nos études.

Dédicace

Al Hamdoulillah, grâce à Allah, Le Tout-Puissant et Le Très Miséricordieux, j'ai pu accomplir ce travail et atteindre cette étape importante de mon parcours.

Je dédie ce travail à la mémoire de ***ma très chère mère***, qu'Allah lui accorde Sa miséricorde et l'accueille dans Son vaste Paradis. Son amour, ses sacrifices et ses prières continuent de m'accompagner chaque jour et de me donner la force d'avancer. Elle restera à jamais présente dans mon cœur et dans chacune de mes réussites.

À mon cher père, pour ses sacrifices, son soutien constant et tout ce qu'il a fait pour moi sans jamais compter.

À mes sœurs Farah et Chaima, mes deux piliers, mes forces et mes confidentes, qui ont toujours été à mes côtés dans les moments de joie comme dans les moments difficiles. Leur amour, leur soutien et leurs encouragements m'ont permis de continuer sans jamais abandonner.

À mon frère Islem, pour son soutien, sa présence et l'énergie positive qu'il m'apporte au quotidien.

À ma cousine Sabrina, qui a toujours été présente à mes côtés, m'a soutenue et encouragée tout au long de mon parcours.

À mes chères amies Amina, Alae et Khaoula, Merci pour votre soutien, votre présence et votre amitié sincère tout au long de ce parcours. Votre affection et vos encouragements ont été une source de force et de motivation. Je vous dédie ce travail avec toute ma gratitude et mon amour.

Je dédie également ce travail ***à mon binôme Abderrahman***, avec qui j'ai partagé cette expérience de travail.

À Monsieur Otmane Habib et à l'équipe de la SARL COFEED pour leur soutien tout au long de mon parcours universitaire.

Je le dédie aussi à mon ***encadrant Nekrouf Djilali*** pour son accompagnement, ses conseils et son soutien tout au long de ce projet.

Dédicace

Avec la grâce **d'Allah**, Le Tout-Puissant et Le Très Miséricordieux,

Je dédie ce modeste travail à **mes très chers parents**, qui ont toujours été pour moi une source de courage, de sacrifice et d'amour inconditionnel. Grâce à leurs prières, leur soutien et leurs encouragements constants, j'ai pu avancer et surmonter les difficultés tout au long de mon parcours.

À **ma mère**, symbole de tendresse, de patience et de générosité, pour tous les sacrifices qu'elle a consentis afin de me voir réussir.

À **mon père**, pour son soutien, sa confiance, ses conseils précieux et tous les efforts qu'il a fournis pour assurer mon avenir.

Je leur exprime à travers ce travail ma profonde reconnaissance et mon immense amour.

À mes chères frères **Mohamed Anes, Mohamed El-Bachir**, ainsi qu'à ma sœur **Meriem**, pour leur présence, leur affection et leur soutien permanent. Vous avez toujours été une source de motivation et de bonheur.

À toute **ma famille**, pour son amour, ses encouragements et sa bienveillance.

À **mes amis**, qui ont partagé avec moi les meilleurs moments de cette expérience universitaire et qui ont toujours été présents dans les moments difficiles.

À ma binôme **SADJI Hadjer**, pour sa collaboration, sa patience et son sérieux durant la réalisation de ce projet. Je lui adresse mes sincères remerciements et toute ma considération.

Je le dédie aussi à mon **encadrant Nekrouf Djilali** pour son accompagnement, ses conseils et son soutien tout au long de ce projet.

Enfin, je dédie ce travail à toutes les personnes qui ont contribué, de près ou de loin, à ma réussite et à l'aboutissement de ce mémoire.

Que ce mémoire soit l'expression de ma gratitude et de mon profond respect envers vous tous.

Résumé

Ce mémoire porte sur l'application des méthodes Root-MUSIC et SVM pour la classification des défauts rotoriques dans un moteur asynchrone. Les défauts de rupture de barres du rotor constituent l'une des défaillances les plus importantes pouvant affecter les performances et la fiabilité des moteurs asynchrones. Afin d'assurer une détection précoce et une classification automatique de ces défauts, une approche basée sur l'analyse du courant statorique est proposée.

La méthode Root-MUSIC est utilisée pour estimer avec précision les fréquences caractéristiques associées aux défauts rotoriques et pour extraire les puissances spectrales correspondantes. Ces puissances sont ensuite exploitées comme paramètres d'entrée d'un classificateur SVM, permettant de distinguer les différents états de fonctionnement du moteur.

Les résultats expérimentaux obtenus montrent que l'utilisation des puissances spectrales extraites par Root-MUSIC constitue une caractéristique efficace pour la reconnaissance et la classification des défauts de barres cassées.

L'approche proposée démontre ainsi l'intérêt de la combinaison des techniques de traitement du signal à haute résolution et des méthodes d'intelligence artificielle pour le diagnostic des moteurs asynchrones.

Mots-clés : Moteur asynchrone, défauts rotoriques, barres cassées, Root-MUSIC, SVM, diagnostic, classification, puissance spectrale.

Abstract

This dissertation deals with the application of Root-MUSIC and SVM methods for the classification of rotor faults in an induction motor. Broken rotor bars are among the most critical faults affecting the performance and reliability of induction motors. To ensure early fault detection and automatic classification, an approach based on stator current analysis is proposed.

The Root-MUSIC method is used to accurately estimate the characteristic frequencies associated with rotor faults and to extract the corresponding spectral powers. These spectral powers are then used as input features for an SVM classifier in order to distinguish between different motor operating conditions.

The experimental results show that the spectral powers extracted by Root-MUSIC provide effective features for the recognition and classification of broken-bar faults. The proposed approach demonstrates the effectiveness of combining high-resolution signal processing techniques with artificial intelligence methods for induction motor fault diagnosis.

Keywords: Induction motor, rotor faults, broken bars, Root-MUSIC, SVM, diagnosis, classification, spectral power.

Liste des figures

<i>Figure I.1 : Vue éclatée d'un moteur asynchrone</i>	<i>4</i>
<i>Figure I.2 : Arbre des différentes familles des moteurs électriques.....</i>	<i>5</i>
<i>Figure I.3 : Représentation du phénomène d'induction et de force de Lorenzo dans le rotor</i>	<i>9</i>
<i>Figure I.4 : Classification des défauts selon leurs origines</i>	<i>9</i>
<i>Figure I.5 : Structure générale d'un système de diagnostic</i>	<i>13</i>
<i>Figure III.1 : Représentation des hyperplans.</i>	<i>25</i>
<i>Figure III.2 : Principe d'hyperplan séparateur, il en existe plusieurs. Celui qui correspond au minimum d'erreurs est l'hyperplan optimal.</i>	<i>26</i>
<i>Figure III.3 : hyperplan optimal H (en gras) avec la marge maximale d.....</i>	<i>26</i>
<i>Figure III.4 : Différents hyperplans possibles ainsi que les vecteurs de supports.</i>	<i>27</i>
<i>Figure III.5 : Maximisation de la marge.....</i>	<i>27</i>
<i>Figure III.6 : Choix de l'hyperplan optimal.....</i>	<i>28</i>
<i>Figure III.7 : Principe du séparateur non-linéaire</i>	<i>30</i>
<i>Figure III.8 : Représentation de l'espace des caractéristiques</i>	<i>30</i>
<i>Figure VI.1 : Principe du système de surveillance</i>	<i>35</i>
<i>Figure VI.2 : Etapes du Système de surveillance par SVM.....</i>	<i>36</i>
<i>Figure VI.3 : Organigramme de l'extraction des puissances associées aux fréquences de défaut</i>	<i>37</i>
<i>Figure VI.4 : Description du banc d'essai</i>	<i>38</i>
<i>Figure VI.5 : Lissajous de la composante directe I_d du courant statorique</i>	<i>40</i>
<i>Figure VI.6 : Lissajous et spectres du courant statorique au défaut de barre</i>	<i>41</i>
<i>Figure VI.7 : Reconnaissance du défaut d'une barre cassée avec différentes probabilités.....</i>	<i>44</i>
<i>Figure VI.8 : Reconnaissance du défaut de deux barres cassées avec différentes probabilités</i>	<i>45</i>
<i>Figure VI.9 : Reconnaissance du défaut de trois barres cassées avec différentes probabilités</i>	<i>45</i>

Liste des tableaux

<i>Tableau 1 : Base de données des fréquences latérales et puissances spectrales associées pour les défauts de barres cassées.....</i>	<i>42</i>
--	-----------

Liste des abréviations

AI : Artificial Intelligence

COLT : Conference on Learning Theory

DOA : Direction Of Arrival

ERM : Empirical Risk Minimization

ESPRIT : Estimation of Signal Parameters via Rotational Invariance Techniques

FFT : Fast Fourier Transform

HR : Haute Résolution

Hz : Hertz

MAS : Machine Asynchrone

MLP : Multi Layer Perceptron

MUSIC : Multiple Signal Classification

MVDR : Minimum Variance Distortionless Response

RBF : Radial Basis Function

ROOT-MUSIC : Root Multiple Signal Classification

RSB : Rapport Signal sur Bruit

SCADA : Supervisory Control And Data Acquisition

SRM : Structural Risk Minimization

SVM : Support Vector Machine

Tr/min : Tours par minute

VC : Vapnik-Chervonenkis

Table des matières

Remerciements	1
Dédicace	2
Dédicace	3
Résumé	4
Liste des figures	5
Liste des tableaux	5
Liste des abréviations	6
Table des matières	7
Introduction Générale.....	1
CHAPITRE I : Moteur asynchrone et diagnostique.....	3
I.1 INTRODUCTION	4
I.2 Le Moteur asynchrone	5
I.2.1 Définition du moteur asynchrone.....	5
I.2.2 Constitution du moteur asynchrone	6
I.2.2.1 Le stator :	6
I.2.2.2 Le rotor :	6
I.2.2.3 Les organes mécaniques :	6
I.2.3 Types de moteurs asynchrones	7
I.2.3.1 Moteur à rotor en cage d'écureuil	7
I.2.3.2 Moteur à rotor bobiné	7
I.2.4 Fonctionnement du moteur asynchrone	8
I.3 Les défauts dans les moteurs asynchrones et diagnostique	9
I.3.1 Différentes défaillances du moteur asynchrone	9
I.3.1.1 Défaillances au stator	10
I.3.1.2 Défaillances au rotor	11

I.3.1.3 Les défaillances mécaniques	12
I.3.2 Méthodes de diagnostic des machines asynchrones	12
I.4 Conclusion	14
CHAPITRE II: Root-MUSIC	15
II.1 INTRODUCTION:	16
II.2 Les méthodes de Haute Résolution (HR)	16
II.2.1 Méthodes basées sur le sous-espace (Eigenstructure Methods)	17
II.2.1.1 ESPRIT (Estimation of Signal Parameters via Rotational Invariance Techniques):	17
II.2.1.2 MUSIC (Multiple Signal Classification) :	17
II.2.2 Méthodes Paramétriques (Modélisation)	17
II.2.2.1 Méthode de Capon (Minimum Variance Distortionless Réponse - MVDR)	18
II.2.2.2 La méthode de Pisarenko	18
II.3 L'algorithme MUSIC (Multiple Signal Classification):	18
II.3.1 La méthode ROOT-MUSIC :	18
II.3.2 Étapes de la méthode Root-MUSIC:	19
II.3.2.1 Acquisition des données	19
II.3.2.2 Calcul de la matrice d'autocorrélation	19
II.3.2.3 Décomposition en valeurs propres et vecteurs propres	19
II.3.2.4 Estimation des fréquences des composantes	20
II.3.2.5 Calcul des énergies des composantes	20
II.3.3 Estimation de puissances des harmoniques:	22
Conclusion.....	22
Chapitre III : Machine à vecteurs de support (SVM).....	23
III.1 INTRODUCTION.....	24
III.2 Présentation de SVM (Machine à vecteurs de support)	24
III.2.1 Objectifs d'un SVM	26

III.2.2 Fonctionnement global de la méthode SVM.....	27
III.2.2.1 Classificateur linéaire	28
III.2.2.2 Classificateur non-linéaire.....	29
III.2.3 Avantages et inconvénients des SVM.....	32
III.2.3.1 Avantages	32
III.2.3.2 Inconvénients	33
III.3 Conclusion.....	33
Chapitre IV : Résultats Expérimentaux & Discussion	34
IV.1 Principe du système de surveillance basé sur les SVM	35
IV.2 Description du banc d'essai	38
IV.3 Extraction des puissances spectrales des composantes de défaut	39
IV.4 Reconnaissance du type de défaut des barres et discussion.....	41
IV.5 Conclusion	46
Conclusion générale	47
Tableau des symboles.....	48
REFERENCES :.....	50

Introduction Générale

Les moteurs asynchrones occupent une place essentielle dans les systèmes industriels modernes grâce à leur robustesse, leur simplicité de construction, leur faible coût de maintenance et leur capacité à fonctionner dans des conditions variées. Ils sont largement utilisés dans les applications industrielles telles que les systèmes de pompage, les mécanismes de levage, les chaînes de production, les systèmes de traction et les entraînements électriques de manière générale. Cependant, malgré leurs nombreux avantages, ces machines restent exposées à plusieurs types de défauts pouvant affecter leur fonctionnement normal, réduire leurs performances et provoquer des arrêts imprévus de production.

