

Université Amar Telidji de Laghouat



Faculté de Technologie
Département d'Electrotechnique

Thèse de Doctorat en Électrotechnique

Discipline : Identification, modélisation et commande des machines électriques

Option : Commande des Systèmes électromécaniques

Présenté par :

Saddam BENSAOUCHE

THEME

Contribution au diagnostic de défauts statoriques et rotoriques par l'utilisation des techniques de l'intelligence artificielle -Application aux machines asynchrones à cage

Soutenue le 29/12/2020 devant le jury d'examen composé de :

Mr: Abdechafik HADJADJ	Président de jury	Prof	Université Amar Telidji, Laghouat, Algérie
Mr: Sid Ahmed BESSEDIK	Rapporteur	M.C	Université Amar Telidji, Laghouat, Algérie
Mr: Aissa AMEUR	Co-Rapporteur	Prof	Université Amar Telidji, Laghouat, Algérie
Mme: Sandrine MOREAU	Co-Rapporteur	M.C	Ecole Nationale Supérieure d'Ingénieurs de Poitiers (ENSIP) de l'Université de Poitiers
Mr: Mecheri KIOUS	Examineur	Prof	Université Amar Telidji, Laghouat, Algérie
Mr: Abdellah KOUZOU	Examineur	Prof	Université Ziane Achour, Djelfa, Algérie
Mr: Tayeb ALLAOUI	Examineur	Prof	Université Ibn Khaldoun, Tiaret, Algérie

2020-2021

Dédicaces

Je dédie le présent travail:

À mes grands-mères: LALA MEBARKA, et DJAMILA (**ALLAH** yarhamha) ;

À ma chère mère: DALLOULA et mon cher père SAAD;

À mes chères sœurs: Bariza, Rachida, Karima, Roumaissa;

À mes chers frères: Belkacem, Rabia, Abd elkader, Fares;

À mes collègues qui m'aident à corriger les publications;

À tous mes collègues avec lesquels j'ai travaillé dans le laboratoire, surtout à Oussama M et Soufiane Kh;

À tous les amis en dehors du cadre professionnel. Je ne peux pas tous les nommer de peur d'en oublier;

À tous les responsables et les ingénieurs de **MathWorks**: <https://mathworks.com>;

Saddam.

Remerciements

Je remercie avant tous **ALLAH** pour son aide, ses innombrables dons, **ALLAH** qui m'a donné la force, la volonté et le moral pour accomplir mes études.

J'exprime mes vifs remerciements à Mr **Sid Ahmed BESSEDIK**, enseignant à l'université de Laghouat, d'avoir encadré et dirigé ces travaux, et pour la confiance qu'il m'a accordée tout au long de cette thèse.

Je suis particulièrement reconnaissante envers Mr **Aissa AMEUR**, enseignant à l'université de Laghouat, pour ces encouragements qui me poussaient toujours vers l'avant et pour sa contribution scientifique qui a été très fructueux dans l'avancement de ce travail.

Qu'il me soit permis d'exprimer à Mme **Sandrine MOREAU**, enseignante à l'université de Poitiers, ma gratitude pour son importante participation dans l'élaboration de ce travail. Ses fructueuses connaissances et expériences ont été pour moi une source constante de savoir.

Je tiens également à remercier les membres de jury d'examen -Mrs **Abdechafik HADJADJ**, **Mecheri KIOUS**, **Abdellah KOUZOU**, **Tayeb ALLAOUI**- pour avoir accepté de participer au jugement de cette thèse.

Abstract

Today, Artificial Intelligence (IA) is more used in the diagnosis of electrical machines, it increases the efficiency and reliability of detection. In particular, the squirrel cage induction machines (MAS) are very present in many industrial applications because of their robustness, reliability, and low cost compared to other types of machines. However, these machines are sometimes prone to failures in their different parts.

The purpose of this thesis is to propose an efficient and automatic diagnostic system, making it possible to correctly detect, identify, and locate stator, rotor, or mixed fault in the MAS. This diagnostic system is based on several artificial intelligence techniques such as a Multi-Layer Perceptron Neural Network (MLPNN), Radial Basis Function Neural Networks (RBFNN), Extreme Learning Machine (ELM), Support Vector Machine (SVM), k Nearest Neighbors (kNN), Naive Bayes (NB), Decision Tree (DT), Random Forest (RF), and Discriminative Analysis (DA).

Three databases are created so that they contain several examples of healthy and faulty operation of the machine, under different load conditions: a database contains stator fault of inter-turns short-circuit type, a database contains rotor failure of broken bars type, and another base has simultaneous stator/rotor fault. These databases will be used to train the proposed IA techniques.

The performance and effectiveness of the proposed diagnostic techniques are tested on a database different from those used for training, in order to evaluate their generalization capacity. The obtained results show the advantage and the efficiency of the application of the proposed methods to the classification, detection, localization, and automatic diagnosis of the MAS faults.

Keywords:

Induction machine, diagnosis, detection, fault location, broken bars fault, inter-turns short-circuit fault, signal processing, artificial intelligence.

Résumé

Aujourd'hui, l'intelligence artificielle (IA) est plus utilisée dans le domaine du diagnostic des machines électriques, elle permet d'augmenter l'efficacité et la fiabilité de la détection. En particulier, les machines asynchrones à cage rotoriques (MAS) sont très présentes dans de nombreuses applications industrielles en raison de sa robustesse, de sa fiabilité et de son faible coût par rapport à d'autres types de machines. Cependant, ces machines sont parfois sujettes à des défaillances dans leurs différentes parties.

Cette thèse a pour but de proposer un système de diagnostic efficace et automatique permettant de détecter, identifier et localiser correctement les défauts statoriques, rotoriques ou le défaut mixte de la MAS à cage. Ce système de diagnostic est basé sur plusieurs techniques d'intelligence artificielle telle que les réseaux de neurones du type Perceptron Multicouche (MLPNN), les réseaux de neurones à fonctions de base radiales (RBFNN), machine d'apprentissage extrême (ELM), machine à vecteurs de support (SVM), k voisins plus proches (kNN), naïve bayes (NB), l'arbre de décision (DT), la forêt aléatoire (RF), et l'analyse discriminative (DA).

Trois bases de données sont conçues de telle sorte qu'elles contiennent plusieurs exemples de fonctionnement sain et défectueux de la machine, sous différentes conditions de charges: une base de données contient de défaut statorique du type court-circuit entre spires, une base de données contient de défaut rotorique de type rupture des barres et une autre base possède des défauts simultanés stator/rotor. Ces bases de données serviront à l'apprentissage des techniques d'IA proposées.

Les performances et l'efficacité des techniques du diagnostic proposées sont testées sur une base de données différentes de celles utilisées pour l'apprentissage, afin d'évaluer leur capacité de généralisation. Les résultats obtenus montrent l'avantage et l'efficacité de l'application des techniques proposées à la classification, détection, localisation et au diagnostic automatique de défaut de la MAS à cage.

Mots-clés:

Machine asynchrone, diagnostic, détection, localisation de défaut, défaut de rupture des barres, défaut de court-circuit entre spires, traitement du signal, intelligence artificielle.

ملخص:

اليوم ، يُستخدم الذكاء الصناعي بشكل أكبر في تشخيص الآلات الكهربائية ، فهو يزيد من كفاءة وموثوقية التشخيص. على وجه الخصوص ، الآلات الاتزامنة مع قفص سنجابي موجودة جدًا في العديد من التطبيقات الصناعية بسبب متانتها وموثوقيتها وتكلفتها المنخفضة مقارنة بأنواع أخرى من الآلات. ومع ذلك ، فإن هذه الآلات تكون أحيانًا عرضة للفشل في أجزائها المختلفة. الغرض من هذه الأطروحة هو اقتراح نظام تشخيص فعال وتلقائي يجعل من الممكن اكتشاف، تحديد و توطين بشكل صحيح خلل الجزء الثابت، خلل الدوار، أو خلل مختلط في الآلة اللاتزامنية ذات القفص السنجابي. يعتمد هذا النظام التشخيصي على العديد من تقنيات الذكاء الصناعي مثل الشبكات العصبية متعددة الطبقات، الشبكات العصبية للوظائف الأساسية الشعاعية، آلة التعلم المتطرفة، آلة ناقلات الدعم، أقرب الجيران ك، بايز البسيط، شجرة القرار، الغابة العشوائية، والتحليل التمايزي.

تم تصميم ثلاث قواعد بيانات بحيث تحتوي على العديد من الأمثلة على التشغيل الصحي وفي حالة خلل الجهاز ، في ظل ظروف تحميل مختلفة: تحتوي قاعدة البيانات على خلل الجزء الثابت من نوع دائرة قصيرة بين اللفات، وقاعدة بيانات يحتوي على خلل الجزء الدوار من نوع كسر القضبان، وقاعدة أخرى للخلل المتزامن للجزء الثابت مع الجزء الدوار. سيتم استخدام قواعد البيانات هذه لتعليم تقنيات الذكاء الاصطناعي المقترحة.

يتم اختبار أداء وفعالية تقنيات التشخيص المقترحة على قاعدة بيانات مختلفة عن تلك المستخدمة للتعلم ، وذلك لتقييم قدرتها على التعميم. أظهرت النتائج التي تم الحصول عليها قدرة وفعالية تطبيق الأساليب المقترحة في التصنيف، الكشف، التوطين والتشخيص التلقائي لخلل الآلة اللاتزامنية ذات القفص السنجابي.

كلمات مفتاحية:

آلة لاتزامنية ، تشخيص ، كشف ، توطين الخلل ، خلل القضبان ، خلل دائرة قصيرة بين اللفات، معالجة الإشارة ، الذكاء الصناعي.

Liste des figures

1.1	Symbole d'une MAS à cage d'écureuil (a), et à rotor bobiné (b)	7
1.2	Machine asynchrone à cage d'écureuil	9
1.3	Pourcentage de défauts dans les MASs à cage d'écureuil	10
1.4	Classification et localisation des défauts d'une MAS à cage d'écureuil	10
1.5	Schéma des enroulements statoriques en défaut	11
1.6	Rotors d'une MAS cage d'écureuil avec et sans défaut	11
1.7	Roulement à billes à l'état sain et en défaut	12
1.8	Techniques de diagnostic des défauts des MAS	14
1.9	Principe de l'observateur	16
1.10	Principe de résidu	17
1.11	Vue schématique d'un roulement à billes	22
1.12	Vue schématique de l'excentricité statique (a) et dynamique (b)	23
1.13	Structure principale d'un système expert	28
1.14	Structure principale de la logique floue	29
1.15	Architecture des RNAs type MLP de deux couches cachées	30
1.16	Architecture principale de l'ANFIS	31
1.17	Classification de deux classes à l'aide de SVM	33
1.18	Transformer l'espace de représentation des données d'entrée en un espace de plus grandes dimensions	33
1.19	Classification d'un échantillon non défini à l'aide de kNN	34
1.20	Principe général de l'algorithme génétique	36
1.21	Structure de naïve Bayes	37
1.22	Exemple d'arbre de décision	38
1.23	Exemple d'une forêt aléatoire	39
1.24	Principe de DA	40
1.25	Architecture de CNN	41
1.26	MLAs et DL	42

1.27	Interactions entre l'IA, MLAs et DL	43
2.1	Schéma électrique équivalent au rotor d'une MAS à cage d'écureuil	49
2.2	Induction magnétique produite par une maille rotorique	50
2.3	Flux mutuelle entre une phase statorique m et une maille rotorique j^{eme}	51
2.4	Représentation schématique des mailles rotoriques	54
2.5	Projection du modèle multi-enroulement sur le modèle dq	58
2.6	Simulation de la MAS dans un état sain- Courants statoriques	68
2.7	Simulation de la MAS dans un état sain- Vitesse de rotation	68
2.8	Simulation de la MAS dans un état sain- Couple électromagnétique	68
2.9	Simulation de la MAS en rupture des barres - Courants statoriques	70
2.10	Simulation de la MAS en rupture des barres- Vitesse de rotation	70
2.11	Simulation de la MAS en rupture des barres- Couple électromagnétique	70
2.12	Schéma des enroulements statoriques avec un court-circuit de phase a	71
2.13	Simulation de la MAS en court-circuit entre spires- Courants statoriques	74
2.14	Simulation de la MAS en court-circuit entre spires- Vitesse de rotation	74
2.15	Simulation de la MAS en court-circuit entre spires- Couple électromagnétique	74
2.16	Simulation de la MAS en défaut simultané- Courants statoriques	75
2.17	Simulation de la MAS en défaut simultané- Vitesse de rotation	75
2.18	Simulation de la MAS en défaut simultané- Couple électromagnétique	75
3.1	Courant statorique i_{sa} - MAS saine et en rupture des barres	79
3.2	FFT de courant statorique i_{sa} [0-100 Hz] - MAS saine et en rupture des barres	80
3.3	MUSIC de courant statorique i_{sa} [0-100Hz] - MAS saine et en rupture des barres	82
3.4	Courants statoriques pour une MAS saine et en court-circuit entre spires	83
3.5	FFT de courant statorique i_{sa} [0-200Hz]- MAS saine et en court-circuit entre spires	84
3.6	MUSIC de courant statorique i_{sa} [0-200Hz]- MAS saine et en court-circuit entre spires	85
3.7	Courant statorique i_{sa} pour un défaut simultané	86
3.8	FFT de courant statorique i_{sa} [0-200Hz] - défaut simultané	87
3.9	MUSIC de courant statorique i_{sa} [0-200Hz]- défaut simultané	88
3.10	Enveloppe de Park pour une MAS saine et en rupture des barres	89

3.11	FFT de PVM [0-10Hz] - MAS saine et en rupture des barres	90
3.12	Enveloppe de Hilbert pour une MAS saine et en rupture des barres	91
3.13	FFT de HM [0-10Hz]- MAS saine et en un rupture des barres	92
3.14	Enveloppe de Hilbert pour une MAS saine et court-circuit entre les spires .	92
3.15	FFT de HM- MAS saine et court-circuit entre les spires	93
3.16	Enveloppe de Hilbert pour une MAS saine et en défaut simultané	94
3.17	FFT de HM - défaut simultané	95
3.18	Principe de DWT	95
3.19	Diagramme de traitement du signal utilisant la méthode de DWT	97
3.20	DWT de courant statorique i_{sa} - MAS saine	98
3.21	DWT de courant statorique i_{sa} - rupture des barres rotoriques	99
3.22	DWT de courant statoriques i_{sa} - court-circuit entre spires	100
3.23	DWT de courant statorique i_{sa} - défaut simultané	101
3.24	L'énergie stockée dans les détails à l'aide de db44 - MAS saine et en rupture des barres rotoriques	102
3.25	L'énergie stockée dans les détails à l'aide de db44 - MAS saine et en court- circuit entre spires	102
3.26	L'énergie stockée dans les détails à l'aide de db44- MAS saine et en défaut simultanée	103
4.1	Architecture principale de RBFNN	109
4.2	Architecture principale d'ELM	109
4.3	Représentation schématique pour détecter une rupture des barres de rotor à l'aide des MLAs	116
4.4	Courant statorique i_{sa} et son enveloppe (HM) pour une barre cassée.	117
4.5	FFT de HM pour une barre cassée avec différentes charges	118
4.6	Base de données d'apprentissage et leur sortie correspondante- MAS saine et en rupture des barres	119
4.7	Base de données de test- MAS saine et en rupture des barres	119
4.8	Sortie de MLPNN (Tansig, 05 neurones)- rupture des barres rotoriques . .	122
4.9	Sortie de RBFNN a (07 neurones)- rupture des barres rotoriques	123
4.10	Sortie d'ELM avec (06 neurones)- rupture des barres rotoriques	124
4.11	Sortie de SVM (OVO, Polynomiale)- rupture des barres rotoriques	125
4.12	Sortie de kNN (City-block, k=3)- rupture des barres rotoriques	127
4.13	Sortie de NB gaussienne- rupture des barres rotoriques	127

4.14	Sortie de DT gdi- rupture des barres rotoriques	128
4.15	Sortie de RF de 25 arbres- rupture des barres rotoriques	129
4.16	Sortie de DA diago-quadratique- rupture des barres rotoriques	131
4.17	Déphasage entre tension v_{sa} et courant i_{sa}	133
4.18	Représentation schématique pour détecter un court-circuit entre spires à l'aide des MLAs	134
4.19	Base de données d'apprentissage et leur sortie correspondant pour une MAS saine et en court-circuit entre les spires	135
4.20	Base de données de test pour une machine saine et en court-circuit entre les spires	136
4.21	Sortie de MLPNN (Tansig, 05 neurones)- court circuit entre spires	136
4.22	Sortie de RBFNN pour 18 neurones- court-circuit entre spires	137
4.23	Sortie d'ELM de 25 neurones- court-circuit entre spires	138
4.24	Sortie de SVM (OVA, polynomiale)- court-circuit entre spires	139
4.25	Sortie de kNN (cosinus, k=3)- court circuit entre spires	140
4.26	Sortie de NB gaussienne- court-circuit entre spires	141
4.27	Sortie de DT gdi- court-circuit entre spires	142
4.28	Sortie de RF (25 arbres)- court-circuit entre spires	143
4.29	Sortie de DA quadratique- court-circuit entre spires	144
4.30	Représentation schématique pour détecter un défaut simultané à l'aide des MLAs	146
4.31	Base de données d'apprentissage et leur sortie correspondante pour un défaut simultané	148
4.32	Base de données de test pour un défaut simultané	149
4.33	Sortie de MLPNN (Tansig, 03 neurones)- défaut simultané	150
4.34	Sortie de RBFNN pour 25 neurones- défaut simultané	151
4.35	Sortie d'ELM pour 25 neurones- défaut simultané	152
4.36	Sortie de SVM (OVA, Polynomiale)- défaut simultané	153
4.37	Sortie de kNN (Euclidien, K = 3)- défaut simultané	154
4.38	Sorties de NB gaussienne- défaut simultanée	155
4.39	Sortie de DT gdi- défaut simultané	156
4.40	Sortie de RF (25 cycles)- défaut simultané	157
4.41	Sortie de DA quadratique- défaut simultané	157
4.42	Système global basé sur SVM (polynomiale, OVA) pour détecter un court-circuit entre spires et / ou une rupture des barres du rotor	160

A.1	Fonctions d'activation de MLPNN	166
A.2	Fonction gaussienne	167
A.3	Distance euclidienne entre deux points	168
A.4	Distribution gaussienne	169

Liste des tableaux

2.1	Paramètres de MAS utilisée pour la simulation	67
3.1	Bandes de fréquences obtenues par décomposition en multi niveaux	97
4.1	Configuration de MLPNN	120
4.2	Performance de MLPNN pour détecter une rupture des barres rotoriques	121
4.3	Configuration de RBFNN	123
4.4	Performance de RBFNN pour détecter une rupture des barres rotoriques	123
4.5	Performance d'ELM pour détecter une rupture des barres rotoriques	124
4.6	Performance de SVM pour détecter une rupture des barres rotoriques	125
4.7	Performance de kNN pour détecter une rupture des barres rotoriques	126
4.8	Performance de NB pour détecter une rupture des barres rotoriques	127
4.9	Performance de DT pour détecter une rupture des barres rotoriques	128
4.10	Performance de RF pour détecter une rupture des barres rotoriques	129
4.11	Performance de DA pour détecter une rupture des barres rotoriques	130
4.12	Arrangement des MLAs appliques pour détecter une rupture des barres rotoriques	132
4.13	Performance de MLPNN pour détecter un court-circuit entre spires	135
4.14	Performance de RBFNN pour détecter un court-circuit entre spires	137
4.15	Performance de ELM pour détecter un court-circuit entre spires	138
4.16	Performance de SVM pour détecter un court-circuit entre spires	139
4.17	Performance de kNN pour détecter un court-circuit entre spires	140
4.18	Performance de NB pour détecter un court-circuit entre spires	141
4.19	Performance de DT pour détecter un court-circuit entre spires	142
4.20	Performance de RF pour détecter un court-circuit entre spires	143
4.21	Performance de DA pour détecter un court-circuit entre spires	143
4.22	Arrangement des MLAs appliqués pour détecter un court-circuit entre spires	145
4.23	Performance de MLPNN pour détecter un défaut simultané	149

4.24	Performance de RBFNN pour détecter un défaut simultané	150
4.25	Performance d'ELM pour détecter un défaut simultané	151
4.26	Performance de SVM pour détecter un défaut simultané	152
4.27	Performance de kNN pour détecter un défaut simultané	154
4.28	Performance de NB pour détecter un défaut simultané	155
4.29	Performance de DT pour détecter un défaut simultané	155
4.30	Performance de RF pour détecter un défaut simultané	156
4.31	Performance de DA pour détecter un défaut simultané	157
4.32	Arrangement des MLAs appliques pour détecter un défaut simultané . . .	158

Acronymes

MAS	Machines Asynchrones
MCC	Machine à Courant Continu
IA	Intelligence Artificielle
MLAs	Machine Learning Algorithms
DL	Deep Learning
MLPNN	Multi-Layer Perceptron Neural Network
RBFNN	Radial Basis Function Neural Networks
ELM	Extreme Learning Machine
SVM	Support Vector Machine
kNN	k Nearest Neighbors
NB	Naive Bayes
DT	Decision Tree
RF	Random Forest
DA	Discriminative Analysis
ES	Expert System
FL	Fuzzy Logic
ANFIS	Adaptive Neuro-Fuzzy Inference System
EMs	Ensembles Methods
PCA	Principal Component Analysis
GA	Genetic algorithm
FFT	Fast Fourier Transform
MUSIC	MUltiple SIgnal Classification
ESPRIT	Estimation of Signal Parameters via Rotational Invariance Techniques
WT	Wavelet Transformation
DWT	Discret Wavelet Transform
RPVM	Reduced Park Vector Modulus

RNAs	Réseaux de Neurones Artificiels
TP	Transformation de Park
HT	Transformation de Hilbert
PVM	Enveloppe de Park
HM	Enveloppe de Hilbert
DWV	Wingner-City Distribution
OAo	One-Against-One
OAA	One-Against-All
MSE	Erreur quadratique moyenne (Mean Squared Error)
MAE	Erreur absolue moyenne (Mean Absolute Error)
CART	Classification And Regression Trees

Table de matière

Abstract

Liste des figures

Liste des tableaux

Acronymes

Introduction Générale	1
1 ETAT DE L'ART DES DEFAUTS DES MACHINES ASYNCHRONES ET LEUR DIAGNOSTIC	6
1.1 Introduction	6
1.2 Machines asynchrones	7
1.3 Constitution d'une MAS à cage d'écureuil	8
1.3.1 Défaillances d'une MAS à cage d'écureuil	9
1.4 Méthodes de diagnostic des défauts	13
1.4.1 Méthodes internes	15
1.4.2 Méthodes externes	17
1.5 Conclusion	42
2 MODÉLISATION DES MACHINES ASYNCHRONE EN VUE DE DIAGNOSTIC DES DÉFAUTS	44
2.1 Introduction	44
2.2 Hypothèses simplificatrices	46
2.3 Modèle multi-enroulements de la MAS	47
2.3.1 Inductances de stator	47
2.3.2 Inductances de rotor	48

2.3.3	Inductances mutuelles	50
2.4	Mise en équations	51
2.4.1	Transformation triphasée biphasée	52
2.4.2	Équations statoriques dans le référentiel dq	52
2.4.3	Équations rotoriques dans le référentiel dq	54
2.4.4	Équations mécaniques	56
2.5	Transformation de Clarke généralisée	57
2.5.1	Matrice d'inductances et des résistances dans un modèle dq équivalent	59
2.6	Simulation de modèle réduit de la MAS	66
2.6.1	Simulation de MAS a l'état sain	66
2.6.2	Simulation de la MAS en présence de défaut rotorique	68
2.7	Modèle réduit avec un défaut de court-circuit entre spires	69
2.7.1	Simulation de MAS en présence d'un défaut statorique	72
2.8	Modèle global de la MAS	73
2.8.1	Simulation de modèle global de la MAS	73
2.9	Conclusion	76

3 DÉTECTION DE DÉFAUTS DE ROTOR ET DE STATOR DE LA MACHINE ASYNCHRONE PAR TRAITEMENT DE SIGNAL 77

3.1	Introduction	77
3.2	Analyse spectrale pour détecter la rupture des barres rotoriques	78
3.2.1	FFT pour détecter une rupture des barres rotoriques	78
3.2.2	MUSIC pour détecter une rupture des barres rotoriques	80
3.3	Analyse spectrale pour détecter un court-circuit entre spires	83
3.4	Analyse spectrale pour détecter un défaut simultané	85
3.5	Diagnostic des défauts par l'analyse spectrale de l'enveloppe de courant statorique	87
3.5.1	Application de la FFT à l'enveloppe de Park	89
3.5.2	Application de la FFT à l'enveloppe de Hilbert	90
3.6	Application de DWT pour le diagnostic des défauts de la MAS	94
3.6.1	DWT de courant statorique pour détecter les défauts d'une MAS	97
3.6.2	Diagnostic de la MAS à base de l'énergie de la décomposition de DWT	101
3.7	Conclusion	103

4	Diagnostic de défauts de la MAS à l'aide d'IAs	104
4.1	Introduction	104
4.1.1	Principe de MLPNN	107
4.1.2	Principe de RBFNN	108
4.1.3	Principe d'ELM	108
4.1.4	Principe de SVM	110
4.1.5	Principe de kNN	111
4.1.6	Principe de NB	112
4.1.7	Principe de DT	113
4.1.8	Principe de RF	114
4.1.9	Principe de DA	114
4.2	MLAs pour détecter une rupture des barres rotoriques	116
4.2.1	Extraction d'une base de données en cas de rupture des barres rotoriques	117
4.2.2	Résultats de classification par MLAs pour détecter une rupture des barres	118
4.2.3	Discussion des résultats de MLAs pour détecter une rupture des barres rotoriques	130
4.3	MLAs pour détecter un court-circuit entre spires	132
4.3.1	Extraction d'une base de données en cas de court-circuit entre spires	132
4.3.2	Résultats de classification par MLAs pour détecter un court-circuit entre spires	133
4.3.3	Discussion des résultats de MLAs pour détecter un court-circuit entre spires	144
4.4	MLAs pour détecter un défaut simultané	145
4.4.1	Extraction d'une base de données en cas de défaut simultané	146
4.4.2	Discussion des résultats de MLAs pour détecter un défaut simultané	158
4.5	Système global de détection des défauts statoriques-rotoriques de la machine	159
4.6	Conclusion	159
Annexe		165
A.1	Fonctions d'activation de MLPNN	165
A.2	Fonction gaussienne	165
A.3	Fonction noyau de SVM	166
A.4	Mesures de distance pour kNN	167

A.5 Fonctions de distribution pour NB	169
A.6 Critère de fractionnement de CART	170
A.7 Analyse discriminante linéaire et quadratique	171
Bibliographie	172

Introduction Générale

Dans plusieurs secteurs industriels, la continuité de fonctionnement des différents types des machines électriques est un enjeu majeur pour assurer la compétitivité optimale des outils de production. Par conséquent, le diagnostic des différents types des défauts au niveau de ces machines- lorsqu'il réalisait avec efficacité- représente un moyen important pour contribuer à obtenir un meilleur gain de productivité. Il permet également d'améliorer la qualité de l'énergie, de réduire les coûts de maintenance et d'éviter l'arrêt complet du processus de production.

Grâce au développement dans le domaine de l'électronique de puissance, notamment, les convertisseurs statiques telle que les onduleurs qui sont utilisés comme des variateurs de vitesse, les Machines Asynchrones (MASs) remplacent de plus en plus les Machines à Courant Continu (MCCs). Ces machines (MASs) sont devenues largement présentes dans de nombreuses industries de production en raison de leur robustesse, de leur puissance massique et de leur faible coût par rapport aux MCCs. En termes statistiques, il existe des millions des MASs utilisés dans divers secteurs industriels, tels que les pompes à eau, les ventilateurs, les éoliennes, les opérations minières, pétrolières et gazières, les véhicules électriques et hybrides, les grues, les ascenseurs, les trains à grande vitesse, ... etc. Aux États-Unis (USA) seul, environ 70 millions des MASs sont fabriqués chaque année [Didier, 2004] - *"Si nous nous concentrons un peu, nous constatons que ces machines nous entourent partout."*-. Pour cela, il est nécessaire de maintenir la santé des différentes parties de ces machines [Thomson and Fenger, 2001, Thomson and Culbert, 2016, Karmakar et al., 2016, Benbouzid, 2000, Boumegoura, 2001, Didier, 2004, Saleh and Ozkop, 2016].

Bien que la MAS soit une machine robuste et puissante, elle peut parfois rencontrer des divers types de défauts, ces dernières peuvent se produire dans des différentes parties de la machine à partir de la connexion des phases statoriques à la source d'alimentation, et en se terminent par un couplage mécanique entre l'arbre de la MAS et la charge entraînée. Les défauts de MAS peuvent être classés en fonction de leur source, que ce soit des défauts électriques sous formes des courts-circuits dans les phases du stator ou des courts-circuits dans les phases rotoriques dans une MAS à rotor bobiné, ou soit une rupture des barres rotorique ou de l'anneau de court-circuit dans le cas d'une MAS à cage d'écureuil. Des défauts mécaniques peuvent également se produire sous forme d'usure des roulements ou

d'excentricité de rotor [Karmakar et al., 2016, Benbouzid, 2000].

En particulier, les MASs à cage rotorique sont le plus fiable, et le plus rigide par rapport les MASs à rotor bobiné. Pour cela, ces types des machines sont plus couramment utilisés dans l'entraînement électrique. Notamment, les MASs à rotor bobiné sont généralement les plus utilisées lorsqu'elles doivent être démarrées directement en charge, car elles ont un couple de démarrage élevé.

Malheureusement, ce type des machines (MAS à rotor bobiné) est soumis aux plusieurs pannes car la partie rotorique est constitué des bobinages, cela entraîne les défauts de court-circuit et l'augmentation des pertes d'énergie (les pertes joules). Ce type de machines est donc généralement utilisé dans des cas spéciaux [Boumegoura, 2001]. Dans le présent travail, nous nous concentrerons donc uniquement sur le diagnostic de défauts électriques dans une MAS à cage rotorique.

Plusieurs causes conduisent à l'apparition de défauts au niveau de la MAS. À titre d'exemple, le fonctionnement de la MAS à pleine charge pour longtemps, le fonctionnement dans des zones de température élevée ou d'humidité élevée, l'utilisation de la MAS dans certaines applications complexe, telles que les compresseurs à pistons ou de concasseurs à charbon. Parfois, les défauts résultant d'une mauvaise fabrication ou de la négligence de certaines des conditions incluses dans l'installation de la machine dans l'industrie. De plus, la longue durée de vie de la machine peut être considérée comme une cause de défaut (vieillesse) [Ondel, 2006, Thomson and Fenger, 2001]. Par conséquent, ces défauts produisent des asymétries dans les différents signaux mesurables de la MAS à partir les courants statoriques, la vibration de la MAS, le couple électromagnétique, et la vitesse rotorique. De plus, elles conduisent à une augmentation des surchauffes de la machine [Karmakar et al., 2016, Thomson and Fenger, 2001].

Dans ce contexte, le diagnostic précoce des défauts des machines est un sujet important depuis que les exigences de fiabilité, la sûreté, et la continuité de production sont nécessaires dans les systèmes industriels, surtout dans certaines des applications sensibles, tels que la production nucléaire et chimique où les éléments du système sont interdépendants si bien qu'une panne dans un élément peut entraîner l'arrêt total du système. Ce qui pourrait entraîner des pertes économiques importantes, cela pourrait également entraîner des pertes humaines. De plus, le diagnostic précoce contribue à réduire le coût des réparations surtout dans le cas des machines fortes puissance, et donne aux ingénieurs la possibilité de prendre des mesures préventives pour éviter les arrêts complets de la chaîne de production [Didier, 2004, Thomson and Fenger, 2001, Cameron et al., 1986].

