الجمهورية الجزائرية الديمقراطية الشعبية

République Algérienne Démocratique et Populaire

وزارة التعليم العالي والبحث العلمي

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

المدرسة الوطنية العليا للتكنولوجيات المتقدمة

Ecole Nationale Supérieure des Technologies Avancées

Département Electrotechnique

Mémoire de fin d'étude en vue de l'obtention du diplôme

D'INGENIEUR d'État

-Filière-

Electrotechnique

-Spécialité -

Traction Electrique

- Thème -

Techniques Avancées de Diagnostic des Défauts de la Machines Asynchrones à Cage d'Ecureuil

Réalisé par

BENELHADJ DJELLOUL M'hamed Redouane

BOUMEHED Badis

Les membres de Jury :

HAMACHE Amar	MCA ENSTA	Président
CHIHANI Tarek	MCB ENSTA	Examinateur
OUADAH M'hamed	MCA ENSTA	Encadrant
ZERROUKI Meriem	Ing –Ministère de l'énergie	Co-Encadrante

Alger, le 22/06/2024

Année universitaire 2023–2024

REMERCIEMENT

Avant tout développement, il apparaît opportun de commencer ce mémoire par des remerciements.

Nous tenons à exprimer notre profonde gratitude envers Dieu Tout-Puissant, le Clément et le Miséricordieux. Sa guidance et Sa bénédiction ont été essentielles pour mener à bien ce projet. Que Sa paix et Sa bénédiction soient sur le Prophète Muhammad.

Nous tenons à exprimer notre profonde gratitude envers notre directeur de mémoire, Monsieur OUADAH M'hamed. Son engagement sans faille, sa patience infinie et ses conseils avisés ont été des éléments clés dans la réalisation de ce travail. Nous sommes reconnaissants pour le temps qu'il nous a consacré, sa disponibilité constante et son soutien inestimable qui ont grandement contribué à l'aboutissement de notre projet.

Nous souhaitons également exprimer notre sincère reconnaissance à notre co-encadrante, Madame ZERROUKI Meriem, pour son soutien indéfectible, ses précieux conseils et son encadrement éclairé tout au long de cette étude. Son expertise et son dévouement ont été d'une aide précieuse pour nous.

Nous souhaitons également adresser nos remerciements les plus chaleureux aux membres du jury, dont le président HAMACHE Amar et l'examinateur CHIHANI Tarek qui auront la responsabilité d'examiner notre travail. Leurs remarques constructives, leur expertise académique et leur rigueur seront des atouts précieux pour évaluer notre mémoire de manière approfondie. Nous sommes conscients de l'importance de leurs contributions dans le processus d'évaluation et nous les remercions sincèrement pour leur engagement envers notre projet.

En outre, nous tenons à exprimer notre reconnaissance envers toutes les personnes qui ont joué un rôle dans la réalisation de ce travail. Que ce soit par leur contribution intellectuelle, leurs conseils éclairés ou leur soutien moral, chaque apport a été d'une valeur inestimable et a contribué à enrichir notre réflexion.

Nos remerciements vont également à nos proches, amis et collègues pour leur soutien indéfectible tout au long de cette aventure académique. Leur encouragement, leur compréhension et leur motivation ont été des sources d'inspiration qui nous ont permis de surmonter les obstacles rencontrés sur notre chemin.

Enfin, nous tenons à exprimer notre profonde gratitude envers toutes les personnes qui ont croisé notre route et ont contribué, de près ou de loin, à la réalisation de ce mémoire. Leur soutien et leur collaboration ont été des éléments déterminants dans notre parcours académique.

À toutes ces personnes, nous présentons nos plus sincères remerciements, empreints de respect et de reconnaissance. Ce mémoire est le fruit d'un travail collectif et nous sommes reconnaissants envers chacun pour sa contribution à sa réalisation.

DEDICACE 01

Louange à Dieu, le Tout-Puissant, pour m'avoir accordé la force, la patience et la persévérance nécessaires à l'accomplissement de ce mémoire et de tout mon parcours académique. Sans Sa guidance et Ses bénédictions, ce travail n'aurait pas été possible.

Je dédie ce mémoire à tous ceux qui ont contribué à sa réalisation et à mon parcours académique.

À mon très cher père, pour son soutien indéfectible, ses conseils avisés, et pour m'avoir inculqué la valeur de la persévérance et du dépassement de soi, sa présence a été une source de force et de motivation.

À ma très chère mère, pour son amour inconditionnel, ses encouragements constants, et pour m'avoir toujours poussé à donner le meilleur de moi-même. Sans quoi, rien de tout cela n'aurait été possible.

À ma sœur et mon frère, pour leur affection, leur soutien moral et leur complicité. Leur présence a été une source de motivation constante.

À mon binôme et ami BENELHADJ DJELLOUL M'HAMED REDOUANE, pour sa collaboration, son engagement, son soutien et sa confiance tout au long de ce projet. Travailler ensemble a été une expérience enrichissante et précieuse.

À notre co-encadrante, Madame ZERROUKI Meriem pour son soutien constant, sa disponibilité et ses encouragements. Son expertise et ses conseils avisés ont été inestimables tout au long de ce travail.

À mes amis, pour leur camaraderie, leurs mots d'encouragement, et leur compréhension durant les moments difficiles. Merci pour les moments de détente qui m'ont permis de garder le cap.

Enfin, je tiens à remercier tous ceux qui, de près ou de loin, ont contribué à ce travail et à mon épanouissement personnel et académique.

DEDICACE 02

Je dédie ce projet de fin d'étude à tous ceux qui ont contribué, de près ou de loin, à sa réalisation et à mon parcours académique.

À mes chers parents, Monsieur Mokhtar Abdelghani et Ma psychologue BERRABAH Fafa Mansouria, pour leur amour inconditionnel, leur soutien constant et leurs encouragements précieux. Merci de m'avoir toujours poussé à donner le meilleur de moi-même.

À mon frère Tarek et à mes sœurs Meriem et Yasmin, pour leur affection et leur compréhension tout au long de ce voyage.

À mon cher binôme BOUMEHED Badis, pour sa collaboration sans faille et son amitié indéfectible, qui ont été essentiels à la réussite de ce projet.

À ma co-encadrante ZERROUKI Meriem, pour ses conseils avisés, sa patience et son expertise, qui m'ont guidé tout au long de ce travail.

À mon cher ami, l'ingénieur MONTASSIR LABIOD, pour son soutien moral, et pour avoir toujours été là quand j'avais besoin de lui.

À mes amis de la chambre, MEKHOUKH Moussa et ASSAL HAMZA, pour leur camaraderie, leurs moments de détente et leurs encouragements, qui ont rendu cette période plus agréable.

Merci à vous tous pour votre soutien indéfectible et votre présence bienveillante. Ce projet est le reflet de notre collaboration et de notre détermination commune.

RESUME

Notre projet a pour but de classifier les défauts dans les machines asynchrones à cage d’écureuil en utilisant des techniques avancées d'apprentissage automatique. Notre contribution réside dans l'amélioration de la détection des défauts par l'étude des harmoniques d'espace, en intégrant méticuleusement les plages de fréquences en fonction de leurs composantes. En combinant la FFT avec des techniques avancées d'apprentissage automatique, nous avons développé une méthode robuste pour le diagnostic en temps réel, capable de minimiser les temps d'arrêt coûteux en détectant rapidement et de manière fiable les défauts potentiels. Ce projet met en évidence l'importance de la surveillance continue des machines pour garantir leur fiabilité opérationnelle et optimiser les performances industrielles. En intégrant l'analyse des harmoniques d'espace avec des techniques d'apprentissage automatique, nous offrons des outils précieux pour une maintenance prédictive plus efficace, contribuant ainsi à une production industrielle plus sûre, plus fiable et plus durable.

Mots clefs

Méthodes avancées, Machines asynchrones à cage d’écureuil, Apprentissage automatique, Analyse fréquentielle, Harmoniques d'espace, Diagnostic en temps réel, Maintenance prédictive, défaut, classification, réseaux de neurones.

الملخص

هدف عملنا هو تصنيف الأعطال في الآلات غير المتزامنة ذات القفص السنجابي باستخدام تقنيات تعلم الآلة المتقدمة. تكمن مساهمتنا في تحسين اكتشاف الأعطال من خلال دراسة التوافقيات المكانية، ودمج نطاقات التردد بدقة بناءً على مكوناتها. من خلال دمج تحويل فوربيه السريع (FFT) مع تقنيات تعلم الآلة المتقدمة، طورنا طريقة قوية للتشخيص في الوقت الفعلي، قادرة على تقليل فترات التوقف المكلفة من خلال اكتشاف الأعطال المحتملة بسرعة وموثوقية. يبرز هذا المشروع أهمية المراقبة المستمرة للآلات لضمان موثوقيتها التشغيلية وتحسين الأداء الصناعي. من خلال دمج تحليل التوافقيات المكانية مع تقنيات تعلم الآلة، نقدم أدوات قيمة للصيانة التنبؤية الأكثر فعالية، مما يسهم في إنتاج صناعي أكثر أمانًا وموثوقية واستدامة.

الكلمات المفتاحية

الطرق المتقدمة، محركات التيار المتناوب بمنظومة القفص السنجابي، التعلم الآلي، التحليل الترددي، الترددات الفضائية، التشخيص في الوقت الحقيقي، الصيانة التنبؤي، عطب، تصنيف، شبكات عصبية.

Abstract

The objective of our work is to classify faults in squirrel-cage induction machines using advanced machine learning techniques. Our contribution lies in improving fault detection by studying spatial harmonics, meticulously integrating frequency ranges based on their components. By combining FFT with advanced machine learning techniques, we have developed a robust method for real-time diagnostics, capable of minimizing costly downtimes by quickly and reliably detecting potential faults. This project highlights the importance of continuous machine monitoring to ensure operational reliability and optimize industrial performance. By integrating spatial harmonics analysis with machine learning techniques, we offer valuable tools for more effective predictive maintenance, thereby contributing to safer, more reliable, and more sustainable industrial production.

Keywords:

Advanced methods, Squirrel-cage asynchronous motors, Machine learning, Frequency analysis, Space harmonics, Real-time diagnosis, Predictive maintenance, Fault, Classification, Neural networks.

TABLE DES MATIERES

REMERCIEMENT ..... **i**

DEDICACE 01 ..... **iii**

DEDICACE 02 ..... **iv**

RESUME ..... **v**

TABLE DES MATIERES ..... **vii**

LISTE DES TABLEAUX ..... **xi**

TABLE DES FIGURES ..... **xii**

ABRÉVIATIONS ..... **xv**

INTRODUCTION GENERALE **1**

CHAPITRE I Construction et Représentation des Défauts de la Machine Asynchrone à Cage d'Écureuil **4**

I.1 Introduction 5

I.2 Constitution de la machine asynchrone à cage d'écureuil 5

I.2.1 Stator 6

I.2.2 Rotor 7

I.2.3 Les paliers 8

I.3 Principe de fonctionnement de la machine asynchrone à cage d'écureuil 8

I.4 Classification des défauts au niveau de la machine asynchrone à cage 9

I.4.1 Les défaillances de la machine asynchrone à cage d'écureuil 9

I.4.1.1 Défaillances d'ordre électriques 9

I.4.1.1.1 Défaillances des circuits électriques statorique 9

I.4.1.1.1 Les courts circuits internes 10

I.4.1.1.2 Les isolations électriques 10

I.4.1.1.3 Décharges partielles 11

I.4.1.2 Défaillances des circuits électriques rotoriques 11
I.4.1.2.1 Les cassures des barres 11
I.4.1.2.1 Cassure d'une portion d'anneau de court-circuit 12
I.4.2.1 Défauts des roulements à billes..... 13
I.4.2.2 Excentricité 13
I.4.2.3 Défaillance de l'arbre 15
I.4.2.4 Défaillance du flasque..... 15
I.4.3 Cause des défaillances 16
I.4.3.1 Cause des défauts statoriques..... 16
I.4.3.2 Cause des défauts rotoriques..... 16
I.4.3.2.1 Cause des défauts de roulement à billes 17
I.4.4 Effets des défauts 17
I.4.4.1 Effets de défauts statoriques (court-circuit)..... 17
I.4.4.2 Effets de défauts rotoriques..... 18
I.5 Synthèse des défaillances..... 20
I.6 Conclusion 23
CHAPITRE II Méthodes classiques de détection des défauts de la machine asynchrone à cage d'écureuil..... **24**
II.1 Introduction..... 25
II.2 Méthodes basées sur le traitement de signal..... 25
II.3 Analyse temps-fréquence et temps-échelle 26
II.3.1 Analyse temps-fréquence 26
II.3.2 Analyse temps-échelle..... 27
II.3 Analyse spectrale..... 28
II.3.1 Analyse des signaux vibratoires 30
II.3.2 Analyse de la température 31

II.4 Analyse des flux magnétiques 31
II.5 Diagnostic des défauts par analyse du vecteur de Park 32
II.6 Diagnostic de défauts par le suivi des grandeurs mesurables 34
II.6.1 Analyse fréquentielle des courants statoriques 35
II.6.2 Analyse fréquentielle du couple électromagnétique et de la vitesse de rotation 35
II.6.3 Analyse spectrale de la puissance instantanée 36
II.7 Conclusion 37
CHAPITRE III Méthodes avancées de détection et classification des défauts des machines électriques 38
III.1 Introduction 39
III.2 Traitement de signal avancé 39
III.2.1 Démodulation des courants statoriques 40
III.2.2 Analyse des signaux non stationnaires des machines asynchrones 40
III.3 Apprentissage automatique 41
III.3.1 Terminologie 41
III.3.2 Étapes vers la machine Learning 42
III.3.3 Réseaux de neurones 45
III.3.3.1 Description de réseau de neurones 45
III.3.3.2 Réseau de neurones feedforward 46
III.3.3.3 Détecteur neuronal 47
III.3.3.4 Extraction des données 49
III.3.4 Machine à vecteurs de support (SVM) 50
III.3.4.1 Fonctionnement des SVM 50
III.3.4.2 Application des SVM dans la détection de défauts 54
III.3.5 Les arbres de décision 55
III.3.5.1 Structure des arbres de décision 56

III.3.5.2 Types d'arbres de décision 57
III.3.5.3 Utilisation des Arbres de Décision pour la Détection des Défauts 59
III.3.6.1 Fonctionnement 60
III.5 Conclusion 63
CHAPITRE IV Classification et Diagnostic de défauts de la machine asynchrone 64
IV.1 Introduction 65
IV.2 Présentation de travail adopté pour la classification 65
IV.1.1 Exploitation des données 66
IV.3 Résultats expérimentaux 70
IV.2.1 Analyse des variations du courant statorique et des spectres fréquentiels pour la détection des défauts dans les machines asynchrones 71
IV.2.2 Analyse de densité spectrale de puissance et la classification des défauts pour les différentes plages 73
IV.2.2.1 Analyse des spectres et la classification des défauts dans la plage [30 - 70] Hz 75
IV.2.2.2 Analyse des spectres et la classification des défauts dans la plage [209 - 349] Hz 78
IV.2.2.3 Analyse des spectres et la classification des défauts dans la plage [509 - 648] Hz 83
IV.2.2 Classification des défauts autour des harmoniques d'espaces 88
IV.4 Conclusion 92
CONCLUSION GENERALE 93
BIBLIOGRAPHIE 95

LISTE DES TABLEAUX

Tableau I 1. Effet de défaut statorique sur les paramètres de la machine 18
Tableau I 2. Effet de défaut rotoriques sur les paramètres de la machine 19
Tableau I 3. Synthèse des défaillances du rotor sur la machine asynchrone 21
Tableau I 4. Synthèse des défaillances du stator sur la machine asynchrone 22
Tableau IV 1. Les plages de points correspondant aux harmoniques d'espaces ainsi que leurs fréquences respectives 74
Tableau IV 2. Résultats classification des défauts dans la plage [30-70] Hz par différents Model/Algorithme 77
Tableau IV 3. Résultats classification des défauts dans la plage [209-249] Hz par différents Model/Algorithme 80
Tableau IV 4. Résultats classification des défauts dans la plage [309-349] Hz par différents Model/Algorithme 83
Tableau IV 5. Résultats classification des défauts dans la plage [509-549] Hz par différents Model/Algorithme 85
Tableau IV 6. Résultats classification des défauts dans la plage [608-648] Hz par différents Model/Algorithme 87
Tableau IV 7. Fréquences correspondent pour chaque harmonique 89
Tableau IV 8. Résultats classification des défauts autour des harmoniques d'espaces par différents Model/Algorithme 91

TABLE DES FIGURES

Figure I 1. Eléments de constitution d'une machine asynchrone 6
Figure I 2. Eléments de constitution du stator 7
Figure I 3. Eléments de constitution du rotor..... 8
Figure I 4. Défaut d'une barre cassée 12
Figure I 5. Différents types de la dissymétrie de l'entrefer..... 14
Figure I 6. Les différentes fréquences induites à cause des défauts..... 20
Figure II 1. Représentation temps-fréquence du courant statorique lors d'une variation du couple de charge avec une barre cassé..... 27
Figure II 2. Principe de la surveillance par analyse spectrale..... 30
Figure II 3. Bobine exploratrice pour la mesure du flux de fuite axial..... 32
Figure II 4. Vecteur de Park des courants statoriques..... 34
Figure II 5. Spectre du courant statorique..... 35
Figure II 6. Spectre de la puissance instantanée 37
Figure II 7. Spectre de la puissance instantanée à basse fréquence 37
Figure III 1. Estimation du signal analytique 40
Figure III 2. Méthodologies courantes d'apprentissage automatique 41
Figure III 3. Bases de l'apprentissage supervisé..... 42
Figure III 4. Exemple de classification..... 42
Figure III 5. Exemple de classification – sortie par rapport à l'entrée..... 43
Figure III 6. Guide simplifié pour le mappage des fonctionnalités 44
Figure III 7. Illustration d'un réseau de neurones feedforward 46
Figure III 8. La structure de base d'un neurone..... 47
Figure III 9. Illustration de la méthodologie adoptée 48
Figure III 10. Algorithme simplifié pour la détection, la classification et la localisation des défauts 49
Figure III 11. Principe de fonctionnement des SVM..... 51
Figure III 12. Les deux cas de linéarité 51
Figure III 13. Séparation linéaire..... 52
Figure III 14. Séparation linéaire avec des erreurs..... 53

Figure III 15. Illustration d'un arbre de décision 56
Figure III 16. Organigramme de l'algorithme KNN 61
Figure IV 1. Schéma des étapes de classification 69
Figure IV 2. Schéma de banc d'essais pour le diagnostic de défaut de la machine asynchrone a cage d'écureuil 70
Figure IV 3. Banc d'essais pour le diagnostic de défaut de la machine asynchrone a cage d'écureuil 70
Figure IV 4. Courant statorique (Régime transitoire) 71
Figure IV 5. Courant statorique (Régime permanent) 72
Figure IV 6. Densité spectrale de puissance du courant statorique 73
Figure IV 7. Spectre de courant statorique dans la plage [30-70] Hz 75
Figure IV 8. Résultat de classification des défauts dans la plage [30 - 70] Hz par cross validation 76
Figure IV 9. Résultat de classification des défauts dans la plage [30 - 70] Hz par Hold Out validation 76
Figure IV 10. Spectre de courant statorique dans la plage [209-249] Hz 78
Figure IV 11. Résultat de classification des défauts dans la plage [209 -249] Hz par Cross validation 79
Figure IV 12. Résultat de classification des défauts dans la plage [209-249] Hz par Hold Out validation 79
Figure IV 13. Spectre de courant statorique dans la plage [309-349] Hz 81
Figure IV 14. Résultat de classification des défauts dans la plage [309-349] Hz par Cross validation 82
Figure IV 15. Résultat de classification des défauts dans la plage [309 -349] Hz par Hold Out validation 82
Figure IV 16. Spectre de courant statorique dans la plage [509-549] Hz 83
Figure IV 17. Résultat de classification des défauts dans la plage [509-549] Hz par Cross validation 84
Figure IV 18. Résultat de classification des défauts dans la plage [509-549] Hz par Hold Out validation 84
Figure IV 19. Spectre de courant statorique dans la plage [608-648] Hz 85

Figure IV 20. Résultat de classification des défauts dans la plage [608-648] Hz par Cross validation.....86
Figure IV 21. Résultat de classification des défauts dans la plage [609-649] Hz par Hold Out validation.....86
Figure IV 22. Densité spectrale de puissance du courant statorique, en représentant les harmoniques d'espaces.....88
Figure IV 23. Résultat de classification des défauts autour des harmoniques d'espaces par Cross validation.....90
Figure IV 24. Résultat de classification des défauts autour des harmoniques d'espaces par Hold Out validation.....90

ABRÉVIATIONS

ESPRIT : Estimation of Signal Parameters via Rotational Invariance Techniques

MUSIC : Multiple Signal Classification

MCSA : Motor Current Signature Analysis

EMTP : Electromagnetic Transients Program

ETAP : Electrical Transient and Analysis Program

N.N : Neural Network

C-C : Court-circuit

QD : Quadratic Discriminant

MAS : Machine Asynchrone

SVM : Machine à Vecteurs de Support

KNN : K-Nearest Neighbours

QDA : Quadratic Discriminant Analysis

PFE : Projet Fin d'Etude

LDA : Linear Discriminant Analysis

FFT : Fast Fourier Transform

DSP : Densité Spectrale de Puissance

ENP : Ecole Nationale Polytechnique

TIR : Total Indicator Reading

RNA : Réseau Neuronal Artificiel

RMS : Root Mean Square

STFT : Short-Time Fourier Transform

THH : Transformée de Hilbert-Huang

CART : Classification and Regression Trees

SDN : Software Defined Network

DDoS : Distributed Denial of Service

INTRODUCTION GENERALE

Les machines asynchrones jouent un rôle important dans diverses applications industrielles **[1][2]**. En raison de leur utilisation répandue, les défauts dans les moteurs à induction peuvent entraîner des temps d'arrêt coûteux et une inefficacité opérationnelle. **[3]** Notre travail vise à développer une méthode de détection précoce des défauts en utilisant des techniques d'apprentissage automatique pour une détection précise et automatisée des anomalies, soulignant ainsi l'importance de la surveillance continue et de la maintenance prédictive pour garantir la fiabilité des moteurs à induction dans les environnements industriels et domestiques **[4][5]**

Le premier chapitre explore en détail la machine asynchrone, en mettant l'accent sur sa conception **[6-9]**, son fonctionnement et les défauts potentiels. Il décrit les composants clés ainsi que les principes fondamentaux de fonctionnement, notamment la création de champs magnétiques tournants et la génération de courants induits **[10][11]**. En examinant les défauts possibles, tels que les ruptures de barres rotoriques et les anomalies du stator **[12]**, le chapitre souligne les conséquences potentiellement graves de ces problèmes sur la performance de la machine. **[13]**

Le deuxième chapitre présente différentes techniques classiques de diagnostic pour détecter les défauts dans les machines électriques **[14]**, L'accent est mis sur l'analyse temporelle et fréquentielle des signaux électriques et vibratoires. **[9]** Ces techniques comprennent l'analyse par ondelette, la démodulation, l'analyse spectrale, l'analyse vibratoire, l'analyse thermique et l'analyse du flux magnétique **[15-22]**. L'utilisation de ces méthodes permet de détecter des anomalies telles que les défauts de roulements, les ruptures de barres et les problèmes de lubrification **[23][24]**. L'analyse fréquentielle du courant statorique, notamment avec l'Analyse de la Signature du Courant Moteur, est particulièrement efficace pour identifier les défauts dans les machines asynchrones **[25]**. En outre, l'analyse du couple électromagnétique et de la puissance instantanée offre des informations précieuses sur l'état de la machine et permet de détecter des oscillations caractéristiques associées à des défauts mécaniques **[24-27]**.

Le Chapitre III se concentre sur les techniques avancées de détection et de classification des défauts dans les machines électriques, essentielles pour la maintenance prédictive et la fiabilité des systèmes électriques industriels **[28]**. Il explore diverses approches modernes telles que les réseaux de neurones **[29-32]**, le traitement de signal avancé et l'apprentissage automatique

[34][35], En se focalisant sur des méthodes spécifiques comme les Machines à Vecteurs de Support (SVM) **[35]**, les Arbres de Décision et l'algorithme des k plus proches voisins (KNN) **[36]**. L'objectif est de fournir une compréhension approfondie de ces techniques et de leur mise en œuvre pratique pour la détection et la classification des défauts dans les machines électriques **[37]**.

Le dernier chapitre explore les stratégies de diagnostic des défauts dans les machines asynchrones, mettant en lumière l'importance croissante du domaine fréquentiel **[3]**. Une approche méthodique est proposée, se concentrant sur l'analyse des données de courant et de tension pour détecter et classifier les anomalies **[9]**, en mettant particulièrement l'accent sur les harmoniques d'espaces de fondamental jusqu'à $13^{ème}$ harmoniques **[1]**. Nous avons utilisé des techniques d'apprentissage automatique pour analyser les données de machines saines et avec des barres cassées ou un court-circuit dans l'anneau. Plusieurs algorithmes de classification ont été évalués, tels que SVM, KNN, arbres de décision **[5]**, réseaux de neurones et analyse discriminante quadratique, avec une attention particulière portée à la validation croisée et à la validation hold-out **[38]** pour évaluer la performance des algorithmes. Les résultats montrent une précision variable selon les harmoniques d'espace, avec une amélioration notable grâce à l'utilisation des réseaux de neurones et à l'analyse des spectres de densité spectrale de puissance. Enfin, une classification réussie des défauts de la machine, avec un taux de précision élevé, a été obtenue en utilisant des algorithmes tels que le discriminant quadratique, démontrant ainsi l'efficacité de l'approche proposée pour la détection précoce des défauts dans les machines asynchrones.

Notre objectif principal est d'améliorer la détection des défauts à l'aide de techniques avancées en étudiant les harmoniques. Nous avons examiné le comportement de la machine par rapport à des harmoniques d'espaces spécifiques, notamment fondamental et les harmoniques, $5^{ème}$, $7^{ème}$, $11^{ème}$ et $13^{ème}$ **[39]**. Notre analyse s'est concentrée exclusivement sur ces harmoniques d'espaces, en excluant les harmoniques temporelles. Nous avons testé différentes configurations, y compris l'utilisation de la fondamentale seule **[40]** et de la fondamentale combinée avec d'autres harmoniques d'espaces jusqu'à la $13^{ème}$ harmonique **[39]**. Les conclusions ont été tirées en fonction des pourcentages de précision obtenus à partir de divers algorithmes de classification.

Nous cherchons à explorer des approches innovantes pour collecter des données de fonctionnement des moteurs **[5]**, en nous concentrant particulièrement sur l'analyse fréquentielle **[4]**, afin de développer des méthodes de surveillance continue de l'état des moteurs à induction

[41-46]. Notre étude vise à faire progresser les travaux existants dans ce domaine, en particulier ceux concernant le diagnostic des défauts grâce à des techniques avancées **[4][5]** et l'identification et la détection des défauts en utilisant les harmoniques d’espaces **[47]**.

CHAPITRE I

Construction et Représentation des Défauts de la Machine Asynchrone à Cage d'Écureuil

I.1 Introduction

Le premier chapitre de notre PFE détaille la composition de la machine asynchrone à cage d'écureuil, également connue sous le nom de machine à induction **[6]**. En mettant en avant ses éléments clés tels que le stator, le rotor et les organes mécaniques **[7][8]**, tout en présentant le principe fondamental de son fonctionnement **[48][49]**. La machine est saluée pour sa simplicité structurelle, sa robustesse et sa large plage de puissance, allant de quelques watts à plusieurs mégawatts **[6]**.

Le stator, équipé d'un enroulement bobiné **[7]**, et le rotor, constitué d'un circuit magnétique avec une cage d'écureuil **[8]**, seront scrutés en détail, soulignant l'importance de leur conception pour un fonctionnement optimal **[48]**. Les paliers, qui soutiennent et permettent la rotation de l'arbre rotorique, complètent la structure de la machine **[9]**.

La section sur le principe de fonctionnement explique comment les courants statoriques génèrent un champ magnétique tournant, produisant ainsi un couple électromagnétique responsable du mouvement du rotor **[48]**. L'analyse du fonctionnement implique la résolution d'équations d'électromagnétisme, avec différentes approches de modélisation en fonction des objectifs **[49]**.

Enfin, le chapitre se clôture par une classification des défauts au niveau de la machine **[11]**, introduisant des types tels que les barres de rotor cassées, les défauts de palier et les défauts de stator **[10-13][52-55]**. Ces défauts peuvent être détectés et classifiés par diverses méthodes telles que l'analyse de vibration, l'analyse de signature de courant **[11][53]**, et des techniques d'intelligence artificielle comme les réseaux neuronaux. En résumé, ce premier chapitre établit les bases nécessaires pour la compréhension de la structure et du fonctionnement de la machine, préparant ainsi le terrain pour l'exploration approfondie des défauts dans les chapitres suivants.

I.2 Constitution de la machine asynchrone à cage d'écureuil

La machine asynchrone, également appelée machine à induction, occupe actuellement une position dominante dans l'industrie en raison de sa capacité à éliminer les contacts électriques glissants, ce qui confère à sa structure une simplicité et une robustesse remarquables, facilitant ainsi sa construction. Sa plage de puissance s'étend de quelques watts à plusieurs mégawatts. Elle est directement connectée au réseau industriel, fonctionnant à une vitesse variable légèrement

décalée par rapport à la vitesse synchrone. Ce type de moteur est largement privilégié pour la réalisation d'entraînements à vitesse constante. De plus, le moteur asynchrone offre la possibilité d'implémenter des entraînements à vitesse variable, et son importance dans ce domaine ne cesse de croître. **[6]**

La machine asynchrone est constituée des éléments fondamentaux suivants :

- Le stator, qui est la partie fixe, se compose de disques en tôles magnétiques portant les enroulements chargés de magnétiser l'entrefer.
- Le rotor, la partie tournante, est formé de disques en tôles magnétiques empilés sur l'arbre de la machine, portant un enroulement injecté.
- Les organes mécaniques jouent un rôle crucial en facilitant la rotation du rotor et en assurant le maintien des différents sous-ensembles. **[7]**

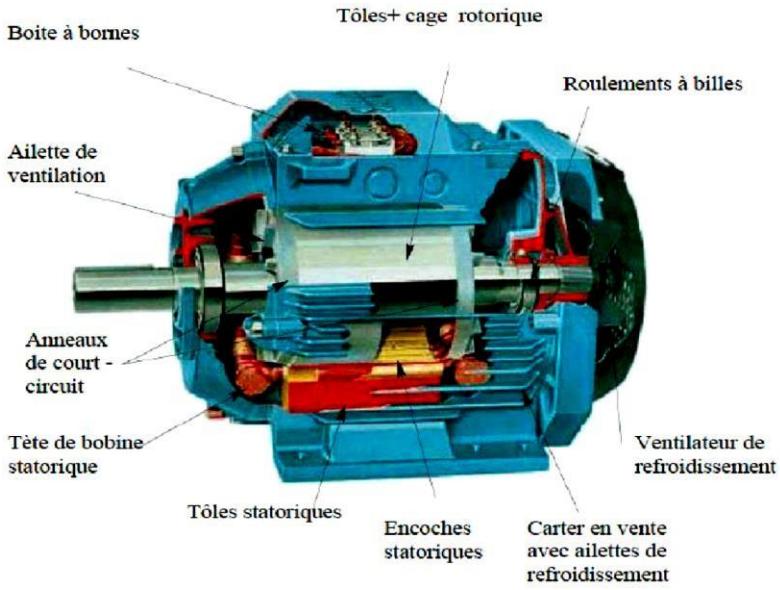


Figure I 1. Eléments de constitution d'une machine asynchrone **[61]**

I.2.1 Stator

Le stator de la machine asynchrone est formé d'un enroulement bobiné réparti dans les encoches du circuit magnétique. Ce dernier est constitué d'un empilement de fines tôles d'acier découpées, mettant en évidence les différentes encoches statoriques. Ces tôles sont généralement revêtues de vernis pour réduire l'effet des courants de Foucault. Le bobinage statorique peut être divisé en deux parties distinctes : les conducteurs d'encoches et les têtes de bobines. Les

conducteurs d'encoches sont responsables de la création d'un champ magnétique dans l'entrefer, induisant ainsi la conversion électromagnétique. Les têtes des bobines, quant à elles, assurent la fermeture des courants en organisant la circulation judicieuse des courants d'un conducteur d'encoche à l'autre. L'objectif est d'obtenir une distribution de courant aussi sinusoïdale que possible à la surface de l'entrefer, afin de minimiser les ondulations du couple électromagnétique.**[8]**

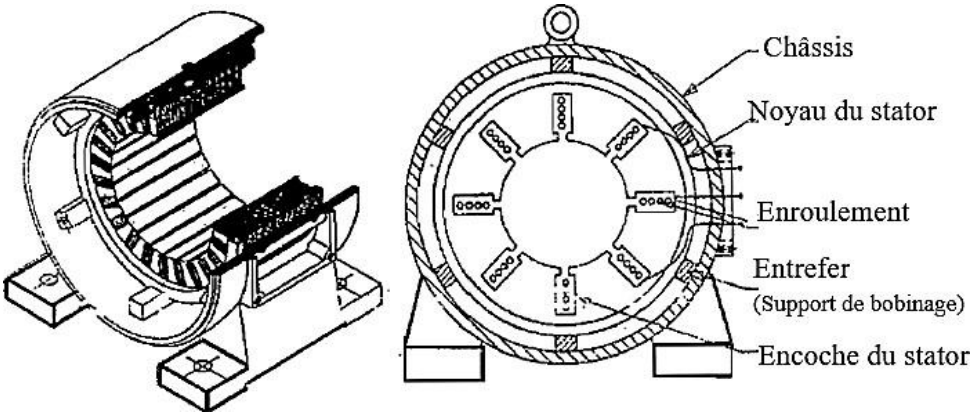


Figure I 2. Eléments de constitution du stator **[62]**

I.2.2 Rotor

Le rotor se divise également en un circuit magnétique composé de tôles d'acier, généralement de la même origine que celles utilisées dans la construction du stator.

Dans le cas du rotor à cage, il est constitué de barres en cuivre pour les moteurs de grande taille ou en aluminium pour les plus petits. Ces barres sont connectées les unes aux autres à chaque extrémité du rotor par un anneau de court-circuit. Souvent, les barres sont inclinées de manière uniforme pour réduire les harmoniques et atténuer significativement le bruit lors de l'accélération de la machine. En général, il y a peu ou pas d'isolation entre les barres rotoriques et les tôles magnétiques. Cependant, leur résistance est suffisamment faible pour que les courants de fuite ne circulent pas à travers les tôles magnétiques, à moins que la cage rotorique ne présente une rupture de barre.