Parmi les défauts les plus importants rencontrés dans les moteurs asynchrones, les défauts rotoriques, notamment les ruptures de barres, représentent un problème critique. Ce type de défaut peut engendrer des oscillations du couple électromagnétique, des vibrations, une augmentation des pertes, une dégradation progressive de la machine et, dans certains cas, une panne complète du système. Pour cette raison, la détection précoce et la classification automatique de ces défauts constituent un enjeu important dans le domaine de la maintenance prédictive et de la surveillance des machines électriques.

Le diagnostic des défauts dans les moteurs asynchrones repose souvent sur l'analyse des signaux mesurés, en particulier le courant statorique. Cette approche, connue sous le nom d'analyse de la signature du courant moteur, présente l'avantage d'être non invasive, facile à mettre en œuvre et efficace pour détecter plusieurs types de défauts. Les défauts rotoriques provoquent l'apparition de composantes fréquentielles caractéristiques dans le spectre du courant statorique. Cependant, l'utilisation directe des méthodes classiques comme la transformée de Fourier rapide peut être limitée lorsque les fréquences sont proches, lorsque le signal est bruité ou lorsque la résolution fréquentielle est insuffisante.

Dans ce contexte, les méthodes de traitement du signal à haute résolution représentent une alternative intéressante. Parmi ces méthodes, Root-MUSIC permet d'estimer avec précision les composantes fréquentielles d'un signal, même en présence de bruit. Cette méthode repose sur la décomposition de la matrice d'autocorrélation en sous-espace signal et sous-espace bruit, ce qui permet d'obtenir une meilleure résolution spectrale par rapport aux méthodes classiques. Dans ce travail, Root-MUSIC est utilisée non seulement pour localiser les fréquences caractéristiques liées aux défauts rotoriques, mais surtout pour extraire les puissances spectrales associées à ces composantes.

L'utilisation de la puissance spectrale comme paramètre d'entrée présente un intérêt particulier. En effet, la fréquence permet de localiser la composante liée au défaut, mais la puissance associée à cette composante donne une information plus significative sur l'importance et la sévérité du défaut. Ainsi, au lieu d'utiliser directement les fréquences comme caractéristiques principales, ce travail exploite les puissances spectrales extraites aux fréquences de défaut. Ces puissances permettent de mieux différencier les différents états de fonctionnement du moteur et constituent des paramètres pertinents pour la phase de classification.

Afin d'assurer la reconnaissance automatique des défauts, la méthode des machines à vecteurs de support, ou SVM, est utilisée. Le SVM est une méthode d'apprentissage supervisé largement employée dans les problèmes de classification. Son principe consiste à rechercher un hyperplan optimal permettant de séparer les différentes classes avec une marge maximale. Grâce à sa capacité de généralisation et à son efficacité dans le traitement de données complexes, le SVM constitue un outil adapté pour la classification des défauts rotoriques à partir des caractéristiques extraites par Root-MUSIC.

Ce projet de fin d'études, intitulé « Application des méthodes Root-MUSIC et SVM pour la classification des défauts rotoriques dans un moteur asynchrone », s'inscrit donc dans le cadre du diagnostic intelligent des machines électriques. L'approche proposée consiste à acquérir les courants statoriques du moteur, extraire la composante directe du courant, appliquer la méthode Root-MUSIC afin de déterminer les fréquences caractéristiques du défaut, puis calculer les puissances spectrales correspondantes. Ces puissances sont ensuite utilisées comme vecteur d'entrée du classificateur SVM pour distinguer les différents états du moteur.

Le mémoire est organisé comme suit. Le premier chapitre présente les notions générales sur le moteur asynchrone, sa constitution, son principe de fonctionnement ainsi que les principaux défauts pouvant l'affecter. Le deuxième chapitre est consacré à la méthode Root-MUSIC et à l'extraction des paramètres spectraux, en mettant l'accent sur l'utilisation des puissances spectrales. Le troisième chapitre présente les principes fondamentaux de la méthode SVM et son rôle dans la classification supervisée. Enfin, le quatrième chapitre est consacré à la présentation des résultats obtenus et à leur discussion, afin de montrer l'efficacité de l'utilisation des puissances spectrales pour la classification des défauts rotoriques.

CHAPITRE I :

Moteur asynchrone et diagnostique

I.1 INTRODUCTION

Le moteur asynchrone est l'un des moteurs électriques les plus utilisés dans les domaines de l'énergie et de l'industrie, grâce à ses nombreux avantages, notamment sa grande robustesse, sa structure simple, sa facilité d'utilisation et d'entretien, ainsi que son coût économique par rapport à d'autres moteurs électriques. Les progrès technologiques, en particulier l'apparition des convertisseurs électroniques à la fin du siècle dernier, ont contribué à élargir le champ d'application de ce type de moteurs, dont la vitesse de rotation peut désormais être contrôlée en modifiant la fréquence d'alimentation dans une large plage.

Le moteur asynchrone est utilisé dans de nombreuses applications industrielles qui reposent sur la combinaison de convertisseurs statiques et d'appareils électriques, tels que les systèmes de traction électrique, les laminoirs, les opérations de levage, ainsi que les systèmes de pompage et diverses autres applications industrielles.

Malgré la bonne réputation de ce moteur en termes de fiabilité et de durabilité, il peut, comme les autres machines électriques, être sujet à plusieurs pannes, qu'elles soient électriques ou mécaniques. Compte tenu des effets négatifs et des pertes économiques importantes que ces pannes peuvent entraîner dans les systèmes industriels, le diagnostic et la détection précoce des pannes ont fait l'objet d'un intérêt particulier de la part des chercheurs au cours des deux dernières décennies.




Figure I.1 : Vue éclatée d'un moteur asynchrone

I.2 Le Moteur asynchrone

I.2.1 Définition du moteur asynchrone

La machine asynchrone, appelée aussi machine à induction, est une machine électrique fonctionnant en courant alternatif et caractérisée par l'absence de connexion électrique directe entre le stator et le rotor. Parmi les différents types existants, la machine à rotor en cage d'écureuil est la plus utilisée en raison de sa simplicité de construction et de sa robustesse.

En gros, asynchrone veut dire que le rotor ne tourne pas à la même vitesse que le champ magnétique du stator. Cette différence de vitesse, on l'appelle glissement, et c'est ça qui fait marcher ce type de moteur.

Grâce à sa fiabilité et à son faible coût de maintenance, la machine asynchrone est largement utilisée dans de nombreux domaines industriels, tels que les systèmes de transport, les comme moteur, elle peut également fonctionner comme génératrice, notamment dans certaines applications comme les éoliennes.

Dans les applications de forte puissance, les moteurs asynchrones sont généralement alimentés par des systèmes triphasés, tandis qu'en alimentation monophasée, un dispositif de démarrage est souvent nécessaire.[1]




Figure I.2 : Arbre des différentes familles des moteurs électriques

I.2.2 Constitution du moteur asynchrone

La machine asynchrone se compose principalement de trois éléments : le stator, le rotor et les organes mécaniques.

I.2.2.1 Le stator :

Il est constitué d'un enroulement bobines dans des fentes d'un circuit magnétique. Ces circuits magnétiques sont faits de feuilles de fer laminées avec des fentes parallèles à l'axe du moteur. Les bobines du stator ont deux parties : les conducteurs dans les fentes et les têtes de bobine. Les conducteurs des fentes créent un champ magnétique, ce qui permet la conversion électromagnétique. Les têtes de bobine ferment le circuit, contrôlant le courant d'un conducteur à l'autre. Le but est d'avoir un courant aussi uniforme que possible pour réduire les variations du couple électromagnétique. [1]

I.2.2.2 Le rotor :

Dans un rotor à cage, les anneaux de court-circuit font circuler le courant d'une barre du rotor à l'autre. Ces barres, réparties régulièrement, forment le circuit du rotor. Cette cage est placée à l'intérieur d'un circuit magnétique fait de disques en tôle empilés sur l'arbre de la machine, un peu comme dans un moteur à rotor bobiné.

Pour les rotors à cage d'écureuil, les conducteurs sont créés en coulant un alliage d'aluminium, ou avec des barres de cuivre préformées insérées dans les tôles du rotor. Il y a rarement (ou pas du tout) d'isolation entre les barres et les tôles magnétiques, mais leur résistance est si faible que les courants de fuite dans les tôles sont minimes... sauf en cas de rupture de barre.

Le moteur à cage d'écureuil est bien plus simple à fabriquer qu'un moteur à rotor bobiné, ce qui le rend moins cher. Il est aussi plus solide. C'est le type de moteur asynchrone le plus courant aujourd'hui. [2]

I.2.2.3 Les organes mécaniques :

Le châssis, c'est comme le squelette de la machine. C'est la coque extérieure qui garde tous les éléments du moteur en sécurité à l'intérieur.

L'arbre, c'est le truc indispensable qui fait passer le mouvement. Il a une partie au milieu qui tient le rotor et un bout où l'on met un demi-accouplement pour envoyer le mouvement à ce qui doit bouger. En général, l'arbre est en acier super costaud, fait à partir de métal fondu ou forgé. Pour calculer la taille de l'arbre, il faut tenir compte de pas mal de choses : les forces qui le

tordent à cause de la vitesse et de l'attraction des aimants, et aussi les forces qui poussent et tirent à cause de la vitesse. Il doit aussi supporter les forces de torsion quand il transmet la puissance, que ce soit tout le temps ou juste de temps en temps.

L'arbre repose sur un ou plusieurs supports qui empêchent le rotor de bouger et lui permettent de tourner sans problème. Souvent, un des supports est fixe et l'autre peut bouger un peu pour compenser quand l'arbre chauffe et se dilate. En plus, on isole souvent un des supports pour éviter que l'électricité ne passe dans l'arbre à cause de petits défauts dans le circuit magnétique. Pour les petites et moyennes machines, ces supports sont souvent des roulements à billes.

Pour changer la vitesse des moteurs et avoir une meilleure conversion d'énergie, beaucoup de machines sont branchées à des convertisseurs électroniques de puissance. Aujourd'hui, dans pas mal d'usines, on voit des systèmes qui combinent ces convertisseurs avec des machines électriques, surtout pour les pompes et les ascenseurs. Ces convertisseurs permettent d'envoyer aux moteurs du courant avec une tension et une fréquence qui changent, ce qui permet de contrôler la force ou la vitesse de la machine. [2] [3]

I.2.3 Types de moteurs asynchrones

Il existe deux types principaux de moteurs asynchrones, selon la façon dont leur rotor est fait :

I.2.3.1 Moteur à rotor en cage d'écureuil

- C'est le type le plus courant dans l'industrie car il est simple, solide et ne coûte pas cher.
- Le rotor a des barres qui conduisent l'électricité, attachées ensemble par des anneaux qui court-circuitent, ce qui forme une cage.
- Ce moteur n'a pas besoin de beaucoup d'entretien et fonctionne bien pour les applications avec une puissance faible ou moyenne.