Par conséquent, les experts de diagnostic ont accordé une attention considérable pendant des décennies pour la surveillance des MASs à l'aide de diverses techniques de diagnostic. Généralement, les techniques de diagnostic sont classées en deux grandes familles:

– La première catégorie est basée sur l'utilisation d'un modèle analytique pour identifier l'état de la machine, elle consiste en l'analyse de la variation des paramètres électriques (identification paramétrique) de la machine lors d'un fonctionnement sain et celle suivie en cas d'une défaillance. De plus, d'autres techniques sont basées sur l'analyse des résidus d'un modèle proche du système à surveiller ou toute variation par rapport aux points de fonctionnement définis sera anormale dans l'état de la machine. D'autres travaux ont également été effectués à l'aide d'observateurs tels que le filtre de Kalman.

– La deuxième catégorie a appelé les méthodes de diagnostic sans modèle car elles ne nécessitent pas nécessairement un modèle pour le système surveillé. Dans ce cas, les différents signaux mesurables de la machine sont traités (traitement du signal) afin de détecter son état. Ces techniques sont basées sur l'extraction des caractéristiques des défauts tels qu'une fréquence, une amplitude et un déphasage ou un angle. L'extraction de ses caractéristiques est effectuée soit dans le domaine temporel, le domaine fréquentiel ou dans le domaine temps-fréquence. Un autre type de diagnostic appartient dans cette catégorie est appelé les techniques de l'Intelligence Artificielle (IA), ces techniques sont souvent utilisées après le traitement de signaux de la MAS pour identifier et localiser le type de chaque défaut [Saleh and Ozkop, 2016, Casimir, 2003, Zhang et al., 2010, Riera-Guasp et al., 2014, Bouzid, 2009, Boumegoura, 2001, Konar and Chattopadhyay, 2011]. En se basant sur la deuxième catégorie, nous utiliserons dans cette thèse des techniques de traitement du signal pour extraire les caractéristiques des défauts qui seront utilisés comme une base de données pour entraîner les techniques d'IA. La thèse est-elle concentrée sur le diagnostic des défauts de court-circuit entre spires dans le stator et la rupture des barres dans la cage rotorique.

L'application de l'AI est augmentée considérablement ces dernières années. Puisque ce domaine est vaste, chaque année de nouvelles techniques sont introduites. Parmi les techniques les plus importantes utilisées pour le diagnostic des MAS on cite: les systèmes experts (ES), les Réseaux Neurones Artificiels (RNAs), la logique floue (FL), machine à vecteurs de support (SVM: Support Vector Machine), le système hybride entre les réseaux neurones et la logique floue (ANFIS). En outre, il existe d'autres techniques émergentes pour détecter les défauts des MAS, telles que: k plus proches voisins (kNN: k-Nearest Neighbor), machine d'apprentissage extrême (ELM: Extreme Learning Machine), naïve bayes (NB: Naive Bayes), arbre de décision (DT: Decision Tree), la forêt aléatoire (RF: Random Forest), méthodes d'ensembles (EMs: Ensembles Methods), l'Analyse discriminante (DA: Discriminant Analysis) et l'apprentissage en profondeur (Deep Learning) [Siddique et al., 2003, Konar and Chattopadhyay, 2011, Filippetti et al., 2000, Ballal et al., 2007]. Ces techniques ont montré une grande capacité à détecter les défauts des MASs.

En principe, l'application de l'IA dans le diagnostic de MAS nécessitait un expert en machines électriques afin d'obtenir un système de diagnostic robuste et fiable, car l'expert

comprend le comportement de la machine, qu'elle soit en état normal ou anormal. Il faut également une expérience en traitement du signal pour sélectionner les meilleures caractéristiques à appliquer dans l'industrie, en tenant compte du diagnostic qui doit être acceptable et au moindre coût.

Dans ce contexte, le but principal de cette thèse est le diagnostic (détection, identification, localisation) des défauts statoriques et/ou rotoriques d'une MAS triphasée à cage rotorique à l'aide de l'IA. Nous appliquerons donc 09 techniques de détection qui sont respectivement, les RNA à Multicouches type MLP (MLP: Multi Layer Percptrone), RNA de type RBF (RBF: Radial Basis Function), ELM, SVM, KNN, NB, DT, RF, EMs, DA.

Cette présente thèse s'articule autour de quatre chapitres de la manière suivante:

LE PREMIER CHAPITRE décrira tout d'abord les applications des MASs à rotor bobiné. Ensuite, on exposera la conception de la MAS à cage d'écureuil et leurs différents défauts, et leurs causes et leurs conséquences. Ce chapitre présente également les deux catégories de diagnostic (avec et sans modèle) en discutant les points forts et faibles pour chaque technique. Il sera terminé par une conclusion.

LE SECOND CHAPITRE sera consacré à présenter un modèle mathématique lié aux circuits qui permet de simuler la MAS soit en absence, soit en présence de défauts électriques de type court-circuit entre spires et/ou une rupture des barres rotoriques. Pour cela, on aura modélisé la MAS à cage d'écureuil en utilisant un modèle multi-enroulements. Ensuite, on effectuera la transformation de ce modèle (le modèle à enroulements) de N_r grandeurs en un modèle dq équivalent appelé le modèle réduit. Ensuite, on analysera les résultats de la simulation pour montrer l'effet de ces défauts sur les différents comportements de la machine (vitesse rotorique, couple électromagnétique et les trois courants statoriques).

LE TROISIÈME CHAPITRE présentera l'approche de traitement du signal pour détecter les défauts de la machine. Pour cela, on sélectionnera le signal de courant statorique comme un signal pour le diagnostic. Ce signal est choisi car il est facile à détecter et ses capteurs sont moins chers que les autres capteurs (comme les capteurs de vibration). De plus, l'installation des capteurs de courant statorique ne nécessite pas d'accès à l'intérieur de MAS (plus simple). En particulier, nous nous appuierons sur trois techniques de traitement du signal: la transformée de Fourier rapide et (en anglais: Fast Fourier Transform, FFT), la technique de classification de signaux multiples (Multiple Signal Classification, MUSIC) et la transformée en ondelettes (Wavelet Transform, WT). À travers les résultats de la simulation, on présentera les principaux avantages et inconvénients de chaque technique.

LE QUATRIÈME CHAPITRE, on donnera tout d'abord une étude théorique des MLPNN, SVM, ELM, KNN, NB, DT, RF, et DA. Ensuite, nous préparerons trois bases

de données acquises auprès d'une MAS à cage rotorique en cas de rupture des barres, un court-circuit entre spires, un défaut simultané. Pour évaluer les neuf techniques d'IA sélectionnées, ces bases de données seront utilisées comme entrées.

UNE CONCLUSION GÉNÉRALE présentera les différents résultats obtenus et les points de vue pour de futures recherches et quelques perspectives.

Chapitre 1

ETAT DE L'ART DES DEFAUTS DES MACHINES ASYNCHRONES ET LEUR DIAGNOSTIC

1.1 Introduction

Aujourd'hui, les Machines Asynchrones (MASs) à cage d'écureuil jouent un rôle important dans la conversion de l'énergie électromécanique, sa propre structure la rend plus robuste par rapport aux autres types de machines électriques. De plus, le prix de leur fabrication était relativement le moins cher. Ces avantages ont rendu ce type de machine fortement présent dans diverses applications industrielles.

Malgré ces avantages, cette machine est sujette à plusieurs défauts dans ses différentes parties, dont les effets peuvent être évidents sur le fonctionnement de la machine ou peuvent ne pas être remarquables, ces défauts peuvent être entraîner un arrêt complet de fonctionnement de la machine et donc l'arrêt de la continuité opérationnelle des processus industriels, et peut également dépasser les dommages causés par ces défauts à la sécurité des personnes. Par conséquent, le diagnostic correct des défauts de ces machines minimise ses temps d'arrêt, réduits les pertes économiques, tout en maintenant la sécurité des personnes [[Thomson and Fenger, 2001](#), [Benbouzid, 2000](#)].

Dans ce contexte, ce chapitre décrit d'abord un petit rappel sur les MASs à rotor bobiné. Après cela, nous présenterons la conception générale des MASs à cage rotorique et leurs défauts. De plus, nous aborderons les causes des défauts et leur origine, ainsi que les techniques les plus utilisées dans le diagnostic des défauts des machines électriques.

1.2 Machines asynchrones

Généralement, les MASs sont divisées en deux types principaux: une MAS à cage d'écureuil et une MAS à rotor bobiné. La figure 1.1 présente un schéma synoptique de ces deux types. Souvent, l'utilisation de la MAS à rotor bobiné est diminué au profit du MAS à cage d'écureuil. Cependant, certaines applications particulières nécessitent les MASs à rotor bobiné. Par exemple [Boumegoura, 2001, Cao, 1997]:

- Le démarrage en charge nécessite un couple de démarrage élevé, cette propriété existe dans les MASs à rotor bobiné. Théoriquement, cela peut s'expliquer par la relation relative entre l'augmentation des résistances rotoriques et le couple de démarrage. Cela peut souvent être trouvé dans des machines telles que les broyeurs et les concasseurs;
- La possibilité de limiter l'appel de courant au démarrage grâce aux résistances variables insérées dans le rotor bobiné. Dans ce cas, le courant de démarrage peut-être abaisser pour protéger la machine contre la surchauffe.




Figure 1.1: Symbole d'une MAS à cage d'écureuil (a), et à rotor bobiné (b)

Malheureusement, ce type de machine (MAS à rotor bobiné) est plus coûteux que le MAS à cage d'écureuil. En plus d'être plus sujet aux pannes que le MAS à cage d'écureuil, qui se caractérise par une grande rigidité. Du côté statistique, la MAS à cage d'écureuil représente 80 à 85% dans l'entraînement électriques [Hassan et al., 2018]. Pour cela, nous nous concentrerons dans ce recherche sur le diagnostic des défauts électriques dans une MAS à cage rotorique.

1.3 Constitution d'une MAS à cage d'écureuil

Généralement, la MAS à cage d'écureuil se compose de trois éléments principaux distincts définis comme suit: le stator, le rotor et les organes mécaniques [Mustafa, 2015, Bouzid, 2009, Cao, 1997, Thomson and Culbert, 2016]. La figure 1.2 [Thomson and Culbert, 2016] présente la structure générale d'une MAS triphasée à cage d'écureuil.

Donc, le **stator** c'est formé d'une carcasse ferromagnétique qui contient les trois enroulements statoriques. Par conséquent, ces enroulements forment trois phases identiques (03 phases) avec un décalage entre elles d'un angle de $\frac{2\pi}{3}$. Ces trois phases seront indicées respectivement a, b, c . Les enroulements sont constitués des bobines de fil de cuivre isolé placées dans les fentes du stator et sont raccordés à une plaque à borne permettant le branchement sur le réseau d'alimentation que ce soit couplage étoile ou triangle selon le besoin, ces bobines statoriques sont régulièrement réparties suivant les nombres des paires de pôles. Le passage de courant électrique dans les enroulements statoriques crée une force magnétomotrice (f.m.m) tournante qui produit un flux magnétique dans l'entrefer qui tourne à la vitesse angulaire, le noyau du stator permet de transporter un flux alternatif;

Le **rotor** est la partie mobile interne dans la MAS, il est relié à la charge mécanique à travers un arbre rotorique. Dans le cas d'une MAS à cage d'écureuil, le rotor est constitué de barres conductrices noyées dans les fentes du fer et court-circuitées à chaque extrémité par un anneau de court-circuit. Habituellement, ces barres sont en cuivre, en aluminium ou en magnésium. Le champ tournant induit dans le rotor des forces électromotrices (f.e.m) qui génère des courants rotoriques, l'interaction entre les deux champs (f.m.m et f.e.m) crée un couple moteur qui fera tourner la machine. Le rotor ne tourne pas en synchronisme avec le champ magnétique, il tourne à moins de vitesse que la vitesse de synchronisation. Pour cela, ils sont appelés des machines asynchrone;

Les **organes mécaniques** ou les palais, qui permettent à l'arbre du rotor d'être

supporté et tourné, sont constitués du flasque et des roulements à billes à insérer à chaud sur l'arbre rotorique. Le flasque est fixées au boîtier du stator à l'aide de boulons ou de tiges de serrage comme nous pouvons le voir sur la figure 1.2. Les éléments rotatifs dans les roulements (billes) sont disposés et insérés dans la cage de roulement, pour assurer un espacement uniforme pour éviter tout contact mutuel entre stator et le rotor.






Figure 1.2: Machine asynchrone à cage d'écureuil

1.3.1 Défaillances d'une MAS à cage d'écureuil

Plusieurs études statistiques déterminent le pourcentage de défauts dans chaque partie de la MAS à cage d'écureuil. Bien qu'il existe une légère différence entre ces statistiques, il a été convenu que le plus grand pourcentage de défauts se produit dans la partie mécanique (défauts des roulements). Les deux études les plus importantes sont l'IEEE-IAS (Institute of Electrical and Electronics Engineers Applications - Application Society) et l'EPRI (Electrical Energy Research Institute). En 1997, l'étude IEEE-IAS portait sur 1141 MAS à cage d'écureuil et 6312 MAS pour l'EPRI en 1985. Ces recherches ont été menées notamment sur les MASs de moyenne puissance. Par conséquent, les statistiques des défauts les plus courants dans la MAS à cage d'écureuil sont présentées dans la figure 1.3 [Hassan et al., 2018, Da Silva et al., 2008, Zhang et al., 2010, Trachi, 2017, Mehala and Dahiya, 2010, Mustafa, 2015, Cruz and Cardoso, 2001, Karmakar et al., 2016]. Il est à noter que ces statistiques ne sont pas valables pour toutes les MASs. Parfois, les conditions de fonctionnement de la machine jouent un rôle important dans l'apparition de ces défauts. Selon la classification présentée dans la figure 1.3, la figure 1.4 fournit une liste plus détaillée des défauts pouvant survenir dans chaque partie au niveau de la machine [Thomson and Fenger, 2001, Liu et al., 2018, Hassan et al., 2018, Trachi, 2017]. De plus, la figure 1.5 résume une vue schématique des différents défauts produits dans les enroulements statoriques. Un rotor à cage d'écureuil avec une barre cassée est présenté dans la figure 1.6 [Nemec et al., 2019]. La figure 1.7 [Zhang et al., 2020] présente un



(a) IEEE



(b) EPRI

Figure 1.3: Pourcentage de défauts dans les MASs à cage d'écureuil




Figure 1.4: Classification et localisation des défauts d'une MAS à cage d'écureuil

roulement à billes dans l'état sain et en défauts de la bague intérieure et extérieure.




Figure 1.5: Schéma des enroulements statoriques en défaut



Figure 1.6: Rotors d'une MAS cage d'écureuil avec et sans défaut

1.3.1.1 Causes des défauts

La plupart des défauts des MASs sont causés par plusieurs raisons qui affectent la santé de ses pièces. Ces causes peuvent être dues à une source électromagnétique, électrique, mécaniques, ou thermiques. L'environnement peut également provoquer des défauts dans la MAS [Ondel, 2006, Bouzid, 2009, Hassan et al., 2018, Cardoso et al., 1999, Trachi, 2017, Tallam et al., 2007, Cruz and Cardoso, 2001]. Parmi ces causes, nous pouvons citer les suivantes:

- Causes électromagnétiques: déséquilibre des forces électromagnétiques, la vibration




Figure 1.7: Roulement à billes à l'état sain et en défaut

excessive, ... etc.;

- Causes thermiques dues à la surcharge thermique, manque de refroidissement, le démarrage direct, ... etc.;
- Causes électriques: dégradation de l'isolation lors de la fabrication, surcharge, déséquilibre de la source d'alimentation, surtensions, etc.;
- Causes mécaniques: dues aux forces électrodynamiques sur les conducteurs, l'usure des roulements, le déséquilibre de la charge, désalignement de l'arbre ...;
- Causes environnementales: conditions extrêmes de chaleur, humidité, poussière, pluie, ... etc.;
- Causes supplémentaires dues à des imperfections dans le processus de fabrication de la machine ou à une mauvaise installation.

1.3.1.2 Conséquences des défauts

Plusieurs phénomènes peuvent être considérés comme des indicateurs de défaillance des MASS, tels que [Elbouchikhi et al., 2017, Vaseghi, 2009, Karmakar et al., 2016, Thomson and Culbert, 2016]:

- Surchauffe de la machine;
- Augmentation le taux de résonance;
- Augmentation du taux de vibration et de bruit;

- Apparitions d’oscillations dans les signaux mesurables de la machine (vitesse rotative, couple, courants statoriques et vibrations ...);

1.3.1.3 Principales étapes du processus de diagnostic

En général, les processus de diagnostic dépendent de trois étapes principales [Ondel, 2006, Khodja, 2007], sont:

- Diagnostic de l’état de la machine, normal ou défectueux;
- Identification du type de défaut en cas de défaillance de la machine, qu’il s’agisse d’un défaut électrique ou mécanique;
- Localisation du défaut: après avoir détecté un défaut dans la machine et identifie son type, la localisation du défaut doit être déterminé soit un défaut de court-circuit d’une phase, rupture des barres, rupture dans la bague, usure des roulements, etc.

1.4 Méthodes de diagnostic des défauts

Depuis des décennies jusqu’à nos jours, la détection des défauts des machines a été un vaste sujet de recherche. Toutes les recherches précédentes visent à améliorer le fonctionnement de la machine et à protéger ses pièces contre tous les défauts. Les techniques de diagnostic sont généralement classées en fonction des manières utilisées pour détecter la présence d’une défaillance dans la machine. La figure 1.8 présente un résumé des techniques les plus courantes utilisées pour détecter les défauts des MASs [Saleh and Ozkop, 2016, Bouzid, 2009, Hassan et al., 2018, Liu et al., 2018, Zhang et al., 2010]. Comme le montre la figure 1.8, la classification des techniques de diagnostic des défauts des machines est généralement classée en deux catégories principales: Méthodes internes et des méthodes externes.

La première catégorie appelé **méthodes internes**, ces méthodes nécessitent un modèle équivalent du système surveillé. Par conséquent, dans certaines recherches, cela s’appelle cette catégorie, diagnostic avec un modèle. Dans ce cas, l’exigence la plus importante pour un diagnostic approprié est la qualité et la robustesse du modèle utilisé pour surveiller l’état de la machine afin d’éviter toute fausse alarme. Les méthodes internes comprennent diverses techniques de diagnostic telles que les techniques d’estimation paramétrique du système à surveiller. La surveillance à l’aide d’observateurs ou d’estimateurs et de techniques de résidus.




Figure 1.8: Techniques de diagnostic des défauts des MAS

La deuxième catégorie, **méthodes externes**, ne nécessite pas de modèle du système surveillé et est également appelée méthodes de diagnostic sans modèle. Ils sont divisés en deux classes principales: les techniques de traitement du signal basées sur l'analyse de différents signaux de la machine, telles que les courants statoriques et la vibration de la machine. La deuxième classe est basée sur les techniques d'IA.

1.4.1 Méthodes internes

En général, les méthodes internes sont basées sur une connaissance a priori du système. Elles reposent donc sur la connaissance des caractéristiques du système étudié ou des variables représentatives développées à partir des acquisitions. Dans ce cas, il convient de noter que la qualité du modèle est d'une importance fondamentale pour détecter efficacement les défauts et pour éviter les fausses alarmes. En principe, la sortie du modèle est comparée aux données accessibles pour former un résidu utilisé pour alimenter un mécanisme dédié à la détection de différents défauts [Vaseghi, 2009, Bouzid, 2009, Mustafa, 2015, Ondel, 2006, Boumegoura, 2001]. Dans cette partie, nous présentons une revue des méthodes internes utilisées pour détecter les défauts des MASs.

1.4.1.1 Méthode d'estimation paramétrique

L'estimation paramétrique permet de déterminer la représentation mathématique d'un système réel à partir des données expérimentales, cette technique est réalisée en tenant compte des informations préliminaires disponibles sur un système fonctionnant dans des conditions nominales [Abed, 2002, Moreau, 1999]. Dans [Coirault et al., 1997], l'estimation paramétrique était basée sur un modèle en temps continu non linéaire défini dans un modèle triphasé abc , ce modèle permet de suivre la variation des paramètres électriques tels que les trois résistances et inductances statorique (R_{sabc}, L_{sabc}) et deux paramètres caractérisent la partie rotorique (la résistance et l'inductance rotorique (R_r, L_r)). Au même principe, les auteurs dans [Bachir et al., 2006] donnent un nouveau modèle d'une MAS à cage d'écureuil (modèle de Park) dédié les défauts statorique (court-circuit entre spires) et rotorique (rupture des barres), ce modèle est réalisé en prenant en compte les informations préalables disponibles pour un système sain, l'estimation de paramètre dans ce cas est utilisée pour effectuer la détection et la localisation des défauts. L'auteur s'est appuyé sur l'estimation de la résistance statorique R_s et rotorique R_r et inductance magnétique L_m de la machine et l'inductance de fuite L_f .

1.4.1.2 Méthode des observateurs

Le principe de cette méthode est basé sur un observateur pour reconstruire la sortie du système à partir des mesures disponibles (Fig.1.9). Généralement, les observateurs sont utilisés à contrôler le fonctionnement des machines électriques. Parmi ces observateurs, notamment: filtre de Kalman, observateur de Luenberger, les filtres de détection de défaut

et les observateurs avec des entrées inconnues et des observateurs à gain élevé [Jamouli, 2003]. Les observateurs sont capables de générer une approximation du vecteur d'état appelé estimateur d'état ou observateur d'état. L'observateur utilise la connaissance dynamique du système et les propriétés statistiques du système et mesure les sources de bruit pour produire une estimation optimale. La première étape de l'estimation consiste à définir un modèle adapté à la machine. En principe, la MAS est décrite par un système d'état non linéaire, et les paramètres doivent être estimés via des estimateurs non linéaires. Pour cela, le filtre de Kalman étendu (EKF) est la méthode la plus répandue pour estimer les variables d'état avec des variables physiques. Le filtre de Kalman nécessite un modèle discret de la machine qui se déduit du modèle continu, c'est un système dynamique à deux (vecteur) entrées, la commande (u) et la mesure (y), c'est-à-dire tous les signaux connus du système.




Figure 1.9: Principe de l'observateur

Cette technique consiste à utiliser plusieurs facteurs tels que la description statistique des bruits du système, des perturbations, des erreurs de mesure et des incertitudes du modèle du système, et les conditions initiales des variables [Alazard, 2006, Loron and Laliberte, 1993, Abed, 2002, Vaseghi, 2009].

1.4.1.3 Méthode de résidu

Les résidus sont des signaux générés par un modèle proche du système surveillé avec des entrées connues (Fig.1.10). Par conséquent, le résidu est conçu de sorte que son amplitude soit nulle pour une machine saine, et différente de zéro en cas de défaillance. Le modèle de processus est basé sur les relations entre deux types de variables inconnues et d'autres variables connues, la génération de résidus doit être suivie d'une évaluation résiduelle pour décider de la détection et de l'isolement. Plusieurs techniques sont utilisées basées sur des résidus tels que le gradient, Newton-Raphson et Levenberg-Marquardt. Parfois,

le résultat du résidu est non nul bien que la machine saine, car le système est affecté par plusieurs facteurs tels que des perturbations et des erreurs de modélisation [Bouzid, 2009, Boumegoura, 2001, Mustafa, 2015, Ondel, 2006, Jamouli, 2003].




Figure 1.10: Principe de résidu

1.4.2 Méthodes externes

Comme mentionné précédemment (Sec.1.4), les méthodes externes en général ne nécessitent pas de modèle mathématique détaillé du système. Ils sont soit basés sur l'analyse, appelée techniques de traitement du signal, des différents signaux extraits de la machine, soit ils peuvent également être basés sur des techniques d'IA.

1.4.2.1 Techniques de traitement du signal

Le traitement du signal est basé sur l'analyse de signaux machine mesurables, qu'il s'agisse des courants statoriques, des vibrations, de la vitesse du rotor, etc., ces signaux peuvent être extraits par des capteurs physiques installés au niveau de la machine, tels que les capteurs de courant à effet Hall, les capteurs de vibrations piézoélectriques, les capteurs de vitesse de rotor (accéléromètre), etc. En particulier, l'analyse du courant statorique est la solution la plus adaptée en raison de la facilité d'installation des capteurs de ce signal dans la machine, ils sont également relativement moins coûteux [Boumegoura, 2001, Ondel, 2006, Cameron et al., 1986, Liu and Bazzi, 2017]. Les techniques de traitement du signal destinées à extraire des caractéristiques de défaut pouvant être une fréquence, une amplitude, un déphasage, etc. Ces techniques peuvent être classées selon le domaine d'analyse, qu'il s'agisse d'analyse temporelle, fréquentielle ou temps-fréquence [Bouzid et al., 2008, Saleh and Ozkop, 2016, Liu and Bazzi, 2017].

A Analyse temporelle

Dans ce cas, le diagnostic de défaut dépend directement de l'interprétation du signal extrait de la machine sans aucun changement du domaine d'étude (temporelle-temporelle). Par conséquent, ces techniques se concentrent sur l'interprétation des changements anormaux dans les caractéristiques du signal, telles que l'amplitude du signal, les déphasages entre les signaux, etc. Malheureusement, l'analyse directe du signal, dans certains cas, peut ne pas être suffisante pour identifier la défaillance de la machine. Par exemple, le diagnostic des défauts de rupture des barres de rotor dans le domaine temporel n'est pas efficace car leur impact sur les signaux mesurables de la machine est faible [Baghli, 1999, Boumegoura, 2001, Liu and Bazzi, 2017, Saleh and Ozkop, 2016].

De plus, le contrôle des MASs est souvent lié aux convertisseurs statiques, dont le plus important est l'onduleur. Ce dernier (l'onduleur) a un effet supplémentaire sur la nature du signal extrait, ce qui induit du bruit ou des fluctuations du signal mesuré. Par conséquent, tous ces facteurs rendent la détection des défauts des MAS dans le domaine temporel plus difficile et complexe [Ondel, 2006, Saleh and Ozkop, 2016]. Parmi les techniques appliquées dans le domaine temporel, on mentionne, le cercle de Park obtenu par les deux courants de Park (i_d, i_q). Dans ce cas, le degré de déformation de ce cercle indique que la machine est en état normal ou en défaut [Cardoso and Saraiva, 1993]. D'autres études ont été basées sur l'observation du courant de séquence négative et de l'impédance de séquence négative pour indiquer l'état de la MAS [Liu and Bazzi, 2017]. En résumé, la précision du diagnostic de MAS est faible dans le domaine temporel. Il faut mentionner que, par exemple, lorsque les conditions ci-dessus se produisent simultanément (détection de rupture des barres pour une MAS alimenté par un onduleur), la détection devient plus complexe [Didier, 2004]. Pour améliorer le processus de diagnostic, l'analyse fréquentielle a été utilisée pour extraire les indicateurs qui caractérisent chaque défaut affectant la MAS.

B Analyse fréquentielle

En général, la défaillance de la machine produit un déséquilibre des signaux extraits et produits donc des composantes de fréquence supplémentaires en raison des fluctuations périodiques induites par les forces mécaniques dans l'entrefer de la machine. Par conséquent, la détection de défauts dans le domaine fréquentiel repose sur l'analyse spectrale des différents signaux de la machine. Malheureusement, cette approche a été affectée par plusieurs facteurs, tels que le type d'alimentation de la machine, les conditions sta-

tiques et dynamiques de charge, le bruit du signal et la géométrie de la machine [Liu and Bazzi, 2017, Benbouzid, 2000].

Dans ce contexte, la FFT a souvent été couramment utilisée pour détecter les défauts de MAS, permettant d'extraire les fréquences associées aux défauts. La FFT de courant statorique est la plus utilisée car elle ne nécessite qu'une simple capture du courant statorique avec effet Hall. Habituellement, la FFT est appliquée pendant le régime stationnaire de la machine (régime permanent) [Didier, 2004]. L'analyse spectrale du courant statorique est donc la plus couramment utilisée pour détecter les différents défauts de la MAS, qu'il s'agisse d'un défaut statorique, rotorique ou d'un défaut mécanique.

– Analyse spectrale du courant statorique pour détecter un défaut de stator

Lorsqu'un défaut survient dans la machine, elle perd son équilibre. Pour cela, le défaut statorique produit un champ inverse tournant en fonction de la fréquence fondamentale. Dans ce cas, les composantes de fréquences qui indiquent le défaut du stator sont définies comme suit [Oumaamar, 2012, KÜÇÜKER and Bayrak, 2015, Mehala and Dahiya, 2010]:

$$f_{cc} = f_s \left[k \pm n \frac{(1-g)}{p} \right]_{k=1,3,5}^{n=1,2,3...} \quad (1.1)$$

avec $k = 1, 3, 5...$ et $n = 1, 2, 3...$ sont des nombres entiers, p c'est le nombre de paires des pôles, et g c'est la différence relative entre la vitesse de rotor (Ω_r) et la vitesse de synchronisme (Ω_s) est appelée le glissement (sans unité), il est calculé comme suit $g = (\Omega_s - \Omega_r)/\Omega_s$.

Ainsi, la présence d'un court-circuit provoque une augmentation de l'amplitude des courants des barres rotoriques. Par conséquent, les fréquences de ce type de défaut (f_{cc}) peuvent être exprimées en fonction du nombre de barres comme suivant [Oumaamar, 2012, KÜÇÜKER and Bayrak, 2015]:

$$f_{cc} = f_s \left[1 \pm \lambda N_r \frac{(1-g)}{p} \right]_{\lambda=1,2,3,...} \quad (1.2)$$

avec λ est un nombre entier et N_r est le nombre total des barres rotoriques.

Souvent, l'apparition de troisièmes harmoniques $f_{cc} = 150Hz$ est considérée comme un indicateur d'un défaut de court-circuit [Oumaamar, 2012, Benbouzid, 2000].

– Analyse spectrale du courant statorique pour détecter un défaut de rotor

La rupture des barres rotoriques crée dans les circuits rotoriques un champ magnétique inverse au champ rotorique direct avec une pulsation de $-gf_s$ dues au déséquilibre des

enroulements rotoriques. Ce type de défaut peut être caractérisé par des fréquences spécifiques données par le suivant [Abed, 2002, Bachir, 2002, Boumegoura, 2001, Thomson and Fenger, 2001]:

$$f_b = (1 \pm 2kg)f_s \quad (1.3)$$

L'analyse spectrale de courant statorique par FFT a été couramment utilisée pour détecter la rupture des barres de rotor. Cependant, cette technique présente certains points faibles qui peuvent réduire sa précision [Puche-Panadero et al., 2009, Choi et al., 2014, Elbouchikhi et al., 2017]:

- Problème de fuite spectrale lorsque la machine fonctionne à faible glissement (faible charge), cette fuite est considérée comme une interférence entre la composante fréquentielle qui est essentielle et les autres fréquences. Ainsi, lorsque les fréquences des défauts (f_b) sont très proches de la fréquence fondamentale, elles sont difficiles à détecter;
- La FFT nécessite un grand nombre de points d'acquisition (nombre d'échantillons) pour garantir une précision de fréquence adéquate;
- La FFT est affectée négativement lorsque la machine est alimentée par un convertisseur statique telle qu'un onduleur;
- La FFT perd son efficacité lorsque la charge appliquée à la machine est faible ou instable;
- La FFT est affectée par le bruit impliqué dans le signal.