Le rotor de la machine asynchrone est également équipé d'ailettes de ventilation, facilitant un refroidissement optimal de la cage. Le rotor à cage d'écureuil peut être considéré comme un enroulement polyphasé fermé. **[8]**

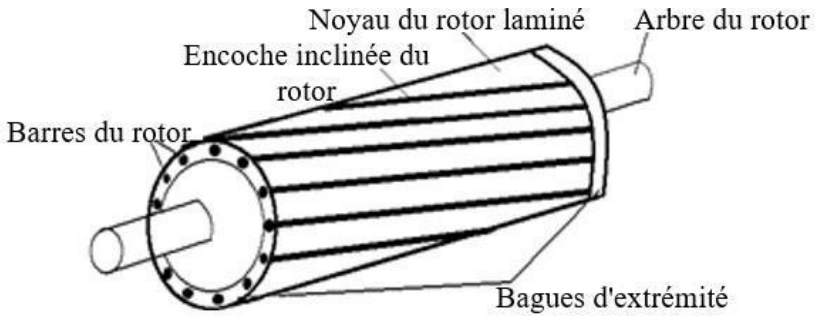


Figure I 3. Eléments de constitution du rotor **[63]**

I.2.3 Les paliers

Les paliers, responsables du support et de la rotation de l'arbre rotorique, se composent de flasques et de roulements à billes insérés à chaud sur l'arbre. Les flasques, fabriqués en fonte, sont solidement fixés sur le carter statorique à l'aide de boulons et de tiges de serrage. Une fois assemblé, cet ensemble forme la machine asynchrone à cage d'écureuil. **[9]**

I.3 Principe de fonctionnement de la machine asynchrone à cage d'écureuil

Les courants statoriques créent un champ magnétique tournant dans le stator, avec une vitesse dictée par la fréquence des courants, égale à celle de l'alimentation électrique. Cette vitesse est appelée vitesse de synchronisme. Le flux changeant dans l'enroulement du rotor génère une force électromotrice induite, produisant des courants rotoriques. Ces courants créent un couple qui met le rotor en mouvement, tentant de suivre le champ statorique, conformément à la loi de Lenz. Ainsi, le rotor commence à tourner pour suivre le champ statorique. **[48]**

Loi de Lenz-faraday :

$$e = -\frac{d\Phi}{dt} \qquad (I.1)$$

L'analyse du fonctionnement de la machine se concentre sur les équations reliant les grandeurs externes, comme les tensions aux bornes de la machine, les courants et le couple disponible. Les différentes méthodes d'étude reposent sur la résolution des équations électromagnétiques, avec des

simplifications basées sur le domaine de fréquence et la structure physique du système. Ces choix sont guidés par les objectifs de la modélisation, comme expliqué au chapitre II. **[49]**

I.4 Classification des défauts au niveau de la machine asynchrone à cage

La classification des défauts dans les machines asynchrones à cage d'écureuil inclut divers types de défauts tels que les barres de rotor cassées, les défauts de palier et les défauts de stator. Ces défauts peuvent être détectés et classifiés à l'aide de méthodes telles que l'analyse des vibrations, l'analyse de la signature du courant et des techniques d'intelligence artificielle comme les réseaux neuronaux. Des recherches ont été menées sur l'utilisation de modèles à bobinages multiples, les différences de courant statorique et les approches d'optimisation pour la détection et la classification des défauts dans les moteurs asynchrones à cage d'écureuil. **[11]**

I.4.1 Les défaillances de la machine asynchrone à cage d'écureuil

Les anomalies au sein de la machine asynchrone à cage d'écureuil englobent divers types de défaillances, dont les barres de rotor endommagées, les anomalies de palier et les défauts de stator. Ces irrégularités peuvent être identifiées à l'aide de méthodes telles que l'analyse vibratoire, l'analyse de la signature du courant, et le recours à des réseaux neuronaux. Les éléments de support et de rotation de l'arbre, à savoir les paliers, jouent un rôle crucial dans le fonctionnement optimal de la machine asynchrone à cage d'écureuil. **[12][52]**

I.4.1.1 Défaillances d'ordre électriques

Les dysfonctionnements d'origine électrique peuvent, dans certains cas, entraîner l'arrêt de la machine, au même titre que les défaillances d'ordre mécanique. Ces défaillances se subdivisent en deux catégories claires, à savoir les anomalies survenant au niveau des circuits électriques du stator et celles se manifestant au niveau des circuits électriques du rotor. **[12]**

I.4.1.1.1 Défaillances des circuits électriques statorique

L'apparition d'un défaut au niveau des circuits électriques statoriques de la machine asynchrone peut avoir diverses origines. Parmi celles-ci, on peut mentionner les défauts de type court-circuit inter-spires qui se manifestent à l'intérieur des encoches statoriques. Ce type de défaut peut résulter de la dégradation des isolants des spires du bobinage statorique. De plus, des courts-circuits peuvent survenir entre une phase et le neutre, entre une phase et la carcasse métallique de la machine, ou encore entre deux phases statoriques. Ces défauts sont souvent d'origine mécanique,

car des vibrations excessives peuvent entraîner le desserrement des boulons de la plaque à bornes de la machine, créant ainsi le court-circuit. Un mauvais serrage d'une cosse à la jonction du câble d'alimentation et des bornes de la machine peut provoquer une ouverture de phase. Parmi les défauts les plus fréquemment rencontrés figure la fusion d'un fusible de protection. Ces anomalies peuvent être identifiées grâce à une analyse harmonique des courants absorbés par la machine. **[10]**

I.4.1.1.1 Les courts circuits internes

Un court-circuit entre les spires de la même phase constitue un défaut relativement fréquent. Cette défaillance trouve son origine dans un ou plusieurs défauts d'isolant au sein de l'enroulement concerné. Elle induit une augmentation des courants statoriques dans la phase touchée, une légère variation d'amplitude sur les autres phases, une modification du facteur de puissance, et une amplification des courants dans le circuit rotorique. En résulte une élévation de la température au niveau du bobinage, accélérant ainsi la dégradation des isolants, susceptible de déclencher un défaut en chaîne, tel que l'apparition d'un deuxième court-circuit. Cependant, le couple électromagnétique moyen fourni par la machine demeure sensiblement constant, à l'exception d'une augmentation des oscillations proportionnelle au défaut. **[12]**

Lorsqu'un court-circuit entre les spires survient, l'application du théorème d'Ampère révèle qu'une excitation magnétique de pulsation Ω_s se crée en plus du champ magnétique principal. Cette excitation est due au nouveau bobinage court-circuité, parcouru par un courant de court-circuit. L'interaction de ce champ avec celui provenant du bobinage statorique génère des ondulations de couple, provoquant au stator des forces magnétomotrices à une fréquence de $2fs$. Par conséquent, les courants statoriques incorporent ces composantes, induisant également des courants de fréquences $3fs$ selon le même mécanisme. Ainsi, des composantes à des fréquences kfs (où k est un entier positif) se retrouvent dans les courants statoriques. **[53]**

I.4.1.1.2 Les isolations électriques

La détérioration des isolants dans les enroulements peut conduire à des courts-circuits. Les diverses pertes (Joule, fer, mécanique, etc.) génèrent des phénomènes thermiques qui se traduisent par une élévation de la température des composants du moteur. Cependant, les matériaux d'isolation présentent des limites en termes de température, de tension et de résistance mécanique. Ainsi, si l'environnement de travail d'un matériau d'isolation dépasse l'une de ces limites, le

matériau peut se dégrader prématurément ou de manière accélérée, perdant finalement son efficacité.

Dans de telles circonstances, un court-circuit peut survenir dans l'enroulement concerné. **[12]**

I.4.1.1.3 Décharges partielles

Ce phénomène naturel, résultant des décharges dans les isolants entre conducteurs ou entre conducteurs et la masse, prend de l'ampleur avec le vieillissement des isolants, et il y'en a peu dans les isolants neufs selon les méthodes de mesure classiques, car ses effets ne sont pas discernables par rapport aux bruits de mesure. Sa manifestation anticipe l'émergence de courts-circuits entre les phases ou entre la phase et la masse, dès lors que ces décharges partielles ont détérioré de manière significative les isolants. **[13]**

I.4.1.2 Défaillances des circuits électriques rotoriques

Deux catégories de défaillances peuvent survenir au niveau du rotor d'une machine asynchrone à cage d'écureuil. La cage, constituée de barres et d'anneaux de court-circuit en aluminium ou en cuivre, subit une défaillance électrique rotorique en cas de rupture partielle ou totale de l'un de ces composants. L'apparition de ce type de défaillance peut avoir des origines diverses. En effet, la rupture d'une barre ou d'un segment d'anneau de court-circuit peut résulter de plusieurs phénomènes souvent indépendants les uns des autres. Des exemples incluent une utilisation inappropriée de la machine asynchrone (charge excessive) ou les conditions hostiles de l'environnement dans lequel elle opère. Une défaillance au niveau de la cage rotorique se produit généralement à la jonction entre une barre et un anneau de court-circuit. Étant donné que les barres rotoriques et les anneaux de court-circuit ne peuvent pas être fabriqués d'un seul bloc (sauf pour les machines de faible puissance), une soudure est réalisée aux extrémités de chaque barre pour les relier aux deux anneaux de court-circuit. La fragilité de ces soudures par rapport aux barres et aux anneaux fabriqués d'un seul bloc entraîne une vulnérabilité particulière à ces endroits spécifiques de la cage d'écureuil. **[10]**

I.4.1.2.1 Les cassures des barres

La rupture ou cassure de barre représente l'un des défauts les plus courants au niveau du rotor. Elle peut se produire soit au niveau de l'encoche, soit à l'extrémité reliant la barre à l'anneau rotorique. La dégradation des barres réduit la valeur moyenne du couple électromagnétique et augmente l'amplitude des oscillations. Ces oscillations entraînent des fluctuations de la vitesse de

rotation de la machine, générant ainsi des vibrations mécaniques et un fonctionnement anormal de la machine qui engendre des défauts mécaniques supplémentaires. La grande amplitude de ces oscillations accélère la détérioration de la machine. Par conséquent, le couple diminue sensiblement avec le nombre de barres cassées, induisant un effet cumulatif de la défaillance. L'impact d'une rupture de barre augmente rapidement avec le nombre de barres cassées. **[12]**



Figure I 4. Défaut d'une barre cassée **[12]**

I.4.1.2.1 Cassure d'une portion d'anneau de court-circuit

La cassure d'une portion d'anneau est un défaut qui survient aussi fréquemment que la rupture de barres. Ces ruptures résultent de bulles d'air qui se sont formé lors de la fabrication ou de dilatations différentielles entre les barres et les anneaux. La rupture d'une portion d'anneau perturbe la répartition des courants dans les barres rotoriques, entraînant ainsi un effet de modulation d'amplitude sur les courants statoriques similaire à celui provoqué par la cassure de barres. En raison de sa difficulté de détection, ce défaut est généralement regroupé, voire confondu, avec la rupture de barres dans les études statistiques. Les portions d'anneaux de court-circuit transportent des courants plus importants que ceux des barres rotoriques. Ainsi, un dimensionnement inadéquat des anneaux, une détérioration des conditions de fonctionnement (température, humidité, etc.) ou une surcharge de couple, et donc de courants, peuvent entraîner leur cassure. **[54]**

I.4.2 Défaillances d'ordre mécanique

Les défaillances mécaniques sont parmi les problèmes les plus couramment rencontrés dans la machine asynchrone. Ces défaillances peuvent se manifester au niveau des roulements à

billes, des flasques ou encore de l'arbre moteur. Nous présentons ci-dessous quelques-unes de ces défaillances. **[55]**

I.4.2.1 Défauts des roulements à billes

Souvent, même dans des conditions normales de fonctionnement avec un équilibre de charge et un bon alignement, les défauts dus à la fatigue peuvent survenir. Ces défauts entraînent une augmentation des niveaux de bruit et de vibrations. Outre les contraintes liées au fonctionnement interne normal, telles que l'excentricité et les courants de roulement, d'autres causes externes peuvent également contribuer, notamment :

a) Contamination et corrosion causées par des particules abrasives, l'action corrosive de l'eau, des acides, etc.
b) Lubrification inadéquate.
c) Mauvaise installation du roulement, souvent due au désalignement de la machine.

Bien que 40 à 50% de toutes les défaillances des moteurs soient liées aux roulements, très peu ont été documentées dans la littérature en ce qui concerne la détection spécifique des défauts de roulement. Les défauts de roulement se présentent sous forme d'asymétries au rotor et sont généralement classés dans la catégorie des défauts liés à l'excentricité. **[50]**

I.4.2.2 Excentricité

L'excentricité notée e caractérise l'aplanissement de l'ellipse par rapport à un cercle. Elle est définie par : $e = c/a$, a étant le 1/2 grand axe de cette ellipse et c la distance d'excentricité.

L'excentricité dans une machine asynchrone se réfère à l'inégalité de l'entrefer entre le stator et le rotor. Est un désalignement ou un déplacement du rotor par rapport à l'axe central du stator, entraînant une variation inégale de la distance entre le rotor et le stator sur tout le pourtour de la machine. Lorsque l'excentricité devient significative, les forces radiales résultantes (également appelées Concentration Magnétique déséquilibrée) peuvent entraîner un contact entre le stator et la surface de frottement du rotor, provoquant ainsi des dommages aux deux composants.

La géométrie naturelle du rotor peut présenter des dissymétries, se manifestant à travers trois catégories d'excentricité de l'entrefer :

- L'excentricité statique, où le centre de rotation de l'arbre du rotor ne correspond pas au centre géométrique du stator, et l'épaisseur minimale radiale de l'entrefer reste fixe dans l'espace. Une telle excentricité statique peut résulter d'un positionnement incorrect du rotor ou du stator lors de la mise en service. Si l'assemblage du rotor et du roulement est suffisamment rigide, le niveau d'excentricité statique reste constant.
- L'excentricité dynamique, où le centre du rotor diffère du centre géométrique du stator, et en plus, le centre du rotor effectue une rotation autour du centre géométrique du stator. Ce désalignement peut être provoqué par divers facteurs tels qu'un arbre de rotor courbé, une usure des paliers, un désalignement, une résonance mécanique à des vitesses critiques, etc.

L'excentricité dynamique dans les nouvelles machines est contrôlée par la lecture totale indiquée (TIR) ou par la bande finale du rotor. **[51]**

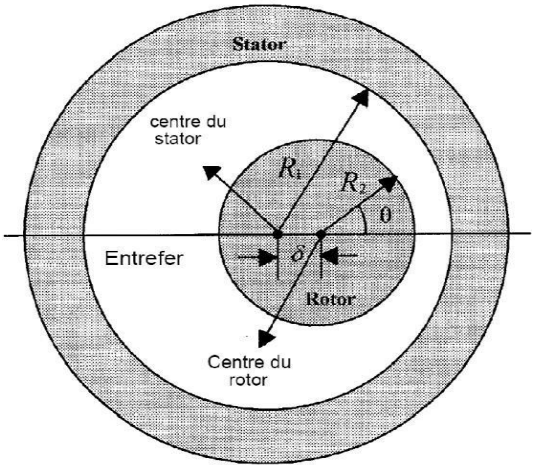


Figure I 5. Différents types de la dissymétrie de l'entrefer **[12]**

Avec : R_1 : Rayon interne statorique, R_2 : Rayon externe rotorique, δ : distance entre le centre du rotor et le centre du stator.

Pour comprendre et modéliser l'excentricité dans une machine asynchrone, il est important d'utiliser des équations mathématiques qui décrivent les effets de ce défaut sur les performances de la machine. Voici les équations importantes :

Équation de l'entrefer : $g(\theta) = g_0 + ecos(\theta - \theta_e)$ $\quad (I.2)$

Où :

$g(\theta)$ Est l'entrefer à un angle θ

g_0 Est l'entrefer nominal

e Est l'excentricité,

θ_e Est la position angulaire du rotor où l'excentricité est maximale.

Pour la force radiale déséquilibrée : $F_r = \frac{1}{2}\mu_0 \left(\frac{N_i}{g(\theta)}\right)^2 A$ $(I.3)$

Où :

F_r Est la force radiale,

μ_0 Est la perméabilité du vide,

N Est le nombre de spires,

Est le courant,

A Est la section transversale du stator. **[90]**

I.4.2.3 Défaillance de l'arbre

Un arbre de machine peut développer une fissure en raison de l'utilisation d'un matériau inapproprié lors de sa construction. À court ou à long terme, cette fissure peut évoluer vers une rupture nette de l'arbre, entraînant ainsi un arrêt immédiat de la machine asynchrone. Les environnements corrosifs peuvent également compromettre la robustesse de l'arbre de la machine. Par exemple, l'humidité peut engendrer des microfissures, conduisant à une défaillance complète de la machine. Une excentricité statique, dynamique, ou mixte peut générer des contraintes importantes sur l'arbre moteur, contribuant ainsi à une fatigue accrue. La détection de ce type de défaillance peut être réalisée par le biais d'analyses vibratoires, d'analyses par ultrasons, d'analyses fréquentielles des courants absorbés, ou simplement par une inspection visuelle de l'arbre de la machine. **[10]**

I.4.2.4 Défaillance du flasque

Les défauts engendrés par les flasques de la machine asynchrone sont le plus souvent attribuables à des erreurs lors de la phase de fabrication. Un positionnement incorrect des flasques

peut entraîner un désalignement des roulements à billes, provoquant ainsi une excentricité au

niveau de l'arbre de la machine. La détection de ce type de défaillance est possible grâce à une analyse vibratoire ou une analyse harmonique des courants absorbés par la machine. **[12]**

I.4.3 Cause des défaillances

Les origines des défauts sont variées et peuvent être regroupées en trois catégories **[13]** :

- Les instigateurs de dysfonctionnements ou déclencheurs de pannes comprennent des facteurs tels que la surchauffe du moteur, les anomalies électriques (court-circuit), les pics de tension, les problèmes d'isolation électrique, l'usure des composants mécaniques (roulements à billes), et les ruptures de fixations, entre autres.
- Les exacerbations de défauts impliquent des conditions telles que des surcharges fréquentes, des vibrations mécaniques, un environnement humide, un échauffement continu, une lubrification inadéquate, le vieillissement, et d'autres facteurs similaires.
- Les défauts inhérents à la fabrication et les erreurs humaines regroupent des éléments tels que des défauts dans le processus de fabrication, des composants défectueux, des protections inappropriées, un dimensionnement inadéquat de la machine, etc. **[12]**

I.4.3.1 Cause des défauts statoriques

Les anomalies au niveau du stator peuvent être attribuées à diverses causes, dont :

- Une dimension excessive du noyau du stator, entraînant une élévation de la température des enroulements.
- Une fixation lâche à l'extrémité de l'enroulement.
- Une contamination résultant de la présence d'huile, de moisissures ou de saletés.
- Des démarrages fréquents du moteur.
- Des surtensions, des décharges électriques et des fuites dans les systèmes de refroidissement.

I.4.3.2 Cause des défauts rotoriques

De manière similaire au stator, les causes des ruptures des barres rotoriques et des ruptures de portions d'anneau de court-circuit sont diverses :

- Contrainte thermique résultant du chauffage de l'anneau de court-circuit et des variations de température dans la barre pendant le démarrage (effet de peau).

- Contrainte magnétique engendrée par les forces électromagnétiques (flux de fuite d'encoche, excentricité de l'entrefer), ainsi que par les bruits et vibrations électromagnétiques.
- Contrainte dynamique due au couple de charge, aux forces centrifuges, ainsi qu'aux sollicitations cycliques.
- Contrainte environnementale résultant de la contamination et de l'abrasion des matériaux rotoriques dues aux particules chimiques.

I.4.3.2.1 Cause des défauts de roulement à billes

Fréquemment, même dans des conditions de fonctionnement normales avec une charge équilibrée et un bon alignement, des défauts liés à la fatigue, en plus de ceux résultant du fonctionnement interne normal lié à l'excentricité, peuvent survenir. D'autres facteurs externes peuvent contribuer, tels que :

- Contamination et corrosion provoquées par l'eau et l'acide…
- Lubrification inadéquate.
- Mauvaise installation du roulement due au désalignement de la machine. **[9]**

I.4.4 Effets des défauts

Les défauts survenant dans les machines asynchrones engendrent divers problèmes susceptibles de compromettre la rentabilité de l'installation dans son ensemble, pouvant même conduire à un arrêt complet. Parmi les conséquences des défauts, on peut citer :

- Altérations au niveau du couple et de la vitesse.
- Appels de courant supplémentaires.
- Déséquilibre dans la tension et le courant de ligne.
- Augmentation des arrêts non planifiés, des pertes de production, et par conséquent, une baisse de l'efficacité globale. **[55]**

I.4.4.1 Effets de défauts statoriques (court-circuit)

Les défauts statoriques dans les machines asynchrones à cage d'écureuil en courant alternatif peuvent provenir de diverses causes, telles que les courts-circuits au sein des spires d'une même phase, les courts-circuits entre phases ou entre bobines, la coupure d'une phase, et les défaillances du circuit magnétique, comme la rupture de tôles **[56]**. Ces défauts peuvent nuire au

fonctionnement de la machine, entraînant des pertes de puissance, des vibrations, et des dysfonctionnements.

Lorsqu'un défaut statorique se produit, il génère des courants électriques et des fréquences spécifiques. Par exemple, un court-circuit dans les spires d'une même phase modifie le courant statorique en raison du court-circuit créé **[57]**.

La détection et le diagnostic des défauts statoriques dans les machines asynchrones à cage d'écureuil sont essentiels pour garantir un fonctionnement optimal et prévenir les problèmes de sécurité et de fiabilité. L'analyse spectrale, combinée à des capteurs de courant et des systèmes d'acquisition de données, permet d'identifier et de caractériser ces défauts **[58]**.

<table>
<tr><td rowspan="2">Type de défaut</td><td colspan="2">Paramètres du modèle $(d-q)$</td><td colspan="2">Paramètres du modèle triphasé</td></tr>
<tr><td>R_r R_s</td><td>L_r L_s</td><td colspan="2">$R_{sa}, R_{sb}, R_{cs}, L_{sa}, L_{sb}, L_{sc}, R_r, L_r$</td></tr>
<tr><td rowspan="2">Court-circuit entre spires d’une phase statorique.</td><td rowspan="2">⇩ ⬈</td><td rowspan="2">⇩ ⇩</td><td>R_{sa}, L_{sa}</td><td>⇩</td></tr>
<tr><td>$R_{sb}, R_{sc},$ L_{sb}, L_{sc}</td><td>⬈</td></tr>
</table>

Tableau I 1. Effet de défaut statorique sur les paramètres de la machine **[60]**

I.4.4.2 Effets de défauts rotoriques

La dissymétrie engendrée par la présence d'une ou plusieurs barres cassées se traduit par la formation d'un champ tournant de sens contraire à celui produit par le stator, avec une fréquence égale au glissement. Par conséquent, des courants additionnels seront générés dans les enroulements statoriques à des fréquences induites : $f_b = (1 \pm 2g).f \quad (Hz)$

Où : $f_b =$ fréquence de barre cassée, g: le glissement et f :la fréquence fondamentale.

- Le signe $(+)$ pour indique l’effet des oscillations en vitesse.
- Le signe $(-)$ pour indique la présence du défaut rotor (barres cassées).

Par contre, les harmoniques d'espaces gênèrent eux aussi des fréquences dont la relation est :

$$f_b = \{(\frac{k}{p})(1-g) \pm g\} f \quad (Hz) \qquad (I.4)$$

En effet, la relation permettant au moteur de fonctionnement en tant que tel repose sur la relation : $f = f_r + f_s \ \ (Hz)$ $(I.5)$

f : Fréquence fondamental du réseau, f_r : Fréquence de rotation, f_g : fréquence de glissement. Dans la dissymétrie f_s est négative, donc : $f_b = f_r - f_s = f - 2f_s = f(1-2g) \quad (Hz) \ (I.6)$

Ainsi, ce courant induira l'apparition d'un couple oscillatoire résultant de l'interaction entre ce courant et le flux fondamental généré par l'alimentation statorique. Ce couple additionnel, résultant du produit du flux par le courant, sera proportionnel à l'amplitude du courant et à la fréquence $(1-2g)f$.

Ainsi, la fréquence d'oscillation sera de $2gf$, entraînant une oscillation de vitesse à cette fréquence dont l'amplitude dépendra de l'inertie du moteur et de la charge. Cette oscillation de vitesse induira une variation de flux, engendrant ainsi une force électromotrice de fréquence fondamentale, ainsi que deux composantes supplémentaires liées aux oscillations de vitesse. Ces dernières seront proportionnelles à l'amplitude de la variation de vitesse, générant deux courants additionnels de fréquence $(1-2g)f$ et $(1+2g)f$, ayant une valeur équivalente. Cependant, il est important de noter que le courant créé à la fréquence $(1-2g)f$ vient se soustraire à celui généré par le défaut rotorique.

Ainsi, nous pouvons conclure que l'amplitude du courant à la fréquence $(1-2g)f$ demeure constante. En revanche, l'amplitude du courant à la fréquence $(1+2g)f$ sera d'autant plus faible que l'inertie totale, résultant de la combinaison de l'inertie du moteur et de celle de la charge ramenée, sera grande et significative.

La variation des paramètres rotoriques se fait comme suit **[59]** :

Type de défaut	Paramètres du modèle $(d-q)$				Paramètres du modèle triphasé
	R_r	R_s	L_r	L_s	$R_{sa}, R_{sb}, R_{cs}, L_{sa}, L_{sb}, L_{sc}, R_r, L_r$
Cassure des barres et des portions d'anneau de court-circuit.	⇧	⇩	⇩	⇩	

Tableau I 2. Effet de défaut rotoriques sur les paramètres de la machine

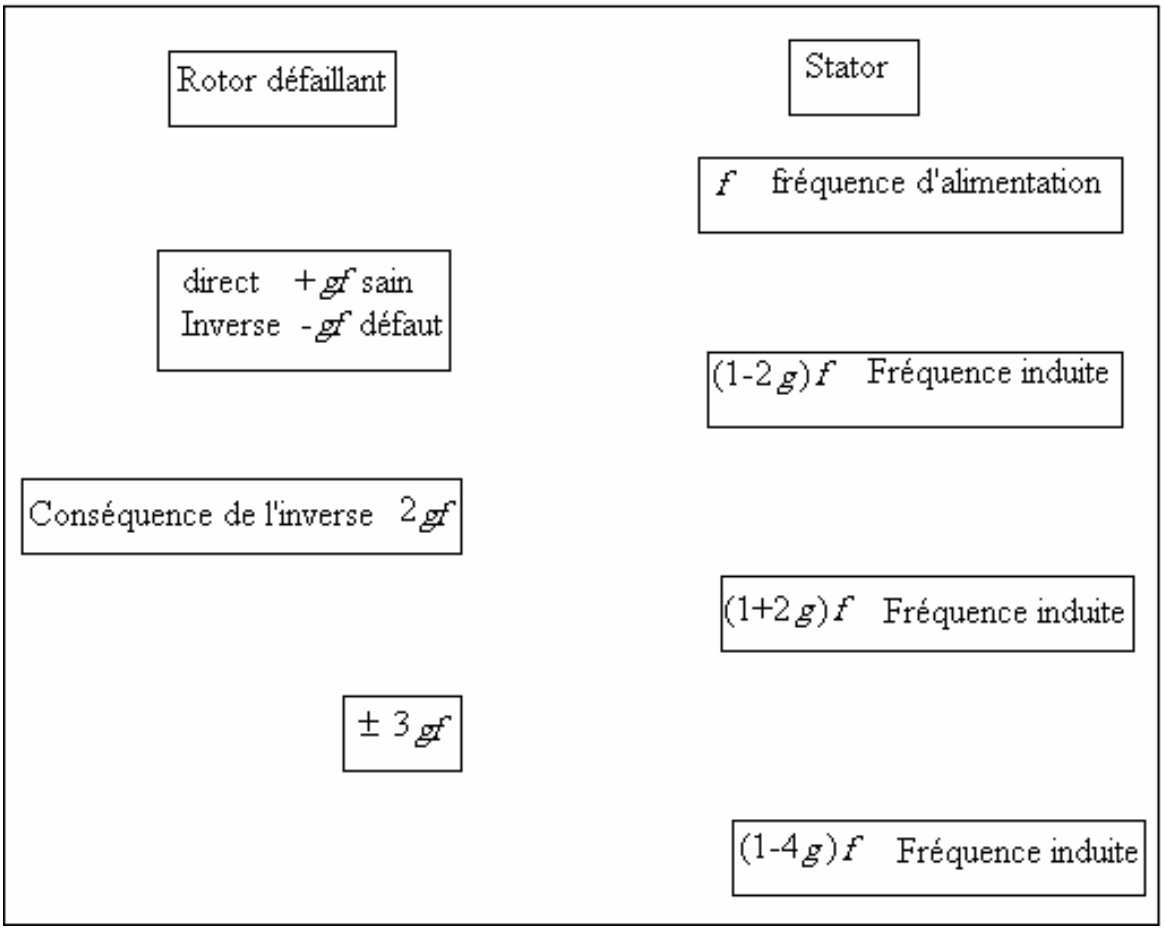


Figure I 6. Les différentes fréquences induites à cause des défauts **[60]**

I.5 Synthèse des défaillances

Les tableaux 1.3 et 1.4 récapitulent la totalité de la relation machine-charge en précisant son point d'origine, ses causes potentielles, ses répercussions sur le système, ainsi que les divers éléments observables envisageables. **[6]**

Composants		Défaillances	Causes possibles	Effets sur le système	Observable
Machine asynchrone a cage d'écureuil	Rotor	Ruptures de barres	Surcharge	Réduction de la valeur moyenne de coupe électromagnétique Oscillations de la vitesse Vibrations mécaniques	Vibrations Couple Electromagnétique Courant
		Rupture d'anneau	Bulles coulées Dilatations différentielles Surcharge du couple Détérioration des conditions de fonctionnement	Déséquilibre la réparation des courants ⟹ modulation d'amplitude des courants statoriques	Courant Vibrations
		Excentricité	Positionnement incorrect des paliers lors de l'assemblage Usure des roulements Défaut de charge Défaut de fabrication	Balourd (mécanique et magnétique) ⟹ oscillations de couple	Vibrations Courant Couple
	Axe	Roulements	Usure Température élevée Perte de lubrification Défaut de montage Huile contaminée	Oscillations du couple de charge ↗ perte ↗ Vibrations Alteration de l'équilibre magnétique	Vibrations Courant Puissance instantanée Variable mécanique

↗ : augmentation ⟹ : entraine

Tableau I 3. Synthèse des défaillances du rotor sur la machine asynchrone **[9]**

Composants		Défaillances	Causes possibles	Effets sur le système	Observable
Machine asynchrone a cage d'écureuil	Stator	Isolant dans un enrouement	Dégradations de l'isolant à la fabrication Tension élevée Courant élevé Vibrations mécaniques Température élevée Vieillissement naturel	Court-circuit dans l'enroulement	Température Vibrations Courants
		Court-circuit entre spires	Défaut d'isolations	↗ Courant statorique, variation d'amplitude sur les autres phases, modification de facteur de puissance, ↗ courants rotoriques	Température Vibration Courant Puissance instantanée
		Court-circuit entre phase	Décharge partielle	Dépend fortement de la localisation <u>Proche de l'alimentation :</u> Fusion des conducteurs Disjonction par les protections <u>Proche du neutre :</u> ↗ Courant des barres et les anneaux déséquilibre des courants statoriques	Courant (déséquilibre) Température Tension Puissance instantanée
		Court-circuit phase/bâti	Dégradation des isolants	↗ Courant dans la phase ⟹ ↗ de la température ⟹ défaut d'isolants Apparition d'une composante homopolaire ⟹ couple pulsatoire	Courant de fuite
		Circuit magnétique		Dissymétrie du fonctionnement de la machine ⟹ surchauffe, surtension élévation du courant	Température Courants Tensions
		Déséquilibre d'alimentation	Problème sur le réseau d'alimentation Défaillance du convertisseur	↗ Des courants dans les autres phases ↗ vibrations ↗ de l'échauffement	Vibrations Courants Tensions Puissance

↗ : augmentation ⟹ : entraine

Tableau I 4. Synthèse des défaillances du stator sur la machine asynchrone **[9]**

I.6 Conclusion

Le premier chapitre de notre mémoire offre une plongée détaillée dans la structure et le fonctionnement de la machine asynchrone à cage d'écureuil. Connue pour sa simplicité et sa robustesse, cette machine est un pilier essentiel dans le domaine industriel, répondant à des besoins variés allant de la petite puissance aux mégawatts.

Nous avons introduit les composants principaux de la machine, notamment le stator et le rotor, en soulignant leurs caractéristiques distinctes et leur conception ingénieuse. Nous avons également expliqué le principe de fonctionnement de la machine, en mettant en relation les courants statoriques et le mouvement du rotor, ce qui révèle la complexité sous-jacente de cette technologie.

Le chapitre aborde ensuite la diversité des défauts potentiels que peut rencontrer une machine asynchrone à cage d'écureuil. Nous avons détaillé les défauts mécaniques et électriques, en expliquant leurs causes, leurs conséquences et leurs effets. Des défaillances des composants internes aux conditions environnementales défavorables, le spectre des défis est vaste et varié.

Ainsi, ce premier chapitre sert d'introduction solide à notre mémoire, établissant le contexte nécessaire pour aborder avec clarté les défis de détection et de diagnostic des défauts dans les machines asynchrones à cage d'écureuil dans les sections suivantes. En comprenant les bases de la machine et ses vulnérabilités, nous sommes mieux préparés à explorer les techniques avancées pour améliorer la fiabilité et l'efficacité opérationnelle.

CHAPITRE II

Méthodes classiques de détection des défauts de la machine asynchrone à cage d'écureuil

II.1 Introduction

Ce chapitre explore les méthodes de diagnostic des défauts dans les machines électriques, essentielles dans diverses applications industrielles. Il souligne l'importance de détecter efficacement les problèmes pour éviter des pannes coûteuses et des interruptions de production **[14]**. L'accent est mis sur les méthodes traditionnelles d'analyse de signal **[25]**, offrant divers outils pour identifier et caractériser une gamme de défauts, de anomalies électromagnétiques aux problèmes mécaniques **[9][25][33]**. Parmi les méthodes qui existent on trouve :

- L'analyse fréquentielle du couple électromagnétique et de la vitesse de rotation pour détecter des anomalies par l'étude des variations de fréquence **[64]**.
- L'analyse spectrale de la puissance instantanée pour identifier les composantes fréquentielles associées à des défauts en analysant la densité spectrale de puissance **[27]**.
- L'analyse fréquentielle des courants statoriques pour examiner les caractéristiques fréquentielles des courants et détecter des anomalies **[26]**.
- Le diagnostic de défauts par le suivi des grandeurs mesurables, analysant des grandeurs comme la tension, le courant et la vitesse de rotation **[25]**.
- L'analyse des flux magnétiques pour détecter des anomalies **[14-16]**.
- L'analyse de la température pour surveiller les températures et détecter des anomalies de surchauffe ou de refroidissement **[14][15]**.
- L'analyse des signaux vibratoires pour exploiter les vibrations et détecter des défauts mécaniques ou électromécaniques **[12][13]**.
- Le diagnostic des défauts par analyse du vecteur de Park, analysant les caractéristiques de ce vecteur pour détecter des déséquilibres ou des courts-circuits **[7][8]**.

En explorant dans ce chapitre ces différentes méthodes de diagnostic pour détecter et diagnostiquer les défauts dans les machines électriques, contribuant à assurer leur fiabilité et efficacité **[14]**.

II.2 Méthodes basées sur le traitement de signal

Les techniques de diagnostic basées sur le traitement du signal constituent une approche prometteuse pour la détection et l'identification des défauts dans les machines électriques. Ces

techniques permettent d'analyser les signaux électriques et vibratoires générés par la machine afin d'extraire des informations sur son état de santé.