I.2.3.2 Moteur à rotor bobiné

- Le rotor est fait avec des enroulements, un peu comme ceux du stator, qui sont reliés à des bagues collectrices.
- Avec ce type de moteur, on peut ajouter des résistances dans le circuit du rotor pour gérer le démarrage et la force, ce qui est pratique pour certaines utilisations industrielles qui demandent beaucoup de force au début.
- Par contre, il est plus compliqué à fabriquer et plus cher qu'un moteur à cage d'écureuil.

En résumé, le type de moteur que vous choisissez dépend de ce que vous voulez faire avec, de combien ça coûte et de la facilité avec laquelle vous pouvez l'entretenir. De nos jours, la plupart des moteurs asynchrones que vous trouverez sont des moteurs à cage d'écureuil.

I.2.4 Fonctionnement du moteur asynchrone

Le moteur asynchrone fonctionne grâce à l'interaction électromagnétique entre le champ magnétique tournant t produit dans le stator et le rotor de la machine. Lorsque les enroulements statoriques sont alimentés par un courant triphasé provenant d'un réseau équilibré, ils génèrent un champ magnétique qui tourne dans l'entrefer de la machine avec une pulsation ω_s

D'après la loi de Lenz, quand un champ magnétique qui tourne passe sur les fils du rotor, ça crée un courant électrique dans le rotor.

L'interaction entre ces courants et le champ magnétique crée des forces électromagnétiques qui produisent un couple moteur, entraînant ainsi la rotation du rotor. Ce phénomène n'arrive seulement si la vitesse du champ tournant est différente de celle du rotor. [4][5]

Dans une machine asynchrone (MAS) le champ magnétique tournant se déplace dans l'entrefer avec une vitesse appelée vitesse de synchronisme Ω_s . Cette vitesse dépend de la fréquence d'alimentation f_s et du nombre de paires de pôles p de la machine.

$$\Omega_s = \frac{\omega_s}{p} = 60 \frac{f_s}{p} \text{ (Tr/min)} \quad (\text{I.1})$$

- f_s représente la **fréquence des tensions triphasées** du réseau d'alimentation [Hz] ;
- p correspond au **nombre de paires de pôles**.

Lorsque le **rotor** est en **court-circuit** et qu'il est soumis à l'action du champ tournant, des **courants induits** (appelés aussi **courants de Foucault**) apparaissent dans ses conducteurs. Ces courants, en présence du champ magnétique, engendrent des **forces électromagnétiques de Laplace**. L'ensemble de ces forces produit un **couple moteur** qui met le rotor en mouvement. Le rotor tourne alors dans le même sens que le champ tournant, mais sa vitesse reste légèrement inférieure à celle de ce ($\Omega < \Omega_s$). [4][6]

Par conséquent, il existe toujours une **différence de vitesse** entre le **stator** et le **rotor**. Cette différence est appelée **glissement (g)**, qui constitue une caractéristique fondamentale des **machines asynchrones**. Le glissement représente l'écart relatif entre la **vitesse de synchronisme Ω_s** et la **vitesse réelle du rotor Ω** . Il s'exprime par la relation suivante :

$$g = \frac{\Omega_s - \Omega}{\Omega_s} \quad (\text{I.2})$$




Figure I.3 : Représentation du phénomène d'induction et de force de Lorenzo dans le rotor

I.3 Les défauts dans les moteurs asynchrones et diagnostique

I.3.1 Différentes défaillances du moteur asynchrone

Les machines électriques et les systèmes d'entraînement peuvent être affectés par différents types de défauts. Selon leur origine, ces défauts sont généralement classés en deux catégories:

- Les défauts d'origine interne
- Les défauts d'origine externe.




Figure I.4 : Classification des défauts selon leurs origines

Les défauts externes sont principalement liés aux conditions d'alimentation électrique, à la charge mécanique appliquée ou encore à l'environnement d'exploitation de la machine. En revanche, les défauts internes proviennent des différents composants de la machine tels que les circuits magnétiques, les enroulements du stator et du rotor, l'entrefer mécanique ou encore la cage rotorique.

Parmi les défauts les plus courants, on peut citer :

- Les **défauts électriques du stator**, caractérisés par l'ouverture d'une phase ou par des courts-circuits entre spires d'une même phase, entre deux phases ou entre une phase et la carcasse du stator
- Les **défauts électriques du rotor**, tels que l'ouverture ou le court-circuit des spires dans les machines à rotor bobiné, ainsi que la rupture ou la fissuration des barres et/ou des anneaux de court-circuit dans les machines à cage
- Les **défauts mécaniques**, notamment les défauts de roulements, les problèmes d'excentricité et les défauts d'alignement
- Les **défaillances des composants électroniques de puissance** intervenant dans la commande du système d'entraînement.

I.3.1.1 Défaillances au stator

Ces problèmes sont généralement dus à l'usure de l'isolation des enroulements. Quand la situation empire, cela peut causer des courts-circuits entre les spires, qui peuvent ensuite évoluer en courts-circuits entre phases ou entre une phase et la terre. Les courts-circuits entre phases se produisent souvent au niveau des extrémités des bobines et peuvent arrêter la machine immédiatement. En revanche, les courts-circuits entre spires de la même phase réduisent le nombre de spires actives, ce qui déséquilibre les courants des trois phases et fait baisser le couple moteur. En plus, ces défauts perturbent les systèmes de contrôle qui utilisent le modèle de Park. Ce type de défaut perturbe également de manière significative les systèmes de commande fondés sur le modèle de Park, lequel repose sur l'hypothèse d'un modèle équilibré.

[7][8][9]

I.3.1.2 Défaillances au rotor

Il faut souligner que, même si les rotors bobinés peuvent avoir des défauts proches de ceux du stator, les rotors à cage ont souvent des problèmes plus compliqués et divers. Les principaux défauts du rotor sont:

• Rupture d'une barre rotorique

- Fréquent et représente environ 10 % des pannes des moteurs asynchrones de grande puissance.
- Peut survenir à l'encoche ou à l'extrémité de la barre.
- Réduit le couple électromagnétique, provoque des oscillations de vitesse et des vibrations, entraînant un fonctionnement anormal et une détérioration accélérée de la machine.
- L'effet cumulatif augmente avec le nombre de barres cassées.

• Rupture d'une portion d'anneau de court-circuit

- Aussi fréquent que la rupture de barre, mais souvent difficile à détecter et confondu avec les ruptures de barres.
- Ces anneaux transportent des courants plus importants, et une mauvaise conception, des conditions de fonctionnement défavorables ou des surcharges peuvent provoquer leur rupture.
- Déséquilibre les courants dans les barres et provoque des modulations d'amplitude sur les courants statoriques.

• Excentricité du rotor

- Correspond à un décentrement du rotor par rapport au stator, modifiant l'entrefer.
- Excentricité statique : désalignement de l'axe rotorique et statorique, souvent dû au décentrage des flasques.
- Excentricité dynamique : le centre de rotation du rotor diffère du centre géométrique du stator, pouvant être causé par des déformations ou des roulements usés.
- Excentricité mixte : combinaison des deux précédentes, la plus fréquente.

En résumé, les problèmes du rotor concernent surtout la casse des barres, la rupture des anneaux de court-circuit et l'excentricité, et chacun de ces défauts influence le couple, les vibrations et les performances générales du moteur.[7][10][11][3][12]

I.3.1.3 Les défaillances mécaniques

Les défaillances mécaniques sont courantes dans les machines asynchrones, surtout au niveau des roulements, des flasques et de l'arbre moteur.

• Défauts de roulements

- Représentent une part importante des pannes, surtout dans les machines de forte puissance.
- Proviennent de l'usure des billes ou de la piste de roulement et peuvent avoir diverses causes : surcharge mécanique, mauvais assemblage, circulation de courant, défaut de lubrification, ou contraintes environnementales (température, corrosion, poussière).
- Effets : vibrations, bruit, variations du couple et, dans les cas extrêmes, blocage du rotor.

• Autres défauts mécaniques

- Flasques : un mauvais positionnement peut désaligner les roulements et provoquer une excentricité de l'arbre.
- Arbre moteur : matériaux inadaptés ou corrosion peuvent provoquer des fissures et éventuellement la fracture de l'arbre, entraînant l'arrêt total de la machine.
- Détection : analyse vibratoire, ultrason, analyse fréquentielle des courants ou inspection visuelle.

En résumé, Les problèmes mécaniques peuvent perturber le fonctionnement du moteur et réduire sa durée de vie. Cela peut se manifester par des vibrations ou des bruits, et dans les cas graves, provoquer un arrêt total si l'arbre se casse ou si les roulements sont bloqués.[13][10][11][5]

I.3.2 Méthodes de diagnostic des machines asynchrones

Le diagnostic vise à identifier l'origine du défaut observé dans le système. On entend par défaut tout changement ou écart anormal dans l'une des valeurs caractéristiques du fonctionnement du système. Les méthodes de diagnostic reposent généralement sur l'analyse d'un ensemble d'indicateurs ou de symptômes qui permettent d'identifier et d'évaluer l'état de fonctionnement du système. [14]




Figure I.5 : Structure générale d'un système de diagnostic

La figure (I.5) représente le schéma du système de diagnostic d'un système industriel. Elle illustre les étapes permettant de surveiller le système, de détecter une panne, puis de prendre la décision appropriée.

D'après la figure (I.5) ci-dessus, on peut distinguer deux étapes fondamentales dans le processus de diagnostic, à savoir : la détection des défauts et leur localisation, ainsi que la détermination de la nature du défaut dans certaines méthodes utilisées. Dans les applications pratiques au sein des équipements industriels, lorsqu'un dysfonctionnement survient, le système de diagnostic s'efforce d'abord de le détecter, puis cherche à en déterminer les causes possibles afin de l'isoler et de le résoudre. De manière générale, le processus de diagnostic des défaillances des systèmes repose sur une série d'étapes fondamentales, comme suit [15][16] :

- **Extraction des informations nécessaires :** À ce niveau, on recueille les données relatives au fonctionnement du système industriel, telles que les mesures de courant, de tension, de vitesse, de température ou de vibrations. Ces informations sont généralement obtenues à l'aide de capteurs et d'appareils de mesure, et constituent la base sur laquelle le système de diagnostic s'appuie pour analyser l'état du système.
- **Élaboration des signatures associées aux symptômes des défauts :** Une fois les données collectées, elles sont traitées afin d'en extraire des indicateurs ou des caractéristiques distinctives appelés « empreintes de défaillance ». Ces empreintes correspondent à des schémas ou à des variations spécifiques des signaux qui indiquent la présence d'un dysfonctionnement potentiel du système.

- **Détection de dysfonctionnements :** À ce niveau, les indicateurs obtenus sont comparés aux valeurs de référence ou à l'état normal du système. Si un écart ou une différence notable est constaté, cela est considéré comme un signe de dysfonctionnement ou de panne du système.
- **Mise en œuvre de la méthode de diagnostic :** Une fois le dysfonctionnement détecté, une méthode de diagnostic appropriée est utilisée pour en déterminer l'origine. Cette méthode peut s'appuyer sur des modèles mathématiques, l'analyse des signaux ou des techniques d'intelligence artificielle, dans le but de localiser le dysfonctionnement et d'en déterminer la nature avec une plus grande précision.
- **Interprétation des données :** À ce niveau, on analyse les résultats obtenus lors du diagnostic afin de comprendre la nature du dysfonctionnement et ses causes possibles. Cette analyse permet de se faire une idée précise de l'état du système et de la gravité du problème.
- **Prise de décision en fonction des conséquences et de l'importance des défauts :** Au final, la décision appropriée est prise en fonction de la gravité de la panne et de son impact sur le fonctionnement du système. Il peut s'agir d'arrêter l'appareil, d'effectuer une maintenance immédiate, de déclencher une alerte ou de poursuivre le fonctionnement tout en surveillant le système.

Ce processus permet de surveiller le système industriel, de détecter les dysfonctionnements à un stade précoce, puis de prendre les mesures appropriées pour éviter des pannes majeures.

I.4 Conclusion

Dans ce chapitre, nous avons présenté les notions fondamentales relatives au moteur asynchrone, notamment sa constitution, son principe de fonctionnement ainsi que ses différents types. Nous avons également étudié les principales défaillances pouvant affecter cette machine, qu'elles soient d'origine statorique, rotorique ou mécanique, en mettant en évidence leurs effets sur les performances et la fiabilité du moteur. Enfin, les différentes méthodes de diagnostic ont été abordées afin de souligner l'importance de la détection précoce des défauts dans les systèmes industriels. Cette étude constitue une base théorique essentielle pour la suite de ce travail consacrée au diagnostic des défauts des moteurs asynchrones.