Pour remédier à ces problèmes, les chercheurs ont suggéré de remplacer le signal de courant statorique par son enveloppe, tels que l'enveloppe de Hilbert ou l'enveloppe de Park [Benbouzid and Kliman, 2003, Jaksch, 2003, Puche-Panadero et al., 2009, Elbouchikhi et al., 2017]. La transformation de Hilbert (HT) présente un avantage par rapport à la Transformation de Park (TP), car elle ne nécessite qu'un seul signal de courant statorique pour extraire l'enveloppe de Hilbert, par contre, la TP nécessite les trois signaux des courants statoriques (i_{sa}, i_{sb}, i_{sc}). Une étude de [Perez-Cruz et al., 2017], qui a montré la possibilité d'utiliser une nouvelle enveloppe appelée l'enveloppe réduite de Park (en anglais: Reduced Park Vector Modulus, RPVM) extraite d'un seul signal de courant statorique. En général, l'analyse spectrale des différentes enveloppes par FFT augmente la résolution de détection et permet de minimiser de fuite spectrale.

Cependant, l'analyse de l'enveloppe FFT a continué à souffrir de la nécessité d'un long temps de mesure (temps d'acquisition) pour extraire la fréquence de défaut tout en éliminant le problème de fuite spectrale.

Par conséquent, pour augmenter la performance de FFT, d'autres extensions ont été proposées comme Zoom-FFT (ZFFT). ZFFT [Kia et al., 2007] permet de minimiser le temps de calcul tout en maintenant les performances de diagnostic.

Grâce au développement du domaine du traitement du signal, de nouvelles techniques de Haute Résolution (HR) ont été appliquées pour améliorer le processus de diagnostic. Parmi celles-ci figurent les techniques de classification multiple signal (en anglais: Multiple Signal Classification, MUSIC), ainsi que la technique d'estimation des paramètres de signal via les techniques d'invariance rotationnelle (en anglais: Estimation of Signal Parameters via Rotational Invariance Techniques, ESPRIT). Ces techniques fournissent un bon diagnostic des défauts avec un temps d'acquisition plus court et avec un taux faible de bruit. Donc, MUSIC et ESPRIT ont souvent été utilisés pour détecter la défaillance des barres rotoriques d'une MAS, ce qui est considéré comme le diagnostic le plus difficile par rapport aux autres défauts. Pour cela, les deux techniques ont été appliquées directement au signal de courant statorique dans [Kia et al., 2007, Elbouchikhi et al., 2017]. De plus, ils ont été appliqués à l'enveloppe de Hilbert pour détecter le même défaut dans une MAS tournant à vide. L'application de ces techniques a été complétée avec succès [Xu et al., 2013]. Dans [Kim et al., 2012], les auteurs ont proposé d'autres extensions comme Zoom-MUSIC et Zoom-ESPRIT pour extraire les fréquences des défauts avec un temps d'acquisition plus court.

– Analyse spectrale du courant statorique pour détecter un défaut de roulement

Les roulements à billes se composent généralement de deux bagues, une bague intérieure et une bague extérieure, en plus des billes qui tournent à l'intérieur du roulement. En pratique, les défauts des roulements augmentent le taux de vibrations et de bruit de la machine. Dans ce contexte, les fréquences de défauts de roulement (f_{rol}) sont directement liées à leurs dimensions, comme suit [Schoen et al., 1995, Nandi and Toliyat, 1999, Nandi et al., 2005, Eren and Devaney, 2004, Blodt et al., 2008]:

$$f_{rol} = |f_s \pm m \cdot f_v| \quad (1.4)$$

avec $m = 1, 2, 3, \dots$ est un nombre entier, et f_v est la fréquence de vibration. Une vue schématique du roulement à billes et de sa géométrie est représentée sur la figure 1.11.




Figure 1.11: Vue schématique d'un roulement à billes

Donc, les défauts des roulements à billes peuvent être classés comme des défauts de la bague extérieure, la bague intérieure, le défaut des billes et le défaut de la cage. La fréquence de chaque type de défaut par l'analyse vibratoire peut être donnée par les suivants [Blodt et al., 2008, Bellini et al., 2008, Immovilli et al., 2010, Oumaamar, 2012]:

$$\begin{cases} f_{ex} = \frac{\eta_b}{2} f_r \left(1 - \frac{D_b}{D_c} \cos \gamma\right) \\ f_{int} = \frac{\eta_b}{2} f_r \left(1 + \frac{D_b}{D_c} \cos \gamma\right) \\ f_0 = \frac{D_b}{D_c} f_r \left(1 - \left(\frac{D_b}{D_c} \cos \gamma\right)^2\right) \\ f_c = \frac{f_r}{2} \left(1 - \frac{D_b}{D_c} \cos \gamma\right) \end{cases} \quad (1.5)$$

où f_{ext} et f_{int} sont respectivement, les fréquences des défauts de la bague intérieure et extérieure. f_0 et f_c sont respectivement les fréquences de défaut des billes et de cage de roulement. En particulier, ces fréquences peuvent être estimées pour la plupart des roulements à billes entre 6 et 12 par les suivants:

$$\begin{cases} f_{ex} = 0.4 \eta_b \cdot f_r \\ f_{in} = 0.6 \eta_b \cdot f_r \\ f_c = 0.6 \eta_b \cdot f_r \end{cases} \quad (1.6)$$

Lorsque les roulements supportent l'arbre du rotor, tout défaut de roulement entraîne également des variations dans l'entrefer de la machine (excentricité). Cette variation provoquant une oscillation dans la densité de flux de l'entrefer [Schoen et al., 1995, Nandi et al., 2005]. Donc, la détection de défaut de roulement a été vérifiée par l'analyse spectrale du courant statorique dans [Schoen et al., 1995]. Selon les recherches présentées par [Knight and Bertani, 2005, Oumaamar, 2012], l'analyse spectrale du courant statorique n'est peut-être pas suffisante pour le diagnostic des défauts de roulement dans

certaines conditions. Un nouveau modèle dédié au défaut a été proposé par [Blodt et al., 2008], qui prend en tenant compte des variations de longueur d'entrefer et le couple de charge. L'étude a montré que les défauts de roulement peuvent entraîner des changements importants dans le spectre du courant statorique qui peuvent être utilisés à des fins de diagnostic de ce type de défauts. Selon [Immovilli et al., 2010], il est possible d'utiliser le signal de courant statorique comme technique fiable pour détecter des défauts de roulement uniquement dans des conditions de fonctionnement spécifiques, car la détection de ce défaut par le signal de courant n'est pas efficace pour les défauts de basses fréquences.

– Analyse spectrale du courant statorique pour détecter un défaut d'excentricité

L'excentricité est définie par une asymétrie de l'entrefer de la machine. Il est classé selon trois types: excentricité statique, dynamique et excentricité mixte.

L'excentricité statique peut être causée par un mauvais positionnement entre le centre de rotor et du stator. Dans le cas de l'excentricité dynamique, le centre du rotor n'est pas le même au centre de rotation (Fig. 1.12). L'excentricité mixte est définie par la présence des deux types précédents en même temps. Donc, l'asymétrie de l'entrefer produit des oscillations dans la densité d'entrefer et donc augmente les vibrations et les bruits de la machine [Nandi and Toliyat, 1999, Cameron et al., 1986].




Figure 1.12: Vue schématique de l'excentricité statique (a) et dynamique (b)

La présence d'excentricités statique et dynamique peut être détectée en utilisant l'analyse spectrale de courant statorique par le suivant [Nandi and Toliyat, 1999, Blodt et al., 2008]:

$$f_{exc} = \left[(\kappa \cdot \lambda \pm \eta_d) \frac{(1 - g)}{p} \pm v \right] \quad (1.7)$$

avec $\kappa = 1, 2, 3, \dots$, λ c'est le nombre d'encoches rotoriques, η_d c'est l'ordre de l'excentricité, $\eta_d = 0$ pour l'excentricité statique, et $\eta_d = 1, 2, 3, \dots$ pour l'excentricité dynamique. $v = \pm 1, \pm 3, \pm 5, \dots$ c'est l'ordre des harmoniques temporel du stator. Dans le cas d'une excentricité mixte (statique et dynamique), les fréquences de défaut ($f_{exc,mix}$) sont donnés par l'équation suivante:

$$f_{exc,mix} = \left[1 \pm \kappa \frac{1-g}{p} \right] f_s \quad (1.8)$$

Il peut également être défini par la relation suivante:

$$f_{exc,mix} = |f_s \pm \kappa f_r| \quad (1.9)$$

La plupart des recherches qui se sont concentrées sur la détection des défauts mécaniques par l'analyse spectrale des courants statoriques et des vibrations ont indiqué que l'analyse des vibrations est plus efficace. Cependant, les capteurs de vibrations sont coûteux par rapport à la capture des courants statoriques. De plus, ces capteurs sont plus susceptibles de survenir en panne car ils sont installés à l'intérieur de la machine. Contrairement aux capteurs de courant du stator installés à l'extérieur de la machine [Nandi and Toliyat, 1999, Nandi et al., 2005].

C Analyse temps-fréquence

Comme mentionné ci-dessus, la FFT est efficace dans le traitement des signaux stationnaires, mais elle n'est pas puissante dans l'analyse des signaux non stationnaires, c'est-à-dire que la FFT n'est pas adaptée pour surveiller l'évolution du contenu de fréquence du signal dans le temps. Par conséquent, l'analyse temps-fréquence a été introduite pour surmonter les limites des techniques du domaine fréquentiel dans le traitement des signaux non périodiques et non stationnaires. Ces techniques combinent les caractéristiques temps-fréquence car elles permettent de définir le spectre des signaux en fonction de la variation du temps. Dans ce contexte, plusieurs techniques de temps-fréquence ont été appliquées, telles que la transformée de Fourier à court terme (STFT), la transformée en ondelettes (Wavelet transformation, WT) et ses extensions en tant que transformées en ondelettes discrètes (DWT) ou continue (CWT). transformation de Hilbert (HT), Wingner-City Distribution (DWV).

STFT permet d'interpréter le signal en fréquence-temps (bidimensionnel-2D). Dans ce cas, le signal temporel passe à travers différents filtres passe-haut et passe-bas qui filtrent les parties hautes et basses fréquence du signal. Ce processus est répété chaque fois qu'une partie du signal correspondant aux fréquences filtrées est retirée du signal.

DWV est une fonction réelle distribuant l'énergie d'un signal dans le plan temps-fréquence, ses distributions marginales sont identifiées avec la puissance instantanée et la densité spectrale du signal, la caractéristique de DWV est qu'il a une résolution infinie dans le temps-fréquence domaine en raison de l'absence de moyennage dans une durée finie. DWV offre une meilleure résolution spectrale car il ne souffre pas d'effet de fuite, contrairement à STFT [Flandrin and Escudié, 1984, Pachori and Nishad, 2016, Pons-Llinares et al., 2014, Pilloni et al., 2013].

WT est similaire à FFT avec une fonction de mérite légèrement différente, où FFT décompose le signal en sinus et cosinus dans l'espace de Fourier, tandis que WT utilise des fonctions situées à la fois dans l'espace réel (temps) et dans l'espace de Fourier (fréquence). DWT est une extension de WT utilisé l'ensemble discret d'échelles. La DWT décompose le signal en un ensemble d'ondelettes mutuellement orthogonales. En d'autres termes, le DWT effectue la décomposition d'un signal échantillonné $s(t) = s_1, s_2, \dots, s_N$ en signaux d'ondelettes $n + 1$ sous la forme des signaux d'approximation $A_n(t)$ et les signaux des détails $D_j(t)$, où $j = 1, 2, 3, \dots, n$, avec n est un entier appelé nombre de niveaux de décomposition. La CWT est également une transformée en ondelettes dans laquelle elle utilise des échelles arbitraires ainsi que des ondelettes pratiquement arbitraires, il a été développé comme une approche alternative à STFT pour augmenter la résolution. La WT a été largement utilisé dans le diagnostic des défauts des MASs, ce qui permet d'interpréter les différents signaux de la machine en régime transitoire [Benbouzid and Kliman, 2003, Chen et al., 2016, Bensaoucha et al., 2020].

HT est également utilisé pour les signaux non stationnaires dont le contenu fréquentiel change avec le temps, ainsi que pour les signaux non périodiques. En bref, HT crée le signal réel $x(t)$ comme un signal complexe $z(t)$, la partie réelle du signal analytique est le signal d'origine ($r(t) = x(t)$), et la partie imaginaire représente la HT de la partie réelle ($jy(t) = HT(x)$). L'avantage de cette transformation est le fait que l'on peut connaître exactement la forme de la partie réelle et de la partie imaginaire, la forme de l'amplitude de phase correspondante peut être définie. De plus, HT permet d'augmenter la résolution de détection des fréquences de défaut [Benbouzid and Kliman, 2003, Didier, 2004, Jaksch, 2003, Bensaoucha et al., 2019].

Toutes ces techniques (WT, STFT, HT,...) ont démontré une détectabilité élevée même avec des variations de charge de la machine, de type de défaut et de taille de signal analytique [Liu and Bazzi, 2017, Saleh and Ozkop, 2016, Hassan et al., 2018, Elbouchikhi et al., 2017, Zhang et al., 2010, Choi et al., 2014, Benbouzid and Kliman, 2003, Delgado-Arredondo et al., 2015, Pilloni et al., 2013].

1.4.2.2 Techniques d'intelligence artificielle (IA)

Dans nos jours, une grande attention est accordée au diagnostic automatique des défauts des machines par l'IA. Dans certains cas, il est difficile de développer un modèle analytique pour détecter les défauts de la machine à tous leurs points de fonctionnement. De plus, l'interprétation des résultats obtenus par l'analyse du traitement du signal est complexe dans certains cas.

Par conséquent, les techniques d'IA offrent la possibilité de détecter automatiquement l'état de la machine, qu'il soit normal ou anormal, à l'aide de structures et de règles basées sur une compréhension du comportement du système. De plus, ces techniques peuvent être utilisées pour fournir une solution indicative générale à un problème spécifique. En général, ces techniques sont faciles à étendre et à modifier et peuvent être rendues adaptables en incorporant de nouvelles données.

Les techniques d'IA peuvent être divisées en deux catégories principales (Fig.1.8): l'IA basée sur des algorithmes d'apprentissage de machine (en anglais: Machine Learning Algorithms, MLAs), et l'apprentissage profond (en anglais: Deep Learning, DL). En principe, l'étape la plus importante du diagnostic à l'aide de l'IA consiste à choisir les meilleures entrées à utiliser dans l'apprentissage.

Depuis les années 2000, les grandes entreprises internationales accordent une grande attention à l'application de DL. Des grandes sociétés internationales, telles que, Google, Facebook, Amazon, et Microsoft ont donné de grands investissements dans ces techniques [Trachi, 2017, Liu and Bazzi, 2017, Consoli et al., 1998, Siddique et al., 2003, Liu et al., 2018, Filippetti et al., 2000, Shao et al., 2017b, Shao et al., 2017a].

La différence major entre les techniques de l'IA est la manière d'apprentissage, que ce soit apprentissage supervisé, non supervisé, ou apprentissage semi-supervisé [Liu and Bazzi, 2017, Schmidhuber, 2015, Shao et al., 2017b, Shao et al., 2017a]. Les points de différence peuvent être résumés comme suit:

- L'apprentissage supervisé s'applique à des systèmes d'entrées-sorties prédéfinis pour créer un modèle spécifique pour identifier de nouvelles entrées non étiquetées. Habituellement, cette classe est suggérée pour la classification des données ou de régression. Dans ce cas, l'extraction des caractéristiques est souvent utilisée pour réduire la taille des données saisies en sélectionnant uniquement les caractéristiques importantes [Yang et al., 2009, Bouzid et al., 2008].

- L'apprentissage non supervisé ne nécessite pas d'apprentissage préalable, c'est-à-dire que la sortie du système n'est pas donnée a priori, le principe de l'apprentissage

non supervisé est la corrélation (similitude) entre les données. Ce type d'apprentissage implique le traitement des données et la recherche d'un bon modèle pour les représenter. Le clustering est une méthode d'apprentissage non supervisé la plus courante qui peut être utilisée. Il est basé sur la reconnaissance de données afin de trouver des modèles cachés pour regrouper ou classer des données.

– Dans l'apprentissage semi-supervisé, les algorithmes d'IA sont entraînés sur une combinaison de données étiquetées et d'autres données non étiquetées. En règle générale, cette combinaison contient une très petite quantité de données étiquetées et une très grande quantité de données non étiquetées. Dans ce cas, les algorithmes utilisés regrouperont d'abord des données similaires à l'aide d'un algorithme d'apprentissage non supervisé, puis utiliseront les données étiquetées existant pour regrouper le reste des données non étiquetées.

A Algorithmes d'apprentissage automatique (Machine learning algorithms)

Dans ce groupe (Fig.1.8), les algorithmes les plus couramment utilisées pour détecter les défauts des MASs sont les systèmes experts (SEs), les RNA, FL, ANFIS, SVM, kNN, GA. De plus, d'autres techniques ont récemment été introduites, tels que NB, RF, DT et DA. Généralement, les MLAs, sont basés sur le prétraitement des différents signaux de la MAS, pour extraire les caractéristiques de défaut (fréquence, amplitude, déphasage, ...). Les caractéristiques sont regroupées et classées après l'étape d'extraction pour construire un modèle basé sur MLA. Par la suite, de nouvelles caractéristiques du même type sont utilisées pour tester le modèle précédemment créé [Shao et al., 2017b, Liu et al., 2018, Silva et al., 2018, Siddique et al., 2003, Liu and Bazzi, 2017].

– Systèmes experts (SEs)

Les SEs sont des algorithmes présentés pour résoudre des problèmes complexes qui ne peuvent pas être formés de la manière habituelle dans les processus de programmation. Il existe plusieurs types de SEs. Parmi les plus importants figurent les SEs basés sur l'ensemble des règles SI-ALORS (en anglais: IF-THEN). En général, le SE comporte deux parties principales (Fig.1.13): la base de connaissances qui contient la base de faits et la base de règles, et le moteur d'inférence [Trachi, 2017, Siddique et al., 2003, Khodja, 2007, Filippetti et al., 1992, Bose, 1994, Simeón et al., 2010].

– La base de connaissances est développée par un humain expert dans le domaine à étudier. Après avoir rassemblé ces connaissances, l'expert écrit de manière appropriée ces

faits sous forme de code à utiliser dans le processus de programmation pour obtenir une base de connaissances;

- Moteur d'inférence qui sélectionne et applique les règles de résolution d'un problème donné, il offre à l'utilisateur la meilleure solution au problème posé par l'interface utilisateur et attend de nouvelles instructions.

Généralement, les performances de SE dépendent des informations stockées pendant le processus de collecte des connaissances pour garantir les meilleures solutions possibles. Par exemple, dans [Filippetti et al., 1992], les auteurs ont établi un SE pour le diagnostic de défaut de rotor dans une MAS.




Figure 1.13: Structure principale d'un système expert

– Logique floue (FL)

La FL est une extension de la logique booléenne créée par Lotfi Zadeh en 1965 [Zadeh, 1965] basée sur des théories des groupes. L'un des avantages de la LF est qu'elle utilise le langage naturel pour formuler le raisonnement humain.

Donc, la FL permet de transformer des termes heuristiques à des termes linguistiques, par exemple, l'état du MAS peut être défini comme une MAS saine, MAS défaillante et MAS très défaillante par des variables numériques selon des règles floues et des fonctions d'appartenance. La figure 1.14 présente la structure principale de la FL. Le principe de FL est similaire au SE (Fig.1.13). Pour cela, on peut dire que le FL est un SE. Donc, FL dépend de trois étapes consécutives: fuzzification, inférence floue et défuzzification [Filippetti et al., 2000, Chudasama, 2016, Trachi, 2017, Zadeh, 1965]:

- La fuzzification consiste à transformer des variables d'entrée réelles en variables floues appelées variables linguistiques;
- Les règles d'inférence peuvent être SI-ALORS, la construction de ces règles reposant principalement sur "ET" ou "OU", par exemple: [Si condition X, Alors opération Y ou




Figure 1.14: Structure principale de la logique floue

...]. En général, plusieurs valeurs de variables linguistiques convenablement définies par les fonctions d'appartenance, et elles sont liées entre elles par des règles d'inférence, pour parvenir à une conclusion.

- La dernière étape de FL est la défuzzification où les sorties floues sont transformées en valeur réelle pour identifier l'état du système.

Plus de détails sur l'application du FL pour la détection des défauts des MAS sont disponibles dans [Benbouzid and Nejari, 2001, Chudasama, 2016, Zeraoulia et al., 2005, Consoli et al., 1998, Razik et al., 2008, Zidani et al., 2003, Romero-Troncoso et al., 2011].

– Réseaux de neurones artificiels (RNAs)

Les RNAs s'inspirent du fonctionnement des neurones biologiques humains et prennent forme dans un ordinateur sous la forme d'un algorithme. Les premières tentatives de modélisation des neurones artificiels sont anciennes et antérieures à l'ère informatique. En 1943, Mc Culloch (neurophysiologiste) et Pitt (logicien) proposent les premières notions de RNA.

Cette conception a ensuite été mise en réseau avec une couche d'entrée et une couche de sortie par Rosenblatt en 1959 pour simuler la fonction de réseau neuronal pour la reconnaissance de formes [Bose, 2007]. En bref, les RNAs sont considérés comme des architectures composées couches d'entrées, couches cachées et de couches de sortie (Fig.1.15). Le neurone est l'unité élémentaire des RNAs qui reçoit des données sous forme d'entrées, et produit une sortie réelle dans laquelle il est associé à ses semblables pour calculer des fonctions complexes.

Les RNAs peuvent se modifier leurs paramètres en fonction de leurs résultats, ce qui améliore l'apprentissage pour obtenir la meilleure résolution de problèmes. Plusieurs types des RNAs proposés dans la littérature telle que le Perceptron Multilayer Neural Network (MLPNN, Multi-Layer Perceptron en anglais) et les réseaux de neurones




Figure 1.15: Architecture des RNAs type MLP de deux couches cachées

à fonction de base radiale (Radial Basis Function Neural Networks, RBFNN), Machine d'apprentissage extrême (Extreme Learning Machine, ELM). En outre, plusieurs types d'algorithmes utilisés pour l'apprentissage des RNAs tels que l'algorithme de Levenberg-Marquardt [Kankar et al., 2011, Bose, 1994, Bose, 2007, Li et al., 2000].

En particulier, les RNAs ont été appliqués dans plusieurs domaines, tels que la classification, la robotique, la reconnaissance de formes, le traitement de signaux et d'images, le contrôle, la détection de défauts. Pour cette raison, cette technique est largement appliquée dans la détection et la classification de divers défauts des MASs. [Bouzid et al., 2008, Bose, 2007, Martins et al., 2007, Kolla and Varatharasa, 2000, Chow et al., 1993, Chow and Yee, 1991, Paya et al., 1997, Li et al., 2000, Kowalski and Orlowska-Kowalska, 2003, Wishart and Harley, 1995, Samanta and Al-Balushi, 2003, Bensaoucha et al., 2019, Saddam et al., 2017]. Les RNAs ont montré une grande capacité à détecter les différents défauts du MASs.

– Système hybride neuro-floue (ANFIS)

L'ANFIS est un réseau neuronal structuré basé sur la logique floue [Jang, 1993]. Dans certains cas de FL uniquement, la configuration des règles floues n'est pas une tâche facile. Par ailleurs, l'un des inconvénients majeurs de la FL est qu'elle ne fournit pas de solution exacte. D'un autre côté, les RNAs ont un problème avec le choix des paramètres de réseau tels que le nombre de couches cachées. L'ANFIS combine donc les avantages des RNAs et des systèmes d'inférence floue. L'ANFIS présente certains avantages, notamment la

capacité de capturer la structure non linéaire d'un processus, la capacité d'adaptation et la capacité d'apprentissage rapide.

La structure de l'ANFIS se compose de cinq couches avec plusieurs entrées et une seule sortie (Fig. 1.16). Cette architecture permet de modifier la structure des règles floues tout en évaluant le système d'inférence floue. Donc, l'ANFIS améliore ses performances en modifiant ses règles et ses fonctions d'appartenance [Yang et al., 2009, Goode and Chow, 1995, Schoen et al., 1995, Ballal et al., 2007, Karnavas et al., 2017, Ye et al., 2001, Abu-Rub et al., 2010, Jang, 1993]. Les algorithmes hybrides de rétro-propagation et des moindres




Figure 1.16: Architecture principale de l'ANFIS

carrés sont utilisés pour ajuster les paramètres des fonctions d'appartenance de l'ANFIS en fonction de leur sortie. La méthode des moindres carrés peut être facilement utilisée pour déterminer la valeur optimale des fonctions. De plus, l'algorithme hybride qui combine la méthode des moindres carrés avec la méthode du gradient descendant est adopté pour accélérer la convergence d'apprentissage [Ballal et al., 2007, Abu-Rub et al., 2010, Yang et al., 2009].

– Machine à vecteurs de support (SVM)

L'algorithme de SVM, initialement proposée par Vapnik à la fin des années 1960 sur la base de la théorie de l'apprentissage statistique [Vapnik, 2013]. Cependant, l'apparition des applications de SVM a été retardée jusqu'à 1990 [Cortes and Vapnik, 1995]. Au début, le SVM a été utilisé pour la classification binaire. Dans ce cas, l'algorithme de SVM recherche un hyperplan optimal qui sépare les données en deux classes. Pour les classes séparables, l'hyperplan optimal maximise une marge (espace qui ne contient aucune observation) qui l'entoure, ce qui crée des limites pour les deux classes, une positive et une négative. Les points les plus proches sont utilisés pour définir la marge et sont appelés vecteurs de support (H1 et H2) (Fig.1.17). Une fois les vecteurs supports sélectionnés, les autres points ne sont pas nécessaires car les vecteurs supports contiennent toutes les informations nécessaires à la classification. Pour les classes inséparables, le but est le même, mais l'algorithme impose une pénalité de longueur de marge pour chaque observation qui se trouve du mauvais côté de sa classe. Par conséquent, un mappage non linéaire est utilisé par l'astuce noyau (kernel function en anglais) pour transformer les données d'entrée en une grande dimension (Fig.1.18). Dans ce contexte, les SVMs dépendent directement du choix de la valeur d'un paramètre du noyau (coefficient de pénalité de C) qui améliorera leurs performances [Singh and Shaik, 2019, Smola and Schölkopf, 2004, Samanta, 2004, Weston and Watkins, 1998]. Après cela, le SVM a été développé pour la classification multi-classe [Weston and Watkins, 1998]. Dans ce cas, plusieurs stratégies sont appliquées pour entraîner le SVM multi-classes. Parmi elles, les stratégies un contre tous (en anglais One-Against-All, OVA) et un contre un (en anglais One-Against-One, OVO) sont les plus utilisées.

En principe, la stratégie OVA crée un modèle de SVM pour chaque classe où le SVM est entraîné pour distinguer les échantillons d'une seule classe des échantillons de toutes les autres classes. La stratégie OVO crée un modèle de SVM pour chaque paire de classes afin de distinguer les échantillons d'une classe des échantillons d'une autre classe [Milgram et al., 2006, Widodo and Yang, 2007].

Actuellement, le SVM est devenu un algorithme populaire dans le domaine de l'apprentissage automatique en raison de ses performances de généralisation élevées par rapport à d'autres algorithmes [Hearst et al., 1998, Cortes and Vapnik, 1995, Vapnik, 2013]. Aussi, dans le domaine du diagnostic de défauts des MASs, cet algorithme a donné d'excellents résultats [Singh and Shaik, 2019, Konar and Chattopadhyay, 2011, Tyagi, 2008, Jack and Nandi, 2002, Kankar et al., 2011, Salem et al., 2012].




Figure 1.17: Classification de deux classes à l'aide de SVM




Figure 1.18: Transformer l'espace de représentation des données d'entrée en un espace de plus grandes dimensions

– k plus proches voisins (kNN)

Le kNN (en anglais k-nearest neighbors, kNN) est un algorithme de classification basée sur l'apprentissage de l'analogie ou des similitudes entre les échantillons de tests et les

échantillons d'apprentissage préétiquetés (Fig.1.19) [Mechefske and Mathew, 1992]. Cet algorithme tente d'établir un modèle entre les k échantillons et ceux d'apprentissage près de l'échantillon inconnu. Le kNN calcule la proximité entre les éléments en fonction de leur distance euclidienne. L'avantage de kNN est de créer une surface de décision adaptée à la manière dont les données d'apprentissage sont réparties en profondeur [Liu et al., 2018, Wang, 2016]. L'inconvénient major de kNN est que la rapidité de classification diminue à mesure que le volume de données augmente, ce qui en fait un choix inconfortable dans certains environnements où la rapidité de classification est nécessaire. Pour cela, les applications de kNN sont souvent implémentées après la réduction des dimensions des données (sélection des données). Dans ce cas, plusieurs techniques de sélection des données ont été utilisées. Le plus important est l'analyse en composantes principales (en anglais Principal Component Analysis, PCA) [Wang, 2016]. Dans la détection des défauts des MASs, le kNN a été appliquée par [Nguyen and Lee, 2010, Dou and Zhou, 2016].




Figure 1.19: Classification d'un échantillon non défini à l'aide de kNN

– Algorithme génétique (GA)

L'algorithme génétique (GA) est un algorithme basé sur la sélection naturelle et les mécanismes génétiques. Cet algorithme est souvent appliqué pour l'optimisation des fonctions. De plus, le GA peut être utilisé pour trouver le minimum global de fonctions

multimodales ou pour des données accompagnées de bruit les rendant insolubles pour les méthodes traditionnelles comme la méthode de descente de gradient. En général, l'GA est basé sur cinq étapes principales (Fig.1.20) sont: la population initiale, évaluation, sélection, croisement et la mutation [Vafaie and De Jong, 1992, Whitley, 1994, Tang et al., 1996]:

- Le processus commence par un groupe d'individus appelé population. Chaque individu est considéré comme une solution au problème à résoudre;
- Évaluation, la fonction fitness détermine la capacité d'un individu à rivaliser avec d'autres individus;
- La sélection vise à sélectionner les individus les plus appropriés et à les laisser transmettre leurs gènes à la génération suivante. Deux couples d'individus (parents) sont sélectionnés en fonction de leur forme physique;
- Le croisement est la phase la plus importante d'un algorithme génétique. Pour chaque couple de parents à accoupler, un point de croisement est choisi au hasard parmi les gènes;
- Pour les descendants nouvellement formés, certains de leurs gènes peuvent être sujets à une mutation avec une faible probabilité aléatoire. Cela implique que certains des bits de la chaîne de bits peuvent être renvoyés.

Les GAs ont gagné en popularité dans plusieurs applications qui nécessitent l'optimisation globale d'une solution. Ces algorithmes sont souvent utilisés avec les techniques d'AI telles que le FL, les RNAs et l'ANFIS pour optimiser le nombre optimal de neurones dans les couches cachées de RNAs et de l'ANFIS. Pour FL, GA utilisé pour optimiser les fonctions d'appartenance. Dans le cas de SVM, il est possible d'intégrer le GA pour optimiser la fonction du noyau et le paramètre C à utiliser [Vafaie and De Jong, 1992, Jack and Nandi, 2002]. Dans [Alonge et al., 1998, Bishop and Richards, 1990], l'GA a été appliqué pour identifier les paramètres de la MAS. En outre, il est utilisé pour trouver les fréquences des défauts des MASs les plus pertinents [Konar and Chattopadhyay, 2015, Razik et al., 2008]. L'inconvénient principal de GA est qu'il n'a aucun concept de solution optimale et aucun moyen de vérifier si la solution est optimale ou non [Siddique et al., 2003].