Les méthodes de diagnostic sont essentielles pour détecter et identifier les défauts dans les machines électriques. Elles reposent sur l'analyse des signaux électriques ou mécaniques, en identifiant les caractéristiques fréquentielles spécifiques qui témoignent du fonctionnement normal ou défaillant du système. La première étape de cette approche consiste à passer du domaine temporel au domaine fréquentielle, en les caractérisant dans le domaine fréquentiel pour déterminer leur contenu spectral et leur variance. Les défauts, tels que ceux liés aux roulements, aux stators ou aux rotors, ainsi que les problèmes d'excentricité, génèrent des symptômes distinctifs tels que des déséquilibres électriques, des fluctuations de couple et une augmentation des pertes énergétiques. Pour relever ces défis, une variété de techniques de diagnostic ont été développées, allant de la surveillance du champ électromagnétique à l'analyse de la signature du courant stator (MCSA) en passant par l'utilisation de l'intelligence artificielle et des réseaux de neurones. Parmi ces approches, le traitement du signal se démarque comme l'une des plus utilisées, exploitant des capteurs conventionnels de courant, de tension ou de vitesse. Ces techniques, économiquement efficaces et rapides, contribuent grandement à leur adoption réussie dans les environnements industriels. **[9][25]**

II.3 Analyse temps-fréquence et temps-échelle

II.3.1 Analyse temps-fréquence

La machine asynchrone est l'une des machines les plus utilisées dans l'industrie en raison de sa robustesse, de sa fiabilité et de son coût abordable. Cependant, ces machines sont sujettes à diverses défaillances qui peuvent entraîner des arrêts de production et des dommages matériels. Le diagnostic précoce des défauts est essentiel pour réduire les coûts de maintenance, améliorer la sécurité et garantir la continuité de la production. Parmi les techniques de Diagnostic Basées sur l'Analyse Temps-Fréquence les Techniques de démodulation du courant statorique qui permettent de détecter les variations d'amplitude et de fréquence. Elle révèle les composantes liées aux défauts, comme les cassures de barres ou les problèmes de roulements. Différentes méthodes de démodulation sont utilisées, telles que la démodulation synchrone et la démodulation par enveloppe. **[33]**

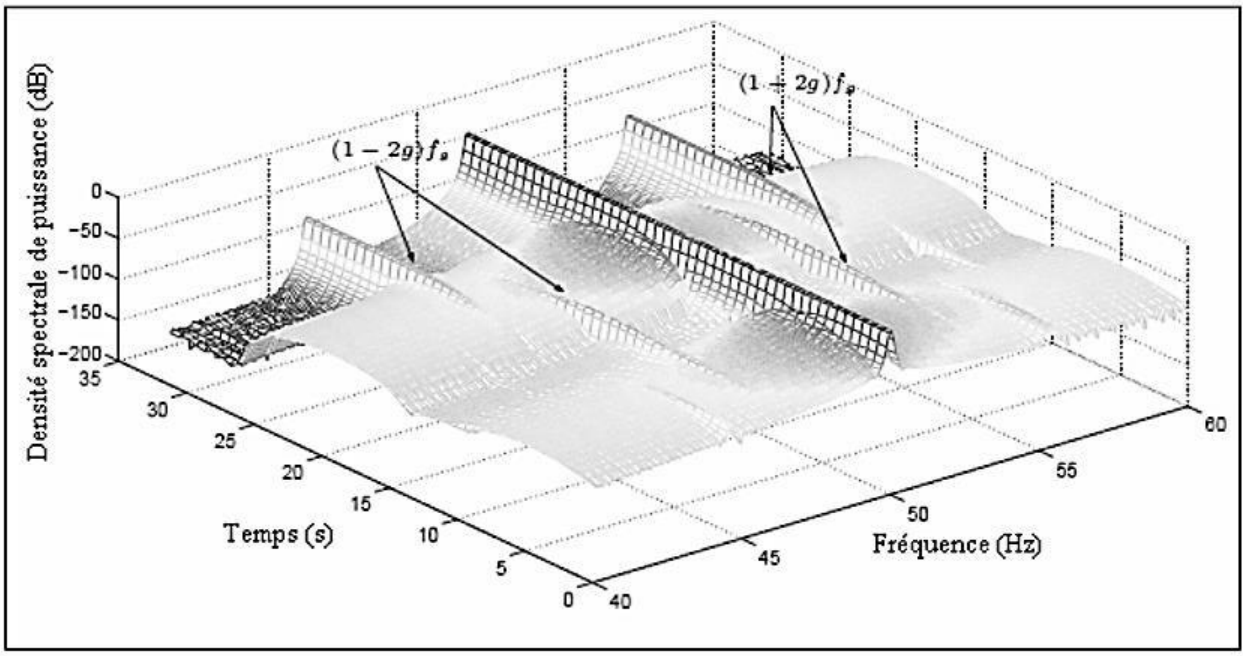


Figure II 1. Représentation temps-fréquence du courant statorique lors d'une variation du couple de charge avec une barre cassé **[9]**

II.3.2 Analyse temps-échelle

Ce mode d'analyse est employé pour détecter des phénomènes se produisant à différentes échelles de fréquences présentes dans un signal. L'idée sous-jacente consiste à décomposer le signal à l'aide de fonctions analysantes spécifiques construites à partir d'une ondelette mère oscillante et à moyenne nulle. À partir de cette ondelette mère, il est possible de générer des ondelettes analysantes centrées autour d'une valeur et avec une échelle variable limitée.

Une technique de fenêtrage utilisant une région de taille variable est mise en œuvre pour améliorer l'analyse du signal, par exemple, le courant statorique d'un moteur asynchrone. L'analyse par ondelettes permet l'utilisation d'intervalles de temps longs pour obtenir une information basse fréquence la plus précise possible, ainsi que d'intervalles de temps plus courts pour disposer d'une information riche en hautes fréquences. La capacité d'effectuer une analyse locale constitue l'un des aspects les plus intéressants de la transformation en ondelette.

L'utilisation des ondelettes pour la surveillance des défauts et le diagnostic des moteurs asynchrones présente un avantage, car cette technique améliore l'analyse du courant statorique pendant les phases transitoires. Les ondelettes peuvent être employées pour une analyse localisée

dans le domaine temps-fréquence ou temps-échelle, en faisant ainsi un outil approprié pour la surveillance et le diagnostic des défauts des machines électriques, notamment lorsqu'il est nécessaire de les utiliser à des vitesses variables. **[9]**

II.3 Analyse spectrale

L'analyse spectrale est une technique puissante utilisée pour examiner les caractéristiques spectrales des signaux électriques ou mécaniques générés par les machines électriques. Cette méthode est utilisée pour détecter et diagnostiquer les défaillances en décomposant un signal temporel en ses composantes fréquentielles. Cela permet d'étudier la répartition des fréquences et d'identifier des motifs caractéristiques associés à différents types de défaillances.

L'analyse spectrale peut être appliquée à divers paramètres tels que le courant, la tension, les vibrations, ou d'autres grandeurs électriques ou mécaniques. Elle offre la possibilité de visualiser la présence de fréquences spécifiques ou d'harmoniques, pouvant indiquer des anomalies ou des défauts dans le fonctionnement de la machine. Cependant, cette méthode nécessite une analyse manuelle par un expert en surveillance des machines électriques.

Il existe plusieurs méthodes pour effectuer une analyse spectrale, dont la Transformée de Fourier, la Transformée de Fourier rapide (FFT), la Transformée de Wigner-Ville et la Transformée de Hilbert. Les deux dernières méthodes, la Transformée de Wigner-Ville et la Transformée de Hilbert-Huang, sont également des techniques d'analyse temps-fréquence. Chaque méthode a ses propres avantages et inconvénients en termes de résolution en fréquence, de complexité et de temps de calcul. **[16] [64]**

La Transformée de Fourier Rapide est un algorithme pour calculer la Transformée de Fourier Discrète (DFT) de manière efficace.

$$X[k] = \sum_{n=0}^{N-1} x[n] \,.\, e^{-j\frac{2\pi}{N}kn} \qquad (II.1)$$

Où :

$X[k]$ Est le coefficient de la DFT à l'indice k

$x[n]$ Est l'échantillon du signal en temps à l'indice n

N Est le nombre total d'échantillons

j Est l'unité imaginaire

La FFT utilise la décomposition de la DFT en des parties plus petites pour réduire la complexité de $O(N^2)$ à $O(NlogN)$. **[91]**

La Transformée de Wigner-Ville est une distribution temps-fréquence qui permet d'analyser la variation temporelle du spectre fréquentiel d'un signal.

$$W_x(t,f) = \int_{-\infty}^{\infty} x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi f\tau}\, d\tau \qquad (II.2)$$

Où :

$W_x(t,f)$ Est la distribution de Wigner-Ville,

$x(t)$ Est le signal temporel,

$x^*(t)$ Est le conjugué complexe du signal,

t Est le temps,

f Est la fréquence,

τ Est la variable de décalage temporel. **[92]**

La Transformée de Hilbert est utilisée pour obtenir l'enveloppe analytique d'un signal.

$$\mathcal{H}\{x(t)\} = \frac{1}{\pi} P.V. \int_{-\infty}^{\infty} \frac{x(\tau)}{t-\tau}\, d\tau \qquad (II.3)$$

Où :

$\mathcal{H}\{x(t)\}$ Est la Transformée de Hilbert du signal $x(t)$,

$P.V.$ Représente la valeur principale de Cauchy de l'intégrale.

Le signal analytique est alors donné par : $x_a(t) = x(t) + j\mathcal{H}\{x(t)\}$ $(II.4)$

Cependant, l'analyse spectrale présente certaines limites, en particulier dans le cas des vibrations. Les contraintes techniques des capteurs peuvent poser des problèmes, car il est impératif de placer le capteur aussi près que possible du processus pour éviter des problèmes de sensibilité graves. Cette contrainte entraîne des problèmes d'accessibilité et des difficultés dans l'installation des capteurs afin d'effectuer les acquisitions à une proximité suffisante du défaut. **[17]**

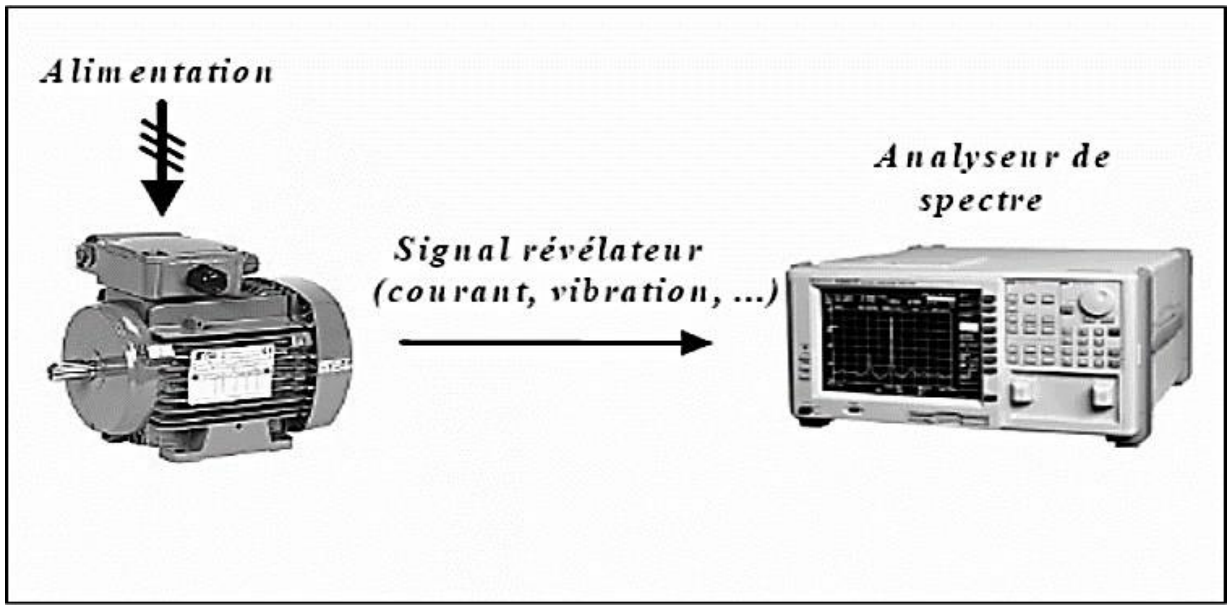


Figure II 2. Principe de la surveillance par analyse spectrale **[66]**

II.3.1 Analyse des signaux vibratoires

L'analyse vibratoire est une méthode efficace pour la détection des défauts dans les machines électriques. Elle repose sur la surveillance des vibrations émises par la machine, qui peuvent révéler des anomalies mécaniques. Les défauts dans les roulements, par exemple, peuvent entraîner des vibrations caractéristiques qui peuvent être détectées et analysées pour identifier les problèmes.

L'analyse vibratoire est également utilisée pour la surveillance et le diagnostic de défauts électriques dans des alternateurs connectés au réseau, en analysant le champ magnétique rayonné à l'extérieur de la carcasse et les vibrations de la machine tournante. **[21]**

Elle offre un moyen efficace de surveiller l'état de santé des machines électriques et de détecter toute anomalie potentielle. En utilisant des accéléromètres positionnés horizontalement

ou verticalement sur la machine, les vibrations générées peuvent être captées et analysées dans le domaine fréquentiel à l'aide de la transformée de Fourier rapide (FFT). **[25]**

Cette analyse permet d'identifier les composantes spécifiques aux défauts en les comparant à celles correspondant à un fonctionnement normal de la machine. Par ailleurs, l'analyse vibratoire des machines asynchrones peut être réalisée en plaçant des accéléromètres sur les paliers dans les directions verticales, axiales et radiales. Ces vibrations fournissent des informations précieuses sur une gamme étendue de défauts mécaniques couramment rencontrés, offrant ainsi un outil précieux pour la maintenance préventive et la détection précoce des problèmes potentiels. **[22]**

II.3.2 Analyse de la température

L'analyse de la température dans la détection des défauts est une méthode essentielle pour identifier des anomalies dans divers systèmes, y compris les machines électriques. Cette approche repose sur la surveillance des variations de température pour détecter des défauts potentiels.

La surveillance thermique revêt une importance capitale dans la détection des défauts des machines électriques. Elle permet de surveiller les températures des supports et des bobines, offrant ainsi des indications cruciales sur les problèmes de refroidissement et les performances en cas de surcharge. Cependant, la mesure des températures des bobines est souvent complexe en raison des défis liés à l'isolation électrique. Parallèlement, l'analyse thermique, qu'elle soit réalisée à l'aide de sondes de température ou de thermographie infrarouge, permet de détecter les défauts induisant un échauffement anormal, tels que les problèmes de lubrification. Bien que cette analyse offre une interprétation rapide des résultats, elle ne permet pas toujours un diagnostic approfondi. De plus, la visibilité limitée des sorties des capteurs, notamment des caméras infrarouges, rend souvent difficile la détection des défauts précoces. **[15] [22]**

II.4 Analyse des flux magnétiques

L'analyse du flux magnétique revêt une importance cruciale dans le diagnostic des défauts des machines électriques, offrant des informations précieuses sur l'état de santé et le fonctionnement de ces systèmes complexes. Lorsque des défauts se développent dans une machine électrique, ils peuvent perturber le flux magnétique, ce qui peut être détecté et analysé pour identifier et localiser les problèmes potentiels.

Une méthode couramment utilisée pour évaluer le flux magnétique est la détection du flux de fuite axial, qui peut être réalisée à l'aide de bobines exploratrices enroulées autour de l'arbre de la machine ou d'autres dispositifs sensibles tels que les sondes à effet Hall. Ces dispositifs permettent de mesurer les asymétries dans les circuits électriques et magnétiques, qui se manifestent par des variations du flux de fuite. L'analyse spectrale de la tension induite résultante révèle les harmoniques des flux de fuite, offrant ainsi des indices sur la présence de défauts et de déséquilibres.

Parallèlement, la conversion électromécanique de l'énergie dans l'entrefer est étroitement liée à l'état du flux magnétique. Tout déséquilibre magnétique, mécanique ou électrique au niveau du rotor ou du stator peut affecter cette conversion, ce qui en fait un paramètre important à surveiller pour le diagnostic des défauts. Bien que ces grandeurs soient parfois difficiles à mesurer directement, des études ont été menées pour extraire des signatures spécifiques à certains défauts à partir de l'analyse du flux magnétique. Ainsi, l'analyse du flux magnétique offre une approche prometteuse pour la détection précoce et la localisation des défauts dans les machines électriques, permettant aux ingénieurs de maintenance de prendre des mesures préventives et correctives pour assurer le bon fonctionnement et la fiabilité de ces équipements essentiels. **[15] [22]**

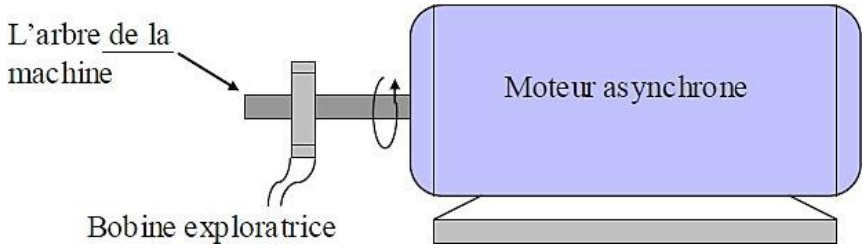


Figure II 3. Bobine exploratrice pour la mesure du flux de fuite axial **[22]**

II.5 Diagnostic des défauts par analyse du vecteur de Park

Le vecteur de Park est un concept mathématique utilisé dans l'analyse des machines électriques. Il est défini par la transformation de Park, qui permet de passer d'un référentiel statorique au référentiel rotatif du moteur. Ce vecteur est utilisé pour représenter le courant statorique dans le référentiel rotatif, ce qui est utile pour analyser les défauts dans le rotor, tels que les ruptures de barres et les portions de court-circuit. **[18]**

Également appelé transformation $\alpha\beta\gamma$, c'est une technique de transformation mathématique qui permet de convertir les grandeurs électriques triphasées (courants et tensions) d'un système en des coordonnées plus simples.

Il est basé sur la décomposition des grandeurs triphasées en deux composantes : une composante directe (α) et une composante quadratique (β).

Le vecteur de Park facilite l'analyse des systèmes électriques en simplifiant les calculs et en fournissant une représentation plus intuitive.

Deux versions de la méthode du vecteur de Park sont couramment utilisées.

La première version est une représentation en deux dimensions peut être utilisée pour décrire les phénomènes des moteurs asynchrones triphasés, basée sur le calcul des courants de Park. En fonction des courants de phase $isa(t)$, $isb(t)$, et $isc(t)$, les courants de Park $id(t)$ et $iq(t)$ peuvent être calculés pour obtenir la courbe de Lissajous.

La forme circulaire de cette courbe et les éventuelles déformations ou changements d'épaisseur fournissent des informations sur les défauts.

Cette approche utilise les grandeurs biphasées is_d et is_q pour obtenir la courbe de Lissajous. L'Approche du Vecteur de Park Étendu, qui repose sur l'analyse spectrale du module du vecteur de Park, permet également de détecter les défauts grâce aux variations observées dans la courbe. **[65][66]**

Les variations d'épaisseur et de forme de cette courbe fournissent des informations sur les défauts potentiels dans la machine électrique. **[66]**

La deuxième version, appelée l'Approche Étendue du Vecteur de Park, est basée sur l'analyse spectrale du module du vecteur de Park Le spectre de fréquence du module des vecteurs de Park comprend une composante continue et, contrairement au spectre du courant statorique, il ne contient pas le fondamental. Bien que des harmoniques résiduels d'amplitude négligeable puissent être présents, l'atténuation du fondamental et des harmoniques temporels permet de repérer facilement les harmoniques liés aux défauts, qui apparaissent à des fréquences différentes. **[58]**

L'analyse du vecteur de Park permet de détecter des défauts de roulements dans les machines électriques. Par exemple, dans un moteur asynchrone, les défauts de roulements peuvent entraîner

des oscillations du couple de charge à des fréquences caractéristiques du roulement, et ces oscillations peuvent être détectées en analysant les modulations de phase sur les courants statoriques **[20]**.

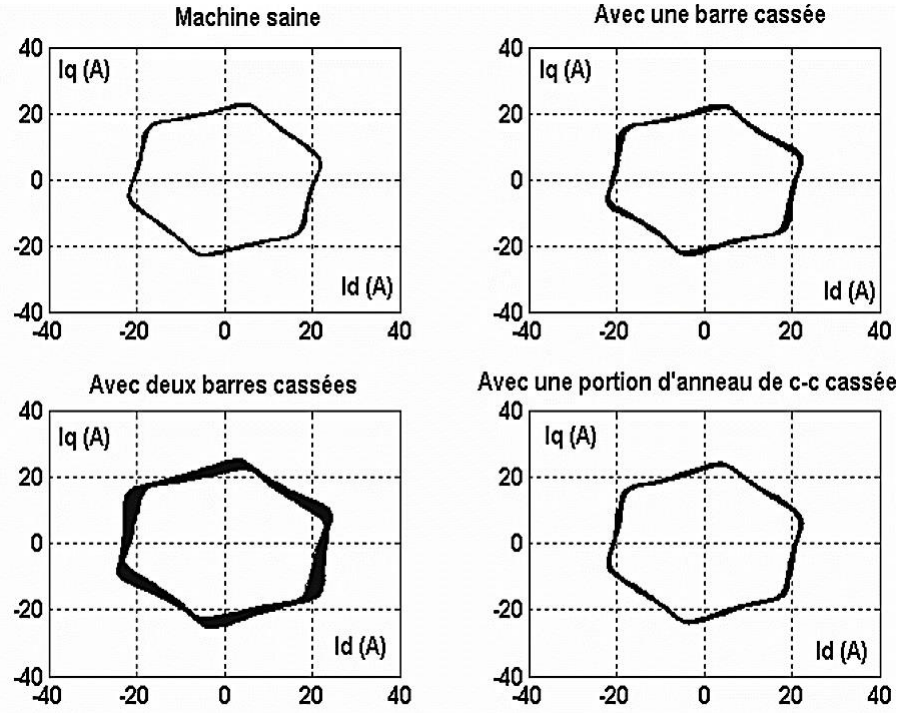


Figure II 4. Vecteur de Park des courants statoriques **[9]**

II.6 Diagnostic de défauts par le suivi des grandeurs mesurables

La méthode la plus couramment utilisée est encore l'analyse fréquentielle, qui est une technique efficace pour identifier les fréquences dominantes d'un signal. Elle est simple, car elle ne nécessite que le calcul de la transformée de Fourier d'un signal.

Elle est souvent utilisée pour la détection de défauts dans les machines électriques. Elle permet l'analyse de quantités facilement mesurables à l'aide de capteurs de courant, de tension ou de vitesse courants. Par exemple, une barre de rotor cassée dans une machine électrique peut entraîner l'apparition d'un nouvel harmonique dans le spectre du courant statorique. L'analyse fréquentielle peut être utilisée pour identifier ce nouvel harmonique et ainsi détecter le défaut.

II.6.1 Analyse fréquentielle des courants statoriques

Le courant statorique est l'un des signaux les plus intéressants pour la détection des défauts dans les machines asynchrones, car il est facilement accessible et peut être utilisé pour détecter à la fois les défauts électriques et mécaniques. Cette technique est connue sous le nom d'Analyse de la Signature du Courant Moteur (MCSA). Les défauts dans les machines asynchrones se manifestent dans le spectre du courant statorique de deux manières :

- L'apparition de nouvelles lignes spectrales dont les fréquences sont directement liées à la vitesse de rotation de la machine, aux fréquences du champ tournant et aux paramètres physiques (nombre de fentes du rotor et nombre de paires de pôles).
- La modification de l'amplitude des lignes spectrales déjà présentes dans le spectre du courant.

La figure suivante compare l'analyse fréquentielle du courant statorique d'une machine asynchrone saine à celle d'une machine présentant deux barres rotoriques cassées. Les lignes apparues sur le spectre sont les composantes de fréquence f_s caractérisant l'existence de la rupture d'une barre rotorique. **[25] [26]**

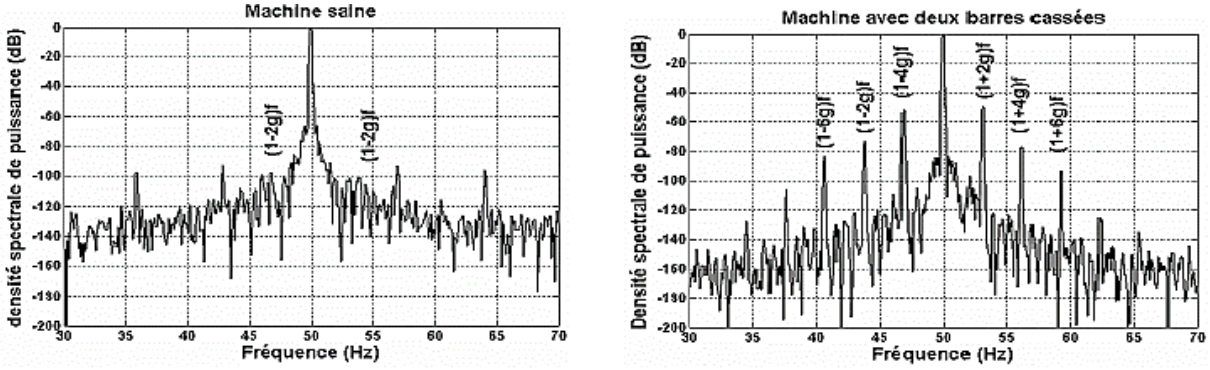


Figure II 5. Spectre du courant statorique **[9]**

II.6.2 Analyse fréquentielle du couple électromagnétique et de la vitesse de rotation

L'analyse du couple électromagnétique peut être utilisée pour détecter les défauts en recherchant des harmoniques dans le domaine fréquentiel. Ces harmoniques sont causées par l'interaction entre le flux et le courant. Il est possible de reconstruire le couple à partir des mesures de la machine électrique ou en utilisant un modèle physique du système. L'analyse du couple électromagnétique est un bon choix pour détecter les défauts au niveau de la charge mécanique.

Cela est dû au fait que les fluctuations du couple de charge se reflètent dans les flux et les courants de la machine, ce qui peut entraîner des oscillations du couple. Lorsque des anomalies surviennent dans la machine asynchrone, telles que le désalignement de l'arbre ou la dégradation des roulements, le couple électromagnétique peut osciller, entraînant l'apparition d'harmoniques. **[64]**

II.6.3 Analyse spectrale de la puissance instantanée

La puissance instantanée est le produit du courant statorique et de la tension. Par conséquent, elle contient plus d'informations que l'analyse du courant seul. En effet, le spectre de la puissance instantanée contient, en plus de la composante fondamentale et des deux bandes secondaires, une composante supplémentaire située à la fréquence de défaut. Cette composante est visible dans la relation suivante : **[27]**

$$P_s(t) = P_{s,0}(t) + \frac{mV_{LL}I_L}{2}\left[\cos\left(2\omega_s - \omega_f\right)t - \phi - \frac{\pi}{6} + \cos\left(2\omega_s + \omega_f\right)t - \phi - \frac{\pi}{6} + 2\cos\left(\phi + \frac{\pi}{6}\right)\cos(\omega_f t)\right] \qquad (II.5)$$

Avec : $P_{s,0}$

$$= V_{LL}I_{LL}\left[\cos\left(2\omega_s t - \phi - \frac{\pi}{6}\right) + \cos\left(\phi + \frac{\pi}{6}\right)\right] \qquad (II.6)$$

Dans cette expression, $P_s(t)$ représente la puissance instantanée d'une phase statorique, m est l'indice de modulation, V_{LL} est la valeur efficace de la tension de ligne à ligne, Il est le courant de ligne, et ω_f est la fréquence d'oscillation (fréquence de défaut) exprimée en radians par seconde. Les termes ω_s et ϕ représentent la fréquence du courant d'alimentation, exprimée en radians par seconde, et l'angle de phase entre le courant et la tension du moteur, respectivement.

Le résultat du calcul de la densité spectrale de puissance (DSP) de la puissance instantanée révèle que certaines composantes dépassent l'amplitude seuil enregistrée pour l'état normal de fonctionnement. De plus, ces composantes présentent des fréquences qui sont des multiples entiers de la fréquence de défaut $2gfs$. À partir de cette fréquence $2gfs$, il est possible d'estimer la valeur du glissement de la machine et de calculer la vitesse de rotation de l'arbre rotorique. Une fois le glissement g déterminé, nous pouvons calculer la fréquence des composantes présentes autour de la fréquence de la puissance instantanée à l'aide de la relation : $2(1 \pm kg)f_s$. À partir de ces fréquences, il est alors possible d'évaluer l'amplitude des composantes correspondantes avec une tolérance toujours inférieure à 1. **[25]**

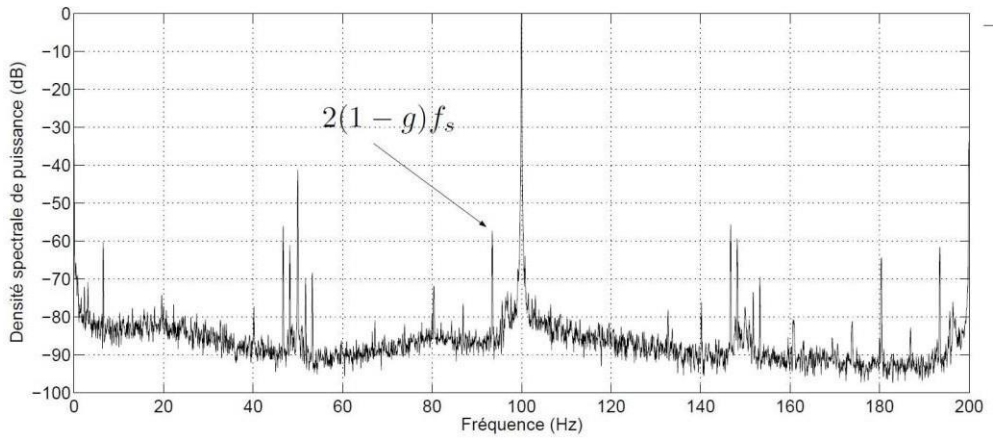


Figure II 6. Spectre de la puissance instantanée **[25]**

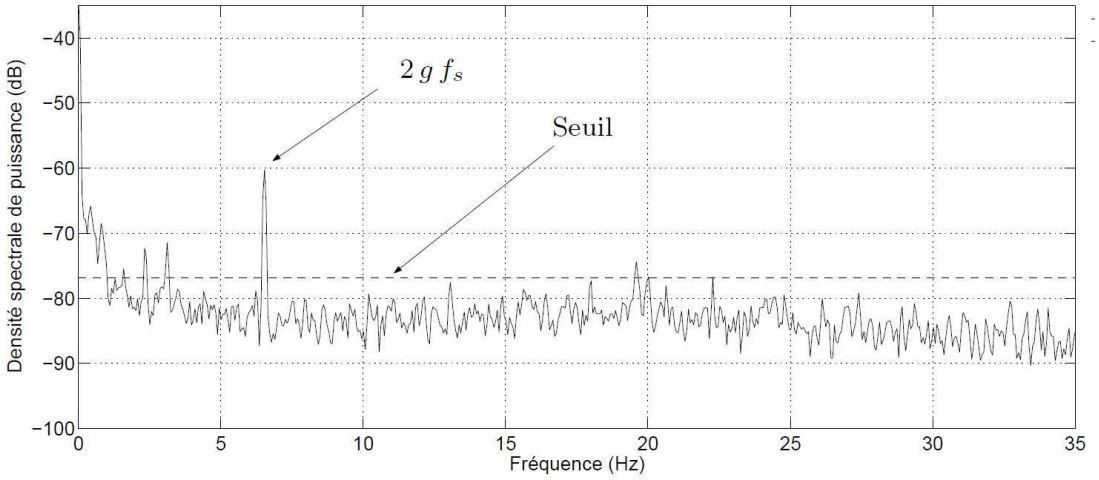


Figure II 7. Spectre de la puissance instantanée à basse fréquence **[25]**

II.7 Conclusion

La conclusion souligne l'importance cruciale des méthodes de diagnostic pour assurer la fiabilité et la performance des machines électriques. En utilisant des techniques telles que l'analyse fréquentielle du couple électromagnétique, l'analyse spectrale de la puissance instantanée, et l'analyse des signaux vibratoires, il est possible d'identifier une gamme étendue de défauts, des anomalies électromagnétiques aux problèmes mécaniques. Ces méthodes, combinées avec le suivi des grandeurs mesurables et l'analyse du vecteur de Park, permettent une surveillance efficace de l'état de santé des machines. En intégrant ces techniques dans une stratégie de surveillance et de maintenance préventive, on peut prévenir les pannes coûteuses et les interruptions de production, améliorant ainsi la fiabilité, la sécurité et la durabilité des machines électriques dans diverses applications industrielles.

CHAPITRE III

Méthodes avancées de détection et classification des défauts des machines électriques

III.1 Introduction

Le Chapitre III se concentre sur les techniques avancées de détection et classification des défauts des machines électriques **[5]**, une étape cruciale dans le domaine de la maintenance prédictive et de la fiabilité des systèmes électriques **[28]**. Dans un contexte industriel où la performance et la disponibilité des machines sont essentielles **[14]**, la détection précoce et précise des défauts est devenue une priorité **[5]**. Ce chapitre explore diverses approches modernes pour améliorer la détection des défauts, notamment les réseaux de neurones **[29-32]**, le traitement de signal avancé **[33]**, et l'apprentissage automatique **[34]**. Nous aborderons également des méthodes spécifiques telles que la Machine à Vecteurs de Support (SVM) **[71-75]**, les Arbres de Décision **[37][74]**, et la méthode des k plus proches voisins (KNN) **[76-78]**, en mettant l'accent sur leur application dans le domaine des machines électriques **[36]**. L'objectif principal est de fournir une compréhension approfondie des techniques avancées disponibles pour la détection et la classification des défauts, ainsi que de leur mise en œuvre pratique.

III.2 Traitement de signal avancé

L'analyse des courants statoriques, notamment par la MCSA (Motor Current Signature Analysis), est couramment utilisée pour détecter les défauts électriques et mécaniques dans les machines électriques. Cette méthode se concentre sur l'analyse de la densité spectrale de puissance (DSP) des courants. Les défauts se révèlent par de nouvelles composantes fréquentielles ou une augmentation d'amplitude à certaines fréquences clés. Les approches pour identifier ces changements se divisent en trois catégories : estimation de la DSP, démodulation du courant statorique, et techniques temps/fréquence. **[33]**

Les signaux, tels que les courants statoriques ou rotoriques des machines asynchrones, servent à transmettre l'information entre capteurs et récepteurs, utilisés à la fois pour le contrôle/commande et le diagnostic. En environnement stable, l'identification des défauts se fait par l'analyse de la densité spectrale de puissance, incluant le périodogramme et les techniques à haute résolution comme MUSIC et ESPRIT. Ces méthodes sont appliquées sur des courants statoriques triphasés échantillonnés avec une fréquence d'une période, comme illustré sur des signaux d'un banc expérimental présentant une défaillance de rupture de barres. **[33]**

III.2.1 Démodulation des courants statoriques

Les techniques de démodulation permettent d'estimer la fréquence et l'amplitude instantanées d'un signal $x[n]$ **[69]**. La plupart des méthodes présentées reposent principalement sur l'évaluation du signal analytique selon le diagramme de la figure III.5.

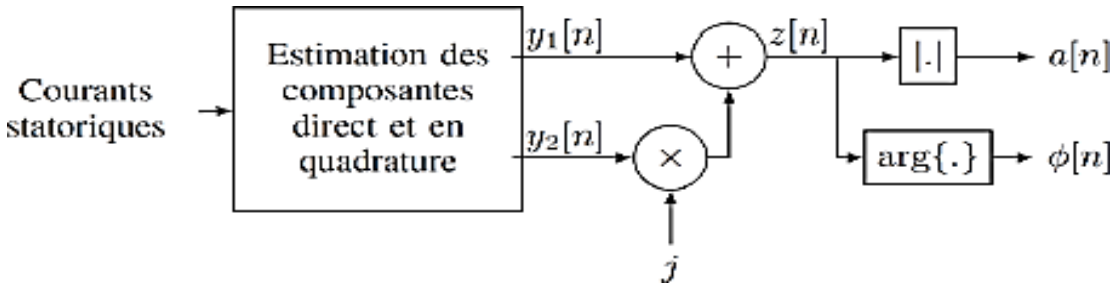


Figure III 1. Estimation du signal analytique

Les méthodes de démodulation se divisent en deux catégories principales : les techniques monodimensionnelles qui se basent sur l'acquisition du courant d'une seule phase, et les techniques multi-dimensionnelles qui exigent la mesure des courants des trois phases. Ces méthodes sont illustrées pour détecter un défaut de roulement, où les courants statoriques triphasés sont échantillonnés sur une période de temps donnée. **[33]**

III.2.2 Analyse des signaux non stationnaires des machines asynchrones

Les signaux provenant des machines asynchrones sont non stationnaires, car leur contenu fréquentiel varie avec le temps. Cette non-stationnarité résulte par :

- La vitesse changeante de la machine électrique (la fréquence des courants statoriques/rotoriques est liée à la vitesse de rotation).
- La phase de démarrage et d'arrêt de la machine (régime transitoire).