CHAPITRE II:

Root-MUSIC

II.1 INTRODUCTION:

Dans le domaine de la maintenance prédictive, l'analyse des signaux issus des systèmes industriels joue un rôle essentiel dans la détection des défauts. Les signaux mesurés, notamment ceux provenant des moteurs électriques, contiennent des informations importantes sur l'état de fonctionnement du système.

Dans le domaine des moteurs asynchrones, l'analyse spectrale constitue une approche particulièrement efficace pour la détection et le diagnostic des défauts. En analysant la répartition fréquentielle des signaux issus du moteur (courant, vibration, flux, etc.), il devient possible d'identifier des perturbations révélatrices de dysfonctionnements internes.

Certaines défaillances du rotor engendrent en effet des composantes fréquentielles caractéristiques qui apparaissent clairement dans le spectre. L'exploitation de ces signatures permet non seulement de détecter la présence d'un défaut, mais aussi d'en déterminer la nature, la localisation et le niveau de sévérité.

Parmi les méthodes d'analyse fréquentielle, la méthode Root-MUSIC (Multiple Signal Classification) est largement utilisée en raison de sa haute résolution et de sa capacité à estimer avec précision les fréquences des composantes sinusoïdales même en présence de bruit.

Cependant, dans ce travail, l'objectif ne se limite pas à l'estimation des fréquences. En effet, la puissance des composantes fréquentielles est exploitée comme caractéristique principale, car elle permet de mieux discriminer les états normaux et défectueux du système.

Ainsi, ce chapitre présente la méthode Root-MUSIC ainsi que le processus d'extraction des caractéristiques basé sur la puissance des composantes du signal, en vue de leur utilisation dans un algorithme de classification.

II.2 Les méthodes de Haute Résolution (HR)

Les méthodes de haute résolution en traitement du signal sont des techniques avancées utilisées pour l'analyse spectrale (estimation de fréquence) ou la localisation de sources (direction d'arrivée - DOA). Contrairement aux méthodes classiques basées sur la transformée de Fourier (FFT), elles permettent de surpasser la limite de résolution de Rayleigh, c'est-à-dire de séparer des composantes fréquentielles très proches ou des sources angulaires très rapprochées, même avec un nombre limité d'échantillons ou un faible rapport signal sur bruit (RSB).

Ces méthodes reposent généralement sur la modélisation du signal comme une somme de sinusoïdes complexes dans un bruit additif, et exploitent la structure propre (valeurs propres et

vecteurs propres) de la matrice de covariance du signal.

Ces méthodes séparent l'espace des données en deux sous-espaces orthogonaux : le **sous-espace signal** et le **sous-espace bruit** [17]

II.2.1 Méthodes basées sur le sous-espace (Eigenstructure Methods)

Ces méthodes séparent l'espace des données en deux sous-espaces orthogonaux : le **sous-espace signal** et le **sous-espace bruit** [17]

II.2.1.1 ESPRIT (Estimation of Signal Parameters via Rotational Invariance Techniques):

Principe : Exploite la structure de décalage invariant (invariance par rotation) entre deux sous-réseaux de capteurs. Elle calcule directement les paramètres sans recherche d'extrema (pas de recherche de pic).

II.2.1.2 MUSIC (Multiple Signal Classification) :

Principe : Exploite l'orthogonalité entre les vecteurs propres du bruit et les vecteurs directeurs du signal. Elle cherche les maxima de la fonction de pseudo-spectre.

Avantage : Très performante pour l'estimation de la direction d'arrivée (DOA) ou de fréquences.

II.2.2 Méthodes Paramétriques (Modélisation)

Les méthodes paramétriques reposent sur l'hypothèse que le signal observé peut être représenté par un modèle mathématique explicite. Contrairement aux méthodes non paramétriques (comme la FFT), elles supposent que le signal est généré par un nombre fini de composantes sinusoïdales perturbées par un bruit additif.

Le modèle général utilisé est :

$$x[n] = \sum_{k=1}^K A_k e^{j2\pi f_k n} + w \quad (II.1)$$

où A_k représente l'amplitude complexe et la f_k fréquence, et $w[n]$ un bruit blanc généralement supposé gaussien.

Ces méthodes exploitent la structure statistique du signal à travers la matrice de covariance afin d'obtenir une estimation plus précise des paramètres fréquentiels. [2]

II.2.2.1 Méthode de Capon (Minimum Variance Distortionless Réponse - MVDR)

La méthode de Capon est une méthode d'estimation spectrale adaptative basée sur un filtrage optimal. Elle consiste à concevoir un filtre linéaire qui :

- Laisse passer sans distorsion la fréquence d'intérêt (gain unitaire),
- Minimise simultanément la puissance totale du signal en sortie, ce qui permet de réduire l'influence du bruit et des interférences.

II.2.2.2 La méthode de Pisarenko

La méthode de Pisarenko est une technique de haute résolution basée sur l'analyse de la matrice d'autocorrélation du signal. Elle repose sur la décomposition en valeurs propres de cette matrice afin d'identifier le vecteur propre associé à la plus petite valeur propre, lequel représente principalement le sous-espace du bruit. À partir de ce vecteur, un polynôme est construit dont les racines permettent d'estimer les fréquences des composantes sinusoïdales du signal. Cependant, cette méthode reste limitée en pratique, car elle est sensible au bruit et peu performante lorsque le nombre de composantes augmente ou lorsque les fréquences sont proches.[2]

II.3 L'algorithme MUSIC (Multiple Signal Classification):

Dans le domaine du traitement d'antennes, la méthode MUSIC a d'abord été proposée de manière autonome par Schmidt bienvenu et Kopp dans les années 1980, est une technique largement utilisée dans le domaine du traitement du signal pour estimer les paramètres des signaux sinusoïdaux à partir des données bruitées. La décomposition en vecteurs propres de la matrice d'autocorrélation est utilisée par l'algorithme MUSIC en relation avec le vecteur des observations. L'espace des observations est divisé en deux espaces vectoriels orthogonaux grâce à cette décomposition : le sous espace de signal et son complément orthogonal, ou le sous-espace bruit.

II.3.1 La méthode ROOT-MUSIC :

La méthode Root-MUSIC constitue une technique puissante pour l'estimation des fréquences d'un signal immergé dans un environnement bruité. Elle offre une excellente résolution spectrale, même en présence d'un bruit important. Toutefois, son principal inconvénient réside dans sa complexité de calcul, notamment lorsque la dimension du signal est élevée ou lorsque le nombre d'échantillons devient important, ce qui peut rendre son utilisation coûteuse en temps

de calcul pour des applications en ligne.

Dans le cas où le signal peut être modélisé comme une somme d'exponentielles complexes pondérées, les méthodes les plus efficaces pour l'extraction des paramètres fréquentiels sont celles basées sur l'exploitation de la structure sous-jacente du signal. Parmi elles, la famille des méthodes de type sous-espace, dont Root-MUSIC fait partie, repose sur la séparation de l'espace des observations en deux sous-espaces orthogonaux : le sous-espace signal et le sous-espace bruit.

Ainsi, la méthode Root-MUSIC exploite cette décomposition afin d'isoler les composantes utiles du signal et d'estimer avec précision leurs fréquences. Pour mieux comprendre son fonctionnement, il est nécessaire d'examiner les différentes étapes qui la composent, lesquelles permettent une analyse robuste et précise des composantes fréquentielles du signal.[2]

II.3.2 Étapes de la méthode Root-MUSIC:

II.3.2.1 Acquisition des données

La première étape consiste à acquérir les données nécessaires à l'analyse. Celles-ci proviennent généralement de capteurs installés sur le moteur synchrone, permettant de mesurer différents signaux, qu'ils soient électriques (courant, tension) ou mécaniques (vibrations). La qualité et la pertinence de ces données sont essentielles pour garantir des résultats fiables.

II.3.2.2 Calcul de la matrice d'autocorrélation

Une fois les données collectées, on procède au calcul de la fonction d'autocorrélation. Cette fonction permet d'évaluer le degré de similarité entre le signal et ses versions décalées dans le temps. Elle met ainsi en évidence les structures périodiques du signal et facilite la distinction entre les composantes utiles et le bruit.

II.3.2.3 Décomposition en valeurs propres et vecteurs propres

À partir de la matrice d'autocorrélation, une décomposition est effectuée afin d'obtenir les valeurs propres et les vecteurs propres associés. Ces derniers représentent les directions principales dans l'espace des données et permettent de séparer le sous-espace du signal de celui du bruit, étape clé dans l'application de la méthode ROOT-MUSIC.

II.3.2.4 Estimation des fréquences des composantes

Après la décomposition, la méthode ROOT-MUSIC est utilisée pour estimer les fréquences des différentes composantes du signal. Ces fréquences identifiées correspondent généralement aux signatures caractéristiques des défauts présents dans le moteur synchrone, ce qui permet leur détection et leur diagnostic.

II.3.2.5 Calcul des énergies des composantes

Enfin, il est possible d'évaluer les énergies associées aux différentes fréquences estimées. Ces valeurs énergétiques permettent d'apprécier l'importance relative de chaque composante fréquentielle au sein du signal. En général, les fréquences présentant des niveaux d'énergie plus élevés correspondent à des contributions plus significatives, souvent liées à des défauts plus prononcés du moteur synchrone.

Après avoir présenté les principales étapes de la méthode, il convient à présent de passer à une application concrète en détaillant les calculs correspondants.

Dans ce cadre, on considère que le courant statorique $I_s(n)$ s'exprime comme suit:

$$\sum_{i=1}^L e^{j(2\pi \frac{f_i}{f_{sh}} n + \phi_i)} + w(n) \quad (II.2)$$

Où:

- $n=0, 1, 2, \dots (N-1)$.
- $W(n)$: Le bruit.
- f_{sh} : La fréquence d'échantillonnage.
- N : Nombre d'échantillonnage.
- L : Nombre de sinusoides ou des sources.

La matrice d'autocorrélation du signal de bruit est la somme des matrices d'auto- corrélation du signal i , et le bruit W définit par :

$$R_i = R_s + R_w = E[i_s(n).i_s^H(n)] + E[w(n).w^H(n)] = S.A.S^H + \sigma_w^2.I \quad (II.3)$$

$I_s(N) = [\dots iL]$ Vecteur d'observation.

$^o(\bullet)$ Est le vecteur complexe transposé et conjugué (hermitien transposé en anglais).

- $E[\bullet]$ L'espace mathématique.
- I : Étant la matrice identité de la taille $(N \times N)$.
- $S = [s1 \dots si; \dots; si; \dots]$: Vecteur d'observation.

$$S_i = [1 \quad e^{j(2\pi \frac{f_i}{f_{sh}})} e^{j(4\pi \frac{f_i}{f_{sh}})} \dots e^{j2\pi(N-1) \cdot \frac{f_i}{f_{sh}}}] \quad (II.4)$$

• A : Est la matrice de puissance des harmoniques.

$$A = \text{diag} [I_1^2 \ I_2^2 \dots \dots I_L^2] \quad (II.5)$$

• σW : La variation du bruit blanc .

• I : ta matrice d'identité.