– Naïve Bayes (NB)

Le NB est un algorithme de classification basée sur la théorie de Bayes qui suppose l'indépendance entre les attributs. Donc, l'algorithme de NB suppose que la présence d'une caractéristique particulière dans une classe n'est pas liée à la présence de toute autre caractéristique [Friedman et al., 1997, Lewis, 1998, Berrar, 2018, Dai et al., 2007].




Figure 1.20: Principe général de l'algorithme génétique

Par exemple, on suppose que $X_1, \dots, X_n$ sont des attributs et Y leurs classes. Le NB apprend des données d'apprentissage la probabilité conditionnelle de chaque attribut X_i étant donné l'étiquette de classe Y . La classification se fait ensuite en appliquant la règle de Bayes pour calculer la probabilité C de compte tenu de l'instance particulière de $X_1, \dots, X_n$, puis prédire la classe avec la probabilité postérieure la plus élevée. Ce calcul est rendu possible en faisant une hypothèse d'indépendance forte: tous les attributs A_i sont conditionnellement indépendants étant donné la valeur de la classe Y . Par indépendance, nous entendons l'indépendance probabiliste, c'est-à-dire, X est indépendant de W étant donné Y chaque fois que $Pr(X|W, Y) = Pr(X|Y)$ pour toutes les valeurs possibles de X ; W et Y , lorsque $Pr(Y) > 0$ [Friedman et al., 1997]. Le NB a une structure simple comme le montre la figure 1.21.

– Arbre de décision (DT)

L'arbre de décision (DT: Decision Tree en anglais) exprimé comme une partition récursive de l'espace d'instance [Friedl and Brodley, 1997, Rokach and Maimon, 2005, Song and Ying,




Figure 1.21: Structure de naïve Bayes

2015]. Comme le montre la figure 1.22, l'ensemble des nœuds de DT est divisé en trois catégories: nœud racine, nœuds internes qui ont des descendants (enfants), qui sont à leur tour des nœuds, et nœuds terminaux (feuilles) qui n'ont pas de non descendants. Le processus décisionnel est réalisé par une descente dans l'arbre de sa racine à l'une des feuilles. Les décisions sont prises dans les feuilles de l'arbre.

Les inducteurs de l'DT sont des algorithmes qui construisent automatiquement un arbre de décision à partir d'un ensemble de données. Généralement, l'objectif est de trouver l'DT optimal en minimisant l'erreur de généralisation. Pour atteindre l'DT optimal, plusieurs méthodes heuristiques sont utilisées. Généralement, ces méthodes peuvent être divisées en deux groupes: de haut-bas et de Top-Down. Souvent, la méthode Top-Down est plus préférée dans la littérature. Top-Down est basé à construisant l'arbre de la racine vers les feuilles [Friedl and Brodley, 1997, Rokach and Maimon, 2005, Song and Ying, 2015].

Nous prenons l'exemple présenté dans la figure 1.22, l'DT utilisé pour détecter la situation d'un patient: est-il malade ou non ? ". La situation du patient est écrite par deux attributs binaires: sa température et son mal de gorge (Gorge irritée). L'attribut prend deux classes: malade ou Bien portant. Dans ce cas, nous pouvons conclure que le patient est malade car il y a deux feuilles indiquant la maladie du patient.

– Méthodes d'ensemble (EMs)

Les méthodes d'ensemble (EMs) sont des algorithmes d'apprentissage automatique qui combinent plusieurs modèles de base pour produire un modèle prédictif optimal. Ainsi, ces algorithmes se combinent en comité pour prendre des décisions plus appropriées pour classer ou régresser de nouvelles instances [Dietterich, 2000, Peng, 2006, Nanni and Lumini, 2009, Genuer and Poggi, 2017]. Souvent, les EMs peuvent produire de meilleures performances prédictives par rapport à un modèle unique. La plupart des EMs utilisent un seul algorithme d'apprentissage de base (par exemple: ensemble de kNN, ensemble de DT, ensemble de DA) pour produire des apprenants de base homogènes. Les techniques les




Figure 1.22: Exemple d'arbre de décision

plus utilisées pour créer des ensembles sont l'agrégation bootstrap (Bagging) et la famille d'algorithmes Adaboost (Boosting) [Dietterich, 2000, Genuer and Poggi, 2017]. Dans l'agrégation, chaque ensemble d'apprentissage est construit en formant une réplique Bootstrap de l'ensemble d'apprentissage d'origine. On suppose un ensemble d'apprentissage D avec N exemples, l'agrégation permet de construire un nouvel ensemble d'apprentissage $\tilde{D}$ est construit en dessinant N exemples uniformément (avec remplacement) à partir de D .

L'algorithme d'Adaboost maintient un ensemble de poids sur l'ensemble d'apprentissage d'origine D et ajuste ces poids après que chaque classificateur a été appris par l'algorithme d'apprentissage de base. Les ajustements augmentent le poids des exemples mal classés par l'algorithme d'apprentissage de base et diminuent le poids des exemples correctement classés.

Généralement, la technique de la forêt aléatoire (Random Forest en anglais, RF) [Breiman, 2001] est la plus couramment utilisée dans les EMs. La RF est considérée comme un ensemble des arbres, chaque arbre de l'ensemble est construit à partir d'un échantillon prélevé avec remplacement (algorithme de bagging). De plus, au lieu d'utiliser toutes les fonctionnalités (caractéristiques), un sous-ensemble aléatoire de fonctionnalités est sélectionné, ce qui randomise davantage l'arborescence. Plus de détails est disponible dans [Dietterich, 2000, Nanni and Lumini, 2009].

La RF, comme son nom l'indique, se compose d'un grand nombre d'DT individuels qui fonctionnent comme un ensemble. Chaque arbre individuel dans la RF crache une prédiction de classe et la classe avec le plus de votes devient la prédiction de notre modèle. La fig-

ure 1.23 montre la structure générale de RF. Cet algorithme est principalement basé sur l'approche de l'agrégation (Bagging).




Figure 1.23: Exemple d'une forêt aléatoire

– Analyse discriminante (DA)

L'analyse discriminante (Discriminant analysis en anglais, DA) trouve un ensemble d'équations de prédiction basées sur des variables indépendantes qui sont utilisées pour classer les individus en groupes. L'algorithme de DA a deux objectifs possibles: trouver une équation prédictive pour classer les nouveaux individus ou interpréter l'équation prédictive pour mieux comprendre les relations qui peuvent exister entre les variables [Delpha et al., 2008, Ayhan et al., 2006, Ramayah et al., 2010]. L'DA est basé sur la transformation de l'espace d'entrée en un nouvel espace. Ainsi, cette méthode est utilisée pour réduire la dimensionnalité d'un problème. L'DA identifie une combinaison linéaire de variables prédictives quantitatives qui caractérisent le mieux des différences entre les groupes a priori choisis. Dans un sens plus précis, l'objectif principal de DA est de trouver un ensemble de combinaisons linéaires de variables dont les valeurs sont aussi proches que possibles au sein des groupes et aussi éloignées que possibles entre les groupes.




Figure 1.24: Principe de DA

B Deep learning

Les algorithmes de DL ont été développés pour construire des algorithmes capables d'apprendre et de se développer indépendamment. En d'autres termes, les algorithmes de DL sont capables d'apprendre des représentations hiérarchiques automatiquement de manière non supervisée [Shao et al., 2017b]. L'ensemble des entrées dans la plupart des MLAs dépend directement du prétraitement des données (des signaux, des images, texte, audio, etc.). Par contre, algorithmes de DL ne nécessitent pas de prétraitement des données. Le DL a une grande capacité à utiliser directement les entrées [Liu et al., 2018, Sobie et al., 2018, Siddique et al., 2003, Schmidhuber, 2015, Cheriyaat, 2013].

La plupart des algorithmes de DL utilisent des architectures des RNAs. Les RNAs classiques n'ont généralement que deux ou trois (2-3) couches cachées, tandis que les algorithmes de DL peuvent avoir jusqu'à 150 couches cachées. Le DL comprend plusieurs algorithmes, tels que: l'auto-encodeur (en anglais, Auto-coder), la machine Boltzmann restreinte (Restricted Boltzmann Machine, RBM), le réseau de croyances profondes (Deep Belief Networks, DBN), et les réseaux de neurones profonds (Conventional Neural Networks, CNN), et le réseau de neurones récurrents (Recurrent neural network, RNN) [Liu et al., 2018, Shao et al., 2017b, Schmidhuber, 2015].

Actuellement, les algorithmes de DL ont été utilisés dans divers domaines, notamment la conduite autonome, la vision par ordinateur, la robotique, les recherches médicales, la reconnaissance vocale, etc. [Liu et al., 2018, Shao et al., 2017b, Schmidhuber, 2015]. Bien que le DL soit encore en développement, il a été utilisé pour diagnostiquer les défauts des MASs [Shao et al., 2017b]. En particulier, le CNN (Fig.1.25) élimine le besoin de prétraitement des données, ce qui élimine la tâche d'extraction des caractéristiques. Le CNN est souvent utilisé pour le traitement d'images, cet algorithme applique des filtres

aux images pour faire ressortir de nouvelles caractéristiques. Cette extraction automatique permet aux modèles de CNN d'atteindre un niveau de précision particulièrement élevé.




Figure 1.25: Architecture de CNN

Les RBMs diffèrent des autres réseaux de neurones en ce qu'ils sont générateurs car ce sont des réseaux de neurones bidirectionnels, ce qui signifie qu'ils sont généralement destinés à la restructuration des données, tandis que les réseaux neuronaux profonds à utiliser pour la classification des données.

Le DBN est également une classe de réseau neuronal profond qui comprend plusieurs couches de modèles graphiques ayant à la fois des bords dirigés et non dirigés. Il est composé de plusieurs couches d'unités cachées, où chaque couche est connectée les unes aux autres mais les unités ne le sont pas. Le DBN peut être construit en empilant plusieurs RBMs un par un pour former une architecture de réseau approfondie [Shao et al., 2017b]. En d'autres termes, CNN est idéal pour évaluer et prédire l'ensemble de données. Le DBN convient à la réparation des données endommagées, mais il peut également corriger

les données afin qu'elles soient plus modulaires et plus facilement identifiées par un autre réseau neuronal. On peut donc dire que le DBN est complémentaire du CNN.

Les RNNs sont de puissants réseaux de neurones profonds et font partie des algorithmes les plus prometteurs du moment car ils sont les seuls à disposer d'une mémoire interne.

En principe, l'efficacité de DL s'améliore avec l'augmentation du volume de données. Pour ce faire, il nécessite des ordinateurs avec une puissance de calcul important. Plus de

détails dans [Liu et al., 2018, Shao et al., 2017b, Cheriadat, 2013, Schmidhuber, 2015]. La

figure 1.26 résumé la différence fondamentale entre les MLAs et algorithmes de DL. En résumé, l'AI est un domaine très vaste, les MLAs sont un sous-domaine de l'AI (Fig.1.27),

le DL est lui-même une sous-catégorie de MLAs.




Figure 1.26: MLAs et DL

1.5 Conclusion

Dans ce chapitre, nous avons présenté un bref rapport sur la structure de la MAS à cage rotorique, ainsi que les différents défauts internes et leur origine qui apparaissent dans




Figure 1.27: Interactions entre l'IA, MLAs et DL

cette machine. En général, ces défauts peuvent être regroupés principalement en deux groupes:

- Défauts électriques tels que court-circuit dans les phases du stator, rupture des barres rotoriques;

- Défauts mécaniques tels que les défauts de roulement, les défauts d'excentricité, etc.

Nous avons également examiné les signaux les plus importants de la machine qui peuvent être utilisés pour surveiller sa situation. Dans ce contexte, on peut dire que la détection de l'état de la machine à l'aide du signal de courant du stator présente plusieurs avantages par rapport aux autres signaux car leurs capteurs sont peu coûteux et faciles à intégrer dans la machine.

Nous avons également examiné les techniques de détection de défauts les plus populaires qui peuvent être classées en deux catégories principales:

- Méthodes internes: ces méthodes sont celles qui utilisent un modèle du système à surveiller. Par conséquent, ces méthodes nécessitent une connaissance a priori du système. L'une des techniques les plus importantes que nous avons mentionnées est l'estimation paramétrique, les observateurs (par exemple le filtre de Kalman), les techniques de résidus;

- Méthodes externes: ces méthodes ne nécessitent pas de modèle de système pour le diagnostic de la MAS, les méthodes les plus courantes sont celles qui utilisent le traitement du signal (temporel, fréquentiel ou temporel-fréquentiel) et dont les techniques d'intelligence artificielle sont soit des MLAs soit les algorithmes de DL.

Dans ce qui suit, le deuxième chapitre est consacré à la modélisation de la MAS à cage rotorique en vue de détecter leurs défauts électriques.

Chapitre 2

MODÉLISATION DES MACHINES ASYNCHRONE EN VUE DE DIAGNOSTIC DES DÉFAUTS

2.1 Introduction

La modélisation des machines électriques est un processus essentiel pour diagnostiquer et contrôler leur fonctionnement. En général, les méthodes numériques et analytiques sont les deux méthodes de calcul les plus utilisées dans la modélisation des machines électriques [Baghli, 1999, Khodja, 2007, Vaseghi, 2009, Delforge-Delmotte and Lemaire-Semail, 1996].

- **Les méthodes numériques** sont des approches basées sur le calcul des champs magnétiques et électriques à partir des équations de champ électromagnétique, telles que les équations de Maxwell. Parmi ces méthodes, on mentionne, la méthode des éléments finis, la méthode des réseaux de perméance, etc. La modélisation par les éléments finis est une approche efficace puisqu'elle permet de calculer avec précision le comportement électromagnétique de la machine. Cette approche permet de simuler les différents défauts des machines de manière plus proche de la réalité, puisqu'elle permet l'observation de certains phénomènes magnétiques, comme la saturation du circuit magnétique, l'effet de la géométrie complexe de la machine et les courants de Foucault. Cependant, cette méthode prend généralement un temps de calcul considérable et exige les paramètres géométriques de la machine;

- **Les méthodes analytiques** présentent la machine sous la forme de circuits électriques

équivalents contenant des résistances, des inductances et des inductances mutuelles, etc. Ces méthodes consistent à traiter les grandeurs globales de la machine telle que les signaux de tensions, des courants et de flux, etc. Les méthodes analytiques généralement basées sur les lois de Kirchhoff et la transformation de Park, Clarke et Concordia pour modéliser le système de machine. Ces lois ne nécessitent pas d'outils complexes pour les appliquer. Pour cette raison, ils sont largement utilisés pour la modélisation des machines électriques. Ces méthodes nécessitent de proposer des hypothèses et de négliger certains phénomènes, comme la saturation des circuits magnétiques, afin de simplifier la modélisation.

Donc, dans ce chapitre, un modèle mathématique pour la MAS à cage rotorique sera présenté pour simuler leur comportement en présence de défauts statoriques de type court-circuit entre spires et de défauts rotoriques de type rupture des barres. Ce modèle permet donc de suivre les grandeurs mesurables de la machine, telles que la vitesse de rotation, les courants statoriques et le couple électromagnétique. Selon les lois de Kirchhoff, Park et de Clark, le modèle est décrit par des équations différentielles utilisant divers paramètres de la machine telle que les résistances et inductances du stator et du rotor.

Tout d'abord, un modèle à multi-enroulements est présenté sous la forme d'équations différentielles basées sur des mailles couplées électriquement et magnétiquement. Ce modèle est appelé un modèle à multi-enroulements car il contient multi-équations selon le nombre de barres de rotor. Pour cela, chaque maille rotorique est composée de deux barres et de deux portions d'anneaux. Après la transformation de Park ($abc \rightarrow dq$), le nombre d'équations différentielles de ce modèle est égal au nombre total de barres rotorique (N_r), de plus deux équations de stator et une équation pour l'anneau de la cage rotorique (c-à-d: $N_r + 3$). La simulation de modèle multi-enroulements nécessite généralement un temps de calcul important. Par conséquent, la transformation généralisée de Clarke permet d'obtenir un modèle diphasé appelé le modèle réduit. Ce modèle est utilisé pour réécrire la cage du rotor avec une représentation de deux équations au lieu d'un modèle N_r équations, afin de réduire la complexité du modèle et d'accélérer la simulation. Selon ce modèle, la rupture des barres du rotor est vérifiée en augmentant les résistances équivalentes de la barre cassée.

Dans ce qui suit, le modèle réduit est généralisé pour simuler le défaut de court-circuit entre spires suivant le travail de [Bachir et al., 2006]. Après cela, le modèle réduit global est utilisé pour analyser l'impact du défaut de court-circuit entre spires et la rupture des barres sur le comportement de la MAS (vitesse du rotor, couple électromagnétique, et courants statoriques). La description de ce modèle avec les résultats de la simulation au cas par cas, qu'il s'agisse d'une MAS saine, de barres de rotor cassées, d'un court-circuit

entre spires ou d'un défaut simultané sera détaillés et discutés dans ce chapitre. Avant de commencer à modéliser la MAS, certaines hypothèses simplificatrices doivent être prises en compte.

2.2 Hypothèses simplificatrices

Comme nous l'avons déjà mentionné précédemment (Sec.2.1), la modélisation analytique repose principalement sur des hypothèses pour simplifier la modélisation des circuits électriques et magnétiques de la machine. Par conséquent, nous supposons ce qui suit [Baghli, 1999, Khodja, 2007, Abed, 2002, Laribi, 2016, Didier, 2004]:

- Les ouvertures des inclinaisons et des encoches ne sont pas pris en compte;
- Le phénomène d'hystérésis avec les courants de Foucault sont négligeables;
- Pas de saturation de circuit magnétique avec une perméabilité constante;
- Les harmoniques spatiales de la distribution du flux sont négligées;
- Distribution sinusoïdale de la force magnétomotrice du stator;
- Les barres de la cage rotorique sont uniformément réparties;
- L'entrefer de la MAS est d'épaisseur uniforme (constante);
- Les inductances propres de la MAS sont constantes.
- La perméabilité relative du fer est très élevée;

De plus, nous considérons que la MAS à cage d'écureuil ayant trois enroulements statoriques identiques et symétriques, chacun de ces enroulements est traité comme un enroulement séparé. En résumé, les étapes principales de modélisation peuvent être divisées en trois selon la nature de l'équation mathématique [Koteich, 2016]:

- Équations électromagnétiques basées sur les relations entre les flux et les courants, telles que $\text{flux} = \text{courant} \times \text{inductance}$;
- Équations électriques basées sur la relation entre les courants et les tensions en utilisant les lois d'Ohm, les lois des mailles, et les lois des nœuds;

- Équations mécaniques basées sur les lois de mouvement de Newton, qui dépendent principalement de la relation entre la vitesse du rotor et le couple de la machine.

L'objectif principal de cette section est d'obtenir un modèle mathématique de la machine (modèle réduit). Mais avant cela, nous devons passer par un modèle multi-enroulements. Par conséquent, dans ce qui suit, nous détaillerons les processus d'obtention du modèle multi-enroulements, en commençant par le calcul des différentes inductances et résistances du stator et du rotor.

2.3 Modèle multi-enroulements de la MAS

Dans cette section, nous commencerons par calculer les différentes inductances du stator, du rotor et les inductances mutuelles [Baghli, 1999, Khodja, 2007, Abed, 2002, Laribi, 2016, Saddam et al., 2018a].

2.3.1 Inductances de stator

En appliquant le théorème d'Ampère, la circulation du champ magnétique (H) sur un contour fermé créé par une phase statorique en tout point peut être calculée comme suit:

$$\oint H dL = \frac{N_s}{p} i_s \quad (2.1)$$

avec L est la longueur active de rotor, N_s est le nombre de spires de stator par phase, i_s est le courant d'une phase de stator et p est le nombre de paires de pôles.

Par conséquent, l'induction magnétique maximale (B_{sMax}) créée dans l'entrefer par le passage du courant statorique s'écrit comme suivant:

$$B_{sMax} = \frac{\mu_0}{2\pi} \frac{N_s}{e.p} i_s \quad (2.2)$$

avec $\mu_0 = 4\pi 10^{-7} [H.m^{-1}]$ est la perméabilité magnétique à vide, (e) est l'épaisseur de l'entrefer de la machine.

Selon la décomposition de l'induction (B_s) par la série de Fourier, on obtient:

$$B_s = \frac{2\mu_0}{\pi} \frac{N_s}{e.p} i_s \cos(p\theta) \quad (2.3)$$

On applique l'intégrale de l'équation (2.3), le flux principal de l'enroulement statorique (Φ_{sp}) est donné par:

$$\Phi_{sp} = N_s R L \int_{-\frac{\pi}{2p}}^{\frac{\pi}{2p}} B_s d\theta \quad (2.4)$$

avec R est le rayon moyen à l'entrefer. Donc, on obtient par l'intégrale de l'équation (2.4) le suivant:

$$\Phi_{sp} = \frac{4\mu_0}{\pi} \frac{N_s^2 RL}{e.p^2} i_s \quad (2.5)$$

Selon l'équation (2.5), on peut réécrire le flux principal Φ_{sp} comme suit:

$$\Phi_{sp} = L_{sp} i_s \quad (2.6)$$

Par conséquent, l'inductance principale (L_{sp}) de la phase statorique est donnée par:

$$L_{sp} = \frac{4\mu_0}{\pi} \frac{N_s^2 RL}{e.p^2} \quad (2.7)$$

De plus, l'inductance cyclique du stator (L_{sc}) est écrite en fonction de l'inductance principale (L_{sp}) et de l'inductance de fuite (L_{sf}) par le suivant:

$$L_{sc} = \frac{3}{2} L_{sp} + L_{sf} = \frac{6\mu_0}{\pi} \frac{N_s^2 RL}{e.p^2} + L_{sf} \quad (2.8)$$

De plus, le flux de fuite (Φ_{sf}) est donné par ce qui suit:

$$\Phi_{sf} = L_{sf} i_s \quad (2.9)$$

Tant que la distribution de force magnétomotrice du stator est sinusoïdale (une hypothèse), les inductances mutuelles ($M_{sab}, M_{sac}, M_{sbc}$) entre les trois phases du stator sont écrits comme suit:

$$\begin{cases} M_{sab} = L_{sp} \cos(\frac{2\pi}{3}) = -\frac{L_{sp}}{2} \\ M_{sac} = L_{sp} \cos(\frac{4\pi}{3}) = -\frac{L_{sp}}{2} \\ M_{sbc} = L_{sp} \cos(\frac{2\pi}{3}) = -\frac{L_{sp}}{2} \end{cases} \quad (2.10)$$

Étant donné que les enroulements statoriques sont symétriques. Donc, on peut écrire:

$$M_{sab} = M_{sac} = M_{sbc} = M_s = -\frac{L_{sp}}{2} \quad (2.11)$$

2.3.2 Inductances de rotor

Comme mentionné précédemment (Sec.2.1), la modélisation du rotor consiste à modéliser chacune des deux barres adjacentes et deux portions de l'anneau comme une maille électrique. Toutes ces mailles sont couplées magnétiquement à travers le flux du rotor (Fig.2.1). Donc, suivant la loi des nœuds, on obtient:

$$i_b^k = i_r^j - i_r^{j+1} \quad (2.12)$$




Figure 2.1: Schéma électrique équivalent au rotor d'une MAS à cage d'écureuil

avec i_r^j est le courant de j^{eme} maille rotorique, tels que $j = 0, 1, 2, N_r - 1$ et i_b^k est le courant de la k^{eme} barre rotorique.

De plus, l'induction magnétique (B_{1r}^j) (Fig.2.2) produite par une maille de rotor dans l'entrefer est:

$$B_{1r}^j = \frac{N_r - 1}{N_r} \frac{\mu_0}{e} i_r^j \quad (2.13)$$

D'après l'équation (2.13), on peut calculer le flux propre (Φ_{rp}^j) d'une maille rotorique par le suivant:

$$\Phi_{rp}^j = RL \int_0^{\frac{2\pi}{N_r}} B_{1r}^j d\theta \quad (2.14)$$

On obtient donc:

$$\Phi_{rp}^j = 2\pi\mu_0 \frac{N_r - 1}{N_r^2} \frac{RL}{e} i_r^j \quad (2.15)$$

Par conséquent, l'inductance principale (L_{rp}) d'une maille rotorique de rotor s'écrit:

$$L_{rp} = \frac{\Phi_{rp}^j}{i_r^j} = 2\pi\mu_0 \frac{N_r - 1}{N_r^2} \frac{RL}{e} \quad (2.16)$$




Figure 2.2: Induction magnétique produite par une maille rotorique

L'inductance principale totale (L_{rpt}) d'une maille de rotor est donnée en fonction de l'inductance de la barre rotorique (L_b) et l'inductance de portion d'anneau (L_e) comme suivant:

$$L_{rpt} = L_{rp} + 2L_b + 2L_e \quad (2.17)$$

De plus, le flux mutuel (Φ_{rr}) entre deux mailles de rotor s'écrit par:

$$\Phi_{rr} = RL \int_0^{\frac{2\pi}{N_r}} B_{2r}^j d\theta = -2\pi\mu_0 \frac{1}{N_r^2} \frac{RL}{e} i_r^j \quad (2.18)$$

Alors, l'inductance mutuelle entre deux mailles de rotor non adjacentes (M_{rr}) est:

$$M_{rr} = \frac{\Phi_{rr}}{i_r^j} = -2\pi\mu_0 \frac{1}{N_r^2} \frac{RL}{e} \quad (2.19)$$

De plus, l'inductance cyclique (L_{rc}) de j^{eme} maille rotorique est écrit comme suivant:

$$L_{rc} = L_{rp} - M_{rr} + 2\frac{L_e}{N_r} + 2L_b (1 - \cos \alpha) \quad (2.20)$$

2.3.3 Inductances mutuelles

Dans cette partie, nous allons calculer l'inductance mutuelle M_{sr} entre l'enroulement d'une phase statorique m et une maille rotorique.

Donc, l'induction magnétique (B_{msr}) produite par une bobine statorique de la phase m dans une maille du rotor est donnée par:

$$B_{msr} = \frac{2\mu_0}{\pi} \frac{N_s}{e.p} i_{sm} \cos(p\theta - m\frac{\pi}{3}) \quad (2.21)$$

$m = 0, 1, 2$ indique les trois phases du stator.

A partir l'équation (2.21), le flux mutuel (Φ_{smrk}) est donné par:

$$\begin{aligned}\Phi_{smrj} &= RL \int_{\frac{\theta}{p} + j \frac{2\pi}{N_r} - \frac{\pi}{N_r}}^{\frac{\theta}{p} + j \frac{2\pi}{N_r} + \frac{\pi}{N_r}} B_{msr}(\theta) d\theta \\ \Phi_{smrj} &= -\frac{2\mu_0}{\pi} \frac{N_s}{e.p} \frac{RL}{p} i_{sm} \left[\sin \left(p\theta - m \frac{2\pi}{3} \right) \right]_{\frac{\theta}{p} + j \frac{2\pi}{N_r} - \frac{\pi}{N_r}}^{\frac{\theta}{p} + j \frac{2\pi}{N_r} + \frac{\pi}{N_r}}\end{aligned}\quad (2.22)$$

La figure 2.3 montre la forme de flux mutuel entre l'enroulement de stator phase- m et une maille rotorique j^{eme} .

Donc, l'inductance mutuelle (M_{smrj}) entre la phase de stator m et une maille de rotor j




Figure 2.3: Flux mutuelle entre une phase statorique m et une maille rotorique j^{eme}

est donnée par le suivant:

$$M_{smrj} = -M_{sr} \cos \left(p\theta - m \frac{2\pi}{3} + j\alpha \right) \quad (2.23)$$

avec $\alpha = p \frac{2\pi}{N_r}$ est l'angle électrique entre deux mailles rotoriques adjacentes.

De plus, l'inductance mutuelle cyclique (M_{sr}) est donnée par:

$$M_{sr} = \frac{4\mu_0}{\pi} \frac{N_s}{e.p} \frac{RL}{p} \sin\left(\frac{\alpha}{2}\right) \quad (2.24)$$

2.4 Mise en équations

Dans cette partie, nous utilisons la transformation de Clarke pour passer de système triphasées (x_a, x_b, x_c) à un système biphasé (x_α, x_β). Ensuite, on passe d'un système

biphasé (α, β) à un système biphasés (d, q) à l'aide d'une matrice de rotation de Park. En principe, la transformation triphasée biphasée dans le cadre de référence dq a été initialement établie pour décomposer la force magnétomotrice créée par le stator en deux axes et pour simplifier la modélisation.

2.4.1 Transformation triphasée biphasée

L'idée de Clarke repose sur le fait qu'un champ tournant créé par un système triphasé (x_a, x_b, x_c) peut l'être défini par un système biphasé (x_α, x_β) de deux bobines équivalent. La transformation directe de Clarke déduit de la formule suivante:

$$\begin{bmatrix} x_\alpha \\ x_\beta \\ x_o \end{bmatrix} = \frac{2}{3} \begin{bmatrix} 1 & -\frac{1}{2} & -\frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \\ \frac{1}{2} & \frac{1}{2} & \frac{1}{2} \end{bmatrix} \begin{bmatrix} x_a \\ x_b \\ x_c \end{bmatrix} \quad (2.25)$$

où α, β, o sont appelées les composantes de Clarke.

Nous pouvons maintenant faire une transformation des variables dans le référentiel stationnaire (α, β) au référentiel dq qui tourne à la vitesse de pulsation synchrone (ω_s) :

$$\begin{bmatrix} x_d \\ x_q \\ x_o \end{bmatrix} = P(\theta) \begin{bmatrix} x_\alpha \\ x_\beta \\ x_o \end{bmatrix} \quad (2.26)$$

$P(\theta)$ est la matrice de rotation de Park et donné par:

$$P(\theta) = \begin{bmatrix} \cos(\theta_s) & -\sin(\theta_s) \\ \sin(\theta_s) & \cos(\theta_s) \end{bmatrix} \quad (2.27)$$

Pour un système équilibré, le composant homopolaire x_o est nul.

2.4.2 Équations statoriques dans le référentiel dq

Nous pouvons écrire les équations de tensions statoriques (v_{abcs}) sous forme vectorielle par l'équation (2.28):

$$[v_{abcs}] = [R_s][i_{abcs}] + \frac{d}{dt}[\Phi_{abcs}] \quad (2.28)$$

avec $[R_s]$ est la matrice des résistances statoriques:

$$[R_s] = \begin{bmatrix} R_s & 0 & 0 \\ 0 & R_s & 0 \\ 0 & 0 & R_s \end{bmatrix}$$

De plus, $[i_{abc}]$ et $[v_{abc}]$ sont respectivement les matrices des courants et des tensions statoriques dans le système abc :

$$[i_{abc}] = [i_{as} i_{bs} i_{cs}]^T ;$$

$$[v_{abc}] = [v_{as} v_{bs} v_{cs}]^T .$$

Les équations de flux statoriques (Φ_{abc}) est définie comme suit:

$$[\Phi_{abc}] = [L_s][i_{abc}] + [M_{sr}][i_r^j] \quad (2.29)$$

avec:

$$[\Phi_{abc}] = [\Phi_{as} \Phi_{bs} \Phi_{cs}]^t .$$

$[L_s]$ est la matrice des inductances statoriques s'écrit sous forme :

$$[L_s] = \begin{bmatrix} L_{sp} + L_{sf} & M_s & M_s \\ M_s & L_{sp} + L_{sf} & M_s \\ M_s & M_s & L_{sp} + L_{sf} \end{bmatrix}$$

et $[i_r^j] = [i_r^0 i_r^1 \dots i_r^{N_r-2} i_r^{N_r-1}]^t$ sont les courants des mailles rotoriques.