Le traitement de ces signaux nécessite des outils adaptés. On utilise des représentations de l'amplitude du signal en fonction du temps et de la fréquence pour visualiser l'évolution du contenu fréquentiel. Parmi les outils employés, on trouve :

- Le spectrogramme basé sur la STFT.
- Les distributions quadratiques temps/fréquence comme le Wigner-Ville.
- Les ondelettes (scalogramme).
- La transformée de Hilbert-Huang. **[33]**

Certaine technique ça représentation a été implémentée en utilisant la Toolbox temps fréquence sous Matlab **[33]** sauf pour la THH qui a été réalisée en utilisant l'algorithme G. Rilling sous Matlab **[70]**.

III.3 Apprentissage automatique

Les techniques d'apprentissage automatique se divisent principalement en deux catégories, l'apprentissage supervisé et l'apprentissage non supervisé, illustrées par la figure III.6.

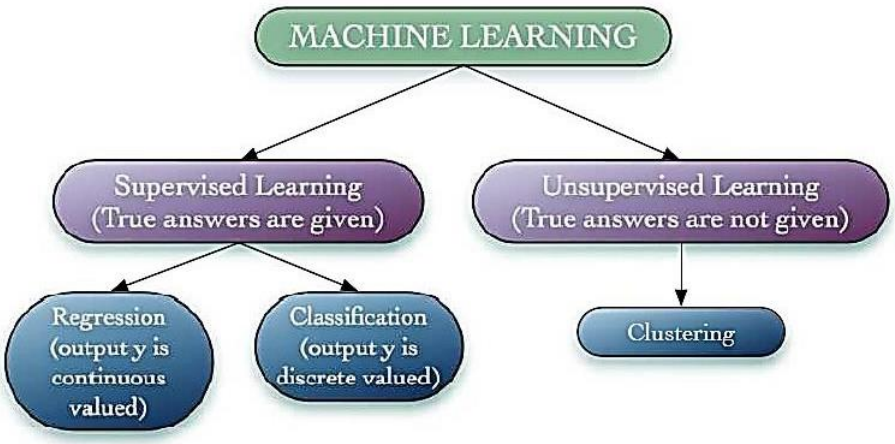


Figure III 2. Méthodologies courantes d'apprentissage automatique **[34]**

En apprentissage supervisé, chaque élément d'entraînement est lié à une solution connue. Ce type d'apprentissage se divise en deux phases : l'apprentissage, où le système analyse les données pour en saisir le fonctionnement, et la prédiction, où il utilise ces acquis pour prédire des résultats, comme montré dans la Fig. III.6. Les formes principales d'apprentissage supervisé incluent la régression et la classification, où la solution correcte est définie pour chaque cas.

À l'opposé, l'apprentissage non supervisé travaille sans accès direct à des solutions pour les données d'entraînement. Par ailleurs, des méthodes mixtes comme l'apprentissage par renforcement combinent des éléments des deux formes d'apprentissage. **[34]**

III.3.1 Terminologie

Cette section propose une introduction aux concepts couramment employés en apprentissage automatique.

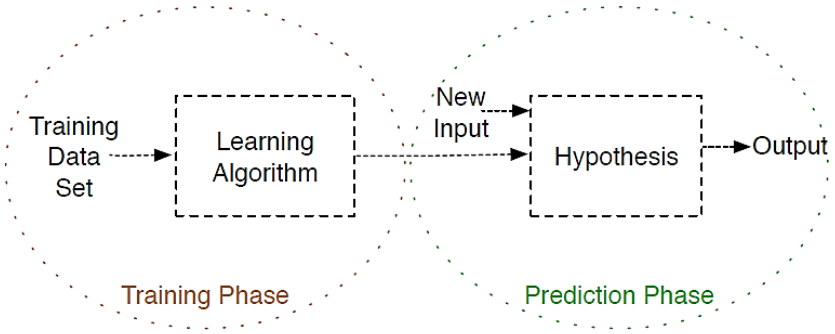


Figure III 3. Bases de l'apprentissage supervisé

Les outils d'apprentissage automatique tels que MATLAB et Tensorflow fournissent des paramètres par défaut simples, adaptés aux débutants. Même si les résultats peuvent ne pas être parfaits, l'utilisation de vecteurs d'entrée et de sortie est aisée pour démarrer. Les configurations peuvent différer, mais une convention standard existe. Chaque élément est présenté sur des lignes séparées du vecteur d'entrée, comme démontré dans un cas de régression supervisée.

III.3.2 Étapes vers la machine Learning

Visualiser les données

Une analyse initiale des données guide le concepteur dans le choix des caractéristiques, du modèle et de la fonction de coût. Bien que les algorithmes ajustent les paramètres, la structure globale est souvent définie par l'humain.

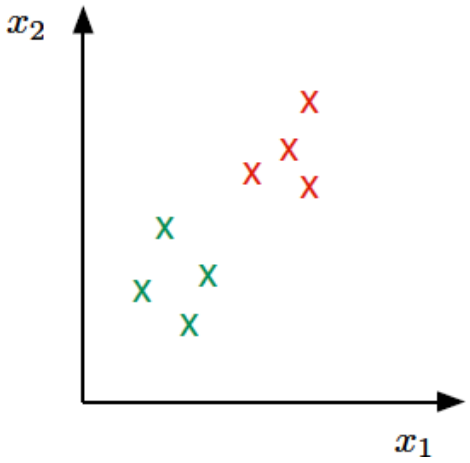


Figure III 4. Exemple de classification

Cette section compare les approches des problèmes de régression et de classification. En régression, l'axe des y représente le résultat, tandis que dans la classification, y indique des classes spécifiques. La régression logistique peut être efficace si les données sont séparées par une limite de décision linéaire, visible sur la figure III.8. Pour des ensembles de données complexes, la sélection du modèle peut nécessiter des techniques avancées plutôt que la simple visualisation.

Cartographie des fonctionnalités

Selon la visualisation des données, il peut être crucial de transformer les caractéristiques pour éviter une simple application de régression linéaire ou logistique.

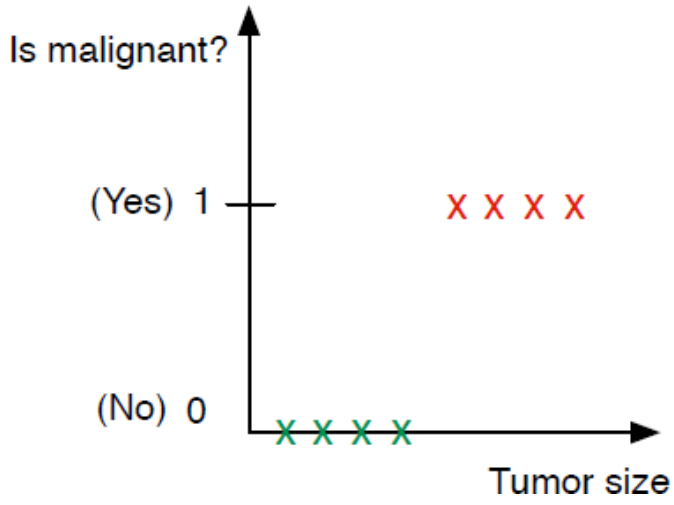


Figure III 5. Exemple de classification – sortie par rapport à l'entrée

En cas d'inadéquation d'un modèle linéaire pour représenter les données, une transformation des caractéristiques est nécessaire. Par exemple, dans la figure III.9, pour améliorer l'ajustement aux données de régression, de nouvelles caractéristiques peuvent être créées en fonction des caractéristiques initiales.

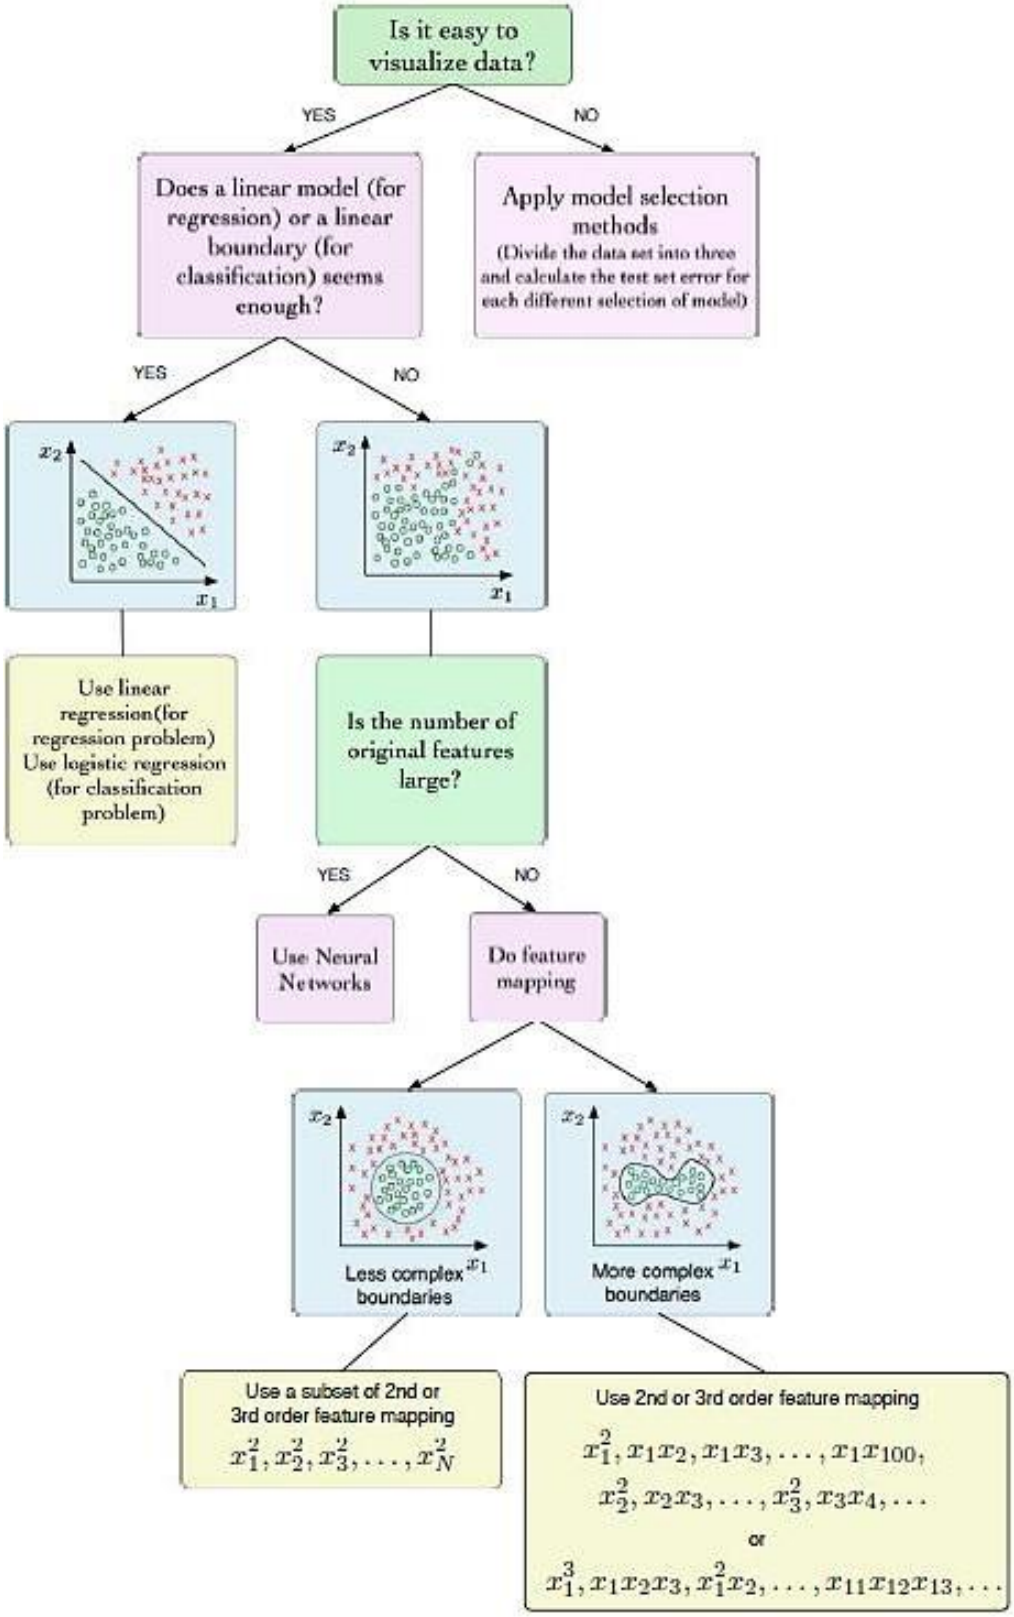


Figure III 6. Guide simplifié pour le mappage des fonctionnalités **[34]**

III.3.3 Réseaux de neurones

Les réseaux de neurones se structurent en couches de nœuds qui transforment de manière non linéaire les entrées en sorties, capturant ainsi les caractéristiques des pages. Ces caractéristiques servent à simuler un raisonnement humain et à ajuster les poids synaptiques lors de la phase d'apprentissage avec un jeu de données (spam, non-spam). Une fois cette étape franchie, le réseau fonctionne comme un filtre anti-spam conventionnel. L'agencement et la configuration des couches et des neurones influencent le processus de classification.

À la différence d'autres méthodes de classification supervisée, les réseaux de neurones se distinguent par leur rapidité et leur capacité à adapter le taux de faux positifs en ajustant la sensibilité. Néanmoins, leur mise en œuvre requiert une expertise poussée pour optimiser leurs paramètres. **[29]**

III.3.3.1 Description de réseau de neurones

Le modèle de réseau neuronal artificiel (RNA) est une structure mathématique inspirée des circuits neuronaux biologiques, conçue pour simuler la manière dont le cerveau humain traite l'information et apprend par expérience. Il s'adapte continuellement, ajustant sa configuration selon la phase d'apprentissage et réagissant de manière adaptée aux nouveaux événements, en s'appuyant sur les connaissances acquises pendant l'entraînement **[30]**. Grâce à leur capacité à appréhender des relations entrée/sortie complexes et non linéaires, les RNA sont utilisés pour résoudre divers problèmes. Ils offrent une grande résistance au bruit et une robustesse élevée, ce qui les rend plus stables que les méthodes conventionnelles en ingénierie électrique face aux variations opérationnelles. **[31]**

La structure d'un RNA se compose de neurones interconnectés organisés en couches. Chaque neurone combine les informations de la couche précédente en fonction de poids et de seuils d'activation spécifiques. Contrairement aux systèmes experts. La figure III.1 présente la structure d’un RNA à propagation avant (feedforward) connu sous le nom de perceptron. **[31]**

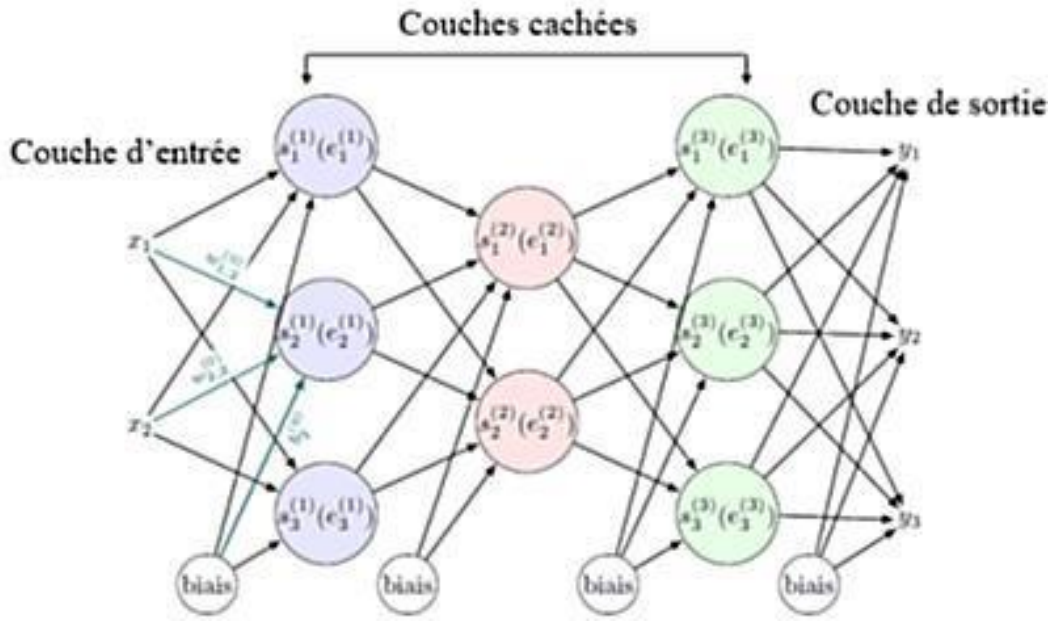


Figure III 7. Illustration d'un réseau de neurones feedforward **[31]**

Les RNA ne reposent pas sur une base de connaissances préétablie ; ils apprennent en ajustant leurs poids et leurs seuils selon les données d'entrée et les sorties souhaitées. **[32]** Ils sont sollicités dans divers domaines, tels que le traitement du signal, la prise de décision, la détection, la classification et la localisation de défauts.

L'un des défis majeurs des RNA réside dans la détermination du nombre optimal de couches et de neurones par couche. Toutefois, leur capacité de généralisation est un atout notable. Conçus pour le calcul parallèle, ils peuvent traiter des entrées non vues pendant l'apprentissage. Un progrès significatif a été la mise au point de l'algorithme d'apprentissage adaptatif, notamment la méthode de propagation de l'erreur, qui ajuste les poids pour minimiser l'écart entre les sorties attendues et réelles lors d'un apprentissage supervisé. **[31]**

III.3.3.2 Réseau de neurones feedforward

Plusieurs types et structures de réseaux de neurones artificiels existent, notamment les réseaux récurrents Elman **[67]**, les réseaux de neurones de type Extrême Learning Machine sont également parmi les architectures utilisé **[68]**. Les réseaux de feedforward sont largement adoptés pour leur facilité d'utilisation et de mise en œuvre. Dans ces systèmes, les données circulent d'une manière linéaire, de l'entrée vers la sortie, sans formes cycliques ou répétitives. Le choix des

fonctions d'erreur et d'activation est souvent influencé par le type de données manipulées. Un modèle multicouche standard est composé de trois couches principales : une pour les entrées, une pour les sorties et une ou plusieurs couches intermédiaires, chacune contenant un nombre spécifié de neurones. Ces neurones combinent les entrées pondérées pour générer une sortie linéaire, sur laquelle est ensuite appliquée une fonction d'activation avant d'être transférée à la couche suivante. La structure de base d'un neurone est présentée dans la figure III.2. **[31]**

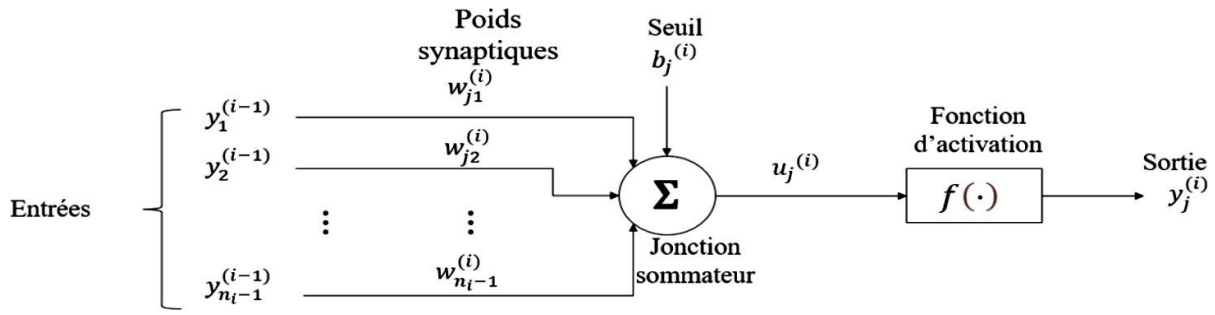


Figure III 8. La structure de base d'un neurone **[31]**

Le modèle mathématique d'un neurone artificiel est structuré de manière plus simplifiée par rapport à son homologue biologique, et peut être représenté par l'équation suivante :

$$y_j^{(i)} = f\left(b_j^{(i)} + \sum_{k=1}^{n_{i-1}} w_{jk}^{(i)} y_k^{(i-1)}\right) \qquad (III.1)$$

Avec :

f C'est la fonction de transfert du neurone j.

i C'est la couche cachée.

$y_k^{(i-1)}$, $k = 1, \ldots, n_{i-1}$, C'est les signaux d'entrée du neurone j et n nombre de neurones dans la couche cachée i.

$w_{jk}^{(i)}$ C'est les coefficients de poids de la connexion entre les entrées et le neurone j.

$b_j^{(i)}$ C'est le biais du neurone j.

III.3.3.3 Détecteur neuronal

La première étape pour protéger les lignes de transmission est la détection des défauts. L'efficacité d'un détecteur neuronal de défauts repose sur la précision de ses mesures d'entrée et la qualité des données d'entraînement. Il est essentiel de gérer, filtrer et mettre à l'échelle ces données

de manière adéquate pour simplifier le problème et réduire la taille du réseau nécessaire. Ce processus est illustré dans la figure III.9. **[31]**

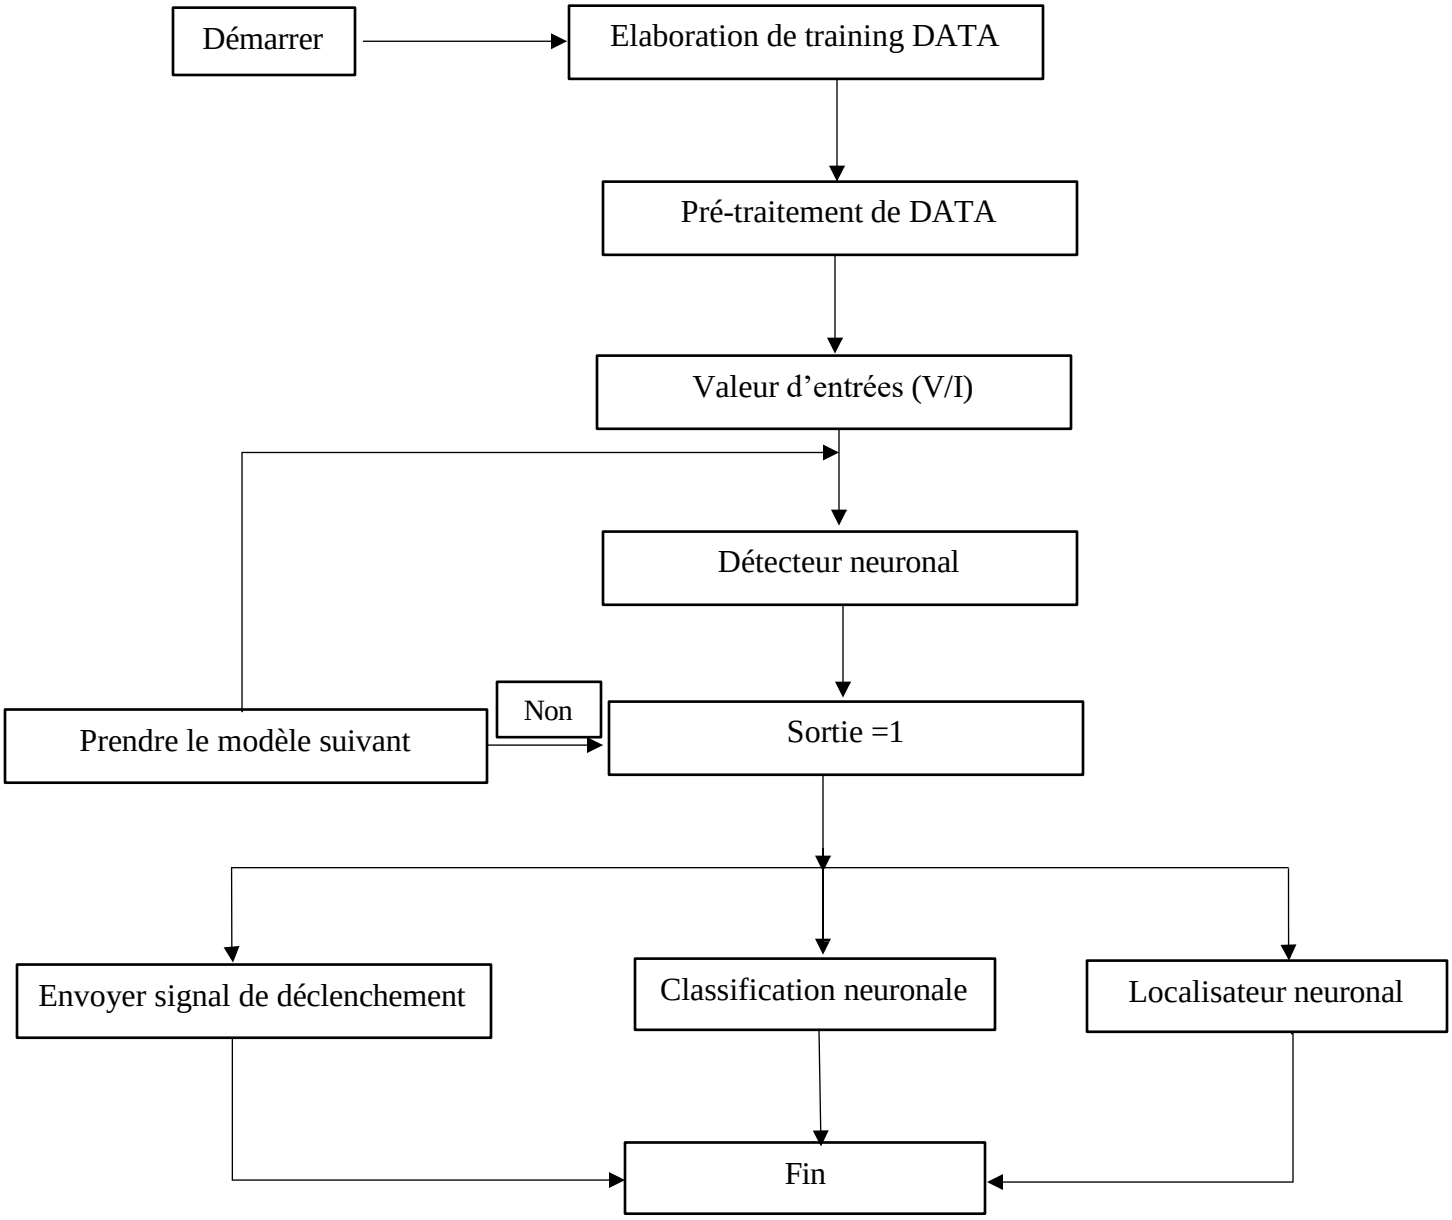


Figure III 9. Illustration de la méthodologie adoptée

Le détecteur neuronal est conçu pour repérer les défauts dans les lignes de transmission en analysant les états du réseau électrique à partir des tensions et courants instantanés $(i_{(t)}, v_{(t)})$. Avant leur traitement par le réseau neuronal, une technique de mise à l'échelle est utilisée pour normaliser ces signaux, ce qui est crucial pour accélérer le temps de calcul.

III.3.3.4 Extraction des données

Pour une simulation réussie du modèle RNA concernant la détection, la classification et la localisation des défauts, il est essentiel de disposer d'un ensemble approprié de données pour l'entraînement, les tests et la validation. Étant donné la difficulté de collecter ces données en grande quantité, les chercheurs les produisent en simulant des défauts électriques à l'aide d'outils comme Matlab/Simulink, ETAP ou EMTP, en modifiant divers paramètres tels que le type et la résistance des défauts.

Bien que les signaux de courant et de tension soient riches en informations, les interpréter directement reste un défi. Pour cela, les techniques d'extraction de caractéristiques sont mises en œuvre pour sélectionner et extraire les données pertinentes, limitant ainsi la complexité du système étudié.

L'utilisation de ces méthodes permet aux chercheurs d'avoir une meilleure compréhension des enjeux de classification ou de localisation des défauts et de les adresser de façon plus efficiente. De plus, en réduisant la taille des données, les algorithmes peuvent gagner en performance, offrant ainsi des résultats plus fiables et précis dans un délai plus court. **[31]**

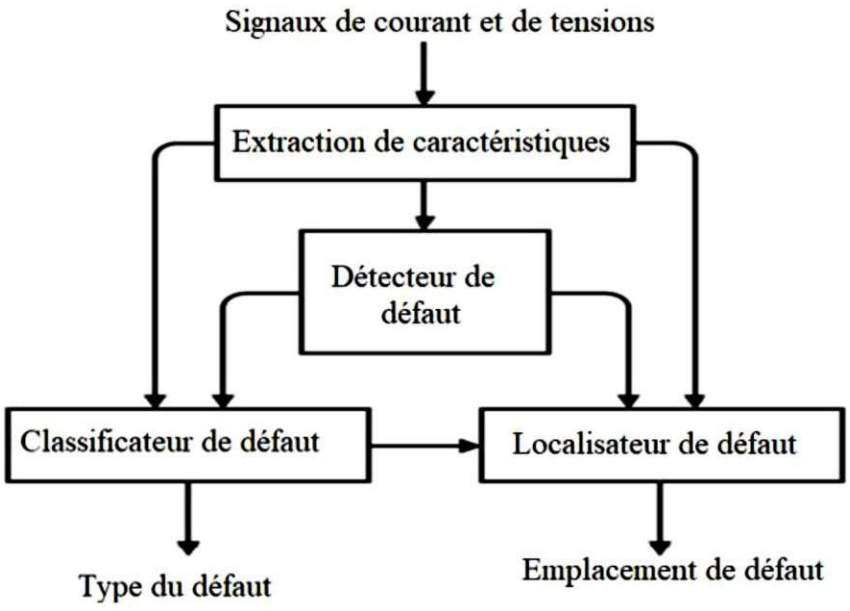


Figure III 10. Algorithme simplifié pour la détection, la classification et la localisation des défauts

Différentes méthodes sont utilisées pour extraire et traiter les signaux, notamment la Transformée de Fourier, la Transformée en ondelette et la Moyenne quadratique (RMS). Dans ce rapport, la méthode RMS est employée pour extraire les caractéristiques des signaux étudiés, consistant à calculer la moyenne quadratique réelle du signal d'entrée par la formule suivante :

$$RMS(f(t)) = \sqrt{\frac{1}{T}\int_{t-T}^{t} f(t)^2 dt} \qquad (III.2)$$

Avec $f(t)$ est le signal d'entrée et $T = \frac{1}{f}$ tel que f est fréquence fondamentale. **[31]**

III.3.4 Machine à vecteurs de support (SVM)

Les Machines à Vecteurs de Support (SVM) ont émergé comme une approche puissante dans le domaine de l'apprentissage automatique, offrant des capacités de classification robustes et précises. Dans le contexte spécifique de la détection de défauts dans les machines électriques, les SVM jouent un rôle crucial en permettant une analyse sophistiquée des données électriques pour identifier les signaux anormaux associés à des problèmes potentiels.

Les SVM offrent une approche prometteuse pour la détection de défauts en exploitant la capacité de séparation des données dans des espaces de dimension supérieure. Grâce à leur capacité à identifier des modèles complexes dans les données électriques, les SVM peuvent être utilisées pour détecter les anomalies subtiles ou les changements subtils dans les signaux électriques qui indiquent un dysfonctionnement émergent dans les machines électriques.

Dans cette partie, nous explorerons en détail le fonctionnement des Machines à Vecteurs de Support (SVM) et leur application spécifique dans la détection de défauts des machines électriques. Nous examinerons les principes fondamentaux des SVM, leur processus d'optimisation, les paramètres clés à prendre en compte, et comment ils peuvent être mis en œuvre pour construire des modèles de détection de défauts robustes et fiables. En outre, nous discuterons des avantages et des limitations des SVM dans ce contexte, ainsi que des meilleures pratiques pour leur utilisation efficace.

III.3.4.1 Fonctionnement des SVM

Les Machines à Vecteurs de Support (SVM) sont des classifieurs basés sur deux principes fondamentaux. Tout d'abord, elles utilisent le concept de marge, qui représente la distance entre une frontière de décision et les échantillons de données. Cette marge est évaluée en se référant aux

vecteurs supports. L'objectif est de sélectionner une frontière de décision qui maximise cette marge (max margin), ce qui permet de trouver la frontière optimale pour séparer les différentes classes dans un ensemble d'apprentissage. **[35]**

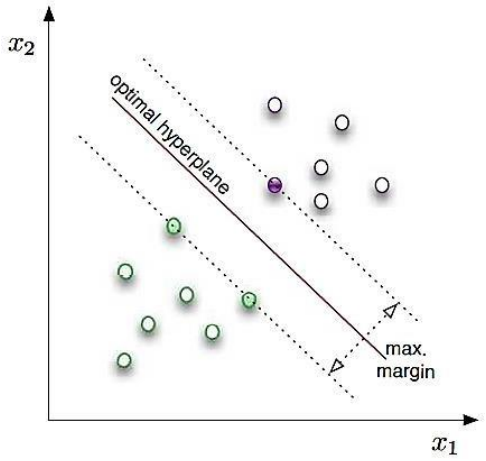


Figure III 11. Principe de fonctionnement des SVM

L'objectif des SVM est de trouver un hyperplan optimal (optimal hyperplane) qui maximise la marge, c'est-à-dire la distance entre les frontières, en les étendant jusqu'à ce qu'elles touchent les premiers points de données (vecteurs supports). **[34]**

Ensuite, pour traiter les situations où les données ne peuvent pas être séparées de manière linéaire dans l'espace d'entrée, les SVM utilisent une technique appelée "kernel trick". Cette méthode consiste à projeter les données dans un espace de plus grande dimension, où il est probable qu'une séparation linéaire puisse être réalisée.

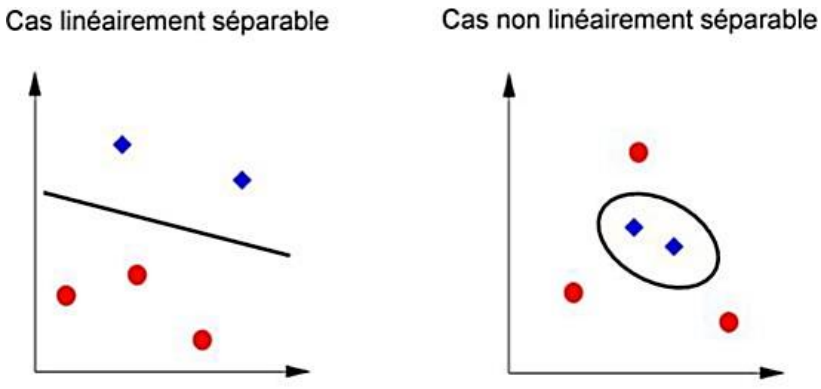


Figure III 12. Les deux cas de linéarité **[72]**

Cas de données linéairement séparables :

Dans le cas le plus simple les données sont linéairement séparables comme indiquées dans la figure III.13 :

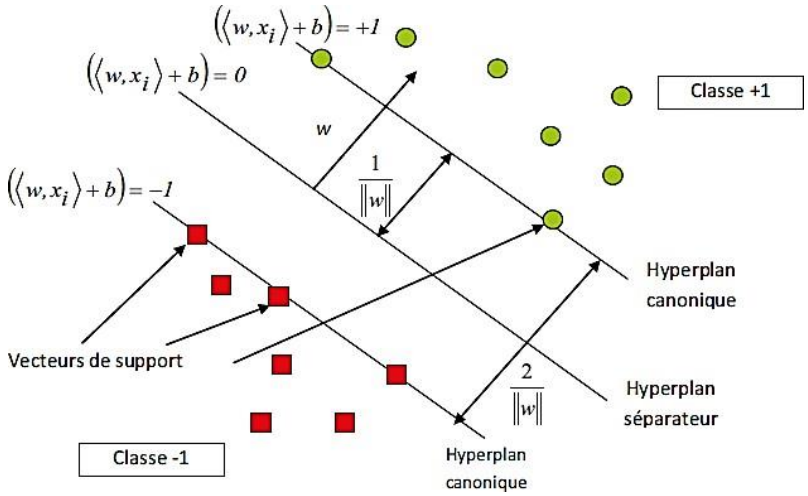


Figure III 13. Séparation linéaire **[72]**

Il est évident qu'il existe une multitude d'hyperplans séparateurs capables de diviser l'ensemble D en deux classes sans erreurs, mais la question demeure : comment trouver le séparateur optimal ? Dans le cas d'une séparation linéaire, l'hyperplan séparateur est défini par une fonction discriminante linéaire des exemples x : $f(x) = \langle w, x \rangle + b$

w Et b sont les paramètres de l'hyperplan séparateur, où w est le vecteur de poids qui définit la direction perpendiculaire à l'hyperplan séparateur et b est le terme de biais (un scalaire). Ces paramètres sont calculés à partir des données constituant l'ensemble D.