La décomposition en valeurs propres de la matrice d'autocorrélation R_i est donnée par :

$$R_i = \sum_{K=1}^N \lambda_K \cdot \mu_K \cdot \mu_K^H = U_S \cdot D_S \cdot U_S^H + U_W \cdot D_W \cdot U_W^H \dots \quad (II.6)$$

Où:

λ_K et μ_K Sont Vecteurs et valeurs propres de R_i .

$$U_S = [U_1 \dots \dots u_1]; D_S = \text{diag} [\lambda_1 \lambda_1] \quad (II.7)$$

$$U_W = [U_{1+1} \dots \dots u_N]; D_W = \sigma_w^2 \cdot I_{N-1} \quad (II.8)$$

Donc

Les matrices U_S et U_W sont composées par les valeurs propres de vecteurs propres disposées dans l'ordre décroissant. L'équation (II.6) montre cela, nous pouvons diviser ces vecteurs propres en deux groupes ou sous-espaces : L vecteurs propres correspondant à L les plus grandes valeurs propres (sous-espaces de signal E_s), et N-1 vecteurs propres de bruit qui idéalement ont des valeurs propres égales à σ_w^2 (sous-espace de bruit E_b). Les matrices diagonales D_S et D_W contiennent les valeurs propres λ_K correspondant aux vecteurs propres; car les valeurs propres du bruit sont égales à la variation du bruit, la matrice D_W peut-être écrite comme montré dans l'équation (6, en comparant les équations (II.3), (III.4) et (II.8) nous pouvant écrire :

$$R_i \cdot R_w = U_w \cdot D_w = \sigma_w^2 \cdot D_w = S \cdot A \cdot S^H \cdot U_w + \sigma_w^2 \cdot U_w \quad (A)$$

CE QUI IMPLIQUE QUE :

$$S^H \cdot U_w = 0 \text{ avec } S_i \in E_s; i=1, \dots, L. \quad \forall U \in E_b$$

La méthode de Root-Music emploie le principe de cette orthogonalité entre le sous-espace de signal et le sous-espace de bruit. Les fréquences d'estimation requis $Z_i = e^{j(2\pi \frac{f_i}{f_{sh}})}$ Sont les racines d'équations (A) et la quelle peut être exprimée comme suit :

$$S_i^H \cdot U_i^H \cdot U_i \cdot S_i = 0 \quad \text{avec } i=1, 2, L \quad (B)$$

Les matrices de (4) vont en paires (c-à d si Z_i est une racine, $1/Z_i$ est aussi). Ces L racines les plus proches du cercle unité correspondent aux harmoniques possibles selon :

$$F_i = \frac{f_{sh}}{2\pi} \cdot \arg(Z_i) \quad \text{Avec } i = 1, 2, \dots, L \quad (C)$$

II.3.3 Estimation de puissances des harmoniques:

$$\mathbf{R}_s = \mathbf{S} \cdot \mathbf{A} \cdot \mathbf{S}^H = \sum_{k=1}^L (\lambda_k + \sigma_w^2) \cdot \mathbf{u}_k \cdot \mathbf{u}_k^H \quad (\text{D})$$

Il est plus facile à inverser $\mathbf{R}_s$ qu'à inverser $\mathbf{S}$. par conséquent les puissances d'harmoniques

peuvent être estimées par la méthode suivante : $\mathbf{Q} = \mathbf{A}^{-1} = \frac{1}{\mathbf{S}^H \cdot \mathbf{S} \cdot \mathbf{R}_s^{-1}}$ (E)

$$\left\{ \begin{array}{l} \mathbf{R}_s^{-1} = \sum_{k=1}^L \frac{1}{\lambda_k + \sigma_w^2} \cdot \mathbf{u}_k \cdot \mathbf{u}_k^H \\ \sigma_w^2 = \frac{1}{N-L} \sum_{k=L+1}^N \lambda_k \end{array} \right.$$

Où: (F)

Le problème d'identification est résolu en sachant les fréquences et les puissances des divers harmoniques. En outre, le rang (l'ordre) de sous-espace qui nous permet d'estimer le positionnement de fréquences. En raison de la longueur finie de données, nous ne pouvons pas avec précision calculer la matrice de corrélation.

Conclusion

Dans ce chapitre, nous avons présenté les principes fondamentaux des méthodes d'analyse spectrale à haute résolution, en mettant particulièrement l'accent sur la méthode Root-MUSIC. Après un rappel des différentes approches de haute résolution telles que Pisarenko, MUSIC et ESPRIT, nous avons détaillé le fonctionnement de l'algorithme Root-MUSIC ainsi que les différentes étapes nécessaires à son application.

Cette méthode repose sur la décomposition de la matrice d'autocorrélation en sous-espace signal et sous-espace bruit, permettant ainsi une estimation précise des composantes fréquentielles même dans des conditions bruitées. Grâce à sa haute résolution spectrale, Root-MUSIC constitue une approche performante pour l'identification des signatures fréquentielles associées aux défauts des moteurs asynchrones.

Par ailleurs, l'estimation des puissances des harmoniques extraites représente une étape essentielle, car ces paramètres constituent des caractéristiques pertinentes pour distinguer les différents états de fonctionnement du moteur. Les informations obtenues à partir de l'analyse fréquentielle serviront ainsi de base à la phase de classification automatique des défauts.

Chapitre III :

Machine à vecteurs de support (SVM)

III.1 INTRODUCTION

Dans les systèmes modernes de diagnostic des machines électriques, l'exploitation des techniques d'intelligence artificielle occupe une place de plus en plus importante [18][19]. Parmi ces techniques, les méthodes de classification supervisée permettent d'identifier automatiquement les états de fonctionnement d'un système à partir des caractéristiques extraites des signaux mesurés [18].

Dans ce contexte, la machine à vecteurs de support (Support Vector Machine – SVM) est une méthode d'apprentissage automatique largement utilisée pour les problèmes de classification [20]. Elle est reconnue pour sa capacité à traiter des données complexes, même lorsque celles-ci ne sont pas linéairement séparables, grâce à l'utilisation de fonctions noyaux [20][19].

Ce chapitre présente les principes fondamentaux de la méthode SVM, ses concepts de base ainsi que son utilisation dans les problèmes de classification des défauts des machines électriques [18]. L'objectif est de préparer l'application de cette méthode dans le cadre du diagnostic des défauts rotoriques.

III.2 Présentation de SVM (Machine à vecteurs de support)

La machine à vecteurs de support (SVM – *Support Vector Machine*) a été proposée pour la première fois en 1992 par Bernhard Boser, Isabelle Guyon et Vladimir Vapnik lors de la conférence COLT-92. Cette méthode fait partie des approches d'apprentissage supervisé et est principalement utilisée pour les problèmes de classification ainsi que de régression [21]. Elle appartient à la famille des modèles linéaires généralisés.

L'idée principale des SVM est de construire un modèle de décision capable de séparer les données avec une grande précision, tout en assurant une bonne capacité de généralisation. Contrairement à d'autres méthodes, les SVM cherchent explicitement à éviter le surapprentissage en optimisant la séparation entre les classes.

Le principe repose sur la construction d'un hyperplan dans un espace de caractéristiques de grande dimension. Cet hyperplan est choisi de manière à maximiser la distance entre les classes, ce qui améliore la robustesse du modèle face aux nouvelles données.

Les SVM ont connu un grand succès dans la communauté scientifique, notamment après leurs performances remarquables dans des tâches complexes comme la reconnaissance de l'écriture manuscrite, où elles ont obtenu des résultats comparables à ceux des réseaux neuronaux avancés [22].

Leur développement repose sur les travaux de Vladimir Vapnik et sur la théorie de l'apprentissage statistique. Plus précisément, les SVM utilisent le principe de minimisation structurelle du risque (SRM), qui vise à minimiser non seulement l'erreur sur les données d'apprentissage, mais aussi la complexité du modèle. Ce principe est plus efficace que la minimisation du risque empirique (ERM), utilisée par les réseaux neuronaux classiques, car il permet une meilleure généralisation.

Initialement conçues pour des problèmes de classification, les SVM ont ensuite été étendues aux tâches de régression [21]. Leur efficacité repose sur la recherche de l'hyperplan optimal qui maximise la marge entre les classes, garantissant ainsi une meilleure stabilité du modèle.

La théorie VC (Vapnik-Chervonenkis) constitue le fondement mathématique des SVM et permet d'expliquer leur capacité à généraliser correctement à partir de données limitées.

Enfin, lorsque les données ne sont pas linéairement séparables dans leur espace d'origine, elles sont projetées dans un espace de dimension supérieure à l'aide de fonctions noyaux. Cette transformation permet de rendre possible une séparation linéaire dans un nouvel espace, tout en conservant une complexité de calcul raisonnable. Grâce à cette approche, les SVM sont capables de traiter efficacement des problèmes complexes tout en limitant le risque de surapprentissage.




Figure III.1 : Représentation des hyperplans.

III.2.1 Objectifs d'un SVM

Soit un ensemble de données composé de points appartenant à deux classes distinctes (par exemple, points rouges et points bleus). L'objectif est de déterminer une frontière de décision, appelée hyperplan séparateur, capable de diviser cet ensemble en deux régions tout en minimisant les erreurs de classification, autrement dit en identifiant l'hyperplan optimal.

Comme illustré à (figure III.2), plusieurs hyperplans peuvent séparer correctement les données et présenter des performances équivalentes en phase d'apprentissage (même risque empirique). Cependant, leurs capacités de généralisation peuvent différer significativement. Pour remédier à cela, Vladimir Vapnik (1995) a démontré qu'il existe un hyperplan unique optimal, défini comme celui qui maximise la marge entre les échantillons des deux classes [18]




Figure III.2 : Principe d'hyperplan séparateur, il en existe plusieurs. Celui qui correspond au minimum d'erreurs est l'hyperplan optimal.

Ainsi, les séparateurs à vaste marge (SVM) visent à éloigner au maximum les deux classes l'une de l'autre. Cela revient à maximiser la distance entre l'hyperplan séparateur H et les points les plus proches de chaque classe (voir figure III.3). Cette distance, appelée « marge d », joue un rôle essentiel : une marge plus large offre une meilleure robustesse face aux nouvelles données. Par conséquent, le classificateur qui optimise cette marge sur les données d'apprentissage est également celui qui présente les meilleures performances pour la classification de nouveaux exemples [23].




Figure III.3 : hyperplan optimal H (en gras) avec la marge maximale d

III.2.2 Fonctionnement global de la méthode SVM

L'objectif de l'approche SVM est d'assurer à la fois une classification précise et une séparation efficace entre les différentes classes. Le classifieur linéaire chargé de cette séparation est appelé hyperplan. Comme illustré à la figure (III.4), cet hyperplan permet de distinguer deux classes, représentées par des cercles bleus et des carrés rouges.




Figure III.4 : Différents hyperplans possibles ainsi que les vecteurs de supports.

Les points les plus proches de chaque classe sont appelés **vecteurs de support**. Ce sont eux qui déterminent la position de l'hyperplan (comme illustré dans la partie droite de la figure). Comme le montre la figure, plusieurs hyperplans peuvent assurer une séparation correcte entre les deux classes.

Cependant, la particularité essentielle des SVM réside dans le choix d'un hyperplan optimal. Parmi tous les hyperplans possibles, on cherche celui qui se situe au mieux entre les deux classes. Intuitivement, cela correspond à sélectionner l'hyperplan le plus fiable, offrant la meilleure précision de classification.

D'un point de vue formel, cela revient à maximiser la distance minimale entre l'hyperplan et les échantillons d'apprentissage. Cette distance est appelée **marge**. Ainsi, l'hyperplan séparateur optimal est celui qui maximise cette marge, d'où l'appellation de **séparateurs à vaste marge** (voir figure III.5).




Figure III.5 : Maximisation de la marge.

La maximisation de la marge vise à améliorer la précision du modèle lors de la classification de nouveaux exemples (phase de test). Comme illustré dans la figure (III.6), la partie gauche montre qu'avec un hyperplan optimal, un nouvel échantillon (cercle jaune) est correctement classé. En revanche, dans la partie droite, une marge plus réduite conduit à une mauvaise classification de ce même exemple.




Figure III.6 : Choix de l'hyperplan optimal.

III.2.2.1 Classificateur linéaire

Nous allons maintenant formuler le SVM d'un point de vue mathématique, en nous limitant dans un premier temps au cas linéaire. L'objectif des SVM est de séparer les données à l'aide d'un hyperplan, puis d'étendre cette capacité de séparation à des cas non linéaires grâce à l'utilisation de l'astuce du noyau.

Dans le cas de données linéairement séparables, l'objectif principal est de trouver un hyperplan qui classe correctement l'ensemble des exemples d'apprentissage. Cet hyperplan est défini par la fonction suivante :

$$w \cdot x + b = 0 \quad (\text{III.1})$$

$$\text{Ce qui implique} \quad y_i(w \cdot x + b) \geq 1; i = 1, \dots, N \quad (\text{III.2})$$

Dans cette équation, x représente un vecteur de caractéristiques, tandis que w désigne le vecteur de poids associé à l'hyperplan. Ainsi, pour assurer une bonne séparation des données, la fonction de décision doit être strictement positive pour une classe et négative pour l'autre.