$[M_{sr}]$ est la matrice des inductances mutuelles entre les trois phases statoriques et les j^{eme} mailles rotoriques:

$$[M_{sr}] = \begin{bmatrix} \dots & \dots & \dots & -M_{sr} \cos(\theta_r + j\alpha) & \dots & \dots & \dots \\ \dots & \dots & \dots & -M_{sr} \cos(\theta_r + j\alpha - \frac{2\pi}{3}) & \dots & \dots & \dots \\ \dots & \dots & \dots & -M_{sr} \cos(\theta_r + j\alpha - \frac{4\pi}{3}) & \dots & \dots & \dots \end{bmatrix}$$

Après la transformation de Clarke et la rotation de Park, les équations des tensions statoriques dans le repère rotorique ($\theta_s = \theta_r$) s'écrit sous forme suivant:

$$\begin{cases} v_{ds} = R_s i_{ds} + \frac{d\Phi_{ds}}{dt} - \omega_r \Phi_{qs} \\ v_{qs} = R_s i_{qs} + \frac{d\Phi_{qs}}{dt} + \omega_r \Phi_{ds} \end{cases} \quad (2.30)$$

avec $v_{dqs} = [v_{ds} v_{qs}]$ et $i_{dqs} = [i_{ds} i_{qs}]$ représentent respectivement les composantes des tensions et des courants statoriques le long des axes dq .

De plus, Φ_{ds} et Φ_{qs} représentent les composantes des flux statoriques dans les axes dq :

$$\begin{bmatrix} \Phi_{ds} \\ \Phi_{qs} \end{bmatrix} = \begin{bmatrix} L_{sc} & 0 \\ 0 & L_{sc} \end{bmatrix} \begin{bmatrix} i_{ds} \\ i_{qs} \end{bmatrix} - M_{sr} \begin{bmatrix} \dots & \dots & \cos j\alpha & \dots & \dots \\ \dots & \dots & \sin j\alpha & \dots & \dots \end{bmatrix} [i_r^j] \quad (2.31)$$

avec $\omega_r(rad/s)$ est la pulsation rotorique ou la vitesse électrique de rotor.

Donc, l'équation électrique du stator dans le repère rotorique s'écrit sous forme matricielle

$[V] = [R][I] + [L]\frac{d}{dt}[I]$ par le suivant:

$$\begin{bmatrix} v_{ds} \\ v_{qs} \end{bmatrix} = \begin{bmatrix} R_s & -\omega_r L_{sc} & \cdots & \omega_r M_{sr} \sin j\alpha & \cdots \\ \omega_r L_{sc} & R_s & \cdots & -\omega_r M_{sr} \cos j\alpha & \cdots \end{bmatrix} \begin{bmatrix} i_{ds} \\ i_{qs} \\ I_r^j \end{bmatrix} + \begin{bmatrix} L_{sc} & 0 & \cdots & -M_{sr} \cos j\alpha & \cdots \\ 0 & L_{sc} & \cdots & -M_{sr} \sin j\alpha & \cdots \end{bmatrix} \frac{d}{dt} \begin{bmatrix} i_{ds} \\ i_{qs} \\ i_r^j \end{bmatrix} \quad (2.32)$$

2.4.3 Équations rotoriques dans le référentiel dq

Pour simuler la rupture d'une barre rotorique k , il suffit d'augmenter sa résistance. Par conséquent, la valeur de résistance doit être augmentée à une valeur appropriée pour couper le courant traversant la barre rotorique selon la loi d'ohm ($I = V/R$). La figure 2.4




Figure 2.4: Représentation schématique des mailles rotoriques

illustre un schéma électrique équivalent de trois mailles de rotor adjacentes. Donc, selon la loi des mailles, la tension v_r^j est donnée par:

$$v_r^j = 0 = \frac{R_e}{N_r} i_r^j - R_{b(k-1)} i_b^{k-1} + \frac{R_e}{N_r} i_e^k + R_{bk} i_b^k + \frac{d}{dt} \Phi_r^j \quad (2.33)$$

La tension $v_r^j = 0$ puisque la cage rotorique est court-circuitée.

De plus, le flux total (Φ_r^j) induit dans la maille rotorique j est composé de la somme suivante:

$$\Phi_r^j = \Phi_{rp}^j + \Phi_{rr}^j + \Phi_{rs}^j + \Phi_{rf}^j \quad (2.34)$$

Tels que, Φ_{rp}^j est le flux principal:

$$\Phi_{rp}^j = L_{rp} i_r^j \quad (2.35)$$

avec Φ_{rr}^j est le flux mutuel entre la maille j et les autres mailles rotoriques i^{eme} :

$$\Phi_{rr}^j = M_{rr} \sum_{\substack{i=0 \\ i \neq j}}^{i=N_r-1} i_r^i \quad (2.36)$$

De plus, le flux mutuel stator-rotor (Φ_{rs}^j) est:

$$\Phi_{rs}^j = -\frac{3}{2}M_{sr} \left[\begin{array}{c|c} \vdots & \vdots \\ \cos j\alpha & \sin j\alpha \\ \vdots & \vdots \end{array} \right] \left[\begin{array}{c} i_{ds} \\ i_{qs} \end{array} \right] \quad (2.37)$$

De plus Φ_{rf}^j est le flux de fuite des barres rotoriques:

$$\Phi_{rf}^j = L_b(i_r^j - i_r^{j-1}) + \frac{L_e}{N_r}i_r^j + L_b(i_r^j - i_r^{j+1}) + \frac{L_e}{N_r}(i_r^j - i_e) \quad (2.38)$$

On peut écrire donc le suivant:

$$\Phi_r^j = (L_{rp} + 2L_b + 2\frac{L_e}{N_r})i_r^j + M_{rr} \sum_{\substack{i=0 \\ i \neq j}}^{i=N_r-1} i_r^j - \frac{3}{2}M_{sr}(i_{ds} \cos j\alpha + i_{qs} \sin j\alpha) + \frac{L_e}{N_r}(i_r^j + i_e^j) - L_b(i_r^{j-1} + i_r^j) - \frac{L_e}{N_r}i_e \quad (2.39)$$

Par conséquent:

$$\Phi_r^j = \left(L_{rp} + 2\frac{L_e}{N_r} + 2L_b \right) i_r^j - M_{rr} \sum_{\substack{i=0 \\ i \neq j}}^{i=N_r-1} i_r^j - L_b(i_r^{j-1} + i_r^{j+1}) - \frac{3}{2}M_{sr}(i_{ds} \cos j\alpha + i_{qs} \sin j\alpha) - \frac{L_e}{N_r}i_e \quad (2.40)$$

En remplaçant l'équation (2.40) dans l'équation (2.33). On obtient:

$$0 = \left[\left(\frac{2R_e}{N_r} + R_{bk} + R_{b(k-1)} \right) i_r^j + R_{b(k-1)}i_r^{j-1} + R_{b(k+1)}i_r^{j+1} + \frac{R_e}{N_r}i_e \right] + \left(L_{rp} + 2\frac{L_e}{N_r} + 2L_b \right) \frac{di_r^j}{dt} + M_{rr} \sum_{\substack{i=0 \\ i \neq j}}^{i=N_r-1} \frac{di_r^j}{dt} - L_b \frac{d}{dt}(i_r^{j-1} + i_r^{j+1}) - \frac{3}{2}M_{sr} \left(\frac{di_{ds}}{dt} \cos j\alpha + \frac{di_{qs}}{dt} \sin j\alpha \right) - \frac{L_e}{N_r} \frac{di_e}{dt} \quad (2.41)$$

Après cela, on peut ajouter l'équation de tension pour l'anneau de court-circuit (v_e^k):

$$v_e^k = 0 = \frac{R_e}{N_r} \sum_{j=0}^{N_r-1} i_r^j + \frac{L_e}{N_r} \sum_{j=0}^{N_r-1} \frac{d}{dt} i_r^j - R_e i_e^k - L_e \frac{d}{dt} i_e^k \quad (2.42)$$

Ensuite, nous pouvons écrire le système à multi-enroulements par un système d'états sous la forme matricielle de $[L]\frac{d}{dt}[I] = [V] - [R][I]$ par la suivante:

$$\begin{aligned}
 & \left[\begin{array}{cc|cccccc|c} L_{sc} & 0 & \cdots & \cdots & -M_{sr} \cos j\alpha & \cdots & \cdots & 0 \\ 0 & L_{sc} & \cdots & \cdots & -M_{sr} \sin j\alpha & \cdots & \cdots & 0 \\ \hline 0 & 0 & L_{rp} + \frac{2L_e}{N_r} + 2L_b & M_{rr} - L_b & \cdots & M_{rr} & M_{rr} - L_b & -\frac{L_e}{N_r} \\ 0 & 0 & M_{rr} - L_b & L_{rp} + \frac{2L_e}{N_r} + 2L_b & M_{rr} & \ddots & M_{rr} & \vdots \\ -\frac{3}{2}M_{sr} \cos j\alpha & -\frac{3}{2}M_{sr} \sin j\alpha & \vdots & \cdots & \ddots & \cdots & \ddots & \vdots \\ 0 & 0 & \vdots & \cdots & \cdots & \ddots & \cdots & \vdots \\ 0 & 0 & M_{rr} - L_b & M_{rr} & M_{rr} & M_{rr} - L_b & L_{rp} + \frac{2L_e}{N_r} + 2L_b & -\frac{L_e}{N_r} \\ \hline 0 & 0 & -\frac{L_e}{N_r} & \cdots & \cdots & \cdots & -\frac{R_e}{N_r} & L_e \end{array} \right] \frac{d}{dt} \begin{bmatrix} i_{ds} \\ i_{qs} \\ \vdots \\ \vdots \\ i_r^j \\ \vdots \\ \vdots \\ \vdots \\ i_e \end{bmatrix} \\
 & = \left[\begin{array}{cc|cccccc|c} R_s & -\omega_r L_{sc} & \cdots & \cdots & M_{sr} \omega_r \sin j\alpha & \cdots & \cdots & 0 \\ \omega_r L_{sc} & R_s & \cdots & \cdots & -M_{sr} \omega_r \cos j\alpha & \cdots & \cdots & 0 \\ \hline 0 & 0 & 2\frac{R_e}{N_r} + R_{b0} + R_{b(Nr-1)} & -R_{b0} & 0 & \cdots & -R_{b(Nr-1)} & -\frac{R_e}{N_r} \\ 0 & 0 & \vdots & \ddots & \cdots & \cdots & \cdots & \vdots \\ 0 & 0 & 0 & -R_{b(k-1)} & 2\frac{R_e}{N_r} + R_{bk} + R_{b(k-1)} & -R_{bk} & 0 & \vdots \\ 0 & 0 & \vdots & \cdots & \cdots & \ddots & \cdots & \vdots \\ 0 & 0 & -R_{b(Nr-1)} & 0 & 0 & -R_{b(Nr-2)} & 2\frac{R_e}{N_r} + R_{b(Nr-2)} + R_{b(Nr-1)} & -\frac{R_e}{N_r} \\ \hline 0 & 0 & -\frac{R_e}{N_r} & \cdots & \cdots & \cdots & -\frac{R_e}{N_r} & R_e \end{array} \right] \begin{bmatrix} i_{ds} \\ i_{qs} \\ \vdots \\ \vdots \\ i_r^j \\ \vdots \\ \vdots \\ \vdots \\ i_e \end{bmatrix} \quad (2.43)
 \end{aligned}$$

Après avoir atteint le modèle multi-enroulement (Eq.2.43) de la MAS, nous passons à l'équation mécanique.

2.4.4 Équations mécaniques

L'équation mécanique du MAS s'exprime par:

$$\frac{d\Omega_r}{dt} = \frac{1}{J}p(C_e - C_r - \frac{f}{p}\Omega_r) \quad (2.44)$$

où Ω_r [rad/s] est la vitesse mécanique de rotor, J est le moment d'inertie, f est le coefficient de frottement, C_e est le couple électromagnétique, C_r est le couple de charge (couple résistant).

Le couple électromagnétique C_e s'écrit sous la forme suivante:

$$\begin{aligned}
 C_e &= \frac{3}{2}p \begin{bmatrix} i_{ds} \\ i_{ds} \end{bmatrix} \frac{\partial}{\partial \theta_r} \begin{bmatrix} \cdots & -M_{sr} \cos(\theta_r + j\alpha) & \cdots \\ \cdots & -M_{sr} \sin(\theta_r + j\alpha) & \cdots \end{bmatrix} \begin{bmatrix} \vdots \\ i_r^j \\ \vdots \end{bmatrix} \\
 C_e &= \frac{3}{2}pM_{sr} \left\{ i_{ds} \sum_{j=0}^{N_r-1} i_r^j \sin j\alpha - i_{qs} \sum_{j=0}^{N_r-1} i_r^j \cos j\alpha \right\} \quad (2.45)
 \end{aligned}$$

avec θ_r est la position (l'angle) mécanique de rotor.

Donc, la simulation de rupture des barres du rotor consiste à augmenter uniquement la résistance de la barre du rotor sans que cela nécessite une nouvelle mise en équation. Par exemple, pour simuler une rupture de la première barre $k = 0$, il suffit d'augmenter la résistance R_b^0 tout en augmentant sa valeur de plus de 200 fois [Baghli, 1999].

Malheureusement, les dimensions du système (Eq.2.43) est élevée. Ce système se compose de deux équations pour le stator et de N_r équations pour la partie rotor, en plus de l'équation du d'annaux rotoriques. En conséquence, le total atteint $N_r + 3$ dimension. La simulation de ce système prend un temps considérable.

Afin de réduire la complexité de ce modèle (Eq.2.43), la transformation généralisée de Clarke permet d'obtenir un modèle mathématique appelé le modèle réduit. Ce dernier permet de simuler la rupture des barres rotoriques en un temps plus rapide et de manière plus simple.

2.5 Transformation de Clarke généralisée

L'objectif principal de cette section est de réduire les dimensions des équations de la cage rotorique de N_r équations à deux équations. Pour cela, la transformation généralisée de Clarke permet de passer de N_r grandeurs équilibrées à deux grandeurs dq équivalentes comme le montre la figure 2.5 [Khodja, 2007]. Donc, la projection de I_1 sur les axes i_r^j est donne comme suivant:

$$\begin{cases} i_r^0 = I_1 \cos \delta \\ i_r^1 = I_1 \cos \left(\delta + \frac{2\pi}{N_r} \right) \\ \vdots \\ i_r^{N_r-2} = I_1 \cos \left(\delta + \frac{2\pi(N_r-2)}{N_r} \right) \\ i_r^{N_r-1} = I_1 \cos \left(\delta + \frac{2\pi(N_r-1)}{N_r} \right) \end{cases} \quad (2.46)$$

Par conséquent :

$$I_1 = \frac{i_r^0}{\cos \delta} = \frac{i_r^1}{\cos(\delta + \frac{2\pi}{N_r})} = \frac{i_r^2}{\cos(\delta + \frac{4\pi}{N_r})} \dots \dots \frac{i_r^{N_r-2}}{\cos(\delta + \frac{2\pi(N_r-2)}{N_r})} = \frac{i_r^{N_r-1}}{\cos(\delta + \frac{2\pi(N_r-1)}{N_r})} \quad (2.47)$$

La projection de I_1 sur les axes dq :

$$\begin{cases} I_d = I_1 \cos(\theta - \delta) \\ I_q = -I_1 \sin(\theta - \delta) \end{cases} \quad (2.48)$$




Figure 2.5: Projection du modèle multi-enroulement sur le modèle dq

avec :

$$\begin{cases} \cos(\theta - \delta) = \frac{2}{N_r} \left[\cos \theta \cos \delta + \cos\left(\theta + \frac{2\pi}{N_r}\right) \cos\left(\delta + \frac{2\pi}{N_r}\right) + \dots + \cos\left(\theta + \frac{2\pi(N_r-2)}{N_r}\right) \cos\left(\delta + \frac{2\pi(N_r-1)}{N_r}\right) \right] \\ \sin(\theta - \delta) = \frac{2}{N_r} \left[\sin \theta \cos \delta + \sin\left(\theta + \frac{2\pi}{N_r}\right) \cos\left(\delta + \frac{2\pi}{N_r}\right) + \dots + \sin\left(\theta + \frac{2\pi(N_r-2)}{N_r}\right) \cos\left(\delta + \frac{2\pi(N_r-1)}{N_r}\right) \right] \end{cases} \quad (2.49)$$

Selon les équations (2.47) et (2.49), nous pouvons réécrire l'équation (2.48) comme suit:

$$\begin{cases} I_d = \frac{2}{N_r} \left[i_r^0 \cos \theta + i_r^1 \cos\left(\theta + \frac{2\pi}{N_r}\right) + i_r^2 \cos\left(\theta + \frac{4\pi}{N_r}\right) + \dots + i_r^{N_r-2} \cos\left(\theta + \frac{2\pi(N_r-2)}{N_r}\right) + i_r^{N_r-1} \cos\left(\theta + \frac{2\pi(N_r-1)}{N_r}\right) \right] \\ I_q = -\frac{2}{N_r} \left[i_r^0 \sin \theta + i_r^1 \sin\left(\theta + \frac{2\pi}{N_r}\right) + i_r^2 \sin\left(\theta + \frac{4\pi}{N_r}\right) + \dots + i_r^{N_r-2} \sin\left(\theta + \frac{2\pi(N_r-1)}{N_r}\right) + i_r^{N_r-1} \sin\left(\theta + \frac{2\pi(N_r-1)}{N_r}\right) \right] \end{cases} \quad (2.50)$$

Par conséquent, nous pouvons conclure ce qui suit:

$$\begin{bmatrix} I_d \\ I_q \end{bmatrix} = [T] \begin{bmatrix} i_r^0 \\ i_r^1 \\ \vdots \\ i_r^{N_r-2} \\ i_r^{N_r-1} \end{bmatrix} \quad (2.51)$$

avec $[T]$ et $[T]^{-1}$ sont des matrices données par:

$$[T] = \frac{2}{N_r} \begin{bmatrix} \cos 0 + \cos(\frac{2\pi}{N_r}) + \cos(\frac{4\pi}{N_r}) + \dots + \cos(\frac{2\pi(N_r-2)}{N_r}) + \cos(\frac{2\pi(N_r-1)}{N_r}) \\ \sin 0 - \sin(\frac{2\pi}{N_r}) - \sin(\frac{4\pi}{N_r}) - \dots - \sin(\frac{2\pi(N_r-2)}{N_r}) - \sin(\frac{2\pi(N_r-1)}{N_r}) \end{bmatrix}$$

$$[T]^{-1} = \begin{bmatrix} \cos 0 & \sin 0 \\ \cos(\frac{2\pi}{N_r}) & -\sin(\frac{2\pi}{N_r}) \\ \cos(\frac{4\pi}{N_r}) & -\sin(\frac{4\pi}{N_r}) \\ \vdots & \vdots \\ \cos(\frac{2\pi(N_r-2)}{N_r}) & -\sin(\frac{2\pi(N_r-2)}{N_r}) \\ \cos(\frac{2\pi(N_r-1)}{N_r}) & -\sin(\frac{2\pi(N_r-1)}{N_r}) \end{bmatrix}$$

Dans ce qui suit, nous utiliserons les matrices $[T]$ et $[T]^{-1}$ pour déduire les matrices des inductances $[L_{eq}]$ et des résistances $[R_{eq}]$ pour le modèle équivalent.

2.5.1 Matrice d'inductances et des résistances dans un modèle dq équivalent

Pour obtenir la matrice équivalente pour les résistances $[R_{eq}]$ pour les inductances $[L_{eq}]$, nous appliquerons les formules ci-dessous:

$$[R_{eq}] = {}^a[T] [R] {}^a[T]^{-1} \quad (2.52)$$

$$[L_{eq}] = {}^a[T] [L] {}^a[T]^{-1} \quad (2.53)$$

Donc, les équations (2.54) et (2.54) présente la matrice globale des résistances et des inductances de $N_r + 3$ grandeurs (dimension élevée) et leur équivalent.

$$\left[\begin{array}{cc|cccccc|c} R_s & -\omega_r L_{sc} & \dots & \dots & M_{sr}\omega_r \sin k\alpha & \dots & \dots & 0 \\ -\omega_r L_{sc} & R_s & \dots & \dots & -M_{sr}\omega_r \cos k\alpha & \dots & \dots & 0 \\ \hline 0 & 0 & 2\frac{R_e}{N_r} + R_{b0} + R_{b(N_r-1)} & -R_{b0} & 0 & \dots & -R_{b(N_r-1)} & -\frac{R_e}{N_r} \\ 0 & 0 & \vdots & \ddots & \dots & \dots & \dots & \vdots \\ 0 & 0 & 0 & -R_{b(k-1)} & 2\frac{R_e}{N_r} + R_{bk} + R_{b(k-1)} & -R_{bk} & 0 & \vdots \\ 0 & 0 & \vdots & \dots & \dots & \ddots & \dots & \vdots \\ 0 & 0 & -R_{b(N_r-1)} & 0 & 0 & -R_{b(N_r-2)} & 2\frac{R_e}{N_r} + R_{b(N_r-2)} + R_{b(N_r-1)} & -\frac{R_e}{N_r} \\ \hline 0 & 0 & -\frac{R_e}{N_r} & \dots & \dots & \dots & -\frac{R_e}{N_r} & R_e \end{array} \right] \equiv \left[\begin{array}{c|c|c} R_1 & R_2 & R_3 \\ \hline R_4 & R_5 & R_6 \\ \hline R_7 & R_8 & R_9 \end{array} \right] \quad (2.54)$$

$$\begin{bmatrix}
L_{sc} & 0 & \cdots & \cdots & -M_{sr} \cos k\alpha & \cdots & \cdots & 0 \\
0 & L_{sc} & \cdots & \cdots & -M_{sr} \sin k\alpha & \cdots & \cdots & 0 \\
0 & 0 & L_{rp} + \frac{2L_e}{N_r} + 2L_b & M_{rr} - L_b & \cdots & M_{rr} & M_{rr} - L_b & -\frac{L_e}{N_r} \\
0 & 0 & M_{rr} - L_b & L_{rp} + \frac{2L_e}{N_r} + 2L_b & M_{rr} & \ddots & M_{rr} & \vdots \\
-\frac{3}{2}M_{sr} \cos k\alpha & -\frac{3}{2}M_{sr} \sin k\alpha & \vdots & \cdots & \ddots & \cdots & \ddots & \vdots \\
0 & 0 & \vdots & \cdots & \cdots & \ddots & \cdots & \vdots \\
0 & 0 & M_{rr} - L_b & M_{rr} & M_{rr} & M_{rr} - L_b & L_{rp} + \frac{2L_e}{N_r} + 2L_b & -\frac{L_e}{N_r} \\
0 & 0 & -\frac{L_e}{N_r} & \cdots & \cdots & \cdots & -\frac{R_e}{N_r} & L_e
\end{bmatrix} = \begin{bmatrix} L_1 & L_2 & L_3 \\ L_4 & L_5 & L_6 \\ L_7 & L_8 & L_9 \end{bmatrix} \quad (2.55)$$

Donc, pour $[R_{1eq}] = [R_1]$, on peut d duire directement:

$$[R_{1eq}] = \begin{bmatrix} R_s & -\omega_r L_{sc} \\ \omega_r L_{sc} & R_s \end{bmatrix} \quad (2.56)$$

De la m me mani re pour $[L_{1eq}] = [L_1]$:

$$[L_{1eq}] = \begin{bmatrix} L_{sc} & 0 \\ 0 & L_{sc} \end{bmatrix} \quad (2.57)$$

Pour obtenir une petite dimension  quivalente   la matrice R_2 , on applique la relation suivante: $[R_{2eq}] = [R_2] [T]^{-1}$.

Par cons quent:

$$[R_{2eq}] = \begin{bmatrix} \cdots & M_{sr} \omega_r \sin j\alpha & \cdots \\ \cdots & -M_{sr} \omega_r \cos j\alpha & \cdots \end{bmatrix} \begin{bmatrix} \cos 0 & -\sin 0 \\ \cos(\frac{2\pi}{N_r}) & -\sin(\frac{2\pi}{N_r}) \\ \cos(\frac{4\pi}{N_r}) & -\sin(\frac{4\pi}{N_r}) \\ \vdots & \vdots \\ \vdots & \vdots \\ \cos(\frac{2\pi(N_r-2)}{N_r}) & -\sin(\frac{2\pi(N_r-2)}{N_r}) \\ \cos(\frac{2\pi(N_r-1)}{N_r}) & -\sin(\frac{2\pi(N_r-1)}{N_r}) \end{bmatrix} \quad (2.58)$$

Donc:

$$[R_{2eq}] = \begin{bmatrix} \sum_{j=0}^{N_r-1} (-M_{sr} \omega_r \sin j\alpha)(\cos j\alpha) & \sum_{j=0}^{N_r-1} -M_{sr} \omega_r \sin^2 j\alpha \\ \sum_{j=0}^{N_r-1} -M_{sr} \omega_r \cos^2 j\alpha & \sum_{j=0}^{N_r-1} (-M_{sr} \omega_r \sin j\alpha)(\cos j\alpha) \end{bmatrix} \quad (2.59)$$

Suivant la figure 2.5, chaque angle dans le premier quart du cercle correspond   un autre angle dans le deuxi me quart, ce qui rend la somme $\sin(j\alpha) \cos(j\alpha)$ pour chacun des deux angles nulle. Supposons, par exemple, les deux angles pour $\frac{2\pi}{N_r}$ et $\frac{30\pi}{N_r}$, donc, $\sin(\frac{2\pi}{N_r}) \cos(\frac{2\pi}{N_r}) + \sin(\frac{30\pi}{N_r}) \cos(\frac{30\pi}{N_r}) = 0$. Il en va de m me pour troisi me et le quatri me

quart du cercle. Par conséquent, on peut écrire le suivant:

$$\begin{cases} \sum_{j=0}^{N_r-1} (\sin j\alpha)(\cos j\alpha) = 0 \\ \sum_{j=0}^{N_r-1} (\cos j\alpha)(\sin j\alpha) = 0 \\ \sum_{j=0}^{N_r-1} \cos^2 j\alpha = \frac{N_r}{2} \\ \sum_{j=0}^{N_r-1} \sin^2 j\alpha = \frac{N_r}{2} \end{cases} \quad (2.60)$$

Donc, la matrice de résistance équivalente $[R_{2eq}]$ est donnée par:

$$[R_{2eq}] = \begin{bmatrix} 0 & -\frac{N_r}{2} \omega_r M_{sr} \\ -\frac{N_r}{2} \omega_r M_{sr} & 0 \end{bmatrix} \quad (2.61)$$

De la même manière pour $[L_{2eq}] = [L_2] [T]^{-1}$, on obtient:

$$[L_{2eq}] = \begin{bmatrix} \cdots & -M_{sr} \cos j\alpha & \cdots \\ \cdots & -M_{sr} \sin j\alpha & \cdots \end{bmatrix} \begin{bmatrix} \cos 0 & -\sin 0 \\ \cos(\frac{2\pi}{N_r}) & -\sin(\frac{2\pi}{N_r}) \\ \cos(\frac{4\pi}{N_r}) & -\sin(\frac{4\pi}{N_r}) \\ \vdots & \vdots \\ \vdots & \vdots \\ \cos(\frac{2\pi(N_r-2)}{N_r}) & -\sin(\frac{2\pi(N_r-2)}{N_r}) \\ \cos(\frac{2\pi(N_r-1)}{N_r}) & -\sin(\frac{2\pi(N_r-1)}{N_r}) \end{bmatrix} \quad (2.62)$$

Donc:

$$[L_{2eq}] = \begin{bmatrix} \sum_{j=0}^{N_r-1} -M_{sr} \cos^2 j\alpha & \sum_{j=0}^{N_r-1} (M_{sr} \cos j\alpha)(\sin j\alpha) \\ \sum_{j=0}^{N_r-1} (-M_{sr} \sin j\alpha)(\cos j\alpha) & \sum_{j=0}^{N_r-1} -M_{sr} \sin^2 j\alpha \end{bmatrix} \quad (2.63)$$

Selon l'équation (2.60), on peut conclure:

$$[L_{2eq}] = \begin{bmatrix} -\frac{N_r}{2} M_{sr} & 0 \\ 0 & \frac{N_r}{2} M_{sr} \end{bmatrix} \quad (2.64)$$

Pour $[R_{3eq}] = [R_3]$, on peut déduire directement que $[R_{3eq}]$ est prend une valeur nulle.