L'hyperplan optimal, également appelé $\boldsymbol{HO}$, est défini comme étant celui qui maximise la marge, représentant la plus petite distance entre les données des deux classes et l'hyperplan. Cette maximisation de la marge équivaut à maximiser la somme des distances entre les données de chaque classe et l'hyperplan. En d'autres termes, l'hyperplan optimal est celui pour lequel la distance aux points les plus proches, également appelée marge, est maximale.

Son expression est définie comme suit :

$$M = \min_{x_i | y_i = 1} \frac{w.x + b}{||w||} - \max_{x_i | y_i = -1} \frac{w.x + b}{||w||} = \frac{1}{||w||} - \frac{-1}{||w||} = \frac{2}{||w||} \qquad (III.3)$$

La recherche de l'hyperplan optimal implique donc la maximisation de la marge max sous

certaine contrainte, parmi elles : **[71]**

- Problème primal
- Problème dual

Cas de données non-linéairement séparables :

Dans la plupart des problèmes réels, les données ne sont pas linéairement séparables en raison de la nature non linéaire des systèmes et de la présence de bruit dans les données mesurées, comme illustré dans la Figure III.14 :

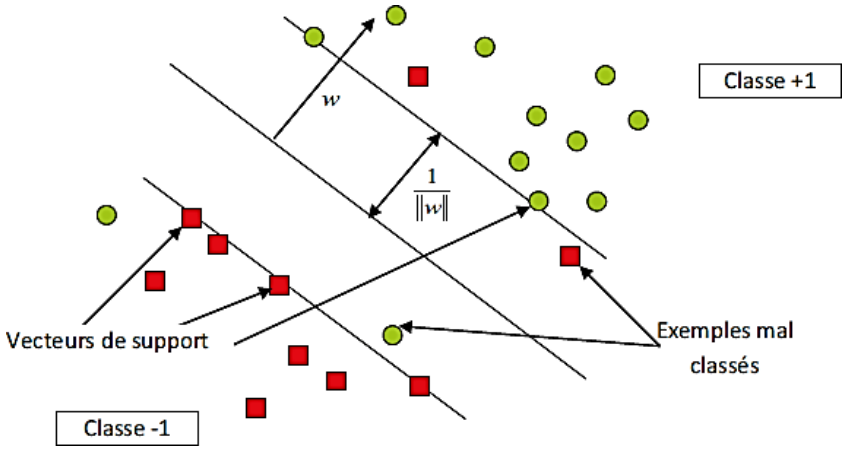


Figure III 14. Séparation linéaire avec des erreurs **[72]**

L'hyperplan optimal sera défini par les conditions suivantes :

- La distance entre les vecteur correctement classés et l'hyperplan optimal doit être maximisée.
- La distance entre les vecteurs incorrectement classés et l'hyperplan optimal doit être minimisée.

Pour formaliser cela, des variables d'écart non négatives, notées ξ_i pour $i = 1, \ldots, m$, sont introduites, l'objectif finale sera de minimaliser la fonction suivante :

$$\boldsymbol{\Psi}(\omega, \Xi) = \frac{1}{2}\omega.\omega + C\sum_{1}^{m}\xi_i \qquad (III.4)$$

Dans cette formule, le paramètre C'est un paramètre de régularisation qui contrôle le compromis entre la maximisation de la marge et la réduction des erreurs de classification.

III.3.4.2 Application des SVM dans la détection de défauts

Les SVM sont largement utilisées dans la détection de défauts dans les machines électriques en raison de leur capacité à séparer efficacement les données en fonction de leur classe. Dans ce contexte, les SVM peuvent être formées sur des ensembles de données comprenant des mesures de diverses grandeurs électriques, telles que le courant, la tension, la puissance, etc., pour détecter les anomalies qui indiquent un dysfonctionnement de la machine.

Pour appliquer SVM à la détection de défauts dans les machines électriques, il est nécessaire de suivre ces étapes :

- Collecter les données de fonctionnement des machines électriques, telles que les signaux de température, courant et tension.
- Prétraiter les données pour enlever les bruits et les anomalies.
- Utiliser SVM pour séparer les classes de données en utilisant une frontière optimale.
- Évaluer les performances de SVM en comparant les résultats de la classification avec des données de test.

Les SVM sont des classifieurs binaires, ce qui signifie qu'ils ne peuvent différencier que deux classes d'individus. Cependant, ils peuvent être appliqués à plusieurs reprises à chaque combinaison possible de classes. Les variables descriptives du problème doivent être des variables continues **[36]**.

L'algorithme de machine à vecteurs de support (SVM) est utilisé pour détecter les défauts dans les machines électriques en utilisant plusieurs critères :

La première considération est la marge de séparation, que SVM cherche à maximiser entre les classes. Cette marge permet de détecter les défauts en évaluant la distance entre les données normales et anormales.

Ensuite, SVM identifie les vecteurs de support, qui sont les exemples les plus proches de la frontière de séparation entre les classes. Ces vecteurs sont essentiels pour définir la fonction de décision qui sépare les classes.

Une autre technique clé utilisée par SVM est le kernel trick, qui consiste à transformer les données dans un espace de plus grande dimension pour trouver une séparation linéaire. Les types

de noyaux utilisés incluent le noyau polynomial, le noyau gaussien, le noyau sigmoïde et le noyau laplacien. **[36]**

SVM nécessite également la définition d'hyperparamètres tels que la fonction de perte, le type de noyau et ses paramètres. L'optimisation de ces hyperparamètres est cruciale pour obtenir les meilleures performances dans la détection des défauts.

Enfin, pour évaluer l'efficacité de l'algorithme, SVM utilise des méthodes de **validation** telles que la validation croisée et la validation holdout. Ces méthodes permettent de comparer les résultats de l'algorithme avec des données de test et de valider la précision et la fiabilité de la détection de défauts.

La SVM combine la maximisation de la marge de séparation, l'identification des vecteurs de support, l'utilisation du kernel trick, la définition des hyperparamètres et la validation pour détecter et classifier les défauts dans les machines électriques.**[36][73]**

En utilisant des SVM, il est possible de construire des modèles de détection de défauts qui peuvent identifier des schémas subtils ou complexes dans les données électriques, permettant ainsi aux opérateurs de surveiller efficacement l'état de santé des machines et de prendre des mesures préventives en cas de besoin. Ces modèles peuvent également être adaptés à différents types de machines électriques et à diverses conditions de fonctionnement pour une détection précise et fiable des défauts.

III.3.5 Les arbres de décision

Les arbres de décision sont des algorithmes d'apprentissage automatique largement utilisés dans le domaine de la détection de défauts des machines électriques. Leur popularité découle de leur capacité à générer des modèles de décision interprétables tout en étant efficaces dans la classification et la prédiction. Dans cette section, nous explorerons en détail les principes fondamentaux des arbres de décision, leur construction, leur fonctionnement, ainsi que leur application spécifique dans la détection de défauts des machines électriques. Nous examinerons également les avantages et les limites de cette méthode, ainsi que les meilleures pratiques pour leurs utilisations dans un contexte de diagnostic de défauts. En comprenant les fondements théoriques et pratiques des arbres de décision, nous serons en mesure d'exploiter pleinement leur potentiel pour améliorer la maintenance prédictive et la fiabilité des machines électriques.

III.3.5.1 Structure des arbres de décision

Les arbres de décision sont parmi les méthodes de classification les plus répandues et les plus appréciées, en raison de leur capacité à résoudre efficacement des problèmes complexes. Leur popularité découle principalement de leur représentation intuitive et de leur capacité à générer des règles de décision compréhensibles. Un arbre de décision se compose de nœuds de décision, où chaque nœud effectue un test sur un attribut spécifique, de branches qui représentent les différentes valeurs de l'attribut sélectionné, et de feuilles qui contiennent les instances appartenant à la même classe.

Pour comprendre comment un arbre de décision prédit une réponse, il est nécessaire de suivre les décisions prises à partir du nœud racine (point de départ) jusqu'au nœud feuille qui contient la réponse. Les arbres de classification fournissent des réponses catégoriques, telles que vrai ou faux, tandis que les arbres de régression fournissent des réponses numériques. Les arbres de décision sont réputés pour leur rapidité et leur facilité d'interprétation ; vous pouvez visualiser clairement le chemin suivi depuis la racine jusqu'à la feuille. Cette traçabilité est particulièrement précieuse lorsqu'il est nécessaire de partager les résultats avec des parties prenantes désireuses de comprendre le processus de prise de décision.

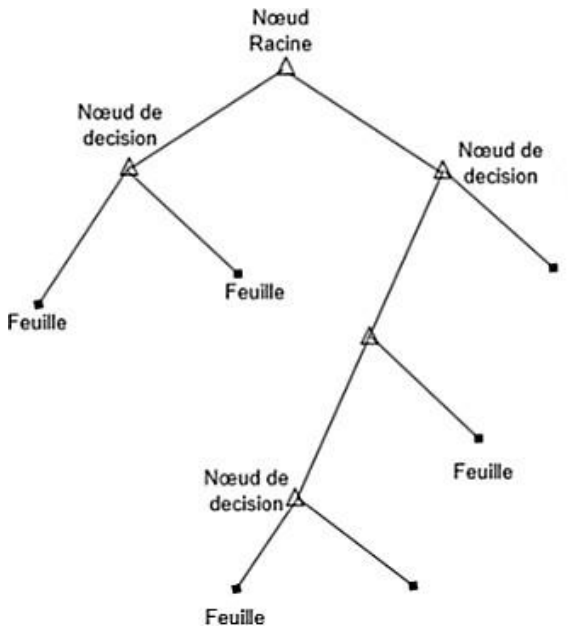


Figure III 15. Illustration d'un arbre de décision **[36]**

L'utilisation des arbres de décision dans la classification implique deux étapes principales : la construction de l'arbre à partir des données d'apprentissage, puis la classification des nouvelles instances en utilisant l'arbre construit. La construction de l'arbre repose sur la sélection d'attributs pertinents pour chaque nœud de décision, ainsi que sur la détermination des classes associées à chaque feuille. Plusieurs algorithmes ont été développés pour cette phase, parmi lesquels ID3, C4.5 et CART, qui sont parmi les plus populaires.

Dans le processus de construction de l'arbre, les données d'apprentissage sont partitionnées en sous-ensembles en fonction des valeurs des attributs. Cette partition est répétée de manière récursive pour chaque sous-ensemble, jusqu'à ce que les feuilles contiennent des instances de la même classe. Il convient de noter que l'algorithme de construction n'est pas déterministe, ce qui signifie que plusieurs arbres différents peuvent être construits pour classifier correctement toutes les instances d'apprentissage. **[74]**

Un arbre de décision est une structure hiérarchique composée de règles logiques ou de production, qui est automatiquement construite à partir d'un ensemble de données donné. La création de cet arbre implique l'utilisation de descripteurs pour diviser progressivement l'ensemble de données en sous-ensembles de plus en plus spécifiques.**[36]** L'algorithme évalue la probabilité qu'une observation appartienne au nœud t en utilisant la formule suivante :

$$P(T) = \sum_{j \in T} w_j \qquad (III.5)$$

Où :

w_j Représente le poids des observations.

T Est l'ensemble des indices d'observation du nœud t.

n Est le nombre total d'observations dans l'ensemble de données.

III.3.5.2 Types d'arbres de décision

Les arbres de décision sont des algorithmes de classification qui utilisent un arbre de décision pour classer des données en fonction de leurs caractéristiques. Il existe plusieurs types d'arbres de décision, chacun avec des avantages et des inconvénients spécifiques. Voici une liste de quelques types d'arbres de décision mentionnés dans les résultats de recherche :

- **Fine Tree :** Les arbres de décision fins sont conçus pour fournir une précision élevée dans la classification des données. Ils sont particulièrement utiles pour les applications où une

grande précision est nécessaire, comme la classification de données médicales ou la détection de spam. Dans le domaine de la classification des données médicales, les arbres de décision fins sont utilisés pour analyser les données de santé et déterminer si un patient est atteint d'une maladie spécifique. Ils sont également utilisés pour la classification de données en fonction de leur importance dans le cadre de la décision médicale.

- **Medium Tree :** Les arbres de décision médiums sont un compromis entre la précision et la rapidité. Ils sont utilisés dans des applications où la précision n'est pas la priorité principale, mais où il est important de traiter les données rapidement. Par exemple, dans le domaine de la classification des images, les arbres de décision médiums sont utilisés pour classer les images en fonction de leurs caractéristiques telles que la taille, la forme et la couleur. Ils sont également utilisés dans le domaine de la classification des données géologiques pour classer les données en fonction de leur importance dans le cadre de la décision géologique 3.

- **Coarse Tree :** Les arbres de décision grossiers sont conçus pour traiter des données en volume rapidement. Ils sont particulièrement utiles pour les applications où la rapidité est la priorité, comme la classification de données en fonction de leur importance dans le cadre de la décision médicale ou la classification des données en fonction de leur importance dans le cadre de la décision géologique. Dans le domaine de la classification des données géologiques, les arbres de décision grossiers sont utilisés pour classer les données en fonction de leur importance dans le cadre de la décision géologique, en particulier pour classer les données en fonction de leur importance stratigraphique et tectonique.

Les arbres de décision sont utilisés dans diverses applications, y compris la classification de données médicales, la détection de spam, la reconnaissance de pattern dans le contrôle statistique des processus, la classification des images, la prédiction de la popularité des affichages publicitaires et la classification des données géologiques. Ils sont également utilisés pour la classification des données en fonction de leur importance dans le cadre de la décision médicale et la décision géologique. **[37]**

Les arbres de décision sont également utilisés dans le domaine de la sécurité informatique pour détecter et prévenir les attaques de type DDoS (distributed denial of service) dans les réseaux de type Software Defined Network (SDN). Dans ce domaine, les arbres de décision sont utilisés pour

classer les données de trafic réseau en fonction de leurs caractéristiques telles que la taille, la fréquence et la durée, et pour détecter les attaques DDoS en fonction de leurs caractéristiques telles que la nature et la gravité **[75]**.

III.3.5.3 Utilisation des Arbres de Décision pour la Détection des Défauts

Les arbres de décision sont des modèles d'apprentissage supervisé qui peuvent être utilisés pour résoudre des problèmes de classification et de régression. Voici comment ils sont appliqués spécifiquement à la détection des défauts dans les machines électriques :

Collecte de Données :

Avant de construire un arbre de décision, il est essentiel de collecter des données provenant des machines électriques. Cela peut inclure des mesures de courant, de tension, de vibrations, de température, etc.

Ces données serviront de base pour entraîner l'arbre de décision à détecter les anomalies.

Construction de l'Arbre :

L'entraînement de l'arbre de décision commence par le nœud racine. À chaque étape, l'algorithme choisit la meilleure caractéristique (ou attribut) pour diviser les données en sous-ensembles homogènes.

Le processus se répète de manière récursive jusqu'à ce que tous les enregistrements soient classifiés sous des étiquettes spécifiques (nœuds feuilles).

Détection des Défauts :

Une fois l'arbre construit, il peut être utilisé pour détecter des défauts potentiels. Si les caractéristiques mesurées dévient de la normale (par exemple, des valeurs de courant ou de tension anormales), l'arbre peut identifier ces anomalies comme des défauts.

III.3.6 Méthode des k plus proches voisins (KNN)

L'algorithme des k plus proches voisins (KNN) est l'une des méthodes les plus simples et les plus populaires en apprentissage supervisé. Il appartient à la catégorie des méthodes d'apprentissage paresseux, car il ne construit pas explicitement de modèle pendant la phase d'apprentissage. Au lieu de cela, il se contente de mémoriser l'ensemble de données d'entraînement pour effectuer des prédictions basées sur la similarité des échantillons.

L'approche sous-jacente de KNN est intuitive : pour prédire la classe d'un nouvel échantillon, il examine simplement les k échantillons les plus proches dans l'espace des

caractéristiques et attribue à l'échantillon à prédire la classe majoritaire parmi ces k voisins. Cette simplicité en fait un outil attrayant pour une variété de tâches de classification et de régression.

Dans cette partie, nous explorerons en détail le fonctionnement de l'algorithme KNN, son utilisation dans la détection de défauts dans les machines électriques et ses implications dans d'autres domaines d'application.

III.3.6.1 Fonctionnement

L'algorithme des k plus proches voisins (KNN) est un algorithme de classification supervisée qui utilise les données d'entraînement pour classer des données nouvellement entrées. Il fonctionne en suivant ces étapes :

Collecte de Données :

Tout d'abord, nous avons besoin d'un ensemble de données déjà classifiées (appelé jeu de données). Ce jeu de données contient des exemples d'entrées avec leurs étiquettes de classe

Choix du Paramètre k :

Nous devons déterminer le nombre de voisins à considérer (k). Une valeur appropriée de k est importante pour obtenir des résultats précis.

Calcul des Distances :

Pour une nouvelle donnée en entrée, nous calculons la distance entre cette donnée et toutes celles déjà présentes dans le jeu de données. Les distances les plus couramment utilisées sont la distance euclidienne et la distance Manhattan. **[78]**

Sélection des k Plus Proches Voisins :

Nous extrayons les k données déjà classifiées les plus proches de la nouvelle donnée entrée.

Ces voisins sont ceux qui ont la plus petite distance avec la nouvelle donnée.

Vote Majoritaire :

Enfin, nous choisissons à quelle famille appartient la nouvelle donnée. Pour cela, nous regardons les étiquettes de classe des k voisins identifiés.

La famille majoritaire parmi ces k voisins est attribuée à la nouvelle donnée.

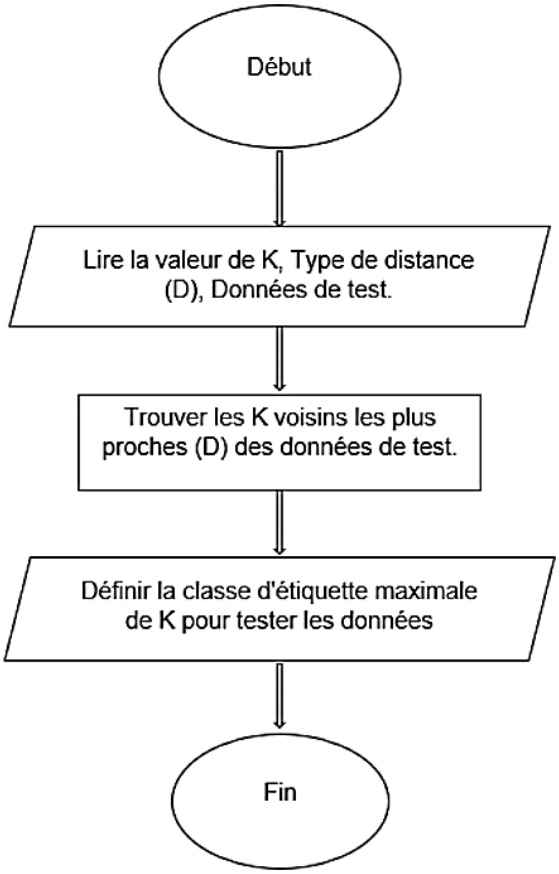


Figure III 16. Organigramme de l'algorithme KNN **[36]**

L'algorithme KNN est relativement simple et efficace pour la classification de données en fonction de leurs caractéristiques. Cependant, il peut être lent pour la classification de données nouvellement entrées, car il nécessite de parcourir les données d'entraînement pour calculer les distances et sélectionner les k plus proches voisins. Les techniques de sélection de prototypes et les algorithmes de KNN pondérés ont été développées pour améliorer les performances de l'algorithme KNN en réduisant la taille des données d'entraînement et en prenant en compte les poids des voisins en fonction de leur proximité **[76][77]**.

La méthode du plus proche voisin est une approche non paramétrique de classification, où une nouvelle observation est attribuée à la classe d'appartenance de l'observation la plus proche dans l'échantillon d'apprentissage, en fonction des covariables utilisées. Cette similarité est évaluée en se basant sur des mesures de distance entre les observations.

Formellement, soit L l'ensemble de données ou l'échantillon d'apprentissage :

$$(L = \{(y_i, x_i), i = 1, \dots, n_L\}) \text{ où } (y \in \{1, \dots, c\})$$

Représente la classe de l'individu i et le vecteur $(x' = (x_1, \dots, x_p))$ désigne les variables prédictives de l'individu i. Le choix du plus proche voisin repose sur une fonction de distance arbitraire $(d(.,.))$.

La distance euclidienne, définie comme suit, est souvent utilisée :

$$d(x, x') = \sqrt{\sum_{j=1}^{p} (x_j - x'_j)^2} \qquad (III.6)$$

Ainsi, pour une nouvelle observation $((y, x))$, le plus proche voisin $((y_{(1)}, x_{(1)}))$ dans l'échantillon d'apprentissage est déterminé par : $[d(x, x_{(1)}) = \min_i(d(x, x_i))]$

La classe prédite $(\hat{y} = y_{(1)})$, celle du plus proche voisin, est alors choisie pour la prédiction de y.

Les notations $(x_{(j)})$ et $(y_{(j)})$ désignent respectivement le (j)ème plus proche voisin de (x) et sa classe d'appartenance.

Parmi les fonctions de distance couramment utilisées, la distance euclidienne est définie comme indiqué précédemment, tandis que la distance de Minkowski s'exprime de manière générale comme suit :

$$d(x, x') = \left(\sum_{j=1}^{p} |x_j - x'_j|^r\right)^{1/r} \qquad (III.7)$$

Cette méthode est justifiée par la nature aléatoire de l'échantillon d'apprentissage. La classe $(Y_{(1)})$ du voisin le plus proche $(x_{(1)})$ d'un nouveau cas (x) est considérée comme une variable aléatoire. Ainsi, la probabilité de classification de (x) dans la classe $(y_{(1)})$ est $P[Y_{(1)}/x_{(1)}]$. Pour de grands échantillons d'apprentissage, les individus (x) et $(x_{(1)})$ sont très similaires, de sorte que $(P[y_{(1)}/x_{(1)}] \approx P[y/x])$.

Ainsi, la nouvelle observation x est prédite comme appartenant à la vraie classe (y) avec

une probabilité approximativement égale à $P[y/x]$. **[77]**

III.5 Conclusion

En conclusion, ce chapitre a présenté un aperçu détaillé des techniques avancées de détection et classification des défauts des machines électriques. Nous avons exploré les réseaux de neurones, le traitement de signal avancé, et l'apprentissage automatique comme des approches prometteuses pour améliorer la précision et l'efficacité de la détection des défauts. Les méthodes spécifiques telles que la Machine à Vecteurs de Support, les Arbres de Décision, et la méthode des k plus proches voisins ont été examinées en détail, mettant en évidence leurs avantages et inconvénients respectifs. Il est clair que l'intégration de ces techniques avancées dans les systèmes de surveillance et de diagnostic des machines électriques peut significativement améliorer la fiabilité opérationnelle, réduire les coûts de maintenance, et prolonger la durée de vie des équipements. Cependant, il est crucial de souligner l'importance d'une mise en œuvre correcte et d'une formation adéquate des modèles pour garantir des résultats fiables et robustes dans des environnements industriels réels. Des recherches continues et des développements innovants dans ce domaine sont nécessaires pour répondre aux défis croissants de la maintenance prédictive et assurer une performance optimale des machines électriques à long terme.

CHAPITRE IV

Classification et Diagnostic de défauts de la machine asynchrone

IV.1 Introduction

Sur l'échelle scientifique de l'industrie 4.0, la sécurité mécanique et électrique joue un rôle crucial dans son évolution. Certaines classifications nous permettent d'obtenir un diagnostic très précis **[2][79]**.

Ce chapitre se concentre sur les stratégies de diagnostic des défauts dans les machines asynchrones, qui revêtent une importance cruciale pour garantir l'efficacité et la durabilité des systèmes industriels électromécaniques **[40-44]**. Nous proposons une approche méthodique pour repérer et classer les anomalies **[3][39][74]**, en couvrant toutes les étapes du processus, de la collecte des données à l'analyse des résultats **[9][41][45]**.

Les récents travaux scientifiques ayant mis en lumière l'importance grandissante du domaine fréquentiel dans le diagnostic des défauts **[1-3][39]**, suggérant ainsi une orientation future vers une exploitation plus efficace des caractéristiques des signaux électriques **[3][5]**.

Une attention particulière sera donc accordée à l'importance des harmoniques d'espaces en tant qu'indicateurs clés de défauts **[3][39][47]**, soulignant les méthodes théoriques et expérimentales utilisées pour la détection et la classification des défaillances **[46][80]**. Contrairement à de nombreux travaux antérieurs, qui utilisent généralement un grand volume de données **[4][5]**, notre approche se concentre spécifiquement sur l'exploitation efficace du courant brut sous forme de densité spectrale avec la tension. Nous avons méticuleusement sélectionné les plages en fonction des harmoniques d'espaces et de leurs composantes principales et additionnelles pour optimiser la sensibilité du diagnostic tout en réduisant la complexité de traitement des données **[47]**.

En évaluant l'efficacité de notre méthode de diagnostic **[79]** à travers des résultats expérimentaux qui se base sur l'apprentissage automatique **[4]**, nous mettrons en évidence la précision et la fiabilité de notre système de détection des défaillances dans diverses conditions opérationnelles **[5]**. Cette approche offre ainsi une contribution significative à l'amélioration de la maintenance préventive et de la gestion des actifs dans les applications industrielles.

IV.2 Présentation de travail adopté pour la classification

Nous avons opté pour l'utilisation des algorithmes disponibles sur les nouvelles versions de MATLAB **[38]** à travers l'outil 'Classification Learner' **[81]** pour effectuer la classification. Après avoir établi un programme MATLAB, nous avons pu importer les données et effectuer des calculs

pour analyser le courant, la tension et la densité spectrale de puissance. Nous avons rassemblé des données sur quatre états spécifiques de la machine asynchrone, à savoir :

- Machine saine.
- Machine avec une barre cassée.
- Machine avec deux barres cassées.
- Machine avec une portion d'anneau de court-circuit cassée.

Chaque état de la machine a été étiqueté avec un chiffre correspondant (1 pour la machine saine, 2 pour celle avec une barre cassée, 3 pour celle avec deux barres cassées, et 4 pour celle avec un court-circuit dans l'anneau). Les signaux ont été générés pour examiner la densité spectrale de puissance (DSP) en utilisant la Transformée de Fourier Rapide (FFT).

Notre objectif principal est d'améliorer la détection des défauts par l'étude des harmoniques en utilisant des techniques avancées. Nous avons étudié le comportement de la machine par rapport à des harmoniques d'espace spécifiques, en particulier les harmoniques fondamentale, $5^{ème}$, $7^{ème}$, $11^{ème}$ et $13^{ème}$. Nous avons centré notre analyse sur ces harmoniques d'espace en excluant les harmoniques temporelles. Nous avons exploré différentes configurations, notamment l'utilisation du fondamental seul et du fondamental combiné avec d'autres harmoniques d'espace jusqu'à la $13^{ème}$ harmonique incluent leurs composantes additionnelles et principales. Les interprétations finales ont été basées sur les pourcentages de précision obtenus à partir des différents algorithmes de classification.

IV.1.1 Exploitation des données

Nous avons développé une méthode d'apprentissage automatique. En collectant un total de 10 000×7 données sous forme de mesures de courant et de tension pour différents défauts de machines, tel que la machine saine, machine avec une barre cassée, avec deux barres cassées et la machine avec une portion d'anneau de court-circuit cassée. Et en utilisant la Transformée de Fourier Rapide, nous avons pu générer la densité spectrale de puissance, ce qui nous a permis de bien comprendre et visualiser le comportement des harmoniques d'espaces. Notre programme de cette méthode peut s'entrainer avec d'autre défauts ou avec d'autre données.

Nous avons utilisé les données de courant et leur spectre pour détecter l'état de la machine. La surveillance de l'amplitude des composantes de fréquence dans le spectre du courant statorique

nous permet de détecter des défauts au niveau de la cage rotorique. De plus, la présence d'une modulation de $2gf$ de courant par rapport au glissement varié donne des informations supplémentaires sur l'état de la machine. Les composantes spécifiques dans le spectre fréquentiel du courant révèlent également des informations sur l'état de la cage rotorique.**[9]**

L'analyse de l'amplitude des harmoniques d'espaces dans le spectre du courant statorique fournit des informations supplémentaires pour le diagnostic de défauts **[9]**. Nous avons constaté qu'une classification basée uniquement sur chaque harmonique d'espace n'était pas optimale, mais en combinant les harmoniques d'espaces jusqu'à la $13^{ème}$, nous avons obtenu une précision élevée. Nous avons présenté le spectre pour chaque harmonique d'espace afin de mettre en évidence les modulations.

Nous avons également pris en compte la tension comme donnée supplémentaire, car elle nous renseigne sur la chute de tension, difficile à détecter par les méthodes classiques. L'utilisation d'un apprentissage automatique a permis d'améliorer la précision de la classification.

Nous avons étiqueté l'état de la machine dans notre matrice de programmation comme suit :

« 1 » Pour la machine saine. « 2 » Pour une machine avec une barre cassée. « 3 » Pour une machine avec deux barres cassées. « 4 » Pour une machine avec une portion d'anneau de court-circuit cassée.

Les résultats obtenus ont été exploités par différents algorithmes, chacun présentant une précision différente. Nous avons choisi les algorithmes les plus résultants tel que :

Support Vector Machine (SVM) : un puissant algorithme d'apprentissage supervisé utilisé pour les tâches de classification. Cela fonctionne en trouvant l'hyperplan qui sépare le mieux les différentes classes dans l'espace des fonctionnalités. SVM vise à maximiser la marge entre les classes tout en minimisant l'erreur de classification **[82]**.

K-Nearest Neighbours (KNN) : un algorithme de classification simple mais efficace. Il classe un point de données en fonction de la classe majoritaire de ses k voisins les plus proches dans l'espace des fonctionnalités. Le choix de « k » affecte la fluidité de la limite de décision**[83]**.

Arbres de décision (Decision Tree) : des algorithmes de classification populaire qui fonctionne en partitionnant l'espace des fonctionnalités en régions, chacune associée à une étiquette

de classe particulière. À chaque nœud de l'arborescence, une décision est prise en fonction de la valeur d'une caractéristique pour diviser les données en deux sous-ensembles ou plus **[84]**.

Réseau de neurones (Neural Network (N.N)) : en particulier les réseaux de neurones à action directe, sont des modèles d'apprentissage automatique polyvalents inspirés de la structure et du fonctionnement du cerveau humain. Ils sont constitués de couches de neurones (nœuds) interconnectées et sont capables d'apprendre des modèles complexes de données grâce à l'entraînement **[85]**.

Analyse discriminante quadratique (Quadratic Discriminant) : est un algorithme de classification probabiliste qui suppose que chaque classe possède sa propre matrice de covariance. Contrairement à l'analyse discriminante linéaire (LDA), la QDA ne suppose pas que la covariance de chaque classe est la même **[86]**.

Les principales différences entre ces algorithmes résident dans leurs principes sous-jacents, leur complexité et les types de limites de décision qu'ils peuvent modéliser. SVM vise à trouver le meilleur hyperplan, KNN utilise des informations locales, les arbres de décision prennent des décisions basées sur des divisions, les réseaux de neurones apprennent des modèles complexes et les modèles QDA classent les densités conditionnelles. Le choix de l'algorithme dépend de la nature des données et des exigences spécifiques de la tâche de classification **[87]**.

Ces algorithmes ont été générés à l'aide de la validation croisée et de la validation Hold-Out :

La validation croisée « cross validation » :

- Divise le jeu de données en k sous-ensembles de taille égale.
- Entraîne le programme sur k-1 sous-ensembles et le valide sur le sous-ensemble restant.
- Répète ce processus k fois, en utilisant chaque sous-ensemble comme ensemble de validation une fois.
- Les performances sont évaluées en moyenne sur toutes les itérations, offrant ainsi une estimation plus robuste des performances du programme **[88]**.

La validation hold-out « Hold out validation »:

- Divise le jeu de données en deux ensembles : un ensemble d'entraînement et un ensemble de test.

- Entraîne le programme sur l'ensemble d'entraînement et l'évalue sur l'ensemble de test.
- Utilise une partie fixe des données uniquement pour la validation.

La principale différence entre la validation croisée et la validation hold-out réside dans la manière dont les données sont divisées et utilisées pour l'entraînement et la validation. La validation croisée est souvent préférée pour des jeux de données plus petits ou lorsque la performance du programme doit être évaluée de manière plus robuste, tandis que la validation hold-out peut être plus rapide et plus simple à mettre en œuvre sur de grands ensembles de données **[89]**.