Parmi l'ensemble des hyperplans possibles, le SVM choisit celui qui maximise la distance entre les classes. En effet, si les données d'apprentissage sont représentatives et qu'un vecteur de test se situe dans un voisinage r d'un vecteur d'apprentissage, un hyperplan bien positionné

permettra de maintenir une classification correcte.

L'hyperplan optimal est donc celui qui se situe le plus loin possible des points d'apprentissage tout en assurant une séparation correcte des classes. Cet hyperplan, qui maximise la marge, passe au milieu des régions définies par les points les plus proches des enveloppes convexes des deux classes. On obtient ainsi les expressions [a], [b] et [c].

En imposant la minimisation de la norme euclidienne de w , c'est-à-dire $\|w\|$, l'algorithme SVM cherche à déterminer un hyperplan séparateur unique et optimal. Dans ce contexte, la distance entre l'hyperplan et les points les plus proches de chaque classe est donnée par $\frac{2}{\|w\|}$

En introduisant des multiplicateurs de Lagrange α_i , l'approche SVM d'entraînement se réduit à la résolution d'un problème quadratique convexe. Résolvons (III.2) maintenant, nous obtenons

$$w = \sum \alpha_i * x_i; b = y_k - w * x_k$$

Pour tout (x_k) tel que $\alpha_k \neq 0$.

Le résultat est une solution unique globalement optimisée à un problème dual, qui a les propriétés suivantes :

$$w = \sum_i^N \alpha_i . y_i . x_i \quad \text{(III. 3)}$$

Si multiplicateurs de Lagrange correspondent à $\alpha_i > 0$, ces x_i sont appelés vecteurs de support. Quand ils sont entraînés, la fonction de décision peut être écrite comme :

$$f(x) = \text{sign}(\sum_{i=1}^n \alpha_i . y_i . (x . x_i) + b) \quad \text{(III. 4)}$$

Pour un cas non linéaire séparable, SVM réalise un mappage non linéaire du vecteur d'entrée x de l'espace entrée R^d dans un espace de Hilbert de dimension supérieure, où le mappage est déterminé par la fonction du noyau. Selon les différents problèmes de classification, de différente fonction noyau peut être sélectionnée pour obtenir des résultats optimaux de classification [24].

III.2.2.2 Classificateur non-linéaire

Lorsque les données sont linéairement séparables, un hyperplan peut être utilisé pour les séparer efficacement. Toutefois, dans de nombreux cas réels, les données présentent une structure non linéaire et deviennent difficilement séparables dans l'espace d'origine.

Dans ce contexte, les fonctions noyau sont utilisées afin de projeter les données d'entrée dans un espace de dimension supérieure, où elles deviennent linéairement séparables. Ce principe permet de transformer un problème non linéaire en un problème linéaire plus simple à résoudre

[11]. Une illustration simplifiée de ce concept est présentée dans la figure (III.7) [25]

Cette transformation est définie par une fonction noyau, donnée par :

$$K(x, y) = \Phi(x) \cdot \Phi(y) \quad (III.5)$$




Figure III.7 : Principe du séparateur non-linéaire

La transformation des données en un espace de caractéristiques permet de définir une mesure de similarité sur la base du produit de points. Si l'espace caractéristique est choisi de manière appropriée, la reconnaissance des formes peut être facile [25].

$$\langle \mathbf{x}_1, \mathbf{x}_2 \rangle \leftarrow K(\mathbf{x}_1, \mathbf{x}_2) = \langle \Phi(\mathbf{x}_1), \Phi(\mathbf{x}_2) \rangle \quad (III.6)$$




Figure III.8 : Représentation de l'espace des caractéristiques

Remarque : Notez que la légende dans la figure (III.8) n'est pas décrite car il s'agit d'un exemple de tracé pour faire comprendre les concepts impliqués. Nous avons vu que lorsque w , b sont obtenus, le problème est résolu pour un scénario linéaire simple dans lequel les données sont

séparées par un hyperplan. L'astuce du noyau permet aux SVM de former des frontières non linéaires.

Les étapes de l'astuce du noyau sont indiquées ci-dessous [24].

- L'algorithme est exprimé en utilisant uniquement les produits scalaires des ensembles de données. C'est ce qu'on appelle le problème dual.
- Les données originales sont passées par des cartes non linéaires pour former de nouvelles données par rapport à de nouvelles dimensions en ajoutant à chaque vecteur de données un produit par paire de certaines des dimensions des données originales.
- Plutôt que d'effectuer un produit scalaire sur ces nouveaux vecteurs plus grands, de les stocker dans des tableaux et de les consulter ultérieurement, nous pouvons représenter un produit de points des données après avoir effectué un mappage non linéaire sur celles-ci. Cette fonction est la fonction noyau.

Les SVM permettent de séparer et de classer différentes classes dans le cas linéaire. Cependant, une séparation linéaire n'est pas toujours suffisante pour discriminer correctement les deux classes. Pour améliorer la séparation et obtenir une meilleure marge, les SVM projettent alors les données d'apprentissage non linéaires vers un espace de dimension plus élevée, appelé **espace des caractéristiques S**, à l'aide d'une transformation $\Phi(x)$. Ainsi, cet espace est défini par :

$$S = (\Phi(x)) \quad (III.7)$$

En substituant (III.7) en (III.4) la fonction de décision peut être définie par :

$$f(x) = \text{sign}(\sum_{i=1}^n \alpha_i y_i (\Phi(x) \cdot \Phi(x_i)) + b) \quad (III.8)$$

En outre, pour assurer cette transformation en classification non linéaire, on utilise la fonction noyau (III.5). En substituant cette dernière en équation (III.8) la fonction de décision pour une classification non-linéaire devient :

$$f(x) = \text{sign}(\sum_{i=1}^n \alpha_i y_i K(x, x_i) + b) \quad (III.9)$$

Il existe différentes fonctions de noyau qui peuvent être utilisées avec les SVM à des fins de classification non linéaire, et ces fonctions de noyau sont telles que :

- Polynôme : Une cartographie polynomiale est une méthode populaire pour la modélisation non linéaire. Le deuxième noyau est généralement préférable car il évite les problèmes liés au fait que la valeur hessienne (valeur de la dérivée seconde partielle) devient nulle.

$$K(x, x') = \langle x, x' \rangle^d$$

$$K(x, x') = (< x \cdot x' > + 1)^d$$

Où d indique la dimension.

- Fonction de base radiale gaussienne : Les fonctions de base radiales ont le plus souvent une forme gaussienne.

$$K(x, x') = \exp \left(-\frac{\|x - x'\|^2}{2 \sigma^2} \right)$$

Où σ indique la largeur de la gaussienne.

- Fonction de base radiale exponentielle : Une fonction de base radiale produit une solution linéaire par morceaux qui peut être intéressante lorsque les discontinuités sont acceptables.

$$K(x, x') = \exp \left(-\frac{\|x - x'\|^2}{2 \sigma^2} \right)$$

- Perceptron multicouche (Sigmoid) : le MLP, établi de longue date, avec une seule couche cachée, dispose également d'une représentation valide du noyau.

$$k(x, x') = \tan (\rho < x \cdot x' > + \delta)$$

Où ρ est le paramètre gain et δ est l'offset de la sigmoïd.

III.2.3 Avantages et inconvénients des SVM

III.2.3.1 Avantages

Les machines à vecteurs de support (SVM) présentent plusieurs avantages par rapport aux méthodes statistiques classiques et aux réseaux de neurones :

- Excellente capacité de généralisation grâce à la théorie de l'apprentissage statistique et au principe de minimisation du risque structurel.
- Bonne performance avec des données de grande dimension, même lorsque le nombre de variables est supérieur au nombre d'observations.
- Solution unique, parcimonieuse et optimale (optimum global garanti).
- Faible nombre de paramètres à régler.
- Mise en œuvre relativement simple, sans problèmes d'instabilité numérique, avec une bonne efficacité de calcul.
- Bonnes performances même avec un ensemble d'apprentissage de petite taille.
- Bonne robustesse face au bruit et aux valeurs aberrantes.
- Réduction des données non pertinentes grâce à la sélection automatique des vecteurs de support.

- Résistance aux variations des paramètres du système.
- Possibilité de modéliser des relations non linéaires à l'aide des fonctions noyau.

III.2.3.2 Inconvénients

Malgré leurs performances, les SVM présentent également certaines limites :

- Utilisation de formulations mathématiques relativement complexes pour la classification.
- Temps de calcul élevé, notamment lors de la phase de test.
- Nature principalement binaire de la classification, nécessitant des stratégies multi-classes (un-contre-un ou un-contre-tous).
- Lorsque le nombre d'échantillons est très grand, les calculs matriciels deviennent lourds et coûteux.
- Temps de calcul important lors du réglage des paramètres, en particulier ceux liés aux fonctions noyaux.

III.3 Conclusion

Dans ce chapitre, nous avons présenté les fondements théoriques de la méthode des machines à vecteurs de support (SVM), une approche d'apprentissage supervisé largement utilisée en classification. Le principe repose sur la détermination de l'hyperplan optimal maximisant la marge entre les classes, ce qui permet d'assurer une bonne capacité de généralisation.

Nous avons ensuite détaillé la formulation du SVM dans le cas linéaire, ainsi que son extension au cas non linéaire à travers l'utilisation des fonctions noyaux, offrant ainsi la possibilité de traiter des données non séparables dans l'espace d'origine. Les principaux types de noyaux utilisés ont également été introduits.

Enfin, les avantages et les limites de cette méthode ont été discutés, mettant en évidence sa robustesse et ses performances en haute dimension, malgré une complexité de calcul parfois importante.

Chapitre IV :

Résultats

Expérimentaux &

Discussion

IV.1 Principe du système de surveillance basé sur les SVM

La surveillance d'un moteur à induction consiste à identifier son mode de fonctionnement à partir des grandeurs mesurées, principalement les courants des phases (I_a), (I_b) et (I_c). Ces mesures sont regroupées sous forme de vecteurs d'observation représentant l'état du moteur à un instant donné.

L'objectif est donc d'analyser chaque nouvelle observation issue du moteur et de déterminer à quelle classe elle appartient, selon une fonction de décision préalablement définie. Dans ce contexte, l'utilisation des machines à vecteurs de support, ou SVM, constitue une approche efficace pour la classification des différents états de fonctionnement.

Cette méthode est particulièrement adaptée au diagnostic et à la surveillance, car elle permet de séparer les différents modes de fonctionnement à partir d'une base d'apprentissage. Les données fournies par les capteurs sont utilisées comme vecteurs d'entrée du modèle SVM. Après la phase d'apprentissage, le système devient capable de classer automatiquement chaque nouveau vecteur mesuré et d'identifier, à chaque instant, l'état de fonctionnement du moteur surveillé, comme illustré dans la figure (VI.1).




Figure VI.1 : Principe du système de surveillance

Cette méthode se déroule en quatre étapes principales, illustrées par l'organigramme de la figure (VI.1), qui sont :

- la construction du vecteur d'entrée ;
- la préparation de la base de données ;
- la phase d'apprentissage ;
- la classification ou la prise de décision.




Figure VI.2 : Etapes du Système de surveillance par SVM

Le processus de classification prend comme entrée un vecteur représentatif d'un mode de fonctionnement du moteur. Ce vecteur regroupe les informations estimées, notamment les puissances latérales situées autour de la composante fondamentale.

La classification est ensuite appliquée en temps réel afin d'identifier l'état de fonctionnement du système. Toutefois, cette étape est précédée par une phase d'apprentissage réalisée hors ligne, dont le rôle est de déterminer les fonctions de séparation entre les différentes classes.

Ainsi, le système s'appuie sur une base d'apprentissage composée d'un ensemble d'échantillons de vecteurs d'observation. Pour chaque échantillon, la classe correspondante est connue à l'avance, ce qui permet au modèle SVM d'apprendre à distinguer les différents modes de fonctionnement avant son utilisation en surveillance réelle.