Donc:

$$[R_{3eq}] = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \quad (2.65)$$

De la même manière, $[L_{3eq}] = [L_3] = 0$

$$[L_{3eq}] = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \quad (2.66)$$

Pour $[R_{4eq}] = [R_4] [T]$:

$$[R_{4eq}] = \begin{bmatrix} 0 & 0 \\ \vdots & \vdots \\ \vdots & \vdots \\ 0 & 0 \end{bmatrix} \frac{2}{N_r} \begin{bmatrix} \cos 0 & \cos(\frac{2\pi}{N_r}) & \cos(\frac{4\pi}{N_r}) & \cdots & \cdots & \cdots & \cos(\frac{2\pi(N_r-2)}{N_r}) & \cos(\frac{2\pi(N_r-1)}{N_r}) \\ -\sin 0 & -\sin(\frac{2\pi}{N_r}) & -\sin(\frac{4\pi}{N_r}) & \cdots & \cdots & \cdots & -\sin(\frac{2\pi(N_r-2)}{N_r}) & -\sin(\frac{2\pi(N_r-1)}{N_r}) \end{bmatrix} \quad (2.67)$$

Par conséquent:

$$[R_{4eq}] = \begin{bmatrix} 0 & 0 \\ 0 & 0 \end{bmatrix} \quad (2.68)$$

Pour $[L_{4eq}] = [L_4] [T]$:

$$[L_{4eq}] = \begin{bmatrix} \vdots & \vdots \\ \vdots & \vdots \\ -\frac{3}{2}M_{sr} \cos k\alpha & -\frac{3}{2}M_{sr} \sin k\alpha \\ \vdots & \vdots \\ \vdots & \vdots \end{bmatrix} \frac{2}{N_r} \begin{bmatrix} \cos 0 + \cos(\frac{2\pi}{N_r}) + \cos(\frac{4\pi}{N_r}) + \cdots + \cos(\frac{2\pi(N_r-2)}{N_r}) + \cos(\frac{2\pi(N_r-1)}{N_r}) \\ \sin 0 - \sin(\frac{2\pi}{N_r}) - \sin(\frac{4\pi}{N_r}) - \cdots - \sin(\frac{2\pi(N_r-2)}{N_r}) - \sin(\frac{2\pi(N_r-1)}{N_r}) \end{bmatrix} \quad (2.69)$$

Donc:

$$[L_{4eq}] = \begin{bmatrix} -\frac{3}{2}M_{sr} & 0 \\ 0 & \frac{3}{2}M_{sr} \end{bmatrix} \quad (2.70)$$

Pour $[R_{5eq}] = [T] [R_5] [T]^{-1}$:

$$[R_{5eq}] = \frac{2}{N_r} \begin{bmatrix} \cos 0 & \cos(\frac{2\pi}{N_r}) & \cos(\frac{4\pi}{N_r}) & \cdots & \cdots & \cdots & \cos(\frac{2\pi(N_r-2)}{N_r}) & \cos(\frac{2\pi(N_r-1)}{N_r}) \\ -\sin 0 & -\sin(\frac{2\pi}{N_r}) & -\sin(\frac{4\pi}{N_r}) & \cdots & \cdots & \cdots & -\sin(\frac{2\pi(N_r-2)}{N_r}) & -\sin(\frac{2\pi(N_r-1)}{N_r}) \end{bmatrix} \times$$

$$\begin{bmatrix} \frac{2R_e}{N_r} + R_{b0} + R_{b(N_r-1)} & -R_{b0} & 0 & \cdots & -R_{b(N_r-1)} \\ \vdots & \ddots & \cdots & \cdots & \cdots \\ 0 & -R_{b(k-1)} & \frac{2R_e}{N_r} + R_{bk} + R_{b(k-1)} & -R_{bk} & 0 \\ \vdots & \cdots & \cdots & \ddots & \cdots \\ -R_{b(N_r-1)} & 0 & 0 & -R_{b(N_r-2)} & \frac{2R_e}{N_r} + R_{b(N_r-2)} + R_{b(N_r-1)} \end{bmatrix} \times \begin{bmatrix} \cos 0 & -\sin 0 \\ \cos(\frac{2\pi}{N_r}) & -\sin(\frac{2\pi}{N_r}) \\ \cos(\frac{4\pi}{N_r}) & -\sin(\frac{4\pi}{N_r}) \\ \vdots & \vdots \\ \cos(\frac{2\pi(N_r-2)}{N_r}) & -\sin(\frac{2\pi(N_r-2)}{N_r}) \\ \cos(\frac{2\pi(N_r-1)}{N_r}) & -\sin(\frac{2\pi(N_r-1)}{N_r}) \end{bmatrix} \quad (2.71)$$

On suppose que $[R_{5eq}]$ est écrit suivant:

$$[R_{5eq}] = \begin{bmatrix} R_{511} & R_{512} \\ R_{521} & R_{522} \end{bmatrix} \quad (2.72)$$

Après la simplification de l'équation (2.71), on peut écrire:

$$[R5_{11}] = \frac{2}{N_r} \left[\left(2\frac{R_e}{N_r} + R_{b0} + R_{b(N_r-1)} \right) \cos^2 0\alpha + \left(2\frac{R_e}{N_r} + R_{b1} + R_{b0} \right) \cos^2 1\alpha + \dots + \left(2\frac{R_e}{N_r} + R_{b(N_r-2)} + R_{b(N_r-1)} \right) \cos^2 (N_r-1)\alpha \right] - \frac{4}{N_r} \left[(R_{b0} \cos 0\alpha \cos 1\alpha) + (R_{b1} \cos 1\alpha \cos 2\alpha) + (R_{b2} \cos 2\alpha \cos 3\alpha) + \dots + (R_{b(N_r-1)} \cos (N_r-1)\alpha \cos 0\alpha) \right] \quad (2.73)$$

Ainsi que, $[R5_{22}]$ est donnée par :

$$[R5_{22}] = [R5_{11}] \quad (2.74)$$

Dans le suivant:

$$[R5_{12}] = -\frac{2}{N_r} \left[\left(2\frac{R_e}{N_r} + R_{b0} + R_{b(N_r-1)} \right) \cos 0\alpha \sin 0\alpha + \left(2\frac{R_e}{N_r} + R_{b1} + R_{b0} \right) \cos 1\alpha \sin 1\alpha + \left(2\frac{R_e}{N_r} + R_{b2} + R_{b1} \right) \cos 2\alpha \sin 2\alpha + \dots + \left(2\frac{R_e}{N_r} + R_{b13} + R_{b14} \right) \cos (N_r-2)\alpha \sin (N_r-2)\alpha + \left(2\frac{R_e}{N_r} + R_{b14} + R_{b15} \right) \cos (N_r-1)\alpha \sin (N_r-1)\alpha \right] + \frac{2}{N_r} \left[(R_{b0} \sin 0\alpha \cos 1\alpha) + (R_{b1} \sin 1\alpha \cos 2\alpha) + (R_{b2} \sin 2\alpha \cos 3\alpha) + \dots + (R_{b(N_r-1)} \sin (N_r-1)\alpha \cos 0\alpha) \right] + \frac{2}{N_r} \left[(R_{b0} \cos 0\alpha \sin 1\alpha) + (R_{b1} \cos 1\alpha \sin 2\alpha) + (R_{b2} \cos 2\alpha \sin 3\alpha) + \dots + (R_{b(N_r-1)} \cos (N_r-1)\alpha \sin 0\alpha) \right] \quad (2.75)$$

De plus, $[R5_{21}]$ est exprimé par le suivant:

$$[R5_{21}] = [R5_{12}] \quad (2.76)$$

Pour $[L5_{eq}] = [T] [L_5] [T]^{-1}$:

$$[L5_{eq}] = \frac{2}{N_r} \begin{bmatrix} \cos 0 & \cos(\frac{2\pi}{N_r}) & \cos(\frac{4\pi}{N_r}) & \dots & \dots & \dots & \cos(\frac{2\pi(N_r-2)}{N_r}) & \cos(\frac{2\pi(N_r-1)}{N_r}) \\ -\sin 0 & -\sin(\frac{2\pi}{N_r}) & -\sin(\frac{4\pi}{N_r}) & \dots & \dots & \dots & \cos(\frac{2\pi(N_r-2)}{N_r}) & -\sin(\frac{2\pi(N_r-1)}{N_r}) \end{bmatrix} \times \begin{bmatrix} L_{rp} + \frac{2L_e}{N_r} + 2L_b & M_{rr} - L_b & \dots & \dots & M_{rr} - L_b \\ M_{rr} - L_b & L_{rp} + \frac{2L_e}{N_r} + 2L & M_{rr} & \ddots & M_{rr} \\ \vdots & \dots & \ddots & \dots & \ddots \\ \vdots & \dots & \dots & \ddots & \dots \\ M_{rr} - L_b & M_{rr} & M_{rr} & \dots & L_{rp} + \frac{2L_e}{N_r} + 2L \end{bmatrix} \times \begin{bmatrix} \cos 0 & -\sin 0 \\ \cos(\frac{2\pi}{N_r}) & -\sin(\frac{2\pi}{N_r}) \\ \cos(\frac{4\pi}{N_r}) & -\sin(\frac{4\pi}{N_r}) \\ \vdots & \vdots \\ \cos(\frac{2\pi(N_r-2)}{N_r}) & -\sin(\frac{2\pi(N_r-2)}{N_r}) \\ \cos(\frac{2\pi(N_r-1)}{N_r}) & -\sin(\frac{2\pi(N_r-1)}{N_r}) \end{bmatrix} \quad (2.77)$$

On obtient:

$$[L5_{eq}] = \begin{bmatrix} L_{rc} & 0 \\ 0 & L_{rc} \end{bmatrix} \quad (2.78)$$

Pour $[R6_{eq}] = [T] [R_6]$:

$$[R6_{eq}] = \frac{2}{N_r} \begin{bmatrix} \dots & \cos j\alpha & \dots \\ \dots & -\sin j\alpha & \dots \end{bmatrix} \begin{bmatrix} \frac{-Re}{N_r} \\ \vdots \\ \vdots \\ \frac{-Re}{N_r} \end{bmatrix} \quad (2.79)$$

On considérons ce qui suit:

$$\begin{cases} \sum_{j=0}^{N_r-1} \cos j\alpha = 0 \\ \sum_{j=0}^{N_r-1} \sin j\alpha = 0 \end{cases} \quad (2.80)$$

Par conséquent:

$$[R_{6eq}] = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \quad (2.81)$$

Dans même manière, $[L_{6eq}] = [T] [L_6]$:

$$[L_{6eq}] = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \quad (2.82)$$

Pour $[R_{7eq}] = [R_7]$. On peut déduire directement:

$$[R_{7eq}] = \begin{bmatrix} 0 & 0 \end{bmatrix} \quad (2.83)$$

De la même façon pour $[L_{7eq}] = [L_7]$. On peut déduire:

$$[L_{7eq}] = \begin{bmatrix} 0 & 0 \end{bmatrix} \quad (2.84)$$

Pour $[R_{8eq}] = [R_8] [T]^{-1}$:

$$[R_{8eq}] = \begin{bmatrix} -\frac{R_e}{N_r} & \dots & \dots & -\frac{R_e}{N_r} \end{bmatrix} \begin{bmatrix} \vdots & \vdots \\ \cos j\alpha & -\sin j\alpha \\ \vdots & \vdots \end{bmatrix} \quad (2.85)$$

On remplace l'équation (2.80) dans l'équation (2.85), on obtient :

$$[R_{8eq}] = \begin{bmatrix} 0 & 0 \end{bmatrix} \quad (2.86)$$

Pour $[L_{8eq}] = [L_8] [T]^{-1}$, on peut déduire que:

$$[L_{8eq}] = \begin{bmatrix} 0 & 0 \end{bmatrix} \quad (2.87)$$

Pour $[R_{9eq}] = [R_9]$, on obtient:

$$[R_{9eq}] = [R_9] \quad (2.88)$$

De même manière, $[L_{9eq}] = [L_9]$:

$$[L_{9eq}] = [L_9] \quad (2.89)$$

Enfin, nous considérons que toutes les barres de rotor et l'anneau de court-circuit sont sains, la nouvelle matrice de résistance $[R_{eq}]$ du modèle dq équivalent s'écrit comme suit:

$$[R_{eq}] = \left[\begin{array}{cc|cc|c} R_s & -\omega_r L_{sc} & 0 & -\frac{N_r}{2} \omega_r M_{sr} & 0 \\ \omega_r L_{sc} & R_s & -\frac{N_r}{2} \omega_r M_{sr} & 0 & 0 \\ \hline 0 & 0 & R_r & 0 & 0 \\ 0 & 0 & 0 & R_r & 0 \\ \hline 0 & 0 & 0 & 0 & R_e \end{array} \right] \quad (2.90)$$

De plus, la nouvelle matrice d'inductance $[L_{eq}]$ de modèle dq équivalent est le suivant:

$$[L_{eq}] = \left[\begin{array}{cc|cc|c} L_{sc} & 0 & -\frac{N_r}{2} M_{sr} & 0 & 0 \\ 0 & L_{sc} & 0 & \frac{N_r}{2} M_{sr} & 0 \\ \hline -\frac{3}{2} M_{sr} & 0 & L_{rc} & 0 & 0 \\ 0 & \frac{3}{2} M_{sr} & 0 & L_{rc} & 0 \\ \hline 0 & 0 & 0 & 0 & L_e \end{array} \right] \quad (2.91)$$

Par conséquent, une représentation du système d'état de la MAS est obtenue en associant le vecteur d'état qui contient les courants statoriques et les courants rotoriques ainsi que l'entrée du système correspondant aux tensions statoriques selon les axes dq par le suivant:

$$[L] \frac{d}{dt} [I] = [V] - [R] [I] \quad (2.92)$$

On obtient, alors:

$$\left[\begin{array}{cc|cc|c} L_{sc} & 0 & -\frac{N_r}{2} M_{sr} & 0 & 0 \\ 0 & L_{sc} & 0 & \frac{N_r}{2} M_{sr} & 0 \\ \hline -\frac{3}{2} M_{sr} & 0 & L_{rc} & 0 & 0 \\ 0 & \frac{3}{2} M_{sr} & 0 & L_{rc} & 0 \\ \hline 0 & 0 & 0 & 0 & L_e \end{array} \right] \frac{d}{dt} \begin{bmatrix} i_{ds} \\ i_{qs} \\ i_{dr} \\ i_{qr} \\ i_e \end{bmatrix} = \begin{bmatrix} v_{ds} \\ v_{qs} \\ 0 \\ 0 \\ 0 \end{bmatrix} - \left[\begin{array}{cc|cc|c} R_s & -\omega_r L_{sc} & 0 & -\frac{N_r}{2} \omega_r M_{sr} & 0 \\ \omega_r L_{sc} & R_s & -\frac{N_r}{2} \omega_r M_{sr} & 0 & 0 \\ \hline 0 & 0 & R_{511} & R_{512} & 0 \\ 0 & 0 & R_{521} & R_{522} & 0 \\ \hline 0 & 0 & 0 & 0 & R_e \end{array} \right] \begin{bmatrix} i_{ds} \\ i_{qs} \\ i_{dr} \\ i_{qr} \\ i_e \end{bmatrix} \quad (2.93)$$

Nous pouvons donc écrire le système d'état sous suivant:

$$\begin{cases} \dot{x}(t) = Ax(t) + Bu(t) \\ y(t) = Cx(t) \end{cases} \quad (2.94)$$

avec:

$$\begin{cases} x = [i_{ds}i_{qs}i_{dr}i_{qr}i_e]^T; & \dot{x}(t) = \frac{dx}{dt} \\ u = [v_{ds}v_{qs}]^T; & y = [i_{ds}i_{qs}]^T \\ A = [R_{eq}] \times [L_{eq}]^{-1}; & B = [L_{eq}]^{-1} \end{cases}$$

$$C = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$

Après la transformation généralisée de Clarke, on peut écrire l'expression de couple électromagnétique par le suivant:

$$C_e = \frac{3}{2}pN_rM_{sr}(i_{ds}i_{qr} - i_{qs}i_{dr}) \quad (2.95)$$

2.6 Simulation de modèle réduit de la MAS

Après avoir terminé le processus de préparation du modèle (Eq.2.93) que permettant de simuler la MAS en rupture des barres rotoriques, nous présenterons ci-dessous les résultats de la simulation du MAS en montrant l'évaluation des leurs grandeurs mesurables: la vitesse du rotor (ω_r), le couple électromagnétique (C_e), et les trois courants statoriques (i_{sa}, i_{sb}, i_{sc}). Tout d'abord, une simulation de machine sera présentée pour une machine saine. Pour cela, nous utilisons le système (2.93) avec la condition qui dépend de l'équation (2.90). Dans ce qui suit, la machine est simulée à l'état de ruptures des barres rotorique en utilisant les équations (2.73-2.76) avec le modèle (2.93).

2.6.1 Simulation de MAS a l'état sain

La simulation est réalisée avec le modèle (2.93) avec les paramètres de MAS indiqués dans le tableau 2.1. Nous avons utilisé le logiciel **MATLAB R2016a** pour la simulation de la MAS, de plus, la résolution des équations différentielles est effectuée par la méthode de commande Runge-Kutta d'ordre 4 (RK4) avec une période d'échantillonnage de $0,1ms$ (i.e: 10^{-4}). Dans MATLAB/Simulink, nous considérons que le MAS est alimenté directement par une source de tension sinusoïdale triphasée et équilibrée (v_{sabc}), puis nous appliquons la transformation Park triphasée biphasée ($v_{sabc} \rightarrow v_{sdq}$), la MAS fonctionne au démarrage sans charge (i.e: à vide), et après avoir chargé la machine avec un couple résistant de $C_r = 7(Nm)$ a $t = 0.7s$.

Table 2.1: Paramètres de MAS utilisée pour la simulation

P_n	Puissance nominale	$1.1kW$
V_s	Tension nominale	$230/400V$
V_s	Courant nominale	$2.6/4.3A$
Ω_n	Vitesse nominale	$1425tr/min$
f_s	Fréquence d'alimentation	$50Hz$
R	Rayon du rotor	$45mm$
e	Épaisseur de l'entrefer	$0.58mm$
L	Longueur active du rotor	$54mm$
p	Nombre de pairs de pôles de la MAS	2
M_{sr}	Inductance mutuelle	$1.73 \times 10^{-4}H$
R_s	Résistance statorique	9.81Ω
L_{sf}	Inductance de fuite d'une phase statorique	$0.021H$
R_{bar}	Résistance de la barre rotorique	$6.1 \times 10^{-7}\Omega$
L_b	Inductance de la barre rotorique	$1.7 \times 10^{-9}H$
R_e	Résistance de l'anneau rotorique	$5.6 \times 10^{-7}\Omega$
L_e	Inductance de l'anneau rotorique	$1.7 \times 10^{-9}H$
N_s	Nombre totale de spires par phase	464
N_b	Nombres totales des barres rotorique	28
f_d	Coefficient de frottement	0.00119 SI
J	Moment d'inertie	0.0125 SI

Par conséquent, les figures 2.6-2.8 illustrent l'évolution de la vitesse de rotation (vitesse électrique ω_r), du couple électromagnétique et des trois courants statoriques. Dans ce cas, on remarque que la vitesse du rotor atteint $314rad/s$ et diminue légèrement ($296.3rad/s$) lorsque la machine est chargée. Il est également possible de noter que le couple électromagnétique de démarrage a atteint une valeur maximale de $32Nm$, il est ensuite revenu se stabiliser à zéro, une fois la charge résistive appliquée au MAS, le couple électromagnétique augmente pour correspondre à la valeur du couple de charge ($C_{em} = 7.18Nm$). Il y a un fort appel aux courants statoriques ($15A$) au démarrage de la machine. Après l'achèvement du régime transitoire, on constate que les trois courants statoriques se sont stabilisés et sont bien équilibrés a une amplitude de $2.6A$.

Après avoir simulé le comportement du MAS dans l'état normal, nous simuler, dans ce qui suit, le MAS en cas de rupture des barres.




Figure 2.6: Simulation de la MAS dans un état sain- Courants statoriques




Figure 2.7: Simulation de la MAS dans un état sain- Vitesse de rotation




Figure 2.8: Simulation de la MAS dans un état sain- Couple électromagnétique

2.6.2 Simulation de la MAS en présence de défaut rotorique

Comme mentionné précédemment, pour simuler la coupure du courant traversant une barre de rotor, il suffit d'augmenter la résistance de la barre cible. Pour cela, les équations (2.73-2.76) sont utilisées pour vérifier la simulation de la défaillance des barres de rotor. Selon des études antérieures, afin de couper le courant dans l'une des barres de rotor, la résistance de la barre est multipliée par un coefficient positif $\rho \geq 11$ [Baghli, 1999].

Cependant, il est important de noter que dans le cas réel (pratiquement), le courant dans la barre cassée n'est jamais nul.

Donc, nous gardons les mêmes conditions de démarrage précédent, c'est-à-dire: un démarrage à vide, alimentation sinusoïdale, on applique une charge de $7Nm$ à $t = 0.7s$. Une fois le régime transitoire terminé, on applique la rupture de la première barre ($k = 0$) à $t = 1s$ en augmentant sa résistance de 11 fois ($R_{bdef}^{k=0} = 11 \times R_b^0$). À l'instant $t = 2s$, nous simulons la rupture de la deuxième barre adjacente ($R_{bdef}^{k=1} = 11 \times R_b^2$) pour mettre en évidence l'effet du nombre de barres brisées. La troisième barre cassée à $t = 3s$ et pour $k = 2$ avec ($R_{bdef}^{k=2} = 11 \times R_b^2$).

Donc, les figures 2.9-2.11 montrent que la rupture des barres du rotor crée des oscillations à la vitesse du rotor et au couple électromagnétique, ainsi qu'une modulation des courants statoriques. Ces ondulations augmentent selon le nombre des barres cassées.

En bref, il convient de noter que l'apparition de barres cassées a entraîné un déséquilibre dans le fonctionnement du MAS, en conséquence, des déséquilibres sont apparus dans les signaux mesurables.

Dans la section suivante, nous montrerons le comportement de la MAS en cas de défaut statorique (court-circuit entre spires). Avant cela, il est important de noter que le modèle mathématique (Eq.2.93) utilisé jusqu'à présent n'est valable que pour simuler la défaillance des barres de rotor. Par conséquent, dans la suite, nous allons généraliser ce modèle pour qu'il soit valide afin de simuler un défaut statorique. Pour cela, nous gardons le même modèle précédent (Eq.2.93) avec l'ajout d'une matrice dans la partie stator, à travers laquelle nous pouvons simuler le défaut de court-circuit entre spires. Dans ce qui suit, nous présentons les détails.

2.7 Modèle réduit avec un défaut de court-circuit entre spires

Dans ce travail, le défaut de court-circuit entre spires dans une phase statorique de MAS sera simulé en utilisant le même modèle (2.73-2.76) avec l'ajout d'une matrice supplémentaire permettant de simuler la présence de court-circuit [Bachir et al., 2006, Bachir, 2002, Saddam et al., 2018a].

Donc, ce type de défaut peut être considéré comme un nouvel enroulement statorique (B_{cc}) en parallèle avec les trois enroulements de stator et localisé selon la première phase- a avec angle de $\theta_{cc} = \frac{2\pi}{3}$ (Fig.2.12), le nouveau bobinage crée un champ magnétique




Figure 2.9: Simulation de la MAS en rupture des barres - Courants statoriques




Figure 2.10: Simulation de la MAS en rupture des barres- Vitesse de rotation




Figure 2.11: Simulation de la MAS en rupture des barres- Couple électromagnétique

stationnaire (H_{cc}) orienté en fonction du bobinage défectueux. Pour cela, le nombre de spires en court-circuit (N_{cc}) peut être exprimé comme une bobine supplémentaire (B_{cc}). En principe, un défaut de court-circuit entre spires dans l'une des trois phases a , b ou c de moteur réduit le nombre utile de spires (N_u) au niveau de l'enroulement statorique. Donc, le nombre de spires utiles (N_u^m) pour chaque phase du stator est donné comme suit:




Figure 2.12: Schéma des enroulements statoriques avec un court-circuit de phase a

$$\begin{cases} N_u^a = N_s - N_{cc}^a \\ N_u^b = N_s - N_{cc}^b \\ N_u^c = N_s - N_{cc}^c \end{cases} \quad (2.96)$$

Dans l'état normal du MAS, l'expression précédente (2.96) est donnée par:

$$N_u^a = N_u^b = N_u^c = N_s \quad (2.97)$$

On peut donc définir les trois coefficients de court-circuit η_{cc}^a , η_{cc}^b et η_{cc}^c correspondant respectivement à la trois phases de stator (a, b, c) de la machine comme suit:

$$\eta_{cc}^m = \frac{N_{cc}^m}{N_s} \quad (2.98)$$

De plus, la résistance statorique de chaque phase (R_s^m) est proportionnelle au nombre de spires utiles. Une fois qu'un défaut de court-circuit entre les spires s'est produit dans l'une des phases du stator, une résistance de court-circuit (R_{cc}) de l'enroulement de défaut équivalent est augmentée et peut être exprimée par:

$$\begin{cases} R_{cc}^a = \eta_{cc}^a R_s \\ R_{cc}^b = \eta_{cc}^b R_s \\ R_{cc}^c = \eta_{cc}^c R_s \end{cases} \quad (2.99)$$

Le défaut de court-circuit peut être simulé sur la base de deux variables principales:

- L'angle θ_{cc} localisant la phase court-circuitée. Cet angle peut prendre les valeurs $0, \frac{2\pi}{3}, \frac{2\pi}{3}$ selon l'emplacement du défaut, soit dans la première phase (a), la deuxième (b) ou la troisième phase (c), respectivement;

- Le rapport de court-circuit η_{cc}^m (Eq.2.98) que indique le taux de défaut de court-circuit entre spires;

Selon les hypothèses simplificatrices mentionnées au (Sec.2.2), en outre, en négligeant les chutes de tension dues à la résistance statorique R_s , et en considérant que la cage du rotor est saine, le système d'état MAS en la présence d'un défaut de court-circuit entre les spires s'écrit comme suit:

$$\begin{cases} \dot{x}(t) = Ax(t) + Bu(t) \\ y(t) = Cx(t) + Du(t) \end{cases} \quad (2.100)$$

Les variables du système (2.100) ($\dot{x}, x, A, B, C, u, y$) sont définis dans l'équation (2.94). De plus, D est la matrice de court-circuit qui est définie par ce qui suit:

$$D = \sum_{m=1}^3 \frac{2\eta_{cc}^m}{3R_s} P(-\theta) \varpi(\theta_{cc}^m) P(\theta) \quad (2.101)$$

où $P(\theta)$ est la matrice de rotation de Park définie par l'équation (2.27):

et $\varpi(\theta_{cc}^m)$ est la matrice localisant l'enroulement de court-circuit décrit comme suit:

$$\varpi(\theta_{cc}^m) = \begin{bmatrix} \cos(\theta_{cc}^m)^2 & \cos(\theta_{cc}^m) \sin(\theta_{cc}^m) \\ \cos(\theta_{cc}^m) \sin(\theta_{cc}^m) & \sin(\theta_{cc}^m)^2 \end{bmatrix} \quad (2.102)$$

Par conséquent, les courants de court-circuit (i_{dqcc}^s) qui traverse la bobine B_{cc} selon les axes de Park dq est donné en fonction de D par le suivant:

$$\begin{cases} i_{dcc}^s = Dv_d^s = \sum_{m=1}^3 \frac{2\eta_{cc}^m}{3R_s} P(-\theta) \varpi(\theta_{cc}^m) P(\theta) v_d^s \\ i_{qcc}^s = Dv_q^s = \sum_{m=1}^3 \frac{2\eta_{cc}^m}{3R_s} P(-\theta) \varpi(\theta_{cc}^m) P(\theta) v_q^s \end{cases} \quad (2.103)$$

Dans le cas d'un stator sain, la matrice D prend une valeur nulle ($D = 0$). Au contraire, pour un défaut statorique la matrice $D \neq 0$.

Dans ce cas, nous présenterons dans le suivant le comportement de la machine en cas de défaut statorique (court-circuit entre spires).

2.7.1 Simulation de MAS en présence d'un défaut statorique

Dans cette partie, nous étudierons la présence du court-circuit entre les spires et leur effet sur le comportement de la machine selon le système d'équations ci-dessus (Eqs.2.100-2.103).

Dans les mêmes conditions de démarrage précédent (démarrage à vide, $C_r = 7Nm$ à $t = 0.7s$, les figures 2.13-2.15 montrent respectivement la vitesse de rotation, le couple électromagnétique et les courants statoriques de la MAS. Dans ce cas, la vitesse du rotor diminue ensuite jusqu'à la vitesse nominale et le couple électromagnétique équilibre le couple résistif. On constate également que le déphasage entre les trois phases des courants statoriques est équilibré.

À $t = 2s$, nous simulons le court-circuit de 29 spires dans la phase a . Ainsi, $\eta_{cc}^a = \frac{29}{464} = 0.0625$. Ensuite, à $t = 3s$, le nombre de spires en court-circuit est augmenté pour atteindre 58 spires $\eta_{cc}^a = \frac{58}{464} = 0.1250$. Dans le cas de la sélection d'un défaut au premier phase (phase a), les deux facteurs (η_{cc}^b, η_{cc}^c) de les autres phases (b, c) prennent une valeur nulle.

Lorsqu'un court-circuit se produit, le système de la machine perd son équilibre, ce qui entraîne l'apparition de déséquilibres dans ses différents signaux. Il est également possible d'observer que le taux d'oscillation augmente en fonction du nombre de spires court-circuitées. Selon les figures 2.13-2.15, on peut noter que l'effet d'un défaut de court-circuit entre spires peut être clairement observé sur les courbes de couple et les courants statoriques. De plus, il existe un déséquilibre dans les déphasages entre les trois courants statoriques qui n'est plus égal à 120° comme dans le cas normal précédent (Fig.2.6).

2.8 Modèle global de la MAS

Dans cette section, nous allons combiner les conditions de rupture des barres rotoriques (Eqs.2.73-2.76) avec les conditions de défauts de court-circuit entre spires (Eqs.2.100-2.103) (Nous l'appelons: le modèle global). Cette combinaison montre l'effet des défauts simultanés sur l'évaluation des signaux mesurables de la machine. Par conséquent, pour simuler la rupture des barres du rotor, il suffit d'augmenter la résistance de la barre sélectionnée. D'autre part, pour simuler le court-circuit entre les spires, il suffit de sélectionner la phase dans laquelle se produit le défaut en fonction du choix de l'angle (θ_{cc}^m) et du paramètre (η_{cc}^m).

2.8.1 Simulation de modèle global de la MAS

La simulation du modèle global (défauts de court-circuit et de rupture des barres du rotor) de la machine est d'abord réalisée pour une MAS saine en démarrage à vide, alimentation sinusoïdale, on applique une charge de $7Nm$ à $t = 0.7s$. À l'instant $t = 1s$, nous simulons




Figure 2.13: Simulation de la MAS en court-circuit entre spires- Courants statoriques




Figure 2.14: Simulation de la MAS en court-circuit entre spires- Vitesse de rotation




Figure 2.15: Simulation de la MAS en court-circuit entre spires- Couple électromagnétique

un court-circuit de 29 spires au niveau de la première phase (c-à-d: $\varpi(\theta_{cc}^m) = \varpi(\theta_{cc}^a)$), en plus $\eta_{cc}^b = \eta_{cc}^c = 0$, alors le nombre de spires raccourcis est augmenté à 58 spires à $t = 2s$. Dans ces conditions, et à $t = 3s$, on simule la rupture de la première barre ($k = 0$) en augmentant sa résistance de 11 fois sa valeur initiale, puis on simule la rupture d'une seconde barre adjacente ($k = 1$) à $t = 4s$.

Les figures 2.16-2.18 montrent l'évolution de la vitesse rotorique, de couple électromagnétique et des courants statoriques au cours de cette simulation. Par conséquent, les résultats de




Figure 2.16: Simulation de la MAS en défaut simultané- Courants statoriques




Figure 2.17: Simulation de la MAS en défaut simultané- Vitesse de rotation




Figure 2.18: Simulation de la MAS en défaut simultané- Couple électromagnétique

la simulation montrent l'existence de grandes ondulations et apparences dans les signaux de la MAS. On voit que lorsque le défaut simultané (stator et rotor) se produit, il est possible de remarquer que le comportement des courbes indique que les deux types de défauts existent simultanément, où la défaillance de la phase statorique introduit une forte augmentation dans l'amplitude des signaux. De plus, la présence de rupture dans les barres du rotor entraîne des distorsions dans la forme des signaux.

2.9 Conclusion

Ce chapitre a été consacré à la modélisation des MAS en vue de leur diagnostic en présence de courts-circuits entre spires et de rupture des barres du rotor.

Premièrement, le passage à un modèle diphasé équivalent (modèle réduit) utilisant une transformation de Clarke généralisée, nous a permis de réduire les dimensions du système de $Nr + 3$ grandeurs à deux équivalents dq grandeurs. À l'aide de ce modèle, nous avons pu mettre en évidence les phénomènes liés à la rupture des barreaux dans le rotor et au court-circuit entre spires telles que l'oscillation du couple, de la vitesse ainsi que des courants statoriques.

Dans le chapitre qui suit, nous ne gardons que les signaux des courants statoriques pour détecter l'état de la machine, qu'il s'agisse d'un état normal ou d'un état de défaut. Donc, ce chapitre se concentrera sur l'analyse du signal de courant statorique pour en déduire l'état du la MAS. Trois techniques analytiques seront appliqués sont: FFT, MUSIC et la DWT.

Chapitre 3

DÉTECTION DE DÉFAUTS DE ROTOR ET DE STATOR DE LA MACHINE ASYNCHRONE PAR TRAITEMENT DE SIGNAL

3.1 Introduction

Après avoir présenté et discuté le modèle de simulation (Eqs.2.94,2.100), qui permet d'observer le comportement du MAS dans différentes conditions de fonctionnement, que ce soit dans des conditions normales ou en défaut rotorique et statorique. Dans ce chapitre, nous nous concentrons sur la détection de l'état du MAS, qu'elle soit saine ou défaillante. Il convient donc de rappeler que le traitement du signal de courant statorique est le plus populaire dans le domaine du diagnostic, étant le plus efficace, simple et peu coûteux. Comme mentionné ci-dessus, l'analyse temporelle des signaux extraits n'est souvent pas suffisante pour fournir un diagnostic efficace de la machine. Par conséquent, les plus grandes études ont été rapportées pour analyser les de la machine signaux dans les domaines de fréquence ou de temps-fréquence afin d'augmenter les performances de diagnostic.