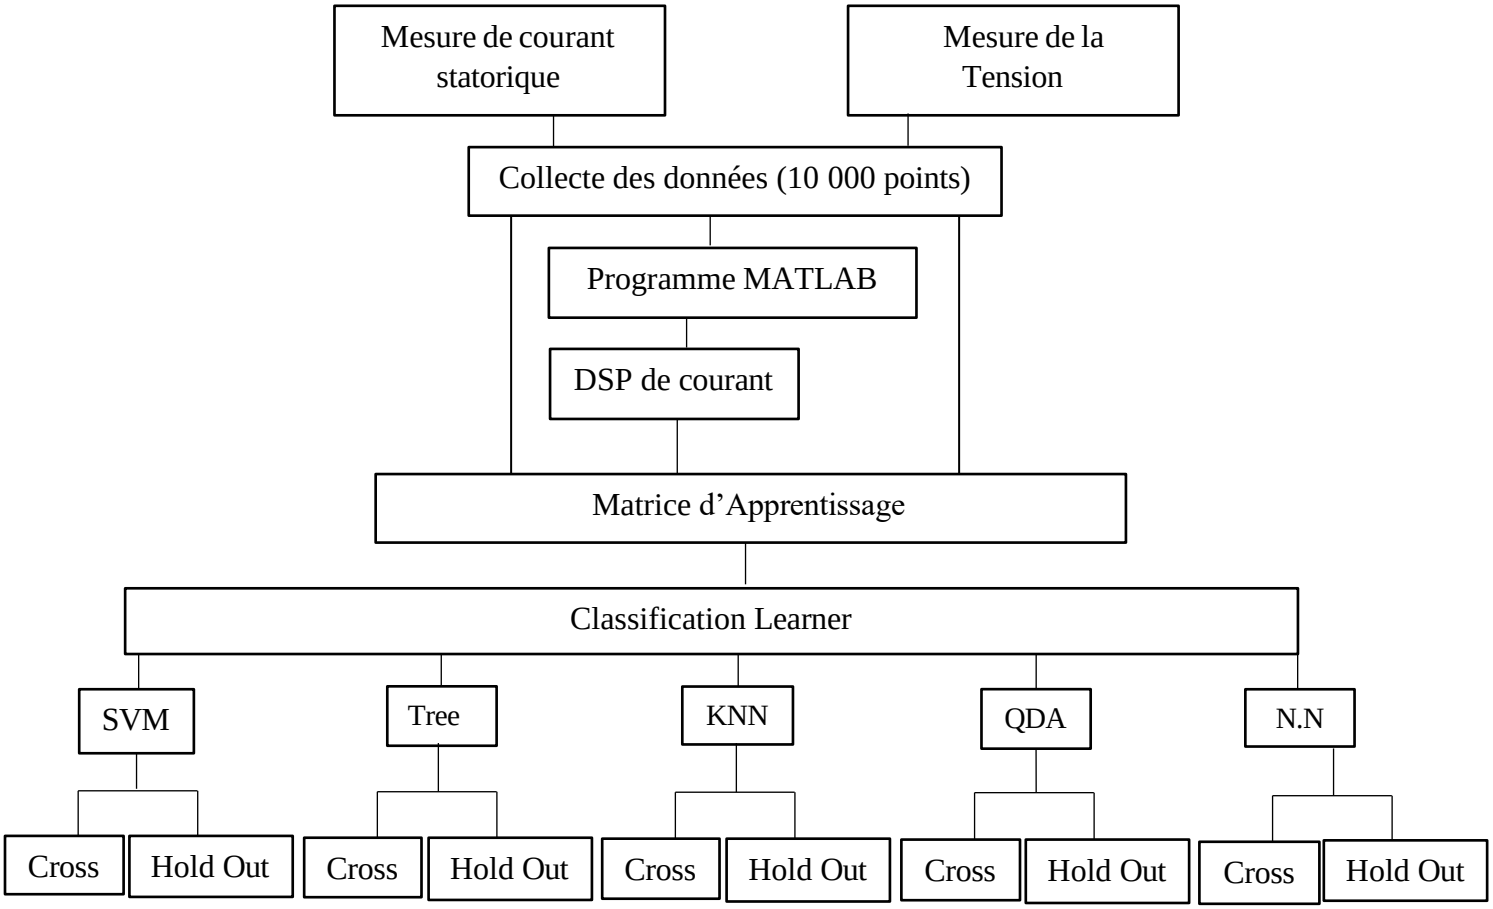


Figure IV 1. Schéma des étapes de classification

IV.3 Résultats expérimentaux

Pour évaluer notre méthode, nous avons opté pour une fréquence d'échantillonnage de 10 kHz. Cette expérience a été menée au laboratoire de recherche en Électrotechnique de l'ENP en 2008 **[9]**, utilisant un banc d'essais et de mesures équipé de quatre machines asynchrones de 4kW.

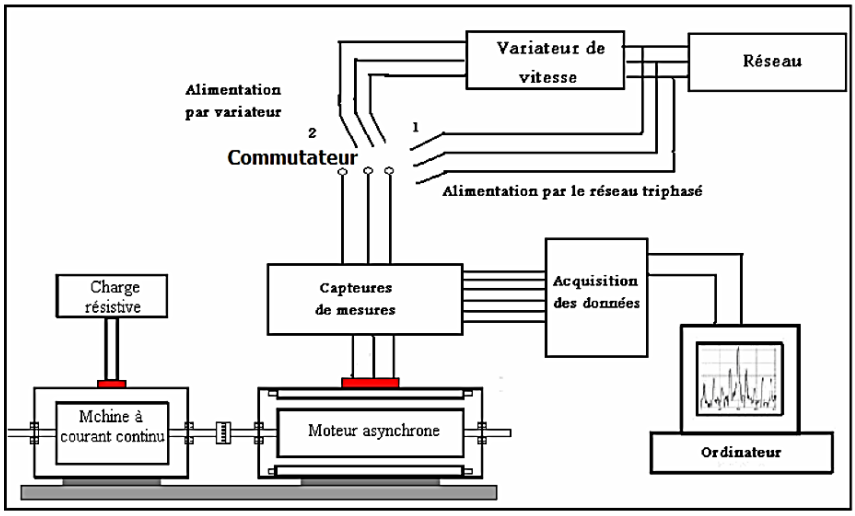


Figure IV 2. Schéma de banc d'essais pour le diagnostic de défaut de la machine asynchrone a cage d'écureuil **[9]**

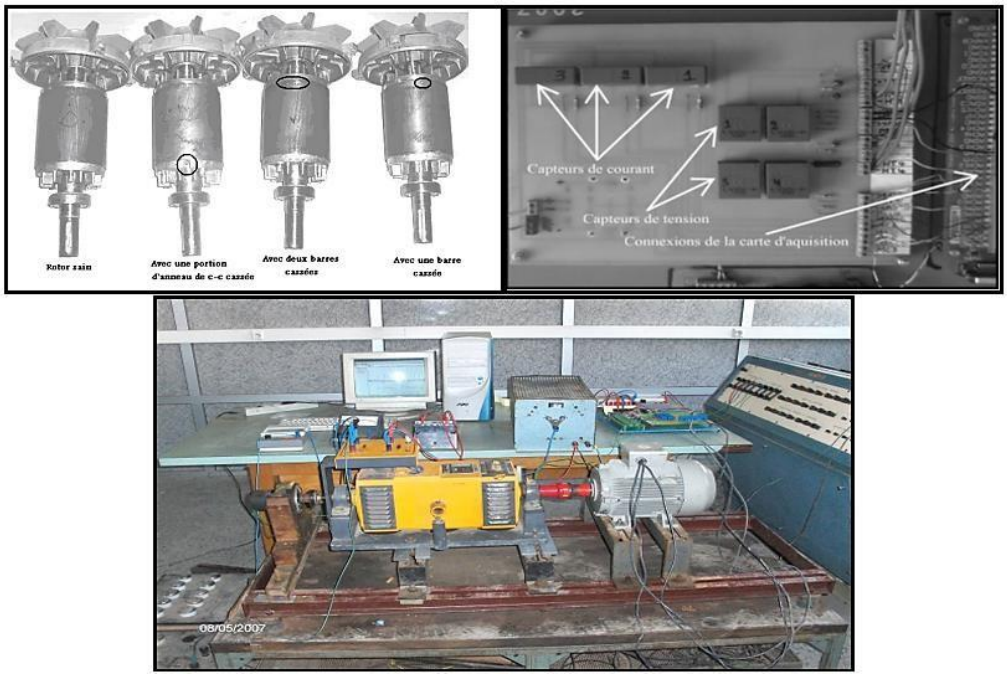


Figure IV 3. Banc d'essais pour le diagnostic de défaut de la machine asynchrone a cage d'écureuil

IV.2.1 Analyse des variations du courant statorique et des spectres fréquentiels pour la détection des défauts dans les machines asynchrones

Les **Figures IV.4** et **IV.5** illustrent la variation du courant statorique lors du démarrage et en régime permanent de la machine asynchrone saine et en présence de défaut (barre cassée, deux barres cassées et une portion de l'anneau de court-circuit cassée). Une légère modulation d'amplitude est observée, attribuable au défaut rotorique.

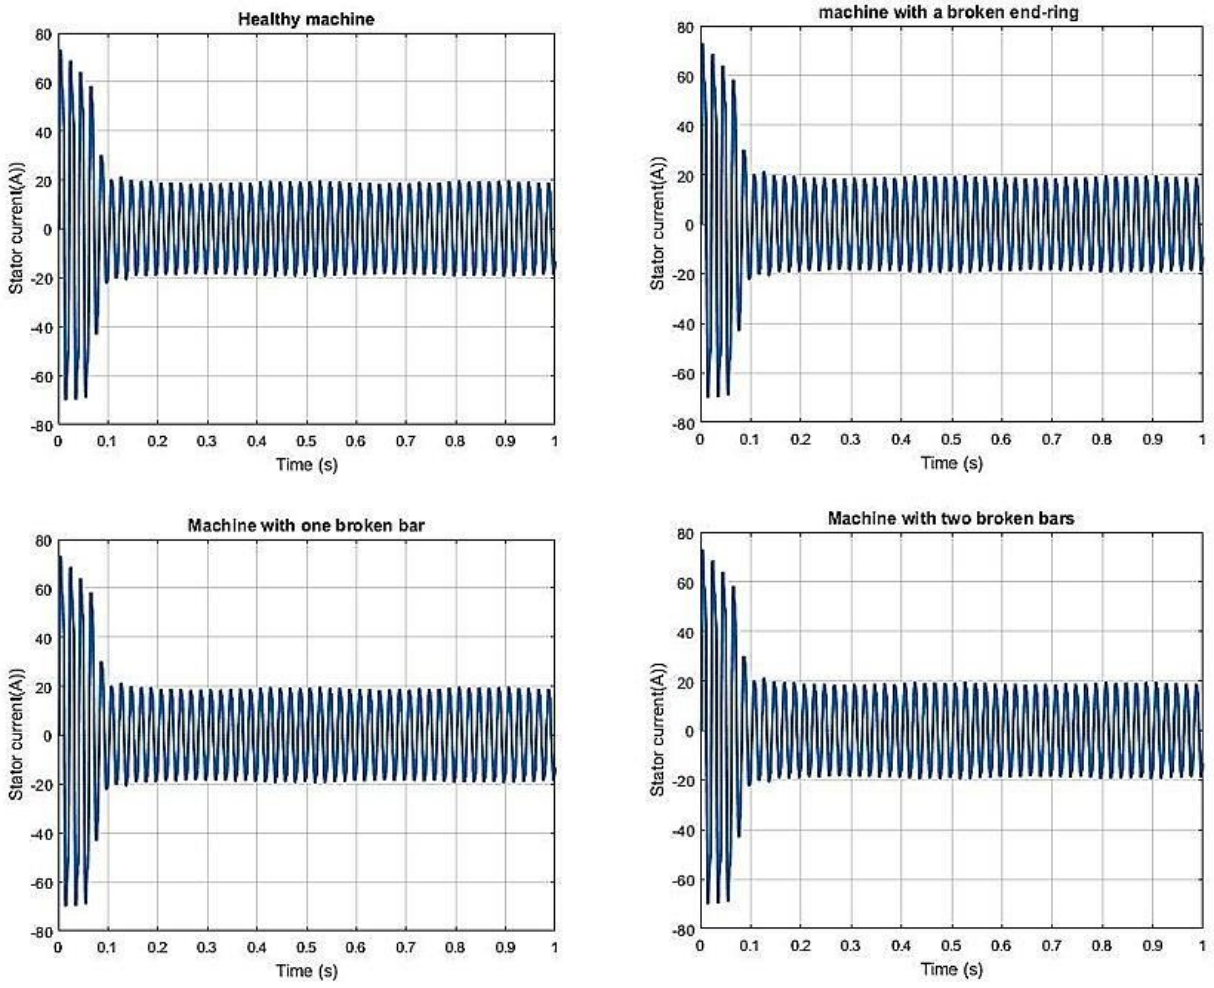


Figure IV 4. Courant statorique (Régime transitoire)

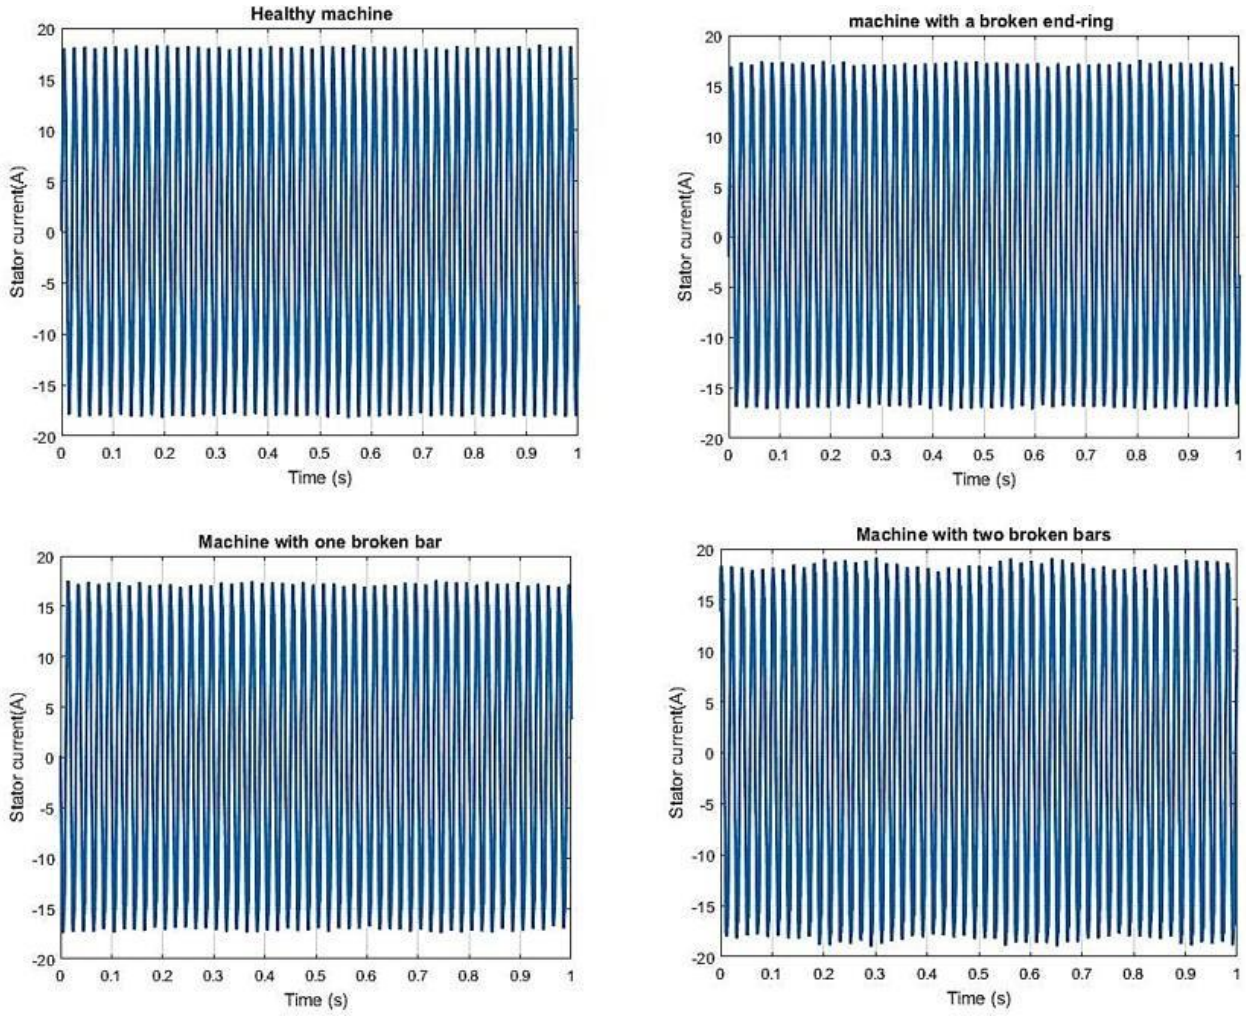


Figure IV 5. Courant statorique (Régime permanent)

Dans la **Figure IV.6**, on observe les spectres fréquentiels des machines asynchrones, qu'elles soient en états sain ou qu'elles présentent des anomalies telles qu'une ou deux barres cassées, ou encore une portion endommagée de l'anneau de court-circuit. Une analyse détaillée révèle une nette différence entre les spectres des machines saines et celles affectées par des défauts, les dernières étant marquées par une profusion d'harmoniques. Ces signaux de densités spectrales de puissance du courant statorique par phase, représentés sur une plage fréquentielle allant de 0 à 1000 Hz, offrent une vue exhaustive des données, mettant en lumière les harmoniques d’espaces pertinentes pour l'étude.

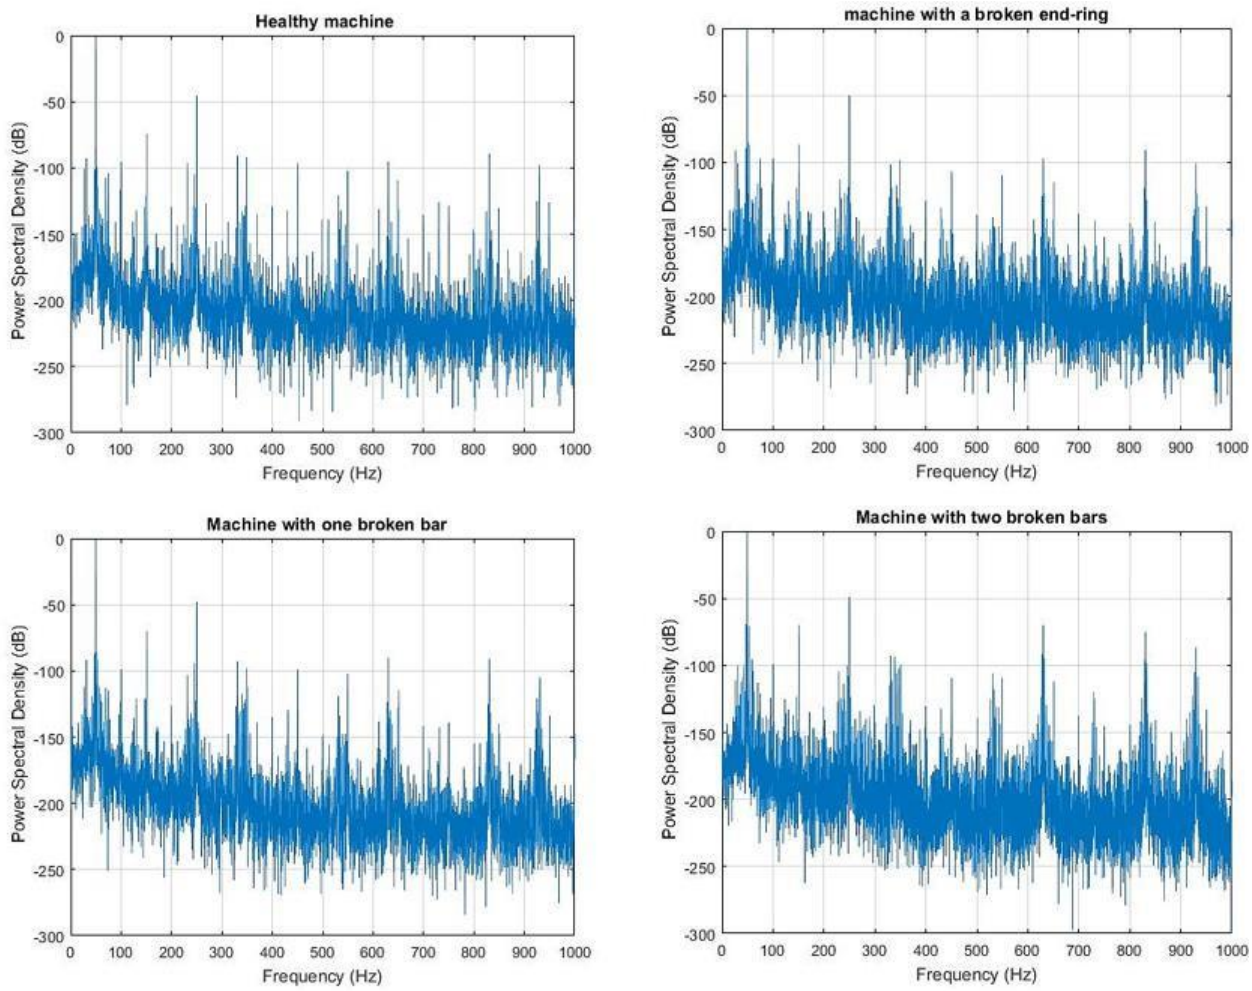


Figure IV 6. Densité spectrale de puissance du courant statorique

IV.2.2 Analyse de densité spectrale de puissance et la classification des défauts pour les différentes plages

L'analyse spectrale, notamment la Densité Spectrale de Puissance (DSP), joue un rôle crucial dans l'évaluation de l'état des machines électriques. Les variations du spectre fréquentiel du courant statorique peuvent révéler des anomalies spécifiques, telles que les composantes à haute fréquence associées à la rupture d'une barre de la cage rotorique. Ces anomalies, détectées dans le spectre du courant statorique, peuvent être interprétées comme des signaux indicateurs de défauts structurels dans les machines, tels que les barres cassées dans un rotor.

La DSP, en quantifiant la contribution de chaque fréquence à la puissance moyenne du signal, offre une méthode puissante pour identifier ces harmoniques d'espace, qui sont des indicateurs clés de la présence de défauts. Dans un contexte opérationnel, une machine électrique

en bon état présentera un spectre de DSP sans ces anomalies significatives, tandis qu'une machine présentant des défauts, comme une barre cassée, affichera des harmoniques d'espace additionnels et distinctifs. Ces caractéristiques capturées par la DSP, peuvent être utilisées comme des factures essentielles pour entraîner des programmes de machine Learning. Ces programmes, en analysant les changements subtils du spectre de DSP, peuvent être efficacement utilisés pour classifier l'état de la machine et détecter précocement les défauts, contribuant ainsi à une maintenance proactive et à la prolongation de la durée de vie des équipements électriques.

Les plages pour les harmoniques :

Les harmoniques d'espaces	Les fréquences (Hz)	Les plages de points
Fondamental.	[30-70]	(300 :700)
$5^{ème}$ Harmonique.	[209-249]	(2090 :2490)
$7^{ème}$ Harmonique.	[309-349]	(3090 :3490)
$11^{ème}$ Harmonique.	[509-549]	(5090 :5490)
$13^{ème}$ Harmonique.	[608-648]	(6080 :6480)

Tableau IV 1. Les plages de points correspondant aux harmoniques d'espaces ainsi que leurs fréquences respectives

IV.2.2.1 Analyse des spectres et la classification des défauts dans la plage [30 - 70] Hz

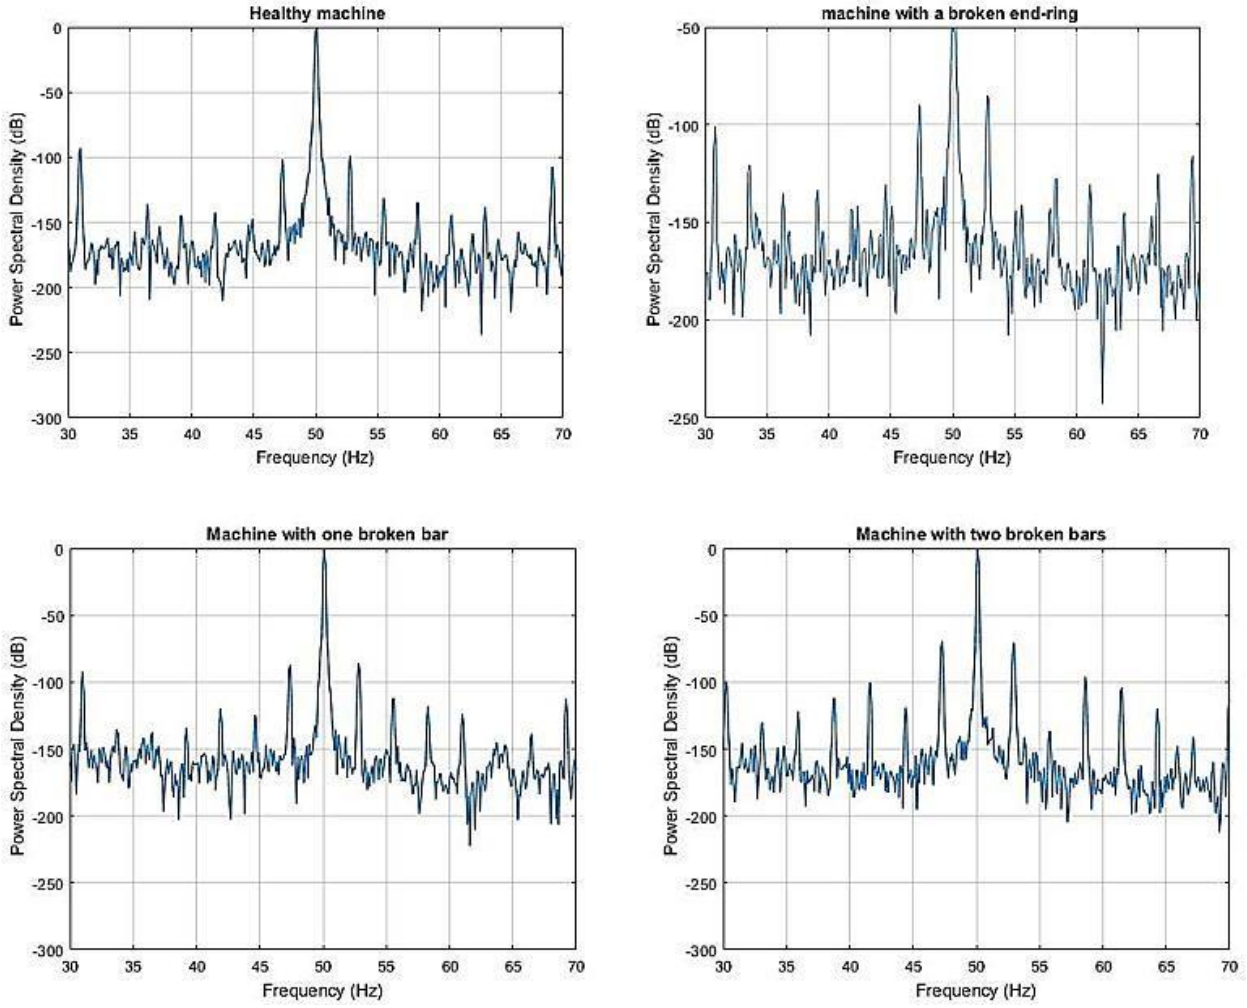


Figure IV 7. Spectre de courant statorique dans la plage [30-70] Hz

La **Figure IV 7.** Illustre le spectre du courant statorique sur une plage de fréquences allant de 30 à 70 Hz, ciblant spécifiquement les défauts autour du fondamental. À 50 Hz, le fondamental est clairement identifié, ce qui nous a conduit à sélectionner une plage de données de 300 à 700 points, comme expliqué dans la section de classification. Cette représentation graphique révèle une amplitude de fréquence relativement faible $(1 \pm 2kg)f$, attribuée aux perturbations qui seront soumises à une classification.

La présence de la fréquence $(1 \pm 2kg)f$ entraîne une rupture dans le spectre du courant statorique, cette modulation pouvant être exploitée pour détecter la présence d'une ou de plusieurs barres cassées.

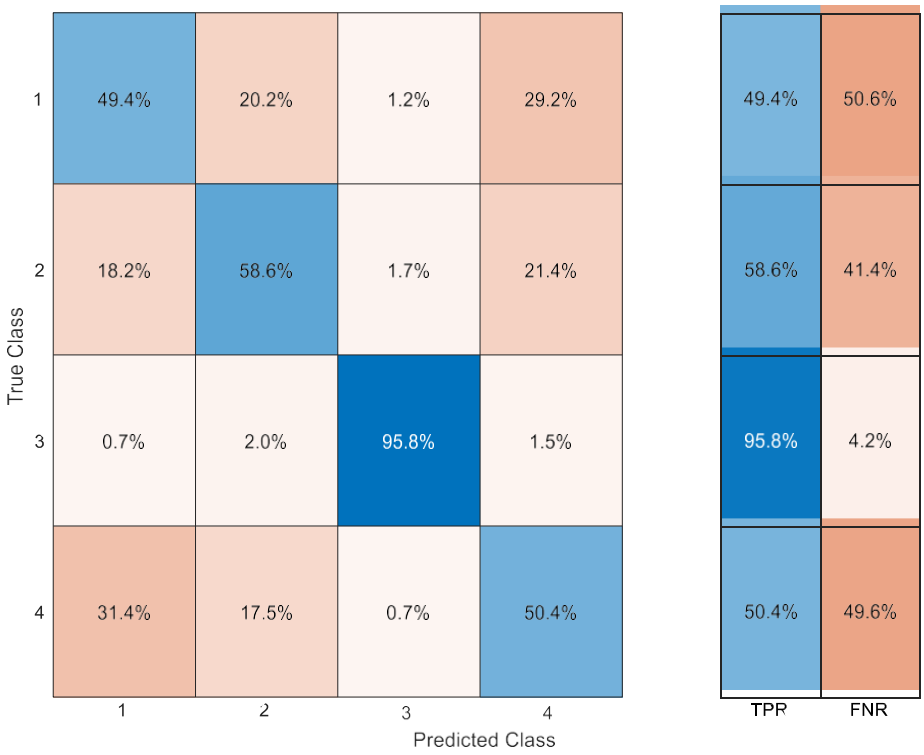


Figure IV 8. Résultat de classification des défauts dans la plage [30 - 70] Hz par cross validation

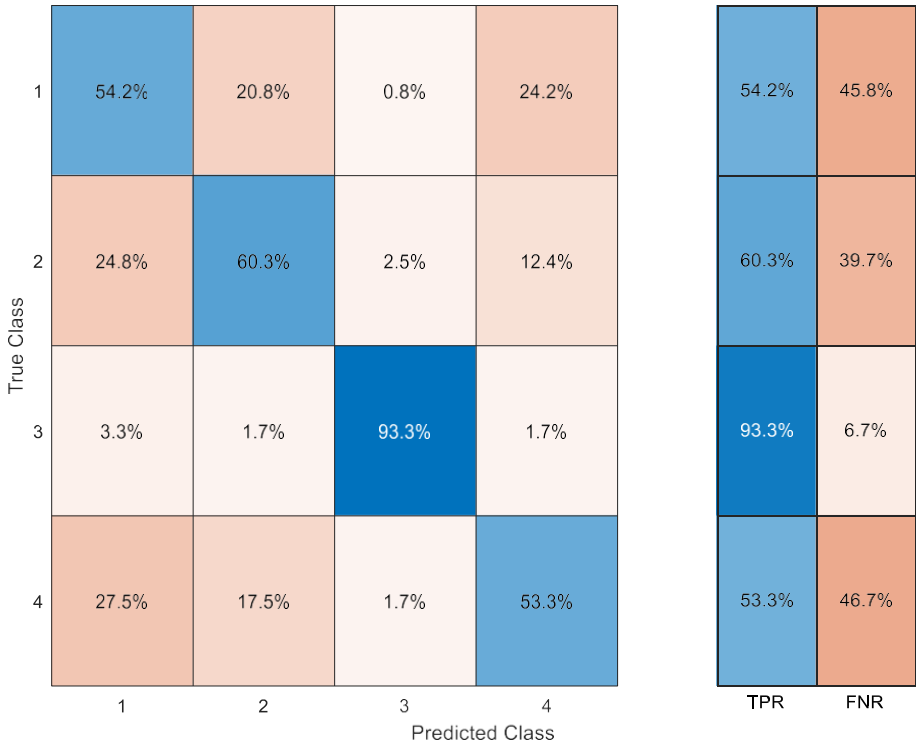


Figure IV 9. Résultat de classification des défauts dans la plage [30 - 70] Hz par Hold Out validation

Harmonique	Algorithme / Model	Résultats par cross validation	Résultats par Hold Out validation
Fondamental	Quadratic Discriminant	52.9%	50.7%
	Neural Network	63.5%	65.3%
	Decision Tree	53.1%	53.2%
	KNN	52.9%	53.2%
	SVM	53.4%	46.6%

Tableau IV 2. Résultats classification des défauts dans la plage [30-70] Hz par différents Model/Algorithme

Nous avons observé que le modèle de réseaux neuronaux affiche le taux de classification le plus élevé parmi les autres algorithmes, mais il présente une précision relativement faible autour du fondamental. Cette situation découle en grande partie du choix des données, car nous constatons une chute de tension similaire pour plusieurs défauts, avec des différences minimes. De plus, le spectre fréquentiel du courant statorique révèle des composantes de faible amplitude, dont les fréquences correspondent à celles générées par une rupture de barre.

Dans notre démarche visant à améliorer notre diagnostic, nous cherchons à analyser comment optimiser la classification autour de chaque harmonique d'espace. Actuellement, cette classification présente des performances faibles à moyennes. Toutefois, nous nous intéressons à explorer les moyens d'accroître cette précision en utilisant les mêmes données, mais en se concentrant exclusivement sur les harmoniques d'espaces. En intégrant ces éléments, nous espérons augmenter de manière significative la précision de notre programme et ainsi renforcer sa capacité à détecter et classifier les défauts avec une meilleure fiabilité.

IV.2.2.2 Analyse des spectres et la classification des défauts dans la plage [209 - 349] Hz

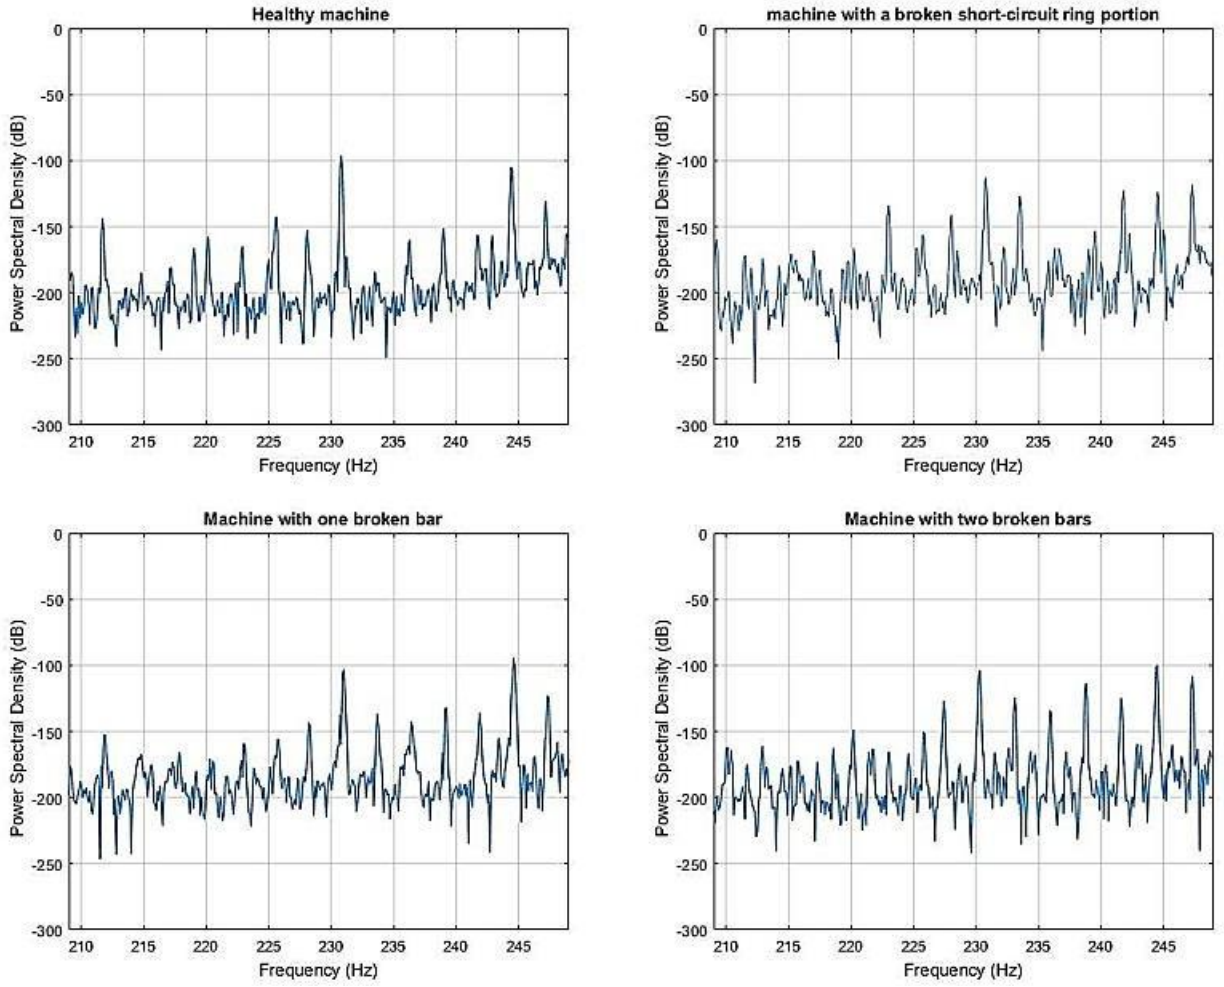


Figure IV 10. Spectre de courant statorique dans la plage [209-249] Hz

La **Figure IV.10** présente le spectre du courant statorique sur une plage de fréquences allant de 209 à 249 Hz, mettant en évidence les anomalies autour de la 5ème harmonique. Cette dernière, présente dans la plage de 209 à 249 Hz, a conduit à la sélection d'une plage de données de 2090 à 2490 points. Les harmoniques détectées dans le spectre fréquentiel ont une influence significative sur le courant statorique. L'amplitude de fréquence va s'accroitre proportionnellement à l'expression $(5(1-g)+5g)f$.