La figure (VI.3) présente les différentes étapes suivies pour l'extraction de la paire de fréquences caractéristiques du défaut. À partir des courants statoriques I_a , I_b et I_c , la composante directe I_d est calculée, puis la matrice d'autocorrélation est déterminée. Ensuite, la méthode Root-MUSIC est appliquée afin d'estimer les fréquences harmoniques et leurs puissances correspondantes. Après le calcul du glissement, les fréquences latérales gauche F_g et droite F_d sont extraites. Les puissances associées à ces deux fréquences constituent ensuite les paramètres d'entrée du classifieur SVM pour la décision finale.




Figure VI.3 : Organigramme de l'extraction des puissances associées aux fréquences de défaut

IV.2 Description du banc d'essai

Afin de valider le système de surveillance proposé, des essais expérimentaux ont été réalisés sur un moteur à induction présentant des défauts de barres cassées. Ces expérimentations ont été effectuées au sein du laboratoire LDEE de l'USTO-MB.

Le banc d'essai utilisé comprend un moteur asynchrone triphasé de type ENEL, à cage d'écureuil, alimenté par un réseau triphasé de fréquence 50 Hz. Ce moteur possède une puissance nominale de 1.5 kW et comporte quatre pôles. Son rotor est constitué de 28 barres obliques non isolées. Le courant statorique nominal en couplage triangle est $I_{\Delta}=7$ A.

La charge mécanique appliquée au moteur est assurée par un générateur à courant continu. Les mesures des courants statoriques sont réalisées à l'aide d'un capteur de courant à effet Hall, comme illustré dans la figure (VI.4). Les caractéristiques détaillées du moteur sont présentées en annexe.



Figure VI.4 : Description du banc d'essai

1 : Moteur asynchrone 1.5 KW

2 : Génératrice à c-c 3 KW

3 : Analyseur de spectre

4 : Oscilloscope

5 : Tachymètre

6 : Capteur de courant à effet Hall

À la fin de l'acquisition, deux fichiers correspondant au premier mode de fonctionnement ont été retenus afin d'effectuer une comparaison et de vérifier la présence éventuelle du défaut. Pour le deuxième mode, une base de données composée de 66 fichiers a été constituée. Parmi

ces fichiers, 42 ont été utilisés pour la phase d'apprentissage, tandis que les fichiers restants ont été réservés à la phase de test.

Afin de mettre en évidence l'influence du défaut dans le domaine temporel, nous avons exploité la combinaison des trois courants statoriques. Pour cela, la composante directe (I_d) a été choisie, car elle permet de regrouper les informations contenues dans les courants des trois phases. Son expression est donnée par la relation suivante :

$$I_d = \frac{2}{3} * (I_a + \alpha I_b + \alpha^2 I_c) \quad (IV.1)$$

Où : $\alpha = e^{j\frac{2\pi}{3}}$ ET I_a , I_b et I_c sont les trois courants de phases.

IV.3 Extraction des puissances spectrales des composantes de défaut

Lors de l'apparition des défauts, notamment les défauts de barres rotoriques, des composantes harmoniques apparaissent dans le spectre du courant statorique. Ces composantes sont principalement liées à la distribution non sinusoïdale des enroulements statoriques et à l'effet des encoches rotoriques. Elles se manifestent généralement sous forme de paires de fréquences latérales situées autour de la fréquence fondamentale. Dans notre approche, ces fréquences sont d'abord déterminées afin de localiser les composantes caractéristiques du défaut. Ensuite, les puissances spectrales associées à ces fréquences sont extraites et utilisées comme paramètres d'entrée du classificateur SVM. Les fréquences harmoniques des encoches du rotor sont données par l'équation suivante :

$$F_{sh} = F_0 \left(\frac{kn_b}{p} (1-s) \pm v \right) \quad (IV.2)$$

À partir de cette relation, les fréquences harmoniques liées aux encoches rotoriques sont déterminées. Ces fréquences permettent ensuite de localiser les composantes caractéristiques du défaut dans le spectre du courant statorique. Dans notre approche, les puissances spectrales associées à ces composantes sont extraites afin de former le vecteur d'entrée du classificateur SVM.

La procédure suivie dans notre travail pour extraire les paramètres spectraux permettant de diagnostiquer les défauts de barres cassées est présentée ci-dessous :

- Vérification de la présence éventuelle d'un défaut par l'application de la représentation de Lissajous à la composante directe du courant statorique I_d (Figure, VI.4).

- Application de la méthode Root-MUSIC à la composante directe du courant statorique, en considérant un ordre de modèle L compris entre 40 et 70.
- Estimation du glissement s à partir de la première harmonique d'encoche du rotor.
- Détermination des fréquences latérales caractéristiques du défaut de barres cassées autour de la fréquence fondamentale
- Localisation des composantes fréquentielles correspondant aux fréquences latérales gauche et droite F_g et F_d dans le spectre obtenu par Root-MUSIC.
- Extraction des puissances spectrales associées à ces deux fréquences latérales, notées respectivement P_g et P_d .
- Construction du vecteur d'entrée du classificateur SVM à partir de la paire des puissances spectrales :

$$X = [P_g \ P_d]$$

- Utilisation de ce vecteur pour l'apprentissage et la classification des différents états du moteur.





Figure VI.5 : Lissajous de la composante directe I_d du courant statorique


Identification des fréquences harmoniques latérales théoriquement prédites autour de la fréquence fondamentale, puis comparaison avec les composantes réellement présentes dans le spectre du courant statorique.

Après cette identification, les puissances spectrales correspondant à chacune des fréquences latérales retenues sont extraites, comme illustré dans la Figure (VI.5).


D'après la Figure (VI.5), la distinction directe entre les différents défauts reste difficile à partir de la simple observation du spectre. Pour cette raison, les puissances spectrales extraites sont utilisées comme paramètres d'entrée d'un classificateur SVM afin d'assurer la reconnaissance automatique du type de défaut.



(a) Une barre cassée



(b) Deux barres cassées



(c) Trois barres cassées

Figure VI.6 : Lissajous et spectres du courant statorique au défaut de barre

IV.4 Reconnaissance du type de défaut des barres et discussion

Dans cette partie, la méthode SVM est utilisée pour la reconnaissance automatique des défauts de barres rotoriques. Étant donné que le nombre d'échantillons disponibles est limité, le choix du SVM est adapté, car cette méthode donne de bonnes performances même avec une base d'apprentissage réduite

Dans notre approche, les fréquences latérales caractéristiques du défaut sont d'abord localisées autour de la fréquence fondamentale à l'aide de la méthode Root-MUSIC. Ensuite, les puissances spectrales correspondant à ces fréquences sont extraites. Contrairement à l'approche basée directement sur les fréquences, nous utilisons ici la paire des puissances spectrales ((P_g , P_d)) comme vecteur d'entrée du classificateur SVM. Après la construction des vecteurs de caractéristiques, chaque échantillon est représenté par la paire de puissances associées aux composantes latérales gauche et droite du défaut. Ces données sont ensuite utilisées pour l'apprentissage du SVM afin de reconnaître les différents types de défauts de barres cassées du rotor.

Pour l'apprentissage, nous avons utilisé 16 paires de puissances spectrales pour chaque type de défaut, comme indiqué dans le tableau (1). Les échantillons restants sont réservés à la phase de test afin d'évaluer la capacité du classificateur à reconnaître correctement les défauts non utilisés pendant l'apprentissage.

Une barre cassée				Deux barres cassées				Trois barres cassées			
Fg(Hz)	Fd(Hz)	Pg(dB)	Pd(dB)	Fg(Hz)	Fd(Hz)	Pg(dB)	Pd(dB)	Fg(Hz)	Fd(Hz)	Pg(dB)	Pd(dB)
48.44	53.49	11.38	1.87	47.17	51.83	2.08	9.39	44.57	52.99	-19.7	3.07
47.75	52.75	5.28	4.12	46.21	55.41	-0.30	-17.2	45.46	53.32	-5.54	-2.58
47.36	52.35	8.07	-2.68	44.35	53.90	-9.77	-2.89	49.31	54.63	26.29	-1.15
43.13	51.71	-5.59	14.92	47.79	52.43	2.70	7.06	44.14	52.04	-10.2	12.69
45.07	56.13	-7	-9.12	44.06	53.66	-10.5	-1.76	43.94	53.18	-7.83	0.10
43.33	54.37	-9.59	-5.76	47.01	51.71	-1.45	11.43	47.22	55.05	-4.28	-3.83
48.03	53.21	7.50	2.49	44.19	53.15	-9.96	-0.05	47.48	55.27	2.93	-29.7
47.89	52.95	7.83	1.42	47.46	55.97	4.87	-13.5	44.11	56.40	-11.0	-13.5
45.92	56.78	-3.78	-10.8	45.69	54.98	-2.13	-14.5	44.78	52.83	-7.89	0.83
45.02	56.35	-6.49	-10.5	44.74	53.93	-13.4	-1.59	46.89	55.65	-0.36	-34.0
43.57	55.01	-9.89	-6.90	46.15	55.79	-0.32	-15.8	47.03	55.11	2.75	-13.8
47.25	52.08	5.62	3.66	46.59	55.47	-1.08	-8.05	44.06	52.12	-15.5	11.80
45.97	56.70	-5.14	-8.75	43.83	53.26	-17.5	2.21	43.76	55.91	-10.1	-17.8
43.56	54.51	-25.2	-1.72	47.23	51.89	3.77	8.40	46.47	54.40	-3.05	-7.81

Tableau 1 : Base de données des fréquences latérales et puissances spectrales associées pour les défauts de barres cassées

Lors de l'entraînement, nous avons choisi un noyau gaussien pour le classificateur SVM. L'optimisation de ses paramètres est réalisée automatiquement par MATLAB, version R2022b. Une fois la phase d'apprentissage terminée, nous avons procédé à la phase de test en introduisant les fichiers restants dans le système de classification afin d'identifier le type de défaut correspondant.

Dans notre cas, la reconnaissance ne repose pas directement sur les fréquences latérales, mais sur les **puissances spectrales associées** à ces fréquences. Ainsi, chaque échantillon est représenté par une paire de puissances ((P_g, P_d)), où (P_g) correspond à la puissance de la

composante latérale gauche et (P_d) à celle de la composante latérale droite. Ces paramètres sont ensuite utilisés comme vecteurs d'entrée du SVM.

La procédure de reconnaissance utilisée est basée sur l'estimation maximale a posteriori (MAP). Cette approche permet d'associer chaque échantillon testé à la classe de défaut la plus probable, en se basant sur les données expérimentales disponibles.

D'après les figures (VI.7), (VI.8) et (VI.9), les résultats obtenus montrent une bonne séparation entre les différentes classes de défauts. Le défaut d'une barre cassée est reconnu avec une probabilité a posteriori allant approximativement de **0,55 à 0,70**. Le défaut de deux barres cassées est reconnu avec une probabilité comprise entre **0,45 et 0,60**, tandis que le défaut de trois barres cassées est reconnu avec une probabilité allant de **0,50 à 0,75**.

Ces résultats montrent que l'utilisation des puissances spectrales extraites par Root-MUSIC permet une classification efficace des défauts rotoriques. En effet, les fréquences latérales permettent de localiser les composantes caractéristiques du défaut, tandis que les puissances associées apportent une information plus discriminante sur l'état du moteur.

Dans [26], un système multi-agents intelligent est utilisé pour la prise de décision dans le diagnostic des défauts d'un moteur à induction triphasé à cage d'écureuil. Les performances obtenues sont comprises entre **80,3 % et 84,9 %** pour une barre cassée, entre **86,3 % et 87,9 %** pour deux barres cassées, et entre **84,1 % et 87,9 %** pour trois barres cassées.

Dans [27], les auteurs utilisent une méthode basée sur la combinaison de l'approche vectorielle de Park (PVA) et de l'approche vectorielle de Park étendue (EPVA) pour la détection et l'identification des défauts de barres cassées du rotor. Cette méthode permet d'obtenir une représentation graphique simple des conditions anormales. Cependant, elle ne fournit pas une estimation quantitative précise de la sévérité du défaut, notamment lorsque le moteur fonctionne à vide ou sous faible charge.