Dans la littérature, une grande partie des publications sur le diagnostic des machines a accordé une grande attention à la détection des ruptures de barres rotoriques. En particulier, la détection de ce type de défaut est plus difficile par rapport aux autres types de défaut. Pour cela, l'efficacité des techniques de traitement du signal est généralement

évaluée par leur capacité à détecter la rupture des barres rotoriques.

En général, la technique la plus couramment utilisée pour l'analyse du signal depuis longtemps est la FFT, qui est la technique la plus simple et la plus pratique par rapport aux autres techniques. Cependant, lors de l'extraction des fréquences de défaut, la FFT souffre de plusieurs facteurs qui diminuent son efficacité (ss.sec.??).

Pour cette raison, des méthodes à haute résolution telle que MUSIC ont été suggérées pour remplacer la FFT dans le littérateur. La technique MUSIC a été appliquée au signal de courant statorique et son enveloppe afin d'améliorer la détection des défauts [Kia et al., 2007, Kim et al., 2012, Choqueuse et al., 2015, Saddam et al., 2018b, Bensaoucha et al., 2020].

Dans le même contexte, de nombreux chercheurs se sont intéressés au diagnostic des défauts des MAS à l'aide de DWT [Bouzida et al., 2010, Riera-Guasp et al., 2008, Bensaoucha et al., 2020]. La DWT est une technique puissante basée sur l'analyse multirésolution qui décompose les signaux non stationnaires en différentes bandes de fréquences. Dans ce chapitre, nous appliquerons les trois techniques de FFT, MUSIC et DWT pour détecter la rupture des barres rotoriques et le court-circuit entre spires d'une MAS à cage rotorique.

3.2 Analyse spectrale pour détecter la rupture des barres rotoriques

Dans cette section, nous appliquerons les techniques d'analyse spectrale de courant statorique pour extraire les fréquences indiquant la rupture des barres du rotor. Nous commencerons par la FFT et puis la technique de MUSIC.

3.2.1 FFT pour détecter une rupture des barres rotoriques

La FFT permet de décrire dans l'espace fréquentiel d'un signal temporel $x(t)$ selon la relation ci-dessous:

$$FFT[x(t)] = x(f) = \int_{-\infty}^{+\infty} x(t)e^{-j2\pi f.t} dt \quad (3.1)$$

La figure 3.1 présente le signal de courant statorique-phase a pour une MAS à l'état sain et en rupture des barres rotoriques. Une charge de $7Nm$ a été appliquée à la MAS. Pour détecter ce type de défaut, l'analyse spectrale du courant statorique fait apparaître des

composantes latérales par rapport au fondamental correspondant à $f_s(1 \pm 2kg)$. Donc, nous appliquerons la FFT pour extraire ces fréquences $f_s(1 \pm 2kg)$. Généralement, la FFT est appliqué sur une signale dans un régime permanent. Avant cela, il convient de




Figure 3.1: Courant statorique i_{sa} - MAS saine et en rupture des barres

noter que l'efficacité de la FFT était directement liée au choix de certains paramètres, notamment [Abed, 2002, Boumegoura, 2001]:

- Sélection d'une fenêtre de pondération (fenêtre rectangulaire, Hanning, ...) qui permet de séparer les fréquences très proches de la fréquence fondamentale;
- Choisir la bonne taille de fenêtre pour améliorer la précision autant que possible;
- Augmenter le temps d'acquisition du signal autant que possible;
- Le choix de l'échelle logarithmique ou linéaire.

Dans notre travail, afin d'obtenir un bon diagnostic et pour séparer les fréquences des défauts liées aux ruptures des barres rotoriques, la fenêtre de Hanning a été sélectionnée avec une taille de fenêtre de 80000 et une fréquence d'échantillonnage f_e de 10^{-4} . Le temps d'acquisition est 8s suivant un régime permanent de la MAS (Fig.3.1). Donc, le spectre du courant statorique obtenu avec une résolution $\Delta f = \frac{1}{T_s} = 0.0125Hz$. L'échelle logarithmique a également été sélectionnée pour améliorer la résolution. Il faut noter que le signal de courant statorique a été analysé dans 8s (en régime permanent) pour chaque cas de la MAS en état normal ou en rupture des barres de rotor.

par conséquent, la figure 3.2 montre les résultats obtenus pour une MAS saine, avec une barre cassée, deux barres et trois barres cassées. D'après les résultats obtenus pour une MAS saine, seule la fréquence fondamentale de $50Hz$ est générée par la FFT. Par

contre, la cassure des barres apparaît de nouvelles harmoniques autour de la fréquence fondamentale selon la relation de $f_s(1 \pm 2kg)$. De plus, on peut clairement noter des composantes harmoniques supplémentaires $[(1 \pm 4g)f_s, (1 \pm 6g)f_s]$ autour du fondamental ce qui permet d'indiquer une augmentation du nombre de barres cassées.




Figure 3.2: FFT de courant statorique i_{sa} [0-100 Hz] - MAS saine et en rupture des barres

Dans ce qui suit, nous remplacerons la FFT par la technique de MUSIC afin de détecter la rupture des barres du rotor. Nous appliquerons cette technique au même signal de courant statorique illustré dans la figure 3.1.

3.2.2 MUSIC pour détecter une rupture des barres rotoriques

L'algorithme de MUSIC est développée dans la catégorie des techniques de traitement du signal à haute résolution. Cette technique a été introduite dans le domaine du diagnostic des défauts des MAS afin d'améliorer la détection des caractéristiques des défauts, tout en surmontant certains inconvénients rencontrés par la FFT.

3.2.2.1 Principe de MUSIC

L'algorithme de MUSIC estime le pseudospectre à partir d'un signal ou d'une matrice de corrélation en utilisant la méthode d'analyse spatiale numérique de Schmidt. MUSIC effectue une analyse d'espace propre de la matrice de corrélation de signal pour estimer le contenu fréquentiel du signal. Cet algorithme est particulièrement adapté aux signaux qui sont la somme des sinusoides avec un bruit gaussien additif. En principe, la MUSIC est appliquée pour réduire l'influence du bruit accompagnant le signal analysé [Kim et al., 2012, Kia et al., 2007, Garcia-Perez et al., 2011].

Mathématiquement, les méthodes de sous-espace supposent que le signal de temps discret $x[n]$ peut être représenté par la somme des ℓ sinusoides complexes et le signal de bruit $e[n]$ comme suit [Kim et al., 2012, Kia et al., 2007, Garcia-Perez et al., 2011]:

$$x[n] = \sum_{i=1}^{\ell} \overline{B_i} e^{j2\pi f_i n} + e[n] \quad (3.2)$$

avec $n = 0, 1, 2, 3, \dots$ est le nombre d'échantillons. De plus, B_i est l'amplitude complexe de i^{eme} sinusoides complexe, ce qui donne comme suit :

$$\overline{B_i} = |B_i| e^{j\vartheta} \quad (3.3)$$

avec f_i et ϑ sont, respectivement, la fréquence et la phase de i^{eme} sinusoides complexe, et $e[n]$ est le signal de bruit.

Pisarenko a découvert que les fréquences des sinusoides peuvent être obtenues à partir du vecteur propre qui correspond aux plus petites valeurs propres de la matrice d'autocorrélation, ce qui a conduit à de nombreuses nouvelles procédures connues par le sous-espace de signal/bruit. Pour cela, pour le moyen de $e[n]$ est nul avec une variance σ^2 , la matrice d'autocorrélation $[R_{Ac}]$ de $x[n]$ peut être représenté par:

$$[R_{Ac}] = \sum_{i=1}^s |B_i|^2 e^{j2\pi f_i} e^{H}(f_i) + \sigma^2 M_{ID} \quad (3.4)$$

avec H est l'exposant la transposée hermitienne, M_{ID} est la matrice d'identité, et $e^{H}(f_i)$ est le vecteur du signal donné par :

$$e^{H}(f_i) = [1 e^{j2\pi f_i} e^{j4\pi f_i} \dots e^{j(N-1)f_i}]^T \quad (3.5)$$

En résumé, à partir de la condition d'orthogonalité de deux sous-espaces, le pseudospectrum de MUSIC du vecteur espace est défini comme suit :

$$P_{MUSIC}(f) = \frac{1}{\sum_{\kappa=\rho+1}^D |v_{\kappa}^H e(f)|^2} \quad (3.6)$$

où D est la dimension des vecteurs propres et v_κ est le κ^{eme} vecteur propre de la matrice de corrélation. L'entier ρ est la dimension du sous-espace du signal. Le vecteur $e(f)$ est constitué d'exponentielles complexes des signaux.

Alors, à l'aide de MATLAB R2016a, on s'appuie sur la technique de MUSIC afin de détecter la rupture des barres rotoriques. Il faut noter que les résultats de pseudospectre par MUSIC dépendent de la sélection des certains paramètres, notamment le nombre des sinusoides complexe (ℓ) et la longueur de segment σ . En fait, il n'existe aucune base théorique permettant de déterminer la valeur exacte de ces paramètres. Seuls des calculs approximatifs sont utilisés [Kim et al., 2012, Kia et al., 2007, Garcia-Perez et al., 2011]. Les résultats obtenus dans la figure 3.3 sont présentés selon l'approximation suivante: $\ell \in (100 : 200)$ et $\sigma \in (4000 : 7000)$, le temps d'acquisition est 8s selon un régime permanent (Fig. 3.1), une fenêtre rectangulaire est sélectionnée.




Figure 3.3: MUSIC de courant statorique i_{sa} [0-100Hz] - MAS sain et en rupture des barres

Les résultats obtenus montrent que seule la fréquence fondamentale ($f_s = 50Hz$) a été extraite par la technique MUSIC dans l'état sain de la machine. D'autre part, nous pouvons remarquer de nouvelles harmoniques (44 et 55.9Hz) autour du fondamental lorsqu'une barre cassée s'est produite. Lorsque l'intensité du défaut augmente (deux

et trois barres cassées), de nouvelles harmoniques peuvent être observées autour de la fréquence fondamentale.

3.3 Analyse spectrale pour détecter un court-circuit entre spires

Dans cette section, les deux techniques de FFT et MUSIC sont appliquées pour traiter le signal de courant statorique afin d'extraire les fréquences spécifiques aux défauts de court-circuit entre les spires. La figure 3.4 montre le signal du courant statorique i_{sa} pour une MAS saine et avec un court circuit entre spires à la phase a. La charge appliquée à la MAS est de $7Nm$. Comme mentionné précédemment (Eq.1.2), la fréquence de $3f_s$ permet de déduire l'état des phases statoriques de la machine qu'elle soit en état normal ou en en court-circuit.




Figure 3.4: Courants statoriques pour une MAS saine et en court-circuit entre spires

Donc, l'analyse spectrale par FFT est appliquée au courant statorique de la phase a pour extraire les fréquences des défauts $3f_s$. Il faut de noter que l'analyse spectre a été appliquée à un signal de courant statorique suivant un régime permanent de $4s$ pour $t \in [1 - 5s]$ (Fig.3.4).

Les résultats de simulation (Fig.3.5) montrent que la fréquence n'apparaît pas dans l'état normal du MAS où seule la fréquence de fondamentale ($f_s = 50Hz$) est observée. Lorsqu'un court-circuit entre spires se produit, la fréquence du défaut apparaît au niveau de $3f_s$. De plus, on peut remarquer que l'augmentation du nombre de spires court-circuitées augmente l'amplitude $|3f_s|$, où l'amplitude $|3f_s|$ était $-49.52dB$ dans le cas de 29 spires puis augmente à $-45.61dB$ lorsque le nombre de spires a été augmenté à 58 spires.




Figure 3.5: FFT de courant statorique i_{sa} [0-200Hz]- MAS saine et en court-circuit entre spires

Dans le suivant, la technique de MUSIC est appliquée pour détecter les fréquences qu'indiquent le court-circuit entre spires suivant les mêmes conditions précédemment, c'est-à-dire, un signal de courant statorique (i_{sa}) dans un régime permanent de 4s pour $t \in [1 : 5s]$, et une charge de $7Nm$. Comme indiqué dans la figure 3.6, dans le cas d'une MAS saine, la fréquence fondamentale f_s était extraite uniquement. Dans le cas d'un court-circuit, la fréquence du défaut $3f_s$ était produite, l'augmentation du taux de court-circuit entraînant une augmentation de l'amplitude de la fréquence $3f_s$. Dans ce qui suit, nous allons appliquer les deux techniques (FFT, MUSIC) pour détecter le défaut simultané (rupture des barres et court-circuit entre spires).




Figure 3.6: MUSIC de courant statorique i_{sa} [0-200Hz]- MAS saine et en court-circuit entre spires

3.4 Analyse spectrale pour détecter un défaut simultané

Tout d'abord, la figure 3.7 montre le signal de courant du stator (phase a) pour une MAS avec une barre cassée et 29 spires court-circuitées. Après cela, seul le nombre de barres cassées est augmenté à deux barres. Dans le troisième cas, on garde les deux barres cassées et on augmente le nombre de spires court-circuitées de 29 à 58 spires.

Donc, les résultats de l'analyse par FFT sont présentés dans la figure 3.8. On peut donc noter que la rupture des barres et le court-circuit entre spires simultanées conduisent à l'apparition de chacune des fréquences qui indiquent le défaut rotor $f_s(1 \pm 2g)$ et le défaut




Figure 3.7: Courant statorique i_{sa} pour un défaut simultané

de court-circuit de $3f_s$.

De plus, la technique MUSIC est appliquée dans les mêmes conditions précédemment, où le signal de courant statorique i_{sa} est analysé pour extraire les fréquences de chaque type de défaut $f_s(1 \pm 2g)$ et $3f_s$. La figure 3.9 illustre les résultats de l'analyse spectrale obtenus par l'application de MUSIC. Par conséquent, il est possible de remarquer la présence des fréquences de défaut des barres cassées $f_s(1 \pm 2g)$ et du court-circuit $3f_s$ en même temps. Lorsque le taux de glissement augmente, les fréquences liées à la rupture des barres sont augmentées et la fréquence liée au court-circuit est restée constante à $150Hz$. Malgré la bonne performance de MUSIC dans le diagnostic des défauts de la MAS par rapport à la FFT, cette technique (MUSIC) est complexe et prend du temps pour extraire les fréquences. En d'autres termes, on peut dire que la technique de FFT reste parmi les meilleures techniques de traitement de signal. Une fois que la taille du signal est suffisante, la FFT peut fournir des performances élevées de manière appropriée et rapide.

Dans le suivant, et afin d'améliorer la résolution du diagnostic, nous appliquons l'analyse spectrale par la FFT sur le signal d'enveloppe (enveloppe de Park, enveloppe de Hilbert) au lieu du signal de courant statorique. La FFT seront appliqués pour extraire les fréquences caractérisées de chaque défaut, qu'il s'agisse de rupture des barres, court-circuit entre spires ou les deux défauts simultanés.




Figure 3.8: FFT de courant statorique i_{sa} [0-200Hz] - défaut simultané

3.5 Diagnostic des défauts par l'analyse spectrale de l'enveloppe de courant statorique

Dans le domaine du diagnostic des MAS, l'efficacité de toute technique d'analyse est jugée quant à son efficacité dans le diagnostic de ruptures des barres rotoriques. Pour surmonter certains des inconvénients précédents de la FFT, de nombreuses études ont proposé d'utiliser l'enveloppe de signal au lieu du signal d'origine. La transformation de




Figure 3.9: MUSIC de courant statorique i_{sa} [0-200Hz]- défaut simultané

Hilbert ou de Park permet d'extraire l'enveloppe pour n'importe quel signal temporel [Puche-Panadero et al., 2009, Jaksch, 2003, Saddam et al., 2018a]. L'analyse spectrale de l'enveloppe a permis d'augmenter la précision de la FFT. Dans ce contexte, la technique FFT sera appliquée dans cette section de l'enveloppe de Park et de Hilbert pour extraire les fréquences liées à la rupture des barres du rotor et aux courts-circuits entre les spires. Avant cela, nous commencerons par présenter la théorie de Park et de Hilbert.

3.5.1 Application de la FFT à l'enveloppe de Park

Mathématiquement, les courants de Park directs (i_d) et quadratiques (i_q) peuvent être extraits des trois courants statoriques (i_{sa}, i_{sb}, i_{sc}) par [Cardoso et al., 1999]:

$$\begin{cases} i_d = (\sqrt{2}/\sqrt{3})i_{sa} - (1/\sqrt{6})i_{sb} - (1/\sqrt{6})i_{sc} \\ i_q = (1/\sqrt{2})i_{sb} - (1/\sqrt{2})i_{sc} \end{cases} \quad (3.7)$$

Un nombre complexe Z_{dq} peut être écrit en utilisant les deux composants i_d, i_q comme suit:

$$Z_{dq} = i_d + ji_q \quad (3.8)$$

Par conséquent, l'enveloppe Park (PVM) est extraite directement par le suivant:

$$PVM = |Z_{dq}| = \sqrt{i_d^2 + i_q^2} \quad (3.9)$$

Donc, après avoir extrait les trois courants statoriques i_{sabc} pour une MAS saine et en ruptures des barres rotoriques, nous appliquons les équations (3.8) et (3.9), respectivement, pour extraire le signal de l'enveloppe de Park (PVM).




Figure 3.10: Enveloppe de Park pour une MAS saine et en rupture des barres

Donc, la figure 3.10 présente les trois courants statoriques (i_{sabc}) et l'enveloppe de Park pour une MAS saine et en rupture des barres rotoriques. On peut noter donc que l'enveloppe de Park (PVM) se comporte de la même manière que les signaux des courants statoriques, mais ne prend que les valeurs maximales.

L'analyse spectrale du PVM permet d'extraire des composantes de fréquences supplémentaires à $2kf_s$ lorsque les barres du rotor se cassent. La FFT de PVM est appliqué dans le suivant pour détecter le défaut de rupture des barres rotoriques. La FFT sera basée sur les

mêmes conditions mentionnées dans le ss.sect 3.2.1, c-à-d: une fenêtre de Hanning avec une taille 80000 et fréquence d'échantillonnage de 10^{-4} , la charge appliquée au MAS étant fixé dans les quatre cas à $7Nm$. Le temps d'acquisition est $8s$ suivant un régime permanent $[2 - 10s]$. La figure 3.11 illustre les résultats obtenus. Donc, a l'état sain de rotor, la FFT




Figure 3.11: FFT de PVM [0-10Hz] - MAS saine et en rupture des barres

de PVM est caractérisé par l'absence des composants fréquentielle. Par contre, dans le cas des ruptures des barres rotoriques, l'analyse spectrale montre la présence de fréquences $2gf_s$ qui indiquent la présence de barres cassées. De plus, on peut noter également que les valeurs des fréquences $2gf_s$ est lié directement à l'augmentation du taux de glissement g . On peut expliquer donc que l'augmentation du nombre des barres cassées augmente le rapport du glissement g , ce qui conduit à une augmentation des fréquences $2gf_s$.

3.5.2 Application de la FFT à l'enveloppe de Hilbert

La transformation de Hilbert (HT) est une transformation linéaire qui prend une fonction $x(t)$ dans le même domaine (temporel-temporel). Donc, le HT d'un signal $x(t)$ est défini selon la fonction de Cauchy de $1/\pi t$ par le suivant [Puche-Panadero et al., 2009, Jaksch,

2003]:

$$HT\{x(t)\} = \frac{1}{\pi \cdot t} x(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (3.10)$$

Dans le domaine du diagnostic des défauts des MASs, le HT a été largement utilisé car il a amélioré l'efficacité du diagnostic, notamment dans la détection des barres cassées.

Par conséquent, nous nous appuyerons sur l'analyse spectrale par FFT de l'enveloppe de Hilbert (HM) résultant par la HT. Donc, la figure 3.12 montre le signal de courant statorique (i_{sa}) et son enveloppe pour une charge de $7Nm$ à l'état sain de la MAS et pour une barre cassée, deux barres et pour trois barres cassées. On peut remarquer donc que HM prend les valeurs maximales du courant statorique.




Figure 3.12: Enveloppe de Hilbert pour une MAS saine et en rupture des barres

La figure 3.13 montre le résultat de l'application de FFT à HM dans chaque cas que ce soit une MAS saine, une barre cassée, deux ou trois barres cassées. Les mêmes conditions que dans le cas de l'analyse de la PVM ont été adoptées telles que la longueur du signal, le type et la taille fenêtre, le régime permanent du signal. L'analyse spectrale de HM montre que les mêmes résultats que ceux obtenus lors de l'analyse du PVM ont été obtenus dans la figure 3.11. On peut constater que les mêmes fréquences ($2gf_s$) et les mêmes amplitudes dans chaque cas.

Tant que les résultats de FFT de HM et PVM sont les mêmes, ce qui suit, nous nous appuyerons sur la FFT de HM pour extraire les fréquences liées aux défauts de court-circuit entre spires. Donc, la figure 3.14, présent le signal i_{sa} et son HM pour une MAS saine, en court-circuit de 29 et de 58 spires. La charge appliquée au MAS est $7Nm$ à $t = 0.7s$.




Figure 3.13: FFT de HM [0-10Hz]- MAS saine et en un rupture des barres

Dans le cas de l'analyse spectrale PVM ou HM, la fréquence de $2f_s = 100Hz$ est souvent sélectionnée pour indiquer la présence d'un défaut de court-circuit entre les spires [Jaksch, 2003, Saddam et al., 2018a].




Figure 3.14: Enveloppe de Hilbert pour une MAS saine et court-circuit entre les spires

Comme le montre la figure 3.15, la présence le défaut de court-circuit entraîne l'apparition de nouvelles fréquences de $100Hz$. On peut également constater que l'augmentation du

nombre de spires court-circuitée augmente l'amplitude de la fréquence $2f_s$.




Figure 3.15: FFT de HM- MAS saine et court-circuit entre les spires

La figure 3.16 montre l'enveloppe de Hilbert pour le signal de courant statorique (i_{sa}) lorsqu'un défaut simultané (court-circuit entre spires et de rupture des barres rotoriques). Une charge de $7Nm$ est appliqué au MAS. Donc, nous appliquerons la FFT au signal de l'enveloppe (HM) afin d'extraire les fréquences des défauts $2gf_s$ et $2f_s$. Nous allons garder les mêmes conditions précédent pour une fenêtre de Hanning, taille de fenêtre de 40000 avec fréquence d'échantillonnage de 10^{-4} . Le signal HM est également analysé dans un régime permanent de $t \in [1 - 5s]$.

Comme il est clair qu'une défaillance simultanée entraîne d'apparition des fréquences spécifique aux défaillances (Fig.3.17). En outre, on peut observer que les fréquences $2gf_s, 4gf_s, 6gf_s$ indiquant que la rupture des barres rotoriques et augmentent suivant la valeur de glissement. D'autre part, il est possible de remarquer que l'amplitude de $2f_s$ du défaut de court-circuit entre spires n'est pas sensible au changement du taux de glissement, mais augmente selon le nombre des spires en court-circuit.




Figure 3.16: Enveloppe de Hilbert pour une MAS saine et en défaut simultané

Ensuite, nous appliquerons la technique de DWT au signal de courant statorique pour détecter l'état de la MAS.

3.6 Application de DWT pour le diagnostic des défauts de la MAS

Pour un signal $x(t)$ de longueur N , l'application de DWT sur le signal $x(t)$ génère deux coefficients qui sont les coefficients d'approximations (cA) et les coefficients de détails (cD). Ces coefficients sont obtenus en convolant le signal $x(t)$ avec deux filtres (Fig.3.18): un filtre passe-bas pour les cA et un filtre passe-haut pour les cD [Pons-Llinares et al., 2014, Riera-Guasp et al., 2008, Bouzida et al., 2010]. Ces coefficients fournissent des informations sur les composantes du signal $x(t)$. Le signal à analyser peut être évalué en observant le comportement de ces coefficients.

Donc, en utilisant un filtre passe-bas, les fréquences de détail (fcD) est appartiennent à la bande suivante [Riera-Guasp et al., 2008, Bouzida et al., 2010]:

$$fcD \in [2^{-(j+1)}f_e, 2^{-j}f_e] \quad (3.11)$$

De même, sur la base d'un filtre passe-haut, les fréquences d'approximation (fcA) qui incluent les basses fréquences du signal appartiennent à la bande suivante:

$$fcA \in [0, 2^{-(n+1)}f_e] \quad (3.12)$$

où n est le nombre d'échantillons du signal $x(t)$, et $j \in [1, 2, 3, \dots, n]$.

Afin d'obtenir une meilleure analyse du signal par la DWT, il est important de choisir




Figure 3.17: FFT de HM - défaut simultané




Figure 3.18: Principe de DWT

les paramètres d'acquisition appropriés, tels que [Bouzida et al., 2010, Riera-Guasp et al., 2008]:

- Un nombre suffisant de niveaux de décomposition pour couvrir tout le spectre de

fréquences sur lequel se trouvent la bande latérale;

- La fréquence de résolution pour obtenir une bonne analyse du signal, pour séparer les fréquences spécifiques au défaut;
- Sélection une ondelette mère appropriée pour effectuer une analyse efficace.
- Le choix de fréquence d'échantillonnage et le nombre d'échantillons;

Dans cette partie, nous allons sélectionner une fréquence d'échantillonnage de $f_e = 10^4$ et le nombre d'échantillons $n = 10000$ qui permet d'obtenir une fréquence de résolution $\Delta f = 0.1Hz$. Pour l'extraction les cA et cD , le nombre de niveaux de décomposition (cN) doit être égal ou supérieur à celui du signal de détail contenant la fréquence fondamentale $f_s = 50Hz$. Le nombre de niveaux de décomposition est donné par le suivant [Bouzida et al., 2010, Riera-Guasp et al., 2008]:

$$2^{-(n_f+1)} f_e \prec f_s \quad (3.13)$$

Par conséquent, le nombre de niveaux de décomposition n_f est calculé par l'expression suivant:

$$cN = \text{int} \left[\frac{\log(f_e/f_s)}{\log(2)} \right] \quad (3.14)$$

Souvent, deux niveaux de décomposition supplémentaires sont ajoutés pour découvrir les évolutions de tous les composants de défaut présents dans les signaux analysées [Bouzida et al., 2010], c.-à-d. :

$$cN \simeq \text{int} \left[\frac{\log(f_e/f_s)}{\log(2)} \right] + 2 \quad (3.15)$$

Considérant que $f_s = 50Hz$ et $f_e = 10^4Hz$. L'équation (3.15) donne ce qui suit:

$$cN = \text{int}(7.64) + 2 = 9 \quad (3.16)$$

Donc, le nombre de niveaux de décomposition cN est 9 niveaux. La décomposition en ondelettes du signal analysé pour $cN = 9$ est montrée dans le tableau 3.1.

Comme il est clair, le niveau de décomposition ($cN = 9$) donne des approximations et des détails ($A9, D9$) dans une bande de fréquences comprise entre 0 et $39,6Hz$. Cela permet d'analyser le signal de courant statorique pour détecter l'état de la MAS, qu'il soit en état normal ou en défaut.

Il existe plusieurs types d'ondelettes mères aux propriétés différentes comme l'ondelette de Daubechies (db1, db2,..., db44, ...), Coiflet, Haar, Simlet (sym2, sym3,..., sym10, ...),

Table 3.1: Bandes de fréquences obtenues par décomposition en multi niveaux

Niveau	Bandes de fréquences d'Approximation [Hz]	Bandes de fréquences de Détails [Hz]
$cN=1$	A1 0-5000	D1 5000-10000
$cN=2$	A2 0-2500	D2 25000-5000
$cN=3$	A3 0-1250	D3 1250-2500
$cN=4$	A4 0-625	D4 625-1250
$cN=5$	A5 0-312.5	D5 312.5-625
$cN=6$	A6 0-156.25	D6 156.25-312.5
$cN=7$	A7 0-78.125	D7 78.125-156.25
$cN=8$	A8 0-39.0625	D8 39.0625-78.125
$cN=9$	A9 0-19.531	D9 19.531-39.0625

Biorthogonal,... etc. Généralement, ces types d'ondelettes mères donnent des résultats similaires. Dans notre cas, Daubechies-44 (db44) est sélectionné comme ondelette mère [Bouzida et al., 2010, Bensaoucha et al., 2020]. La figure 3.19 résume les étapes principales pour analyser un signal à l'aide de DWT.




Figure 3.19: Diagramme de traitement du signal utilisant la méthode de DWT

3.6.1 DWT de courant statorique pour détecter les défauts d'une MAS

Dans cette partie, nous nous concentrerons sur l'analyse du courant statorique (i_{sa}) dans les différentes situations de la machine:

- DWT de courant statorique pour une MAS à l'état normal ;
- DWT de courant statorique pour une rupture des barres rotoriques ;
- DWT de courant statorique pour un court-circuit entre spires-phase a;
- DWT de courant statorique pour un défaut simultané (stator et rotor).

Dans tous les cas, le signal de courant du stator de phase a est obtenues pour une charge $7Nm$ selon un régime permanent de $1s$. L'ondelette mère est du type Daubechies44 (db44), la fréquence d'échantillonnage est $f_e = 10^4$.

3.6.1.1 DWT de courant statoriques pour détecter une rupture des barres rotorique

Dans ce cas, le DWT est appliqué au signal de courant du stator pour une MAS saine.




Figure 3.20: DWT de courant statorique i_{sa} - MAS saine

En comparant les résultats de l'application du DWT sur la phase statorique pour une machine saine (Fig.3.20) et en rupture des barres (Fig.3.21), on constate une augmentation de l'amplitude des détails (cD8 et cD9) en cas de rupture des barres de rotor. De plus, il est clair que l'amplitude du coefficient de détail est augmentée suivant le nombre de barres cassées.

Dans ce qui suit, nous appliquerons la technique DWT sur le signal de courant du stator pour détecter le court-circuit entre spires-phase a.




Figure 3.21: DWT de courant statorique i_{sa} - rupture des barres rotoriques

3.6.1.2 DWT de courant statorique pour détecter un défaut de court-circuit

Par la comparaison des signaux de détail (D9, D8, D7 et D6) et d'approximation (A9) pour une MAS saine (Fig.3.20) et en court-circuit (Fig.3.22), on peut remarquer une

apparition de nouvelles oscillations au niveau du coefficient de détails et d'approximations, ces oscillations augmentent lorsque la sévérité du court-circuit augmente.




Figure 3.22: DWT de courant statoriques i_{sa} - court-circuit entre spires

3.6.1.3 DWT de courant statorique pour détecter un défaut simultané

Dans ce cas, nous analyserons le signal de courant statique en présence de barres cassées et d'un court-circuit entre spires en même temps (Fig.3.23). Les mêmes remarques peuvent être montrées lorsque l'apparition du défaut simultané entraîne une augmentation des oscillations au niveau coefficients des détails et d'approximations. Pour améliorer l'efficacité du diagnostic, la plupart des recherches passent au calcul de l'énergie E_{cD} stockée dans chaque coefficient de détail. Par conséquent, nous montrons dans ce qui suit les résultats de l'énergie E_{cD} calculée pour chaque cas.