En examinant la **figure IV.10**, on observe la présence de deux autres harmoniques à la fréquence $2gf$, symétriquement disposées par rapport aux composantes principales. Cette configuration traduit un défaut au rotor, en l'occurrence une barre cassée.

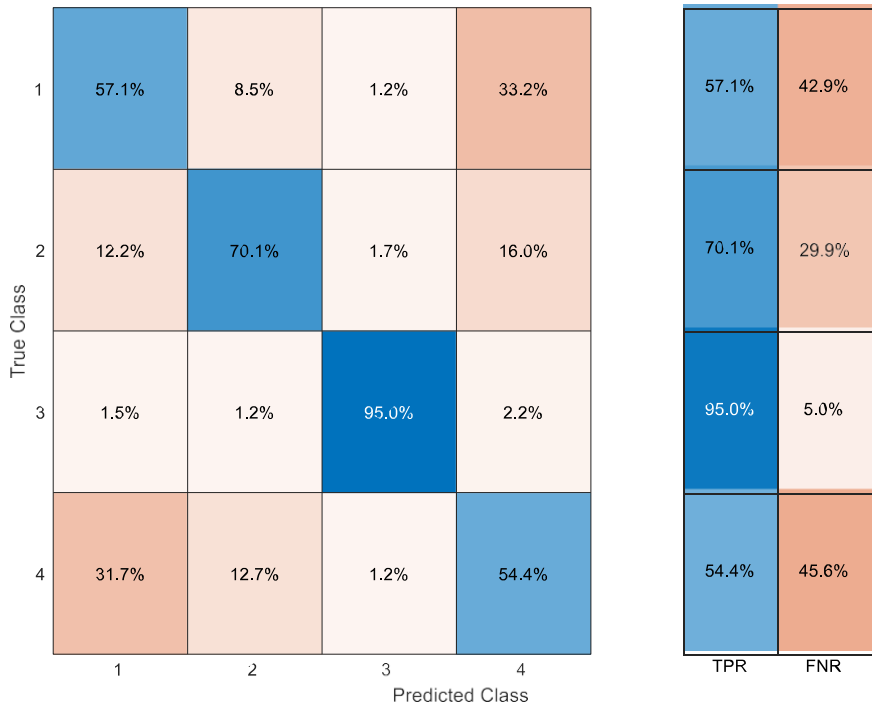


Figure IV 11. Résultat de classification des défauts dans la plage [209 -249] Hz par Cross validation

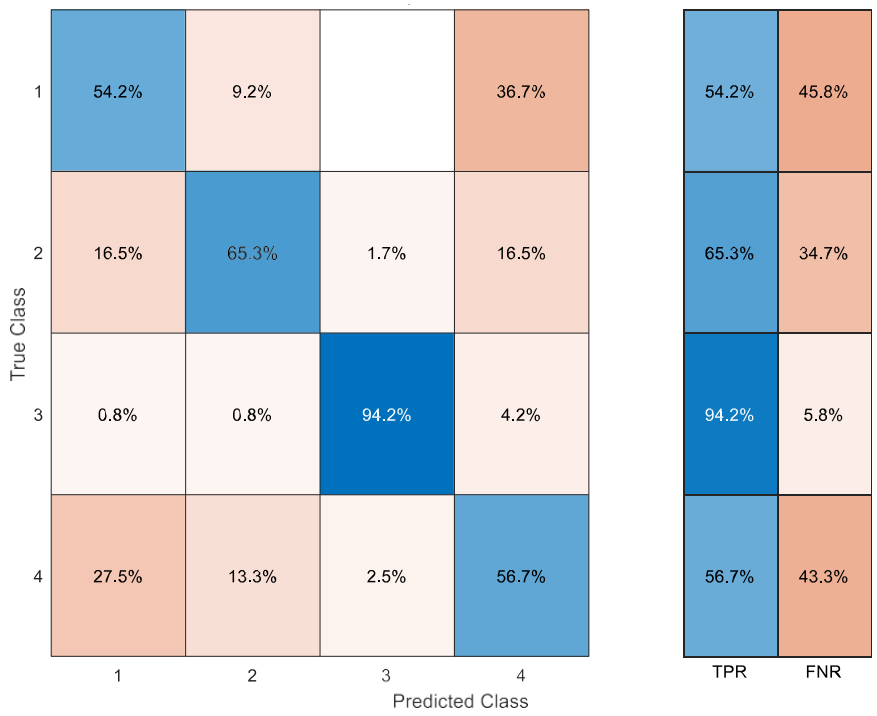


Figure IV 12. Résultat de classification des défauts dans la plage [209-249] Hz par Hold Out validation

Harmonique	Algorithme / Model	Résultats par cross validation	Résultats par Hold Out validation
$5^{ème}$ Harmonique	Quadratic Discriminant	49.6%	49.5%
	Neural Network	69.1%	67.6%
	Decision Tree	59.2%	58.6%
	KNN	58.4%	58.4%
	SVM	56%	55.8%

Tableau IV 3. Résultats classification des défauts dans la plage [209-249] Hz par différents Model/Algorithme

Lorsque notre machine est soumise à des défauts, des harmoniques sont générés. Les harmoniques sont des multiples entiers de la fréquence fondamentale du système, et le 5ème harmonique est cinq fois la fréquence du fondamental.

Nous avons remarqué que notre programme de réseaux neuronaux a le taux de classification le plus élevé parmi les autres programmes, atteignant 69,1%. Cependant, sa précision est relativement faible lorsqu'il s'agit de détecter les défauts liés au $5^{ème}$ harmonique. En revanche, cette précision est plus élevée pour les défauts autour de la fréquence fondamentale. Cette observation suggère que l'amélioration de notre programme pourrait résider dans sa capacité à traiter efficacement les harmoniques dans leur ensemble.

La **Figure IV.13** présente la densité spectrale de puissance sur une plage de fréquences s'étendant de 309 à 349 Hz, englobant ainsi le $7^{ème}$ harmonique ainsi que les modulations qui l'entourent.

Cette représentation offre une claire visualisation des différents états de fonctionnement de la machine dans cette plage spectrale, facilitant ainsi l'identification et la délimitation précise d'une zone propice à la classification des défauts liés au $7^{ème}$ harmonique.

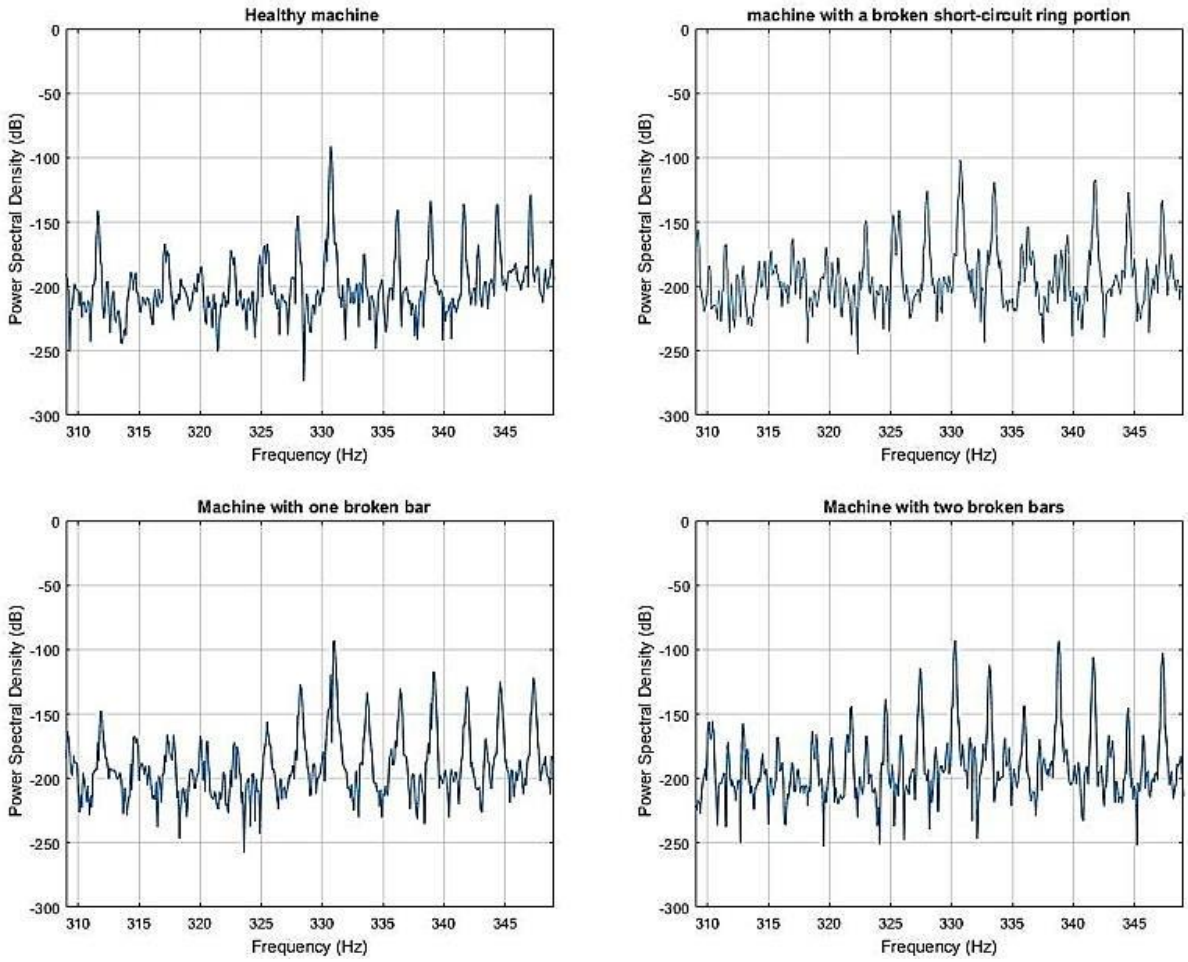


Figure IV 13. Spectre de courant statorique dans la plage [309-349] Hz

La **figure IV.14** et la **figure IV.15** présentent clairement la classification relative au 7ème harmonique. Il est notable, d'après le **tableau IV.4**, que le programme de Réseaux de Neurones affiche systématiquement un taux de classification correct de 65,1%, surpassant les autres algorithmes. Cependant, sa précision reste modérée, ce qui pourrait être attribué à la plage de points sélectionnée, étant donné que plusieurs données représentent les mêmes états de la machine.

Cette observation souligne l'importance de la classification dans la prédiction des résultats autour des harmoniques, tout en mettant en évidence une faible précision spécifiquement autour d'un seul harmonique.

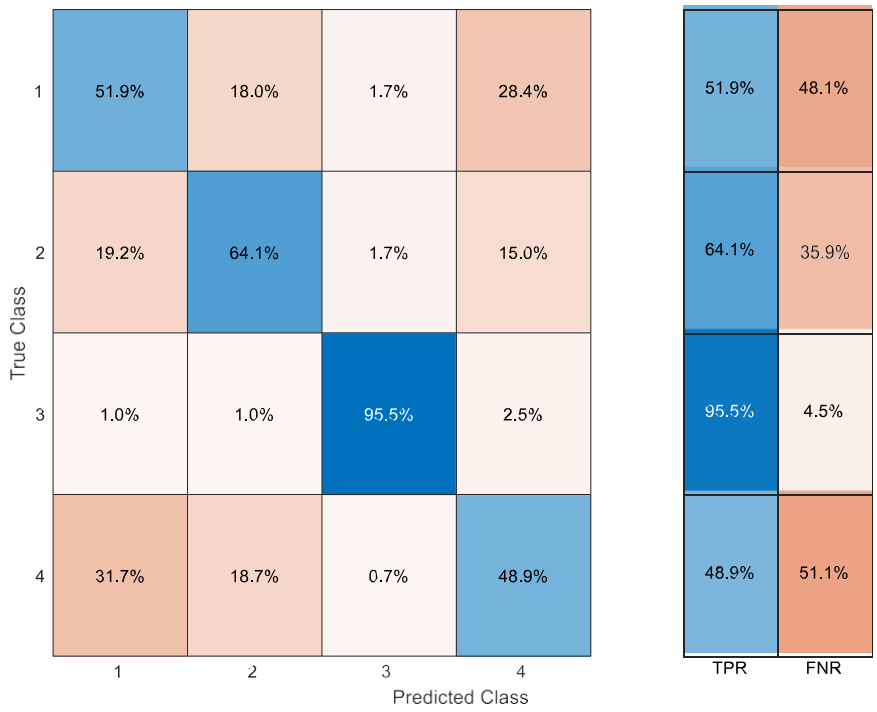


Figure IV 14. Résultat de classification des défauts dans la plage [309-349] Hz par Cross validation

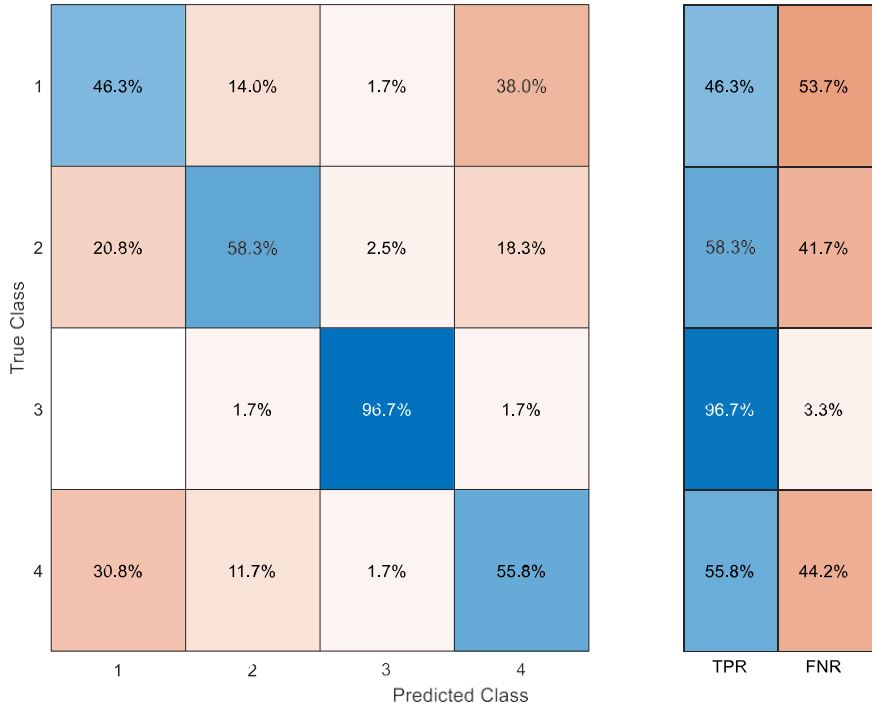


Figure IV 15. Résultat de classification des défauts dans la plage [309 -349] Hz par Hold Out validation

Harmonique	Algorithme / Model	Résultats par cross validation	Résultats par Hold Out validation
$7^{ème}$ Harmonique	Quadratic Discriminant	48.9%	44.3%
	Neural Network	65.1%	64.5%
	Tree	57.0%	53.0%
	KNN	55.3%	52.4%
	SVM	53.4%	53.1%

Tableau IV 4. Résultats classification des défauts dans la plage [309-349] Hz par différents Model/Algorithme

IV.2.2.3 Analyse des spectres et la classification des défauts dans la plage [509 - 648] Hz

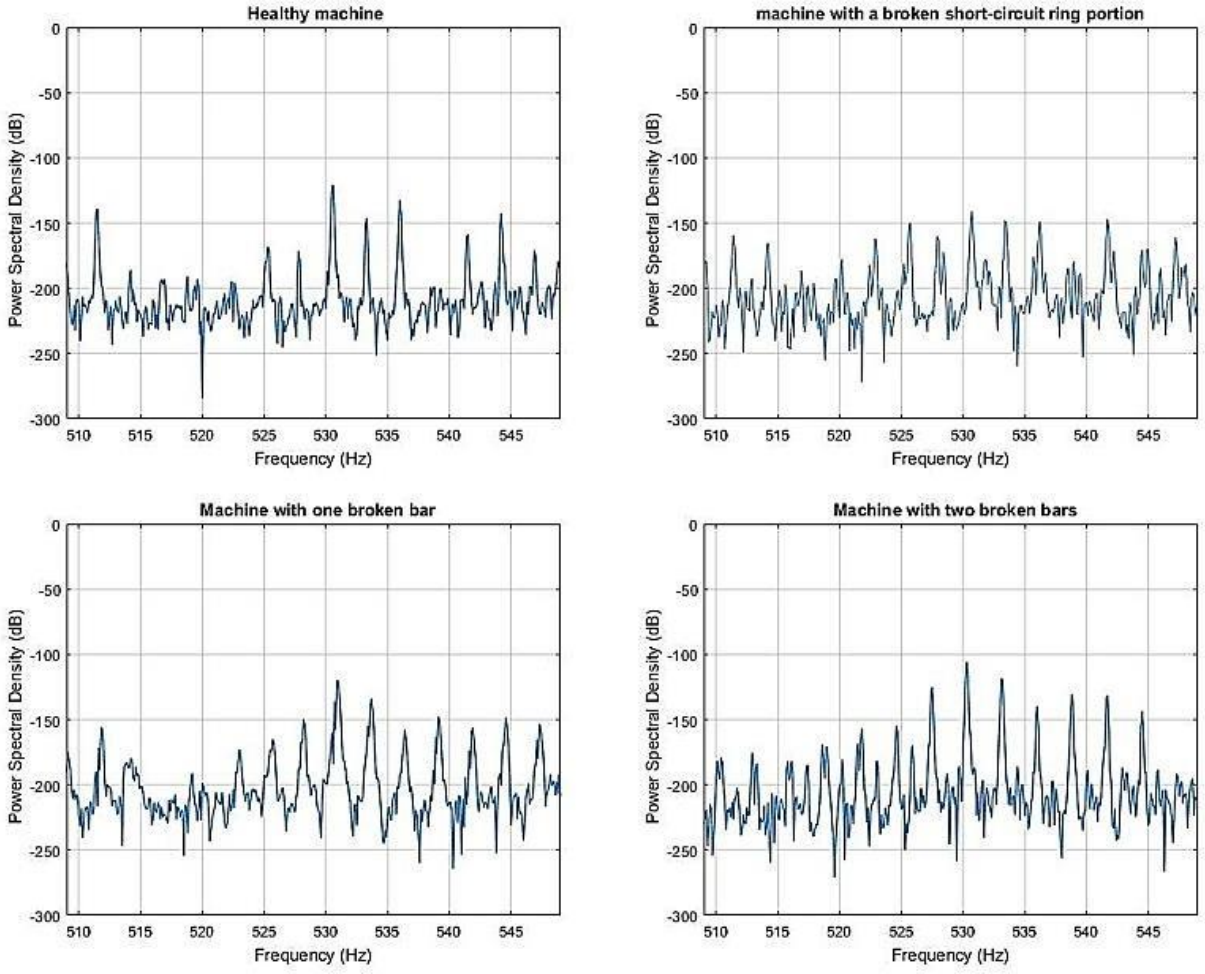


Figure IV 16. Spectre de courant statorique dans la plage [509-549] Hz

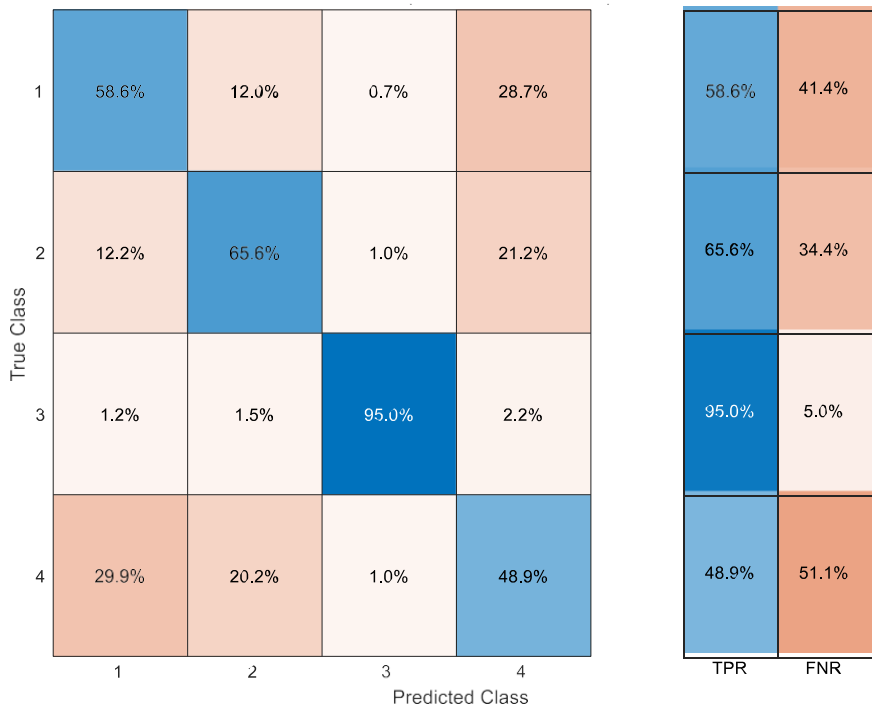


Figure IV 17. Résultat de classification des défauts dans la plage [509-549] Hz par Cross validation

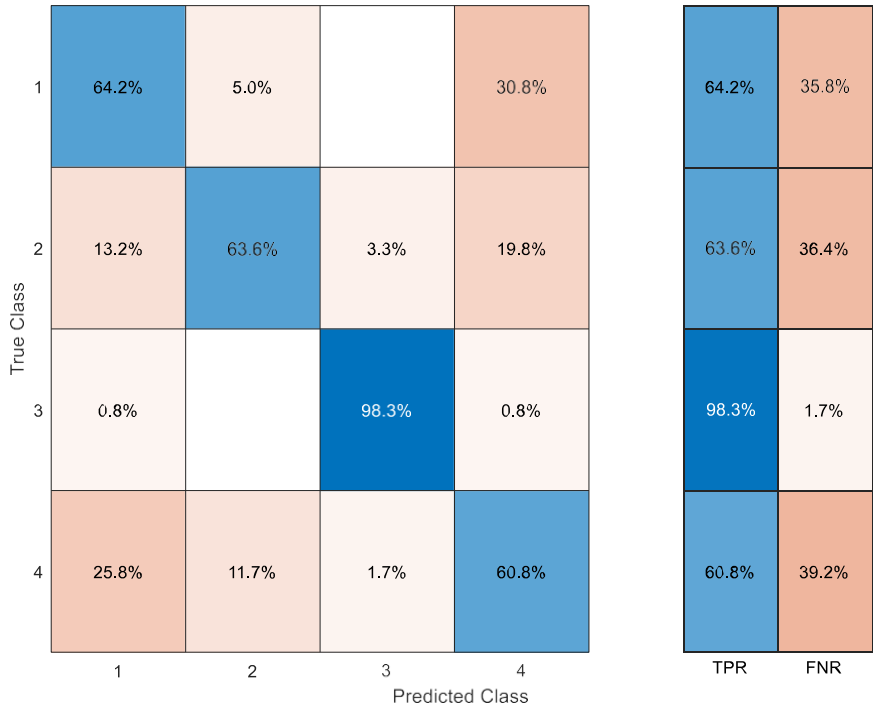


Figure IV 18. Résultat de classification des défauts dans la plage [509-549] Hz par Hold Out validation

Harmonique	Algorithme / Model	Résultats par cross validation	Résultats par Hold Out validation
$11^{ème}$ Harmonique	Quadratic Discriminant	47.8%	49.5%
	Neural Network	67.0%	71.7%
	Decision Tree	56.9%	54.3%
	KNN	56.5%	56.5%
	SVM	54.2%	52.9%

Tableau IV 5. Résultats classification des défauts dans la plage [509-549] Hz par différents Model/Algorithme

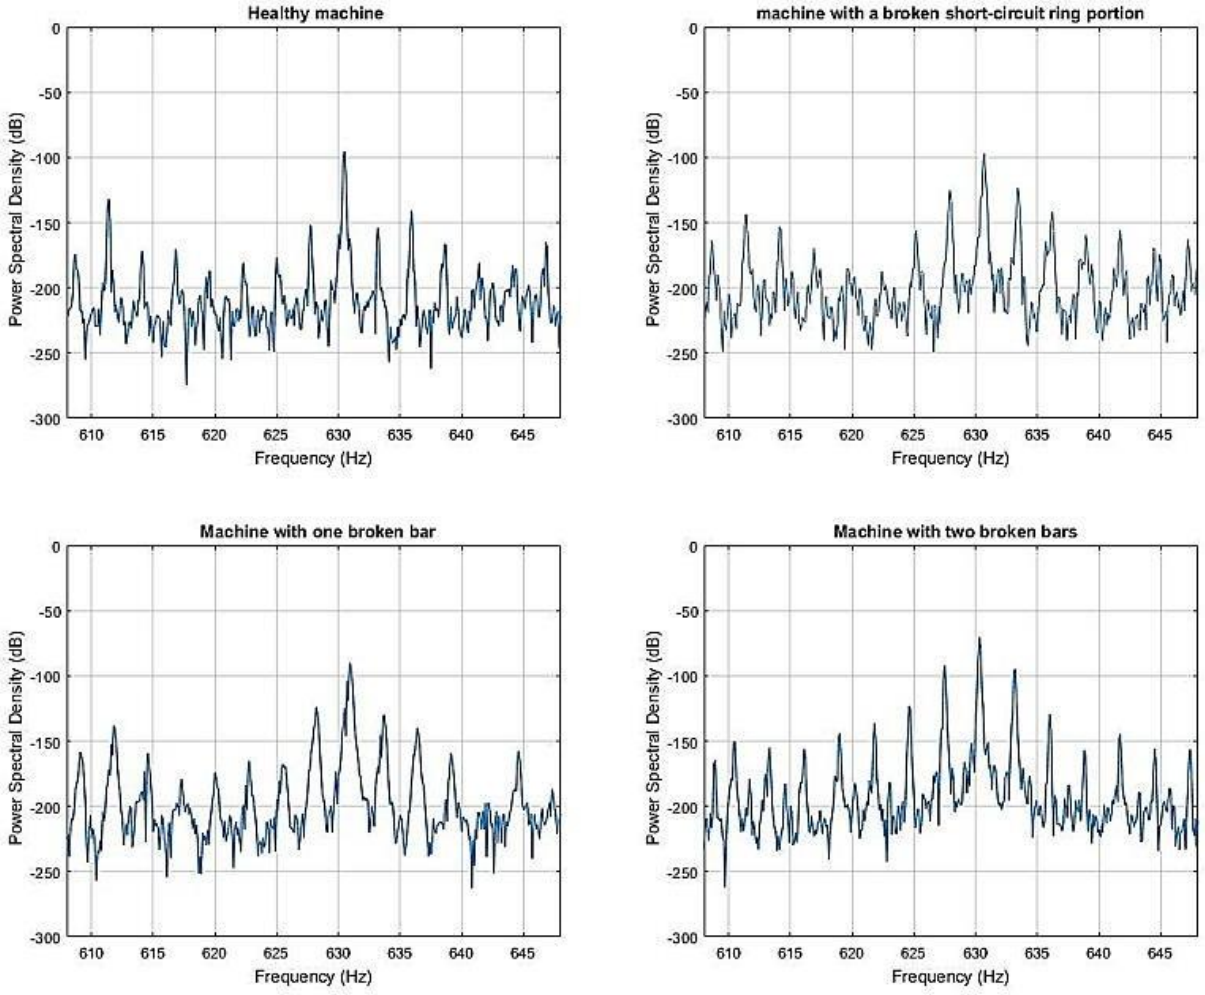


Figure IV 19. Spectre de courant statorique dans la plage [608-648] Hz

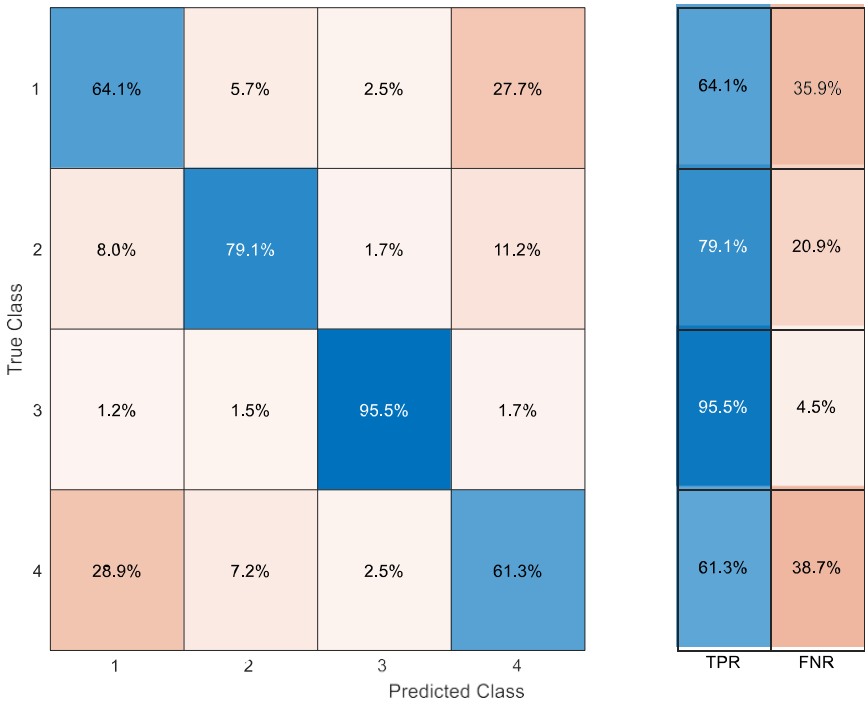


Figure IV 20. Résultat de classification des défauts dans la plage [608-648] Hz par Cross validation

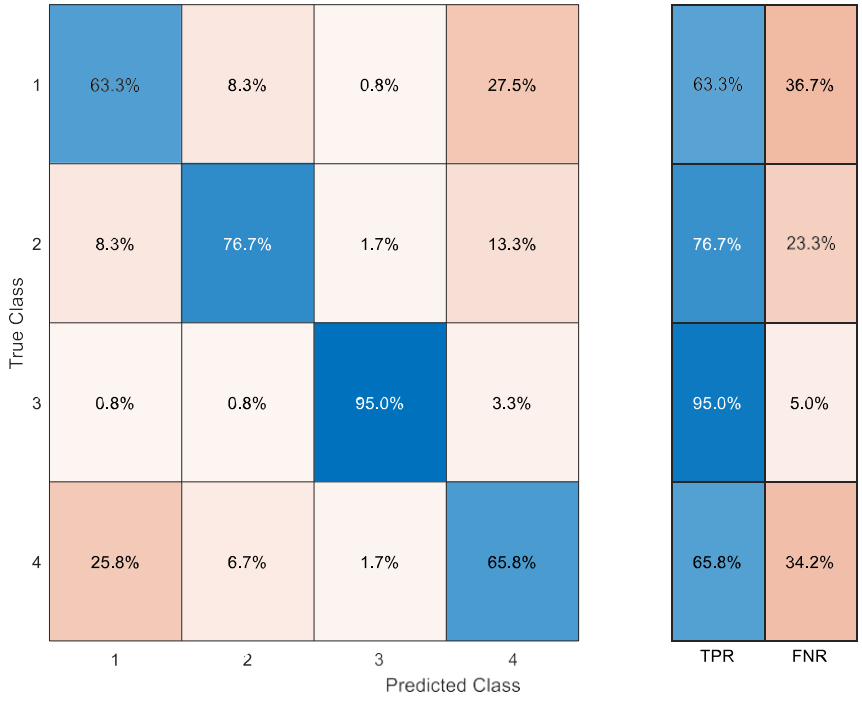


Figure IV 21. Résultat de classification des défauts dans la plage [609-649] Hz par Hold Out validation

Harmonique	Algorithme / Model	Résultats par cross validation	Résultats par Hold Out validation
$13^{ème}$ Harmonique	Quadratic Discriminant	57.5%	56.1%
	Neural Network	75.0%	75.3%
	Decision Tree	57.9%	57.8%
	KNN	61.3%	60.5%
	SVM	57.5%	55.7%

Tableau IV 6. Résultats classification des défauts dans la plage [608-648] Hz par différents Model/Algorithme

Les **figures IV.16** et **IV.19** présentent clairement le spectre dans les plages de fréquences allant de 509 à 549 Hz et de 608 à 648 Hz, mettant en évidence respectivement les harmoniques 11 et 13. Notre objectif principal est de générer cette densité spectrale de puissance pour représenter l'harmonique d'espace ainsi que les modulations qui l'entourent en termes de fréquence et d'amplitude.

Ces données sont ensuite utilisées pour classer les 4 états de la machine autour de chaque harmonique individuellement, ainsi que autour des harmoniques d'espace dans leur ensemble.

Nous observons une précision relativement faible autour de chaque harmonique isolément, notamment pour le $11^{ème}$ et le $13^{ème}$, comme indiqué sur les **figures IV.17, IV.18, IV.20** et **IV.21**. Cette faible précision peut être attribuée au manque d'informations ou de données, qui présentent des valeurs quasiment identiques.

Cependant, malgré cela, nous notons une amélioration significative grâce à l'utilisation du programme de Réseaux de Neurones, combiné avec les données de courant, le spectre sur des plages spécifiques et la tension. Cela se traduit par un taux de classification de 75,3% autour du 11ème harmonique et de 71,1% autour du 13ème harmonique, comme illustré dans les **tableaux IV.5** et **IV.6**.