Dans [28], les coefficients d'ondelettes issus de l'analyse de la signature du courant moteur sont utilisés pour extraire les caractéristiques, tandis que le SVM est employé pour distinguer les états sains et défectueux. La précision obtenue est proche de **93,33 %**.

Par comparaison, notre système basé sur l'association **Root-MUSIC/SVM** et sur l'exploitation des **puissances spectrales** permet de reconnaître avec succès les différents types de défauts de barres cassées. Les résultats obtenus montrent que les puissances spectrales constituent des paramètres efficaces pour la discrimination entre une barre cassée, deux barres cassées et trois barres cassées. Ainsi, le taux de reconnaissance obtenu dans notre application atteint **100 %**, ce qui confirme la pertinence de l'approche proposée pour la classification automatique des défauts rotoriques.




Figure VI.7 : Reconnaissance du défaut d'une barre cassée avec différentes probabilités




Figure VI.8 : Reconnaissance du défaut de deux barres cassées avec différentes probabilités




Figure VI.9 : Reconnaissance du défaut de trois barres cassées avec différentes probabilités

IV.5 Conclusion

Le principe de diagnostic présenté dans ce chapitre repose sur deux étapes principales. La première consiste en l'extraction des signatures des défauts de la machine asynchrone à l'aide de la méthode Root-MUSIC. La seconde étape est dédiée à la détection et à la classification des défauts en utilisant un système basé sur les machines à vecteurs de support (SVM).

Les résultats obtenus mettent en évidence l'efficacité de la combinaison de l'approche SVM avec la méthode Root-MUSIC pour le diagnostic des défauts de barres dans les machines asynchrones, à condition de bien choisir le nombre de coefficients issus de Root-MUSIC ainsi que la fonction noyau du SVM, dont l'adéquation joue un rôle déterminant dans la performance de classification.

Conclusion générale

Dans ce mémoire, nous nous sommes intéressés au diagnostic des défauts rotoriques dans les moteurs asynchrones, en particulier les défauts de barres cassées. Ces défauts peuvent provoquer une dégradation des performances du moteur et entraîner des arrêts imprévus dans les systèmes industriels, d'où l'importance d'une détection précoce et fiable.

L'objectif principal de ce travail a été d'appliquer la méthode Root-MUSIC associée aux machines à vecteurs de support (SVM) afin de classifier les défauts rotoriques à partir des courants statoriques du moteur. La méthode Root-MUSIC a permis d'extraire avec précision les composantes fréquentielles caractéristiques des défauts ainsi que leurs puissances spectrales. Contrairement à plusieurs travaux basés uniquement sur l'exploitation des fréquences de défaut, notre approche s'est appuyée sur l'utilisation des puissances spectrales comme paramètres d'entrée du classificateur SVM. Les résultats obtenus sous MATLAB ont montré que cette approche permet une meilleure distinction entre les différents états de fonctionnement du moteur et améliore la précision de classification des défauts.

Enfin, ce travail représente une contribution dans le domaine du diagnostic des machines asynchrones et peut constituer une base pour des études futures portant sur une validation expérimentale ou une implémentation en temps réel dans des systèmes industriels.

Tableau des symboles

N° équation	Paramètre	Définition
II.1	$x[n]$	Signal observé au temps discret n
	A_k	Amplitude complexe de la k -ième composante sinusoïdale
	K	Nombre total des composantes fréquentielles
	f_k	Fréquence de la k -ième composante
	n	Indice d'échantillonnage
	$w[n]$	Bruit additif blanc gaussien
II.2	$I_S(n)$	Signal du courant statorique
	L	Nombre de composantes harmoniques
	f_i	Fréquence de la i -ième harmonique
	f_{sh}	Fréquence d'échantillonnage
	ϕ_i	Phase initiale de la i -ième composante
	$w(n)$	Bruit additif
II.3	R_i	Matrice d'autocorrélation du signal observé
	R_s	Matrice d'autocorrélation du signal utile
	R_w	Matrice d'autocorrélation du bruit
	S	Matrice des vecteurs directeurs
	A	Matrice diagonale des puissances
	σ_w^2	Variance du bruit blanc
	I	Matrice identité
II.4	S_i	Vecteur directeur associé à la fréquence f_i
	f_i	Fréquence de la composante considérée
	f_{sh}	Fréquence d'échantillonnage
	N	Nombre d'échantillons analysés
II.5	A	Matrice diagonale des puissances
	I_i^2	Puissance de la i -ième composante harmonique
	L	Nombre total des composantes
II.6	R_i	Matrice d'autocorrélation
	λ_k	k -ième valeur propre
	μ_k	k -ième vecteur propre
	N	Nombre total de valeurs propres
II.7	U_S	Matrice du sous-espace signal
	u_i	Vecteur propre du sous-espace signal
	L	Nombre de sources
II.8	D_S	Matrice diagonale des valeurs propres du signal
	λ_i	Valeur propre associée
	L	Nombre de composantes du signal
II.9	U_W	Matrice du sous-espace bruit
	u_i	Vecteur propre associé au bruit
	N	Nombre total de valeurs propres
	L	Nombre de composantes du signal
II.10	D_W	Matrice diagonale du sous-espace bruit
	σ_w^2	Variance du bruit
	$I_{(N-L)}$	Matrice identité d'ordre $N-L$
II.11	S_i	Vecteur directeur
	U_W	Sous-espace bruit

	$(.)^H$	Transposée conjuguée (hermitienne)
II.12	F_i	Fréquence estimée par Root-MUSIC
	f_{sh}	Fréquence d'échantillonnage
	Z_i	Racine du polynôme Root-MUSIC
	$\arg(Z_i)$	Argument du nombre complexe
II.13	R_s	Matrice du signal utile
	λ_k	Valeur propre du signal
	σ_w^2	Variance du bruit
	u_k	Vecteur propre associé
	L	Nombre de composantes
II.14	Q	Matrice inverse des puissances
	A^{-1}	Inverse de la matrice des puissances
	S	Matrice des vecteurs directeurs
	R_s^{-1}	Inverse de la matrice du signal

REFERENCES :

- [1] Bachir S., Contribution au diagnostic de la machine asynchrone par estimation paramétrique, Thèse de doctorat, Université de Poitiers, France, Décembre 2002.
- [2] NEKROUF, Djilali, Contribution à l'amélioration des techniques de traitement de signal à haute résolution destinées au diagnostic des défauts dans un entraînement. Thèse de doctorat en électronique, Université des Sciences et de la Technologie d'Oran Mohamed Boudiaf (USTO-MB), Oran, Algérie, 2025.
- [3] Ondel O., Diagnostic par reconnaissance des formes : Application a un ensemble convertisseur-machine asynchrone, Thèse de doctorat, Ecole Centrale de Lyon, 2006
- [4] J. Pierre Caron, J. Paul Hautier, « Modélisation et commande de la machine asynchrone », Editions TECHNIP, Paris, 1995.
- [5] M. Poloujadoff, “ The Theory of Three Phase Introduction Squirrel Cage Motors “, Review of Electrical Machines and Power Systems, Vol. 13, pp. 245-264, 1987
- [6] C. Combastel, « Méthodes d'Aide à la Décision pour la Détection et la Localisation de Défauts dans les Entraînements Electriques », Thèse de doctorat, Institut National Polytechnique de Grenoble, 2000.
- [7] Ali IBRAHIM, « Contribution au diagnostic de machines électromécaniques: Exploitation des signaux électriques et de la vitesse instantanée », Thèse de doctorat, Ecole doctorale Sciences, Ingénierie, Santé, Université de Saint Etienne, France, 2009.
- [8] B. Vaseghi, "Contribution à l'étude des machines électriques en présence de défaut entre spires," Thèse de Doctorat, GREEN - Groupe de Recherche en Electrotechnique et Electronique de Nancy, Nancy Université - Institut National Polytechnique de Lorraine, 2009.
- [9] H. Razik, "Le contenu spectral du courant absorbe par la machine asynchrone en cas de défaillance, un état de l'art," La revue 3EI, vol. 29, pp. 48-52, Juin 2002.
- [10] W. T. Thomson, "A review of on-line condition monitoring techniques for three-phase Squirrel cage induction motors—past, present and future," in 2nd IEEE International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives - SDEMPED '99, Gijon, Spain, 1999, pp. 3-17.
- [11] Andrian CEBAN, “ Méthode globale de diagnostic des machines électriques», Thèse de Doctorat de l'université en génie électrique, Université Lille de Nord de France – École Doctorale SPI, 2012.

- [12] R.N. Andriamalala, « Modélisation du défaut d'excentration dans une machine asynchrone – Application au diagnostic et à la commande de deux machines spécifiques », thèse de doctorat, Institut National Polytechnique de Lorraine, 2009
- [13] G. Didier, "Modélisation et diagnostic de la machine asynchrone en présence de défaillances," Thèse de doctorat, Groupe de Recherche en Electrotechnique et Electronique de Nancy, Université Henri Poincaré, Nancy-I, Nancy, France, 2004
- [14] Rosario Toscano « Commande et diagnostic des systèmes dynamiques » modélisation, analyse, commande par PID et par retour d'état, diagnostic, 2eme Edition Ellipses (2011) ISBN-10: 2729863362, ISBN-13: 978-2729863364
- [15] Gilles Zwinglstein, «Diagnostic des défaillances, théorie et pratique pour les systèmes industriels», Traité des nouvelles technologies. Série Diagnostic et maintenance, Editions Hermès Science Publications, Paris 1995. ISBN 9782866014636
- [16] F. Filippetti, G. Franceschini, M. Martelli, C. Tassoni, "An approach to knowledge representation about induction machine diagnosis in expert systems" Proc. Int. Conf. Electrical Machines, Vol. 3, pp. 289-296, Pisa, Italie, Sep. 1988.
- [18] Vojislav Kecman, "Learning and Soft Computing Support Vector Machines, Neural Networks, and Fuzzy Logic Models", The MIT Press (2001)
- [17] G. Richard, "Méthodes HR," Télécom Paris
- [19] Trevor Hastie, Robert Tibshirani & Jerome Friedman, *The Elements of Statistical Learning*, Springer, 2009.
- [20] Corinna Cortes & Vladimir Vapnik, "Support-Vector Networks", Machine Learning Journal, 1995.
- [20] Corinna Cortes & Vladimir Vapnik, "Support-Vector Networks", Machine Learning Journal, 1995.
- [21] Vojislav Kecman, "Learning and Soft Computing Support Vector Machines, Neural Networks, and Fuzzy Logic Models", The MIT Press (2001) J.P.Lewis, "Tutorial on SVM ", CGIT Lab, USC, 2004.
- [22] F. Filippetti, G. Franceschini, and C. Tassoni, "Neural networks aided on-line diagnostics of induction motor rotor faults," IEEE Trans. on Industrial Applications, Vol. 31, No. 4, pp. 892-899, July/August 1995.
- [23] Zidelmal. Mémoire doctorat , Présentée et soutenue par Zahia Zidelmal épouse Amirou,

thème Reconnaissance d'arythmies cardiaques par Support Vector Machines (SVMs). PhD thesis, 2012.

[24] Burges B. Schölkopf, "Advances in Kernel Methods--Support Vector Learning". MIT press, 1998. 78

[25] Richard O. Duda, Peter E. Hart, David G. Stork: "Pattern Classification" Wiley-interscience, 2001(ISBN 0-471-05669-3). 69

[26] M. Drakaki, Y.L. Karnavas, A.D. Karlis, I.D. Chasiotis, P. Tzionas, "Study on Fault Diagnosis of Broken Rotor Bars in Squirrel Cage Induction Motors: A Multiagent System Approach Using Intelligent Classifiers", IET Electric. Power Appl., Vol. 14, Issue 2, pp. 245-255, 2020.

[27] Ouahib GUENOUNOU, « Méthodologie de conception de contrôleurs intelligents par l'approche génétique-application à un bioprocédé », pour obtention le grade de docteur à l'université de Toulouse III-Paul Sabatier, spécialité : Systèmes Automatiques, avril 2009.

[28] M. Messaoudi, A. Flah, A.A. Alotaibi, A. Althobaiti, L. Sbita, C. Ziad El Bayeh," Diagnosis and Fault Detection of Rotor Bars in Squirrel Cage Induction Motors Using Combined Park's Vector and Extended Park'