IV.2.2 Classification des défauts autour des harmoniques d'espaces

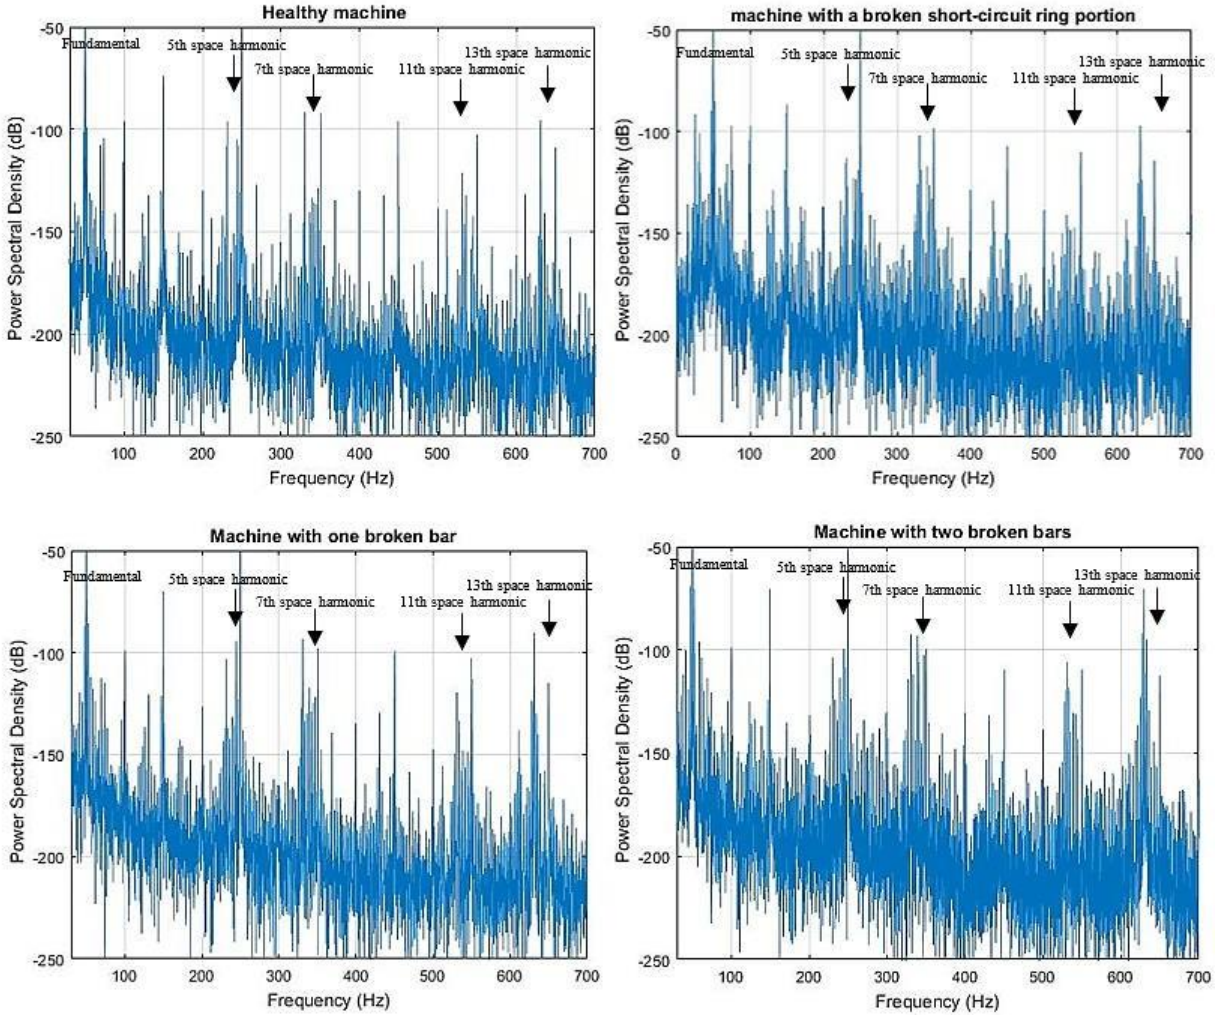


Figure IV 22. Densité spectrale de puissance du courant statorique, en représentant les harmoniques d'espaces

Dans notre étude, nous nous concentrons sur les harmoniques d'espaces, allant du fondamental jusqu'à la 13ème harmonique, afin de déterminer les plages de fréquences englobant toutes les modulations autour de chaque harmonique et les principaux éléments des harmoniques. En utilisant les grandeurs temporelles de la machine asynchrone à cage d'écureuil dans le domaine fréquentiel, nous avons analysé le spectre du courant rotorique pour détecter les signatures fréquentielles résultant de la rupture de barres de la cage rotorique.

La **figure IV.22** présente la densité spectrale de puissance du courant statorique dans une plage de fréquences allant de 200 à 700 Hz. Cette représentation nous permet d'observer les

harmoniques d'espaces pour la machine saine, ainsi que pour la machine présentant une ou plusieurs barres cassées, voire une portion d'anneau de court-circuit cassée.

Le spectre du courant statorique révèle les ruptures de barres de la cage rotorique dans la partie haute fréquence, avec des composants supplémentaires apparus suite à ces défauts, comme indiqué dans le spectre du courant statorique. Ces composants se manifestent lorsqu'un défaut survient, et ils sont décrits par la relation :

$$fv = (v(1-g) + 1g)f \quad \text{Avec } v = 5{,}7{,}11 \; et \; 13 \qquad (IV.1)$$

Nous avons ensuite vérifié que les fréquences des modulations pour les faibles amplitudes autour du fondamental et des autres harmoniques étaient totalement incluses dans les plages choisies. Cette vérification nous permet de constater que ces données ajoutent des informations sur l'état de la machine. Toutefois, il est toujours nécessaire de recourir à d'autres paramètres ou grandeurs, tels que le courant et la tension, pour classifier les harmoniques d'espace ensemble.

Les différentes fréquences et plages qui entourent les valeurs de $(1 \pm 2g)f$ et $vf - (v \pm 1)gf$ sont représentées dans le tableau suivant :

Les harmoniques d'espaces	Fréquences	Les fréquences (Hz)	Les plages de points
Fondamental	$(1 \pm 2g)f$	[30-70]	(300 :700)
5ème Harmonique	$5f - (5 \pm 1)gf$	[209-249]	(2090 :2490)
7ème Harmonique	$7f - (7 \pm 1)gf$	[309-349]	(3090 :3490)
11ème Harmonique	$11f - (11 \pm 1)gf$	[509-549]	(5090 :5490)
13ème Harmonique	$13f - (13 \pm 1)gf$	[608-648]	(6080 :6480)

Tableau IV 7. Fréquences correspondent pour chaque harmonique

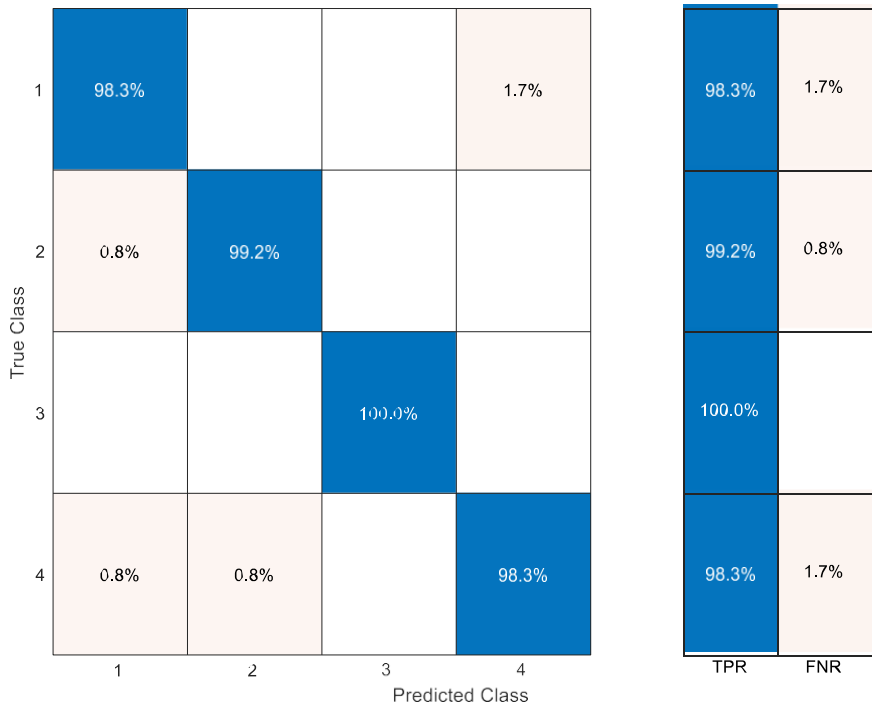


Figure IV 23. Résultat de classification des défauts autour des harmoniques d'espaces par Cross validation

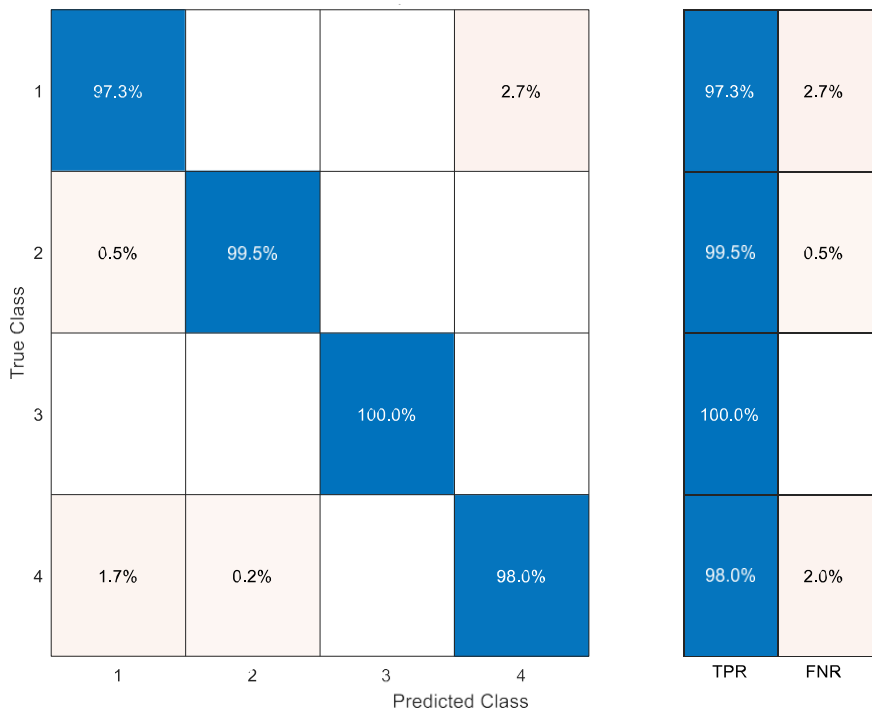


Figure IV 24. Résultat de classification des défauts autour des harmoniques d'espaces par Hold Out validation

Algorithme / Model	Résultats par cross validation	Résultats par Hold Out validation
Quadratic Discriminant	98.7%	99.0%
Neural Network	95.0%	95.2%
Decision Tree	61.3%	58.2%
KNN	70.5%	78.0%
SVM	83.5%	83.4%

Tableau IV 8. Résultats classification des défauts autour des harmoniques d'espaces par différents Model/Algorithme

La classification des défauts de la machine sur ses 4 états (saine, avec barre cassée, avec deux barres cassées et avec portion d'anneau c-c cassée) est représentée sur les **figures IV.23** et **IV.24**. Nous avons collecté les données de la même façon que dans les plages précédentes (courant statorique, la tension et les densités spectrale de puissance). Mais cette fois nous avons démontré une augmentation du taux de précision de classification en prenant les harmoniques d'espaces du fondamental jusqu'à la $13^{ème}$ harmonique, et ainsi de décortiquer la fiabilité de notre programme notre d'apprentissage. Suivant le **tableau IV.8** on remarque un taux de précision très élevé en utilisant cette fois le programme de discriminant quadratique ce dernier est présenté par son pourcentage de 99% avec une erreur de 1% par la représentation de 'Hold Out Validation' cette technique permet d'entrainer notre algorithme par 70% des données et tester par 30% des données par contre la 'Cross Validation' en prenant des paques des données (5 paquets) entrainés et tester par les autres paquet a eu une précision très élevé pour les deux algorithmes les deux représentations.

Certains défauts sont très distinctifs et leur précision de détection est donc de 100 % ' les défaut d'une machine avec deux barres cassées entre autres' ce que nous constatons pour toutes celle avec plusieurs barres cassées.

IV.4 Conclusion

Notre étude révèle l'importance cruciale de la classification et du diagnostic précis des défauts dans les machines asynchrones pour garantir la fiabilité des systèmes industriels électromécaniques tout en minimisant les coûts de maintenance. En intégrant des techniques innovantes telles que l'analyse des harmoniques d'espaces dans le courant statorique et l'utilisation de l'apprentissage automatique et des densité spectral de puissance, nous avons développé une approche robuste et efficace pour détecter et classifier les défauts. Cette méthode offre des perspectives prometteuses pour une maintenance proactive et des applications industrielles pratiques. En réduisant les données redondantes et en se concentrant sur des caractéristiques essentielles, notre approche basée sur les données du courant statorique et de la tension, combinée à des algorithmes d'apprentissage automatique tels que les réseaux de neurones et le discriminant quadratique, démontre une précision satisfaisante pour le diagnostic des pannes en temps réel. Enfin, notre contribution comprend l'exploration de méthodes avancées pour extraire des caractéristiques pertinentes des données de fonctionnement des machines, ainsi que le développement de techniques de surveillance continue de l'état des moteurs à induction, offrant ainsi une perspective novatrice pour la maintenance industrielle.

CONCLUSION GENERALE

Notre projet de fin d'étude se concentre sur le développement de méthodes avancées pour la détection précoce et précise des défauts dans les machines asynchrones, en utilisant des techniques d'apprentissage automatique et d'analyse fréquentielle avancée. À travers une exploration détaillée des différentes composantes des machines asynchrones, des méthodes de diagnostic traditionnelles aux approches modernes basées sur l'intelligence artificielle, notre travail vise à répondre à un besoin crucial dans le domaine de l'ingénierie électromécanique industrielle.

Nous avons démontré la faisabilité et l'efficacité de notre approche en combinant des connaissances théoriques sur le fonctionnement des machines asynchrones avec des méthodes de diagnostic. Cette approche permet de détecter et de classifier une large gamme de défauts, allant des problèmes mécaniques aux anomalies électriques. Notre projet souligne l'importance de la surveillance continue de l'état des machines pour garantir leur fiabilité opérationnelle, minimiser les temps d'arrêt coûteux et optimiser les performances industrielles.

Contrairement à de nombreux travaux antérieurs qui utilisent généralement un grand volume de données, notre méthode se concentre spécifiquement sur l'exploitation efficace du courant brut sous forme de densité spectrale. Nous avons méticuleusement sélectionné les plages en fonction des harmoniques d'espaces et de leurs composantes, optimisant ainsi la sensibilité du diagnostic tout en réduisant la complexité de traitement des données. Les dernières avancées scientifiques ont souligné l'importance croissante du domaine fréquentiel, et les futures recherches devront se concentrer sur l'exploitation efficace des caractéristiques spectrales des signaux électriques.

En intégrant des techniques innovantes telles que l'analyse des harmoniques d'espace dans le courant statorique et l'utilisation de l'apprentissage automatique, nous avons développé un programme robuste et efficace pour le diagnostic des pannes en temps réel. Cette approche ouvre de nouvelles perspectives pour la maintenance industrielle proactive. Notre contribution comprend également l'exploration de méthodes avancées pour extraire des caractéristiques pertinentes des données de fonctionnement des machines, ainsi que le développement de techniques de surveillance continue de l'état des moteurs à induction.

Notre projet représente une avancée significative dans le domaine de la maintenance prédictive des machines asynchrones, offrant des outils et des méthodes précieuses pour garantir la fiabilité, la sécurité et la durabilité des systèmes industriels. Nous sommes convaincus que notre approche contribuera à améliorer les pratiques de maintenance dans divers environnements industriels, ouvrant ainsi la voie à une production plus efficace, plus sûre et plus durable.

BIBLIOGRAPHIE

[1] M. Ouadah, O. Touhami, et R. Ibtiouen, «Novel Method for Rotor Bar Fault Diagnosis of Induction Machines Containing Space Harmonics», Proceedings of the 8th International Conference on Systems and Control, Marrakech, Morocco, October 23-25, 2019

[2] M'hamed Ouadah, Omar Touhami, Rachid Ibtiouen, Mohammed Khorchef et Djilali Allou, «Corrosion Effects on the Magnetic Behavior of Magnetic Circuit of an Induction Machine», Progress In Electromagnetics Research M, Vol. 68, 79–87, 2018.

[3] M. Ouadah, O. Touhami, R. Ibtiouen, «Improvement of the detection of the defect squirrel cage rotor by the study of additional components of the space harmonics», Electrical Engineering, July 2018. «»

[4] Muhammad Samiullah ID, Hasan Ali, Shehryar Zahoor et Anas Ali. Article «Fault Diagnosis on Induction Motor using Machine Learning and Signal Processing», Conference de "School of Electrical Engineering and Computer Science, (SEECS), National University of Sciences and Technology", Islamabad, Pakistan. 27 Jan 2024.

[5] Rafia Nishat Toma, Alexander E. Prosvirin et Jong-Myon Kim, Article «Bearing Fault Diagnosis of Induction Motors Using a Genetic Algorithm and Machine Learning Classifiers», sensors, March 2020.

[6] Olivier Ondel, « Diagnostic par reconnaissance des formes : Application a un ensemble convertisseur machine asynchrone » Thèse de doctorat en Génie Électrique, École Centrale de Lyon, France, Octobre 2006.

[7] Mamadou Lamine Doumbia, Abdoulaye Traoré. Article « modélisation et simulation d'une machine asynchrone à cage à l'aide du logiciel matlab/simulink » Sciences de l'ingénieur (Génie électrique) - academia.edu. Juillet, 2002.

[8] METROUH Mohamed, MOUSSI Rafik « Identification d'une machine asynchrone à cage » Mémoire de Fin d'Etudes de master académique, université MOULOUD MAMMERI, Tizi-Ouzou. 2017.

[9] OUADAH M'hamed, « Modélisation et Diagnostic des Défauts des Machines Asynchrones à Cage D'écureuil par L'approche des Circuits Multiples Couplés Magnétiquement en Tenant Compte des Harmoniques D'espace » Mémoire de Magister, École Nationale Polytechnique d'Alger. 2008.

[10] G. Didier, « Modélisation et diagnostic de la machine asynchrone en présence de défaillances » Thèse de doctorat, Université Henri Poincaré - Nancy I, Octobre 2004.

[11] Ibrahim Chouidira, Djalal Eddine Khodja, Hani Benguesmia. Article « Detection and Diagnosis faults in Machine asynchronous based on single processing », International Journal of Energetica (IJECA). Octobre 2019.

[12] Omar sid, « Diagnostic des défauts de la machine asynchrone à cage par les réseaux de neurones » mémoire de magister, Université des Sciences et de la Technologie Houari Boumediene Alger, 2011.

[13] Tarek BOUMEGOURA, « Recherche de signature Electromagnétique des défauts dans une machine asynchrone et synthèse d'observateurs en vue du Diagnostic » Thèse de doctorat en Génie Electrique, Ecole Centrale De Lyon, France, Mars 2001.

[14] Andrian Ceban, « méthode globale de diagnostic des machines électriques », Thèse présentée en vue de l'obtention du grade de Docteur de l'Université. École doctorale SPI. Université Lille de Nord de France. Février 2012.

[15] Marouane FRINI, Abdenour SOUALHI, Mohamed EL BADAOUI, Article « Diagnostic des engrenages à base des indicateurs géométriques des signaux électriques triphasés », Université Lyon, UJM-Saint Etienne, SAINT-ETIENNE, France 2019

[16] Michel Parrot. « Méthodes numériques d'analyse spectrale ». [Rapport de recherche] Note technique CRPE n°35, Centre de recherches en physique de l'environnement terrestre et planétaire (CRPE). France 1976.

[17] Matthieu Durnerin, Nadine Martin, Corinne Mailhes, Gérard Lejeune, Joël Liénard, Jean-Louis Lacoume, Francis Castanié, Pascale Prieur, Georges Goullet, André Silvent « Démarche d'Analyse Spectrale en vue d'une Interprétation Automatique, Application à un Signal d'Engrenages », Grenoble, France. Septembre 1997.

[18] Abdennacer Aboubou, Mohammed Sahraoui, Salaheddine Zouzou, Noureddine Harid, Hubert Razik, Abderrezak Rezzoug, Article « Comparaison de trois techniques dédiées au diagnostic des défauts rotoriques dans les moteurs asynchrones triphasés à cage. » RS – RIGE. 2005.

[19] Mario El Tabach « Diagnostic de défauts mécaniques dans les machines tournantes par analyse des signaux électriques d'alimentation » Thèse de doctorat, Université de Technologie de Compiègne. France 2004.

[20] SAHRAOUI Mohamed, « Etude Comparative des Méthodes de Diagnostic des Machines Asynchrones » Thèse en Vue de l'Obtention du Diplôme de Doctorat en Science. Université Mohamed KHIDER Biskra. 2010

[21] Mauricio Andrés Cuevas Salvatierra, « Méthodes non-invasives de diagnostic de défauts et d'analyse thermique des machines synchrones à pôles saillants », Thèse de doctorat. École doctorale Sciences pour l'ingénieur. Lille. 2017.

[22] Roland Casimir. Diagnostic des défauts des machines asynchrones par reconnaissance des formes. Thèse pour obtenir le grade de Docteur. Ecole Centrale de Lyon, France. Décembre 2003

[23] HARIR Miloud, « Etude des Défauts dans La Machine Asynchrone à Cage d'Ecureuil par l'Emploi de la Fonction d'Enroulement Modifiée ». Mémoire en vue de l'obtention du diplôme de magister. Université des Sciences et de la Technologie Mohamed BOUDIAF d'Oran. 2009.

[24] Marouane Frini. « Diagnostic des engrenages à base des indicateurs géométriques des signaux électriques triphasés ». Thèse doctorat. Université de Lyon, France. Octobre 2018.

[25] Ahcene BOUZIDA « Diagnostic de Défauts des Machines Asynchrones par la Technique du Traitement du Signal ». Thèse doctorat en sciences. École Nationale Polytechnique. Alger. Avril 2015

[26] Neelam Mehala, Ratna Dahiya, Article « Motor Current Signature Analysis and its Applications in Induction Motor Fault Diagnoses » International journal of systems applications, engineering & development. 2007

[27] Andrzej M. Trzynadlowski et Ewen Ritchie, Article «Comparative investigation of diagnostic media for induction motors: A case of rotor cage faults». IEEE Transactions on Energy Conversion. Octobre 2000.

[28] BOUKOUCHA Abdelaziz, OUAGUED Sofiane, « Télédiagnostic de Défauts Electriques de la Machine Asynchrone », projet de fin d'études, Ecole Nationale Polytechnique, Alger 2012.

[29] Fatima Ait Mohammed, « Approches d'apprentissage automatique pour la détection du spam web : exploration de diverses caractéristiques », Mémoire présenté comme exigence partielle de la maîtrise en informatique. Université du Québec à Montréal. Canada. Mars 2018

[30] Tharam S Dillon et Dagmar Niebur, Article « Neural Networks Applications in Power Systems ». Elecfrical Power & Energy Systems, Pullman, États-Unis 1997.

[31] Raghda ALILOUCH, « détection, classification et localisation des défauts dans les lignes de transmission par les réseaux de neurones artificiels », mémoire présenté comme exigence partielle de la maîtrise en ingénierie, université du Québec en Abitibi Témiscamingue. Canada, November 2022.

[32] M. Jamil, S. K. Sharma, et R. Singh, Article « Fault detection and classification in electrical power transmission system using artificial neural network», SpringerPlus, 2015.

[33] Elbouchikhi Elhoussin, Yassine Amirat, Gilles Feld, Franck Le Gall, Mohamed Benbouzid, Article « Diagnostic et détection des défauts dans les machines asynchrones par des méthodes avancées de traitement du signal » La Revue 3EI, Université de Brest, France. Janvier 2018.

[34] Elgiz Baskaya, « Détection & diagnostic de pannes pour les drones utilisant la machine Learning ». Thèse en vue de l'obtention du doctorat. Université Paul Sabatier - Toulouse III, France. Mai 2019.

[35] Aleksandr Petrusev, Vincent Debusschere, Rémy Rigo-Mariani, Patrick Reignier, Nouredine Hadjsaid, Article « L'intelligence artificielle pour la gestion des réseaux de distribution ». La Revue de l'électricité et de l'électronique, 2022.

[36] WendBenedo Arnaud Bienvenue ZOUNGRANA, « Application des algorithmes d'apprentissage automatique pour la détection de défauts de roulements sur les machines tournantes dans le cadre de l'Industrie 4.0 » Mémoire présenté en vue de l'obtention du grade de

Maître ès sciences appliquée en ingénierie, profil recherche. Université du Québec à Chicoutimi. 2020.

[37] Bahzad Taha Jijo, Adnan Mohsin Abdulazeez, Article « Classification Based on Decision Tree Algorithm for Machine Learning ». Journal of applied science and technology trend, 2021.

[38] John Chaussard, « Introduction à Matlab », LAGA – Université Paris 13, France 2017.

[39] Ahcène Bouzida, Omar Touhami, Rachid Ibtiouen, Adel Belouchrani, Maurice Fadel, et A. Rezzoug, Article « Fault Diagnosis in Industrial Induction Machines Through Discrete Wavelet Transform». IEEE Transactions on Industrial Electronics, 2011,

[40] Chen yiguang, Zhang Hongxia, Shen Yonghuan, Article «Method of EMD and ZOOM-FFT to Detect the Broken Bars Fault in Induction Motor», Electrical Power Engineering, Janvier 2010.

[41] Kouidri Mohammed Ali, Nouar Allal, Djilali Mahi, Article «Diagnosis and Protection of Alternators Against Mass Faults», Modelling, Measurement and Control B, December, 2020

[42] Ahcene BOUZIDA; Radia ABDELLI; Aimad BOUDOUDA et Omar BENDJGHABA, M'hamed OUADAH, Article «Lumped-Parameter Thermal Model of Induction Motor under Phase Open-Circuit Fault», IEEE. 2019.

[43] Jose Antonino-Daviu, Selin Aviyente, Elias G. Strangas, Martin Riera-Guasp, Jose Roger-Folch et Rafael B. Pérez, Article «An EMD-based invariant feature extraction algorithm for rotor bar condition monitoring», IEEE. 2011.

[44] Petros Karvelis, George Georgoulas, Chrysostomos D. Stylios, Ioannis P. Tsoumas, Jose Alfonso Antonino-Daviu, Vicente Climente-Alarcón, Article «An Intelligent Icons Approach for Rotor Bar Fault Detection», IEEE. 2013.

[45] R. Puche-Panadero, M. Pineda-Sanchez, M. Riera-Guasp, J. Roger-Folch, J. A. Antonino-Daviu, J. Perez-Cruz, Article «Diagnosis of rotor bar breakages based on the Hilbert Transform of the current during the startup transient», IEEE. 2009.

[46] J. Antonino-Daviu, J. Roger-Folch, J. Pons-Llinares, M. Pineda-Sánchez, R.B. Pérez, C. Article «Charlton-Pérez, Application of the Empirical Mode Decomposition to condition monitoring of damper bars in synchronous motors», IEEE. 2011.

[47] J. Antonino-Daviu, V. Climente-Alarcon, I. Tsoumas, G. Georgoulas, R.B. Pérez, Article «Multi-harmonic tracking for diagnosis of rotor asymmetries in wound rotor induction motors», IEEE. 2013.

[48] Jean-Pierre Caron, Article « Modélisation et commande de la machine asynchrone », TECHNIP, coll. « Méthodes et pratiques », France, 1995.

[49] SCHAEFFER Emmanuel, « Diagnostic des machines asynchrones : modèles et outils paramétriques dédiés à la simulation et à la détection de défauts » Thèse de doctorat, École Centrale de Nantes, France, 1999.

[50] B. Yazici, G.B. Kliman, W.J. Premerlani, R.A. Roegl, G.B. Robinson and A. Abdel- Malek. Article « An adaptive on-line statistical method for fault detection using stator current». IEEE-IAS, New Orleans, LA, 1977.

[51] H. A. Bonnett and G. C. Soukup. Article «Rotor failures in squirrel cage induction motor». IEEE Trans. Industry Applications, Décembre 1986.

[52] NOUREDDINE Lahcène, « Diagnostic de défauts au rotor d'une machine asynchrone à cage d'écureuil » Mémoire de Magister, Ecole Nationale Polytechnique Alger, 2005.

[53] R. Abdelli, « Perturbations singulières appliquées au modèle de machine asynchrone avec défauts au stator et au rotor » Mémoire de magister en électrotechnique, Ecole national polytechnique d'Alger, Juin 2007.

[54] ZERROUKI Meriem, BENTOUTI Manel. « Diagnostic des défauts dans la machine asynchrone à cage d'écureuil », Mémoire d'ingéniorat d'état, Ecole Supérieure des Sciences Appliquées d'Alger, 2020.

[55] BERREHAIL Belkacem, « identification des parametres d'un moteur asynchrone a cage », Mémoire de Fin d'Etudes master, Université Mohamed Khider Biskra, 2013, P31.

[56] ACHOUR Houssam, « Etude comparative des indicateurs des défauts rotoriques dans les MAS à cage », Mémoire de Fin d'Etudes master, Université Mohamed Khider Biskra, 2014.

[57] Mr HARIR Miloud « Etude des Défauts dans La Machine Asynchrone à Cage d'Ecureuil par l'Emploi de la Fonction d'Enroulement Modifiée », mémoire de magister, université des sciences et de la technologie d'Oran Mohamed Boudiaf, 2009.

[58] Abdelghani Chahmi. « Analyse Spectrale des Défauts Rotoriques sur un Entraînement Electrique par les Vecteurs de Park ». JCGE, Cherbourg, France. Jun 2015.

[59] R. Casimir, E. Boutleux, G. Clerc and F. Chappuis. «Comparative study of diagnosis methods for induction motors». These doctorate, Ecole Centrale de Lyon. France 2003.

[60] Mr. F. BENABIDA, Mr. M. OUADAH « Diagnostic de défauts au stator et au rotor par estimation paramétrique de la machine asynchrone à cage d'écureuil », Projet de fin d'études D'Ingénieur d'Etat, ecole nationale polytechnique alger, 2006.

[61] Y. LAAMARI, « estimation par filtre de karman étendu des états et paramètres de la machine asynchrone en vue de détection des défauts. », mémoire de fin d'études en vue de l'obtention du diplôme de master université de m'sila, 2013.

[62] lecture notes on, electrical machine-ii, subject code - bee 1401 for b-tech 4th sem ee & eee, veer surendra sai university of technology, burla, sambalpur, odisha 768018, www.vssut.ac.in

[63] www.jimchapmancommunities.com

[64] Marouane Frini. « Diagnostic des engrenages à base des indicateurs géométriques des signaux électriques triphasés ». Université de Lyon, 2018. Français.

[65] Allal Abderrahim, « Grandeurs non invasives pour le diagnostic des machines asynchrones », Magister En Electrotechnique, université Ferhat Abbas, Sétif 2010.

[66] Abdelghani Chahmi. « Identification paramétrique de la machine asynchrone dédiée au diagnostic ». Energie électrique. Université des sciences et technologie d'Oran, 2017.

[67] S. Ekici, S. Yildirim, et M. Poyraz, Article « A transmission line fault locator based on Elman recurrent networks », Applied Soft Computing, vol. 9, 2009.

[68] R. Dubey, S. Samantaray, et B. Panigrahi, Article «An Extreme Learning Machine based Fast and Accurate Adaptive Distance Relaying Scheme», International Journal of Electrical Power & Energy Systems, 2015.

[69] El Houssin El Bouchikhi, Vincent V. Choqueuse, Mohamed Benbouzid. Article «Condition Monitoring of Induction Motors Based on Stator Currents Demodulation». international review of electrical ENGINEERING-IREE, 2015.

[70] G. Rilling, P. Flandrin, et P. Gonçalves, Article «On empirical mode decomposition and its algorithms», in IEEE-EURASIP Workshop on Nonlinear Signal and Image Processing, Grado, Italia, 2003

[71] Mohamadally Hasan Fomani Boris, « SVM : Machines à Vecteurs de Support ou Séparateurs à Vastes Marges » BD Web, ISTY3 Versailles St Quentin, France, 16 janvier 2006

[72] Nassim Laouti, « Diagnostic de défauts par les Machines à Vecteurs Supports : application à différents systèmes multivariables non linéaires ». Thèse présentée pour obtenir le grade de docteur en automatique. Université Claude Bernard - Lyon I, 2012.

[73] Aymen CHERIF « Réseaux de neurones, SVM et approches locales pour la prévision des séries temporelles » thèse doctorat, université François Rabelais de tours. France 2013.

[74] Nahla Ben Amor- Salem Benferhat-Zied Elouedi, Article « Réseaux bayésiens naïfs et arbres de décision dans les systèmes de détection d'intrusions » Conférence de 14ème Congrès Francophone AFRIF-AFIA de Reconnaissance des Formes et Intelligence Artificielle, Toulouse, France. Janvier 2004.

[75] H. Kousar, M. M. Mulla, P. Shettar and D. G. Narayan, Article «Detection of DDoS Attacks in Software Defined Network using Decision Tree» 2021 10th IEEE International Conference on Communication Systems and Network Technologies (CSNT), Bhopal, India, 2021.

[76] Fatiha Barigou, Baya Naouel Barigou, Baghdad Atmani, Bouziane Beldjilali, Article « Sélection de prototypes en vue d'une catégorisation de textes avec les K plus proches voisins : étude comparative ». Journal Extraction et Gestion des Connaissances, 2014.

[77] Eve Mathieu-Dupas, Article « Algorithme des k plus proches voisins pondérés et application en diagnostic ». 42èmes Journées de Statistique, Marseille, France. 2010.

[78] SENOUSSI Hafida « Sélection de Données pour l'Apprentissage des Réseaux de Neurones, Arbres de Décision et les k-Plus Proches Voisins : Application en Diagnostic de Pannes », Thèse doctorat, Université des Sciences et de la Technologie d'Oran Mohamed BOUDIAF. 2022.

[79] Jean-Claude TRIGEASSOU, « Diagnostic des machines électriques », Hermès Science, EGEM, 2011

[80] Ilias OUACHTOUK, Soumia EL HANI, Said GUEDIRA, Khalid DAHI, Lahbib SADIKI, Article «Advanced Model of Squirrel Cage Induction Machine for Broken Rotor Bars Fault Using Multi Indicators», power engineering and electrical engineering, 2016.

[81] eduscol.education.fr, « Logiciel, Matlab Classification Learner »

[82] Abdelhamid DJEFFAL, « Utilisation des méthodes Support Vector Machine (SVM) dans l'analyse des bases de données », Thèse Doctorat en Informatique, Université Mohamed Khider – Biskra, 2012.

[83] Jérémy Boes, « Apprentissage du contrôle de systèmes complexes par l'auto-organisation coopérative d'un système multi-agent : Application à la calibration de moteurs à combustion ». Système multiagents [cs.MA]. Université de Toulouse III - Paul Sabatier, France 2014.

[84] Alain Girard, « exploration d'un algorithme génétique et d'un arbre de décision à des fins de catégorisation », université du Québec. Canada. Avril 2007.

[85] Erwann Martin, « Réseaux de neurones à l'échelle nano. Quels modèles d'apprentissage ? » Intelligence artificielle [cs.AI]. Université Paris-Saclay, 2022. Français.

[86] Charles Bouveyron, « Modélisation et classification des données de grande dimension : application à l'analyse d'images ». Mathématiques [math]. Université Joseph-Fourier - Grenoble I. France 2006.

[87] Amina Alaoui Belghiti, « Prédiction de situations anormales par apprentissage automatique pour la maintenance prédictive : approches en transport optimal pour la détection d'anomalies ». Robotique [cs.RO]. Université Paris-Saclay, France 2021.

[88] Sylvain Arlot, « Validation croisée », université-paris-Saclay. France September 2020

[89] Jamilu Awwalu and Ogwueleka Francisca Nonyelum, « On Hold out and Cross Validation A Comparison between Neural Network and Support Vector Machine », International Journal of Trend in Research and Development, Volume 6(2). Apr. 2019.

[90] [Schoen, R. R., Habetler, T. G., Kamran, F., & Bartheld, R. G. (1995). Motor bearing damage detection using stator current monitoring. IEEE Transactions on Industry Applications, 31(6), 1274-1279

[91] Cooley, J. W., & Tukey, J. W. (1965). An algorithm for the machine calculation of complex Fourier series. Mathematics of Computation, 19(90), 297-301

[92] Cohen, L. (1989). Time-frequency distributions—A review. Proceedings of the IEEE, 77(7), 941-981