Figure 3.23: DWT de courant statorique i_{sa} - défaut simultané

3.6.2 Diagnostic de la MAS à base de l'énergie de la décomposition de DWT

La valeur propre de l'énergie E_j pour chaque bande de fréquences est défini comme suite [Bouzida et al., 2010]:

$$E_j = \sum_{k=1}^{k=n} \left| D_{j,k}(n) \right|^2 \quad (3.17)$$

avec $D_{j,k}$ est l'amplitude en chaque pont discret du coefficient d'ondelette du signal. Donc, la figure 3.24 montre la variation de l'énergie dans les bandes de fréquences de décomposition de l'ondelette pour le cas sain et en rupture des barres rotoriques.




Figure 3.24: L'énergie stockée dans les détails à l'aide de db44 - MAS saine et en rupture des barres rotoriques

De la même manière, la variation de l'énergie emmagasinée dans le signal de décomposition pour une machine saine et en court-circuit est illustrée dans la figure 3.25. La figure 3.26 présente la variation de l'énergie dans les bandes de fréquences à l'état sain de la machine et en défaut simultané. Comme le montre les figures 3.24-3.26, les résultats de l'énergie




Figure 3.25: L'énergie stockée dans les détails à l'aide de db44 - MAS saine et en court-circuit entre spires

stockée dans chaque niveau de détail confirment qu'une forte augmentation est observée dans le coefficient de détail niveau 7 dans tous les cas.

On peut remarquer dans la figure 3.24 que l'amplitude de l'énergie stockée n'est pas proportionnelle au nombre de barres cassées. Par conséquent, il convient de noter que l'absence de relation entre le nombre de barres et la valeur de l'énergie stockée rend difficile la détermination de la gravité du défaut.




Figure 3.26: L'énergie stockée dans les détails à l'aide de db44- MAS saine et en défaut simultanée

3.7 Conclusion

Dans ce chapitre, nous avons étudié trois techniques de traitement du signal (FFT, MUSIC et DWT) et leurs applications pour la détection des barres cassées et de courts-circuits entre spires dans une MAS à cage. Les trois techniques sont basées sur l'analyse du signal de courant statorique et de son enveloppe (HM, PVM) en régime permanent.

En conséquence, l'analyse spectrale (soit par FFT ou MUSIC) de courant statorique a montré une efficacité dans la détection des défauts de la MAS.

De plus, l'analyse par DWT est également sensible aux défauts du stator et du rotor affectant la MAS, ce qui a donné de bons diagnostics. La présentation de l'énergie stockée à chaque niveau de décomposition, obtenue par l'analyse en ondelettes donne des informations utiles pour décider de la situation de la machine.

En outre, on peut conclure que l'analyse de l'enveloppe de courant statorique (HM ou PVM) est plus efficace pour détecter les défauts de machine, notamment en cas de cassure des barres rotoriques. Dans le chapitre suivant, nous présenterons un système de diagnostic automatique basé sur des MLAs qui classent chaque type de défaut séparément (rupture de barres ou court-circuit entre spires) ou un défaut simultanément.

Chapitre 4

Diagnostic de défauts de la MAS à l'aide d'IAs

4.1 Introduction

De nos jours, l'intelligence artificielle (IA) est le sujet principal de nombreuses recherches. En 2020, la plupart des pays développés, à commencer par la Chine, se sont appuyés sur l'IA pour lutter contre l'épidémie de Corona (COVID-19). L'IA a remplacé les humains dans plusieurs domaines, à commencer par la surveillance des mouvements de personnes, le nettoyage des rues, le traitement des images de patients et l'identification des cas de COVID-19. Dans certains cas, des robots ont remplacé le médecin pour s'occuper directement des patients. L'IA a montré un grand potentiel pour aider l'humain. En outre, l'IA a permis des avancées dans de nombreux domaines tels que le diagnostic des pannes, la reconnaissance de formes, la compréhension du langage, la supervision de systèmes de production industriels, la robotique. En fait, la grande révolution de l'IA peut considérablement améliorer l'efficacité opérationnelle, réduire les risques et les marges d'erreur et accroître la sécurité au travail [Villani et al., 2018].

Dans le même contexte, le diagnostic des pannes des MASs à l'aide de l'IA a attiré l'attention des experts du domaine. Il est difficile de développer un modèle analytique qui décrit correctement les performances des machines dans tous ses points de fonctionnement. Par conséquent, le diagnostic automatique des défauts des MAS est un sujet important de la plupart des processus industriels.

Par conséquent, l'objectif principal de ce chapitre est de détecter la rupture des barres rotoriques et les défauts de court-circuit entre spires dans une MAS en utilisant neuf (09)

MLAs. Ces algorithmes sont: MLPNN, RBFNN, SVM, ELM, kNN, NB, DT, RF, DA. Ces algorithmes permettent de décider automatiquement de l'état du MAS, soit une MAS saine, en rupture des barres, en court-circuit entre les spires, ou une MAS en défaut simultanée.

Souvent, dans les applications des MLAs supervisés, l'étape la plus importante est de choisir les meilleures entrées qui permettent de donner de bonnes performances et de meilleures classifications [Bouzig et al., 2008, Sun et al., 2016]. Ces entrées sont utilisées pour effectuer les étapes d'apprentissage et de test de ces algorithmes. Pour cela, de nombreuses recherches ont été présentées pour le diagnostic des MASs ont utilisé plusieurs caractéristiques des défauts comme entrées pour les MLAs. Dans certaines références comme [Ballal et al., 2007], les auteurs ont utilisé comme entrées pour entraîner l'ANFIS à détecter le court-circuit entre les spires et le défaut d'usure des roulements d'une MAS à cage rotorique les caractéristiques suivantes: la température de bobinage du stator, vitesse du rotor, température du roulement, valeurs RMS (valeurs effectives) des courants statoriques et le bruit de la MAS. De plus, le RMS des courants statoriques a été utilisé comme entrée pour la FL afin que la détection des défauts de court-circuit dans [Rodríguez and Arkkio, 2008]. Dans [Bouzig et al., 2008], les auteurs ont utilisé le déphasage entre les signaux de courant statoriques et leurs tensions correspondantes comme trois entrées pour entraîner le MLPNN à la détection et à la localisation des courts-circuits entre les spires. Dans [Saddam et al., 2017], les caractéristiques extraites par la FFT de HM (fréquence, amplitude) et les valeurs de charge appliquées au MAS utilisées comme trois entrées pour entraîner le MLPNN afin de détecter et identifier le nombre des barres cassées.

D'après ces recherches, et afin de détecter le nombre de barres cassées, on peut noter que l'utilisation des caractéristiques amplitude-fréquence qu'obtenus par l'analyse spectrale de courant statorique ou de son enveloppe (HM, PVM) est le meilleur choix pour entraîner les algorithmes des MLAs. Tant que l'analyse spectrale de l'enveloppe de courant statorique (HM, PVM) permet d'augmenter la résolution des fréquences liées aux défaillances de la MAS, nous choisirons dans ce chapitre la FFT appliquée à l'enveloppe Hilbert (HM) pour extraire les fréquences de défaut rotorique afin d'évaluer la performance des MLAs pour détecter et identifier le nombre de barres cassées.

Pour détecter et localiser le défaut de court-circuit entre spires, les déphasages courant-tension de stator peuvent être considérés comme les meilleures caractéristiques pour entraîner les MLAs. Ces entrées présentent plusieurs avantages, tels que [Bouzig et al., 2008, Bensaoucha et al., 2018]:

- L'extraction de ces caractéristiques se fait dans le domaine temporel sans qu'il soit nécessaire de changer le domaine d'étude en domaine fréquentiel.
- Elles sont obtenues à partir de signaux de courant statoriques qui sont à l'origine extraits dans la plupart des applications pour contrôler la vitesse de la machine;
- Les capteurs de courants statoriques sont plus sensibles à tout changement dans la machine, et donc les changements de phases sont également sensibles à toutes variations de l'état de la machine;
- Les entrées de déphasage sont moins des bruits contrairement aux autres entrées, telles que les signaux de vibration ou les valeurs RMS des courants statoriques, ce qui permet une meilleure classification des données.

Cependant, il est important de noter que les entrées de déphasage tension-courant sont inefficaces pour entraîner les MLAs pour détecter le nombre de barres cassées. Cela peut s'expliquer par le fait que l'effet de la rupture des barres rotoriques aux signaux temporels du la MAS est faible et qu'il n'y aura donc pas beaucoup de différences entre les valeurs des déphasages pour une MAS saine et une MAS avec des barres cassées. Pour cela, l'application de l'analyse spectrale (fréquences, amplitudes) à l'aide de la FFT ou de MUSIC est préférée à l'analyse temporelle.

Par conséquent, ce chapitre peut être divisé en trois parties principales:

La première partie du chapitre vise à détecter et identifier la rupture des barres rotoriques. Dans ce cas, on utilise neuf MLAs: MLPNN, SVM, RBFNN, ELM, kNN, NB, DT, RF, DA). Après avoir collecté une base de données obtenue par analyse spectrale de l'enveloppe Hilbert pour différentes situations de la MAS (machine saine et en rupture des barres rotoriques), nous allons entraîner et tester ces algorithmes afin de détecter ce type de défaut.

La deuxième partie de ce chapitre vise à explorer la variation des déphasages entre les courants et les tensions statoriques pour détecter et localiser le défaut de court-circuit entre les spires, en utilisant les neuf algorithmes mentionnés ci-dessus. Donc, ces algorithmes sont comparés entre eux dans les mêmes conditions en utilisant le même ensemble de données (une base de données pour l'apprentissage et une autre pour le test).

Dans la **troisième partie**, nous testerons ces algorithmes pour détecter un défaut simultané (ruptures des barres et un court-circuit entre les spires). Dans ce cas, nous nous appuyerons sur l'analyse spectrale (FFT) de l'enveloppe de Hilbert (HM de isa) pour extraire les caractéristiques du défaut ($2gfs$, $A2gfs$, $A2fs$). Après cela, nous avons utilisé ces

caractéristiques pour entraîner les MLAs afin de détecter l'état de la MAS.

Avant de présenter les résultats obtenus par ces algorithmes, ce chapitre présente d'abord une synthèse bibliographique de chaque algorithme utilisé.

4.1.1 Principe de MLPNN

Le MLPNN est un type de réseau neuronal artificiel conçu par plusieurs couches à l'intérieur desquelles les données passent de la couche d'entrée à la couche de sortie. Ainsi, le MLPNN comprend au moins trois couches: la couche d'entrée, la couche cachée et la couche de sortie (Fig.1.15). Les couches cachées sont responsables de la connexion de la couche d'entrée à la couche de sortie. Chaque nœud de la couche cachée représente un neurone qui utilise une fonction d'activation spécifique. Les sorties de la couche cachée dépendent de leur fonction d'activation et du nombre de neurones.

Le MLPNN utilise une approche d'apprentissage supervisé appelée rétro-propagation pour l'apprentissage. Il peut faire la distinction entre des données qui sont linéairement inséparables. La méthode d'apprentissage supervisé de MLPNN consiste à déterminer les poids qui minimisent l'erreur (e_i) entre les valeurs de sortie souhaitées (la cible) y_c et les valeurs de sortie estimé y_e . Le minimum de la fonction quadratique suivante doit être trouvé [Konar and Chattopadhyay, 2011, Liu et al., 2018]:

$$e(i) = y_{ci} - y_{ei} \quad (4.1)$$

$$\varepsilon_w = \frac{1}{N} \sum_{i=1}^N e^2(i) \quad (4.2)$$

avec N est le nombre d'échantillons d'apprentissage.

Après avoir choisi les fonctions d'activation appropriées, l'apprentissage se produit dans le perceptron en faisant varier les poids après le traitement de chaque donnée d'entrée, en fonction de la valeur d'erreur dans la sortie par rapport à la décision attendue (Éqs.4.1-4.2). Ceci est effectué grâce à l'algorithme de rétro-propagation. Les poids des nœuds sont ensuite ajustés en fonction de l'étape de l'ajustement qui minimise la valeur d'erreur dans la sortie.

Donc, il est important de noter que l'efficacité de MLPNN dépend en grande partie du bon choix du nombre de couches cachées et du nombre de neurones dans chaque couche, ainsi que du type de la fonction d'activation.

Alors, il existe différentes fonctions d'activation comme la fonction Log-sigmoïde (Logsig), Tangente-hyperbolique (Tansig) et linéaire (purelin). Plus de détails dans l'annexe A.1.

Puisque la plupart des systèmes réels sont des systèmes entrées/sorties non linéaires, les fonctions du type Logsig et Tansig sont principalement utilisées pour résoudre les problèmes non linéaires. La fonction de transfert Purelin est une fonction linéaire peut-être utilisée à résoudre les problèmes entrée/sorties linéaire [Dorofki et al., 2012].

4.1.2 Principe de RBFNN

Le RBFNN est de conception similaire à MLPNN, mais avec une seule couche cachée et avec une fonction d'activation non linéaire de type fonction de base radiale. Plus de détails dans l'annexe A.6. La sortie de RBFNN est une fonction scalaire du vecteur d'entrée $y = \mathbb{R}^n \times \mathbb{R}$, qui est définie comme [Liu and Bazzi, 2017]:

$$y(x) = \sum_{i=1}^z w_i \rho(\|x_i - c_i\|) \quad (4.3)$$

où z est le nombre de neurones de la couche cachée. Les paramètres c_i et w_i représentent, respectivement, le vecteur central et le poids du neurone i^{th} . En principe, tous les attributs d'entrée sont connectés à chaque neurone caché. La norme $\|\cdot\|$ définit la distance euclidienne et la fonction de base radiale est alors considérée comme gaussienne:

$$\rho(\|x_i - c_i\|) = \exp[-\beta\|x_i - c_i\|^2] \quad (4.4)$$

Les paramètres c_i , w_i et β_i sont identifiés en optimisant l'ajustement entre y et les données d'entrée pendant la phase de l'apprentissage. La figure 4.1 montre le schéma d'architecture de RBFNN.

4.1.3 Principe d'ELM

L'ELM a été initialement proposé par [Huang et al., 2006] comme un nouveau type de MLA conçu pour surmonter les inconvénients des réseaux de neurones conventionnels, tels que le piégeage local limité et l'apprentissage qui prend du temps. Cet algorithme est composé de trois couches, la couche d'entrée, la couche cachée et la couche de sortie (Fig.4.2). Les avantages d'ELM sont que ses paramètres de couche cachée peuvent être attribués au hasard avant l'entraînement sans intervention manuelle. De plus, le poids de sortie peut être déterminé analytiquement en utilisant l'approche d'estimation des moindres carrés. Ces avantages rendent l'ELM facile à mettre en œuvre avec de bonnes performances de généralisation et une vitesse d'apprentissage élevée [Huang et al., 2006, Zong et al., 2013, Chen and Ou, 2011].




Figure 4.1: Architecture principale de RBFNN




Figure 4.2: Architecture principale d'ELM

Pour un ensemble d'échantillons d'apprentissage $(x_i, t_i) \in \mathbb{R}^n \times \mathbb{R}^m$, avec x_i est les paramètres à n dimensions de l'échantillon i^{th} et t_i représente le vecteur de cible à m dimensions. Les sorties réseau avec L nœuds cachés sont formulées mathématiquement par:

$$\rho \sum_{i=1}^L \beta_i g(w_i, b_i, x_i) = t_j \quad (4.5)$$

où, $j = 1, \dots, N$ et $g()$ est la fonction d'activation du nœud caché i^{th} . Les paramètres w_i et b_i sont respectivement le vecteur de poids d'entrée et le biais du nœud caché i^{th} . Initialement, w_i et b_i sont choisis au hasard. $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ est le vecteur de poids de sortie reliant les nœuds de sortie au nœud caché i^{th} .

La formule d'ELM peut être écrite sous forme matricielle comme suit [Huang et al., 2006]:

$$H\beta = T \quad (4.6)$$

avec

$$H(w_1, \dots, w_L, b_1, \dots, b_L, x_1, \dots, x_L) = \begin{bmatrix} g(w_1, b_1, x_1) & \cdots & g(w_L, b_L, x_1) \\ \vdots & \ddots & \vdots \\ g(w_1, b_1, x_N) & \cdots & g(w_L, b_L, x_N) \end{bmatrix}_{N \times L} \quad (4.7)$$

$$\beta = [\beta_1, \dots, \beta_L]^T \quad (4.8)$$

et,

$$T = [t_1, \dots, t_N]^T \quad (4.9)$$

Pour identifier β , nous optimisons la fonction objective suivante:

$$\min : J_{ELM} = \frac{1}{2} \|\beta\|^2 + \frac{\gamma}{2} \sum_{i=1}^N \|e_i\|^2 \quad (4.10)$$

où e_i est l'erreur d'apprentissage et γ est le paramètre de régularisation. Les poids de sortie β peut être estimé comme:

$$\beta = H^T \left(\frac{1}{\gamma} + HH^T \right)^{-1} H \quad (4.11)$$

4.1.4 Principe de SVM

La forme de base de SVM qui classe un vecteur d'entrée $x \in R^n$ est définie comme:

$$f(x) = w\phi(x) + b_i \quad (4.12)$$

où w et b sont deux paramètres qui doivent être estimés à partir les entrées. $\phi(x)$ est la fonction de mappage non linéaire dans l'espace d'entités. Contrairement aux autres algo qui sont basés sur l'erreur empirique pour minimiser les erreurs de classification, le SVM est basé sur la minimisation du risque structurel pour trouver un compromis entre la mesure de confiance correspondant à la généralisation et l'erreur empirique. Par

conséquent, le but est de trouver les paramètres w et b tels que $f(x)$ puisse être déterminé en optimisant le problème contraint suivant:

$$\min_{w,b,\xi_i} \frac{1}{2} \|w\|^2 + C \frac{1}{N} \sum_{i=1}^N \xi_i \quad (4.13)$$

avec

$$y_i(w \cdot \phi(x_i) + b_i) \leq 1 - \xi_i \quad (4.14)$$

$$\xi_i \geq 0, \text{ pour } i = 1, \dots, N \quad (4.15)$$

où $x_i \in n, i = 1, \dots, N$ représente les vecteurs d'apprentissage avec les étiquettes de classe correspondantes, et le paramètre C contrôle le lissage entre les deux mesures. La solution du problème d'optimisation peut donner les éléments suivants:

$$w = \sum_{i=1}^N \alpha_i y_i \phi(x_i) \quad (4.16)$$

$$b = \sum_j^N \alpha_j y_j \phi(x_i) \cdot \phi(x_j) + y_i, \forall i \quad (4.17)$$

où $\alpha_i, i = 1, \dots, N$ sont les multiplicateurs de Lagrange correspondant aux entrées de formation x_i . Ici, les vecteurs de support sont les vecteurs d'apprentissage à coefficients non nuls α_i qui contribuent à déterminer le paramètre w . Le calcul dans l'espace d'entrée peut être mappé dans un autre espace d'entités à l'aide de la fonction noyau comme suit:

$$k(x_i, x_j) = \phi(x_i) \phi(x_j) \quad (4.18)$$

Il est noté que toute fonction qui satisfait au théorème de Mercer peut-être utilisée comme fonction de noyau. Enfin, la fonction d'estimation peut s'exprimer comme suit:

$$f(x) = \sum_j^N \alpha_j y_j k(x_i, x) + b \quad (4.19)$$

4.1.5 Principe de kNN

Contrairement à d'autres algorithmes (RNAs, SVM, ANFIS,...), le kNN stocke les ensembles de données d'apprentissage plutôt que d'apprendre la fonction discriminante. Par conséquent, le kNN peut être défini comme l'algorithme le plus simple pour classer de nouvelles données en fonction de leur distance aux données d'entraînements préétiquetés. Le kNN essaie de rechercher une étiquette d'une instance non classée (Fig.1.19) en observant la classe des voisins les plus proches [Liu et al., 2018]. Plus de détails dans

l'annexe A.4.

Deux critères doivent être considérés pour obtenir la meilleure classification du nouvel échantillon non classifié à partir de cet algorithme [Mechefske and Mathew, 1992, Liu et al., 2018, Medjahed et al., 2013]: La distance entre chaque échantillon classifié et l'échantillon non classifié, et le choix du nombre de voisins k ($k = 1, 2, 3, \dots, N$), où N est le total des données d'apprentissage. Différentes méthodes utilisées pour trouver la distance métrique entre l'ensemble de données classifiées et les données non classées. Les méthodes les plus utilisées avec l'algorithme kNN sont la distance euclidienne, cosinus, mahalanobis, minkowski, corrélation, city block, hamming, jaccard. Plus de détails dans l'annexe A.4.

De plus, le choix du paramètre k contrôle fortement l'efficacité de kNN. En général, les grandes valeurs de k réduisent l'effet du bruit sur la classification mais avec le risque de sur-apprentissage qui rend la séparation entre les classes moins distincte.

4.1.6 Principe de NB

Comme mentionné ci-dessus (ss.sec.A), l'algorithme de NB exploite le théorème de Bayes et suppose (naïvement) que les prédicteurs sont conditionnellement indépendants, compte tenu de la classe [Friedman et al., 1997, Lewis, 1998]. Cet algorithme applique une estimation de densité aux données. Bien que l'hypothèse soit généralement violée dans la pratique, le NB a tendance à produire des distributions a posteriori robustes aux estimations de densité de classe biaisées, en particulier lorsque le postérieur est de 0.5 (la limite de décision). Cet algorithme attribue donc des observations à la classe la plus probable.

Le théorème de Bayes est donné comme suit [Berrar, 2018]:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (4.20)$$

tels que: $P(A)$ et $P(B)$ est la probabilité d'occurrence des deux événements A et B. $P(A|B)$ est la probabilité d'occurrence de l'événement A étant donné que l'événement B est vrai; $P(B|A)$ est la probabilité d'occurrence de l'événement B étant donné que l'événement A est vrai;

Dans le théorème de Bayes, chaque terme a une dénomination spécifique, tel que:

Le terme $P(A)$ est la probabilité a priori de A, $P(A)$ est aussi appelée la prior de B. $P(A|B)$ est appelée la probabilité conditionnelle de A sachant B. Elle est "postérieure", au sens qu'elle dépend directement de B. Le terme $P(B|A)$ est appelé la fonction de

vraisemblance de B .

Le terme B peut s'écrire comme suit:

$$\begin{aligned} P(B) &= \sum_{i=1}^n P(B|A_i)P(A_i) \\ &= P(B|A)P(A) + P(B|A^c)P(A^c) \end{aligned} \quad (4.21)$$

Si l'espace d'échantillonnage Λ peut être divisé en un nombre fini d'événements mutuellement exclusifs $A_1, A_2, \dots, A_n$, et si B est un événement avec $P(B) > 0$, qui est un sous-ensemble de l'union de tous A_i , on peut réécrire la formule de Bayes comme suivant pour chaque A_i :

$$P(A_i|B) = \frac{P(B|A_i)P(A_i)}{\sum_{j=1}^n P(B|A_j)P(A_j)} \quad (4.22)$$

Alors:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B|A)P(A) + P(B|A^c)P(A^c)} \quad (4.23)$$

Si l'espace d'échantillonnage Λ peut être divisé en un nombre fini d'événements mutuellement exclusifs $A_1, A_2, \dots, A_n$, et si B est un événement avec $P(B) > 0$, qui est un sous-ensemble de l'union de tous A_i , on peut réécrire la formule de Bayes comme suivant pour chaque A_i :

4.1.7 Principe de DT

Généralement, les deux principaux algorithmes d'apprentissage par l'DT sont l'algorithme de CART (Breiman) et de C4.5 (Quinlan). L'DT consiste à construire un petit arbre composé de la plupart des données. Ainsi, pour construire le plus petit arbre de décision possible qui capture le mieux des données, CART a proposé l'indice de diversité de Gini et C4.5 utilise la notion d'entropie pour déterminer le Gain d'Information (IG).

L'entropie d'un ensemble de données $Ent(S)$ avec des classes C est donnée par:

$$Ent(S) = \sum_{i=1}^C \frac{|S_i|}{|S|} \times \log_2 \left(\frac{|S_i|}{|S|} \right) \quad (4.24)$$

où S_i est la probabilité de choisir au hasard un élément de la classe i -c'est-à-dire- la proportion de l'ensemble de données composé de la classe i .

Le IG est la clé principale utilisée par la DT. Le IG est capable de détecter les instances ayant le plus d'informations, sur la base d'une classe spécifique. Il est dérivé de l'entropie. L'entropie est utilisée pour choisir la valeur permettant de maximiser le IG.

On suppose que le cas où les attributs descriptifs sont binaires (deux classes). Soit ρ la

position courante de l'arbre en construction et T un test de potentiel, on obtient le IG de l'entropie comme suit:

$$IG(\rho, T) = Ent(S_\rho) - \sum_{j=1}^2 P_j \times Ent(S_{\rho j}) \quad (4.25)$$

où S_ρ est l'échantillon associé à la position ρ et P_j est la proportion des éléments de S_ρ qui satisfont la j^{eme} branche du test T . Plus de détails dans l'annexe [A.7](#)

4.1.8 Principe de RF

La RF [[Breiman, 2001](#)] est un terme général pour les méthodes d'ensemble utilisant des classificateurs de type arbre $h(x, Hk), k = 1, \dots$ où les Hk sont des vecteurs aléatoires indépendants distribués de manière identique et x est un motif d'entrée. Dans les processus de classification, chaque arbre dans la RF émet un vote unitaire pour la classe la plus populaire à l'entrée x . La sortie du classificateur est déterminée par un vote majoritaire des arbres dans le cas de classification et le moyenne des arbres dans le cas de régression. Donc, l'algorithme de RF peut gérer des données de grandes dimensions et utiliser un grand nombre d'arbres dans l'ensemble [[Yang et al., 2008](#), [Gislason et al., 2006](#)].

On suppose une base de données B échantillons avec remise de $Z_i, i = 1, \dots, B$. Pour chaque échantillon i , un arbre de CART $G_i(x)$ est construit, chaque fois qu'un nœud doit être coupé (étape de "division")) et une partie des attributs sont tirés au hasard (q parmi les p attributs) et on choisi le meilleur division dans ce sous-ensemble. Donc, pour la régression, on applique agrégation le moyenne:

$$G(x) = \frac{1}{B} \sum_{i=1}^B G_i(x) \quad (4.26)$$

Pour le classification, nous appliquons l'agrégation des votes:

$$G(x) = \text{VoteMajoritaire}(G_1(x), \dots, G_B(x)) \quad (4.27)$$

Plus de détails sont disponibles dans [[Cutler et al., 2012](#), [Patel and Giri, 2016](#), [Yang et al., 2008](#)].

4.1.9 Principe de DA

L'objectif principal de DA est de trouver un ensemble de combinaisons linéaires de variables dont les valeurs sont aussi proches que possibles au sein des groupes et aussi éloignées que possibles entre les groupes. L'DA est basé sur le calcul de la matrice de covariance.

Selon le théorème de Huyghens', la matrice de variance-covariance totale (CM) peut s'écrire [Delpha et al., 2008]:

$$CM = W + B \quad (4.28)$$

où W représente la covariance au sein des groupes est donnée par:

$$W = \sum_k n_k \times W_k \quad (4.29)$$

avec n_k désigne les observations appartenant au k^{eme} groupe a priori. W_k représentant la dispersion des données à l'intérieur du k^{eme} groupe. De plus, B désigne la covariance matrice entre les groupes pour une base de données u et pour chaque groupe u_k :

$$B = \sum_k n_k (u_k - u)(u_k - u)^T \quad (4.30)$$

Pour une instance x_a de classe inconnue, DA consiste à essayer d'identifier cette instance en les classant dans les groupes choisis. Donc, la nouvelle instance x_a est affectée au k^{eme} groupe avec le résultat linéaire le plus bas comme suit:

$$x_a \in k \text{ si } f(x_a) = \min\{f_k(x_a)\} \quad (4.31)$$

où $f_k(x_a)$ est appelée la fonction discriminante et donnée par:

$$f_k(x_a) = d(x_a, u_k) x_a^T R^{-1} x_a \quad (4.32)$$

De plus, $d(x_a, u_k)$ est la distance entre la nouvelle instance x_a et les centres de gravité des groupes:

$$d(x_a, u_k) = (x_a - u_k)^T R^{-1} (x_a - u_k) \quad (4.33)$$

L'algorithme de DA peut être linéaire, en essayant de trouver une ligne droite qui sépare les données en catégories, ou elle peut s'adapter à une variété de courbes comme l'DA quadratique et l'DA diago-quadratic, etc. La différence major entre eux est la méthode d'estimation de la matrice de covariance. L'DA linéaire estime une matrice de covariance pour toutes les classes, l'DA quadratique estime une matrice de covariance pour chaque classe. L'DA diago-quadratic utilise la diagonale de matrice de covariance de l'DA quadratique. Généralement, l'DA quadratique est un peu plus flexible que les autres extensions. Plus de détails sont disponibles dans [Ayhan et al., 2006, Delpha et al., 2008].

4.2 MLAs pour détecter une rupture des barres rotoriques

Comme mentionné précédemment (Sec.4.1), la première étape de diagnostics basés sur les MLAs consiste à extraire la base de données utilisées comme entrées. La base de données est divisée en deux parties: la première est consacrée à l'apprentissage des MLAs et le reste pour leur test. Dans notre cas, figure 4.3 montre le diagramme schématique qui résume le processus de détection des barres cassées par les MLAs.




Figure 4.3: Représentation schématique pour détecter une rupture des barres de rotor à l'aide des MLAs

4.2.1 Extraction d'une base de données en cas de rupture des barres rotoriques

Comme le montre la figure 4.3, les caractéristiques extraites ($2gf_s$ et son amplitude $A2gf_s$) en appliquant la FFT de HM sont utilisées comme entrées pour entraîner les MLAs, ces entrées sont extraites dans différentes conditions de fonctionnement de la machine. Dans ce cas, la charge appliquée au MAS est augmentée de 1 à 7 Nm, que le MAS soit saine ou avec des barres de rotor cassées.

Pour montrer l'effet de la charge sur la fréquence $2gf_s$, nous appliquons trois charges différentes à la MAS pour une barre cassée. Donc, la figure 4.4 présente l'évolution de courant statorique phase a et son enveloppe (enveloppe de Hilbert) pour une charge de 1, 3, 6 Nm pour une seule barre cassée. On peut noter donc que l'augmentation de la charge produit plus d'oscillations dans le signal de courant du stator et son enveloppe.

De plus, la figure 4.5 montre le résultat obtenu en appliquant la FFT à l'enveloppe de Hilbert pour une barre cassée pour les trois charges appliquées. Donc, on peut noter que l'augmentation de la charge appliquée au MAS augmente la valeur de fréquence $2gf_s$.




Figure 4.4: Courant statorique i_{sa} et son enveloppe (HM) pour une barre cassée.

Sur la base de ces fréquences et de leurs amplitudes, nous collecterons autant de données que possibles pour rendre les MLAs plus efficaces pour détecter la rupture des barres rotoriques. Ensuite, nous regroupons les données totales en deux parties, une pour l'apprentissage et une pour le test. On obtient donc ce qui suit:

La base de données de l'apprentissage (Fig.4.6) est composée de 21 échantillons représentant trois états différents de la MAS comme MAS saine, une barre cassée, deux barres cassées. Dans ce cas, la charge appliquée à la machine prend sept valeurs de $c_r = 1, 2, 3, 4, 5, 6, 7 Nm$. Comme résultat, $21 = 7 \times 3$.




Figure 4.5: FFT de HM pour une barre cassée avec différentes charges

La sortie (la cible) de chaque MLA sélectionné peut prendre l'une de ces étiquettes 0, 1, 2, où 0 indiquent une MAS saine et 1 et 2 pour une barre et deux barres cassées, respectivement.

La base de données de test (Fig.4.7) est composée de 18 échantillons représentant une MAS saine, une barre cassée, deux barres cassées. Dans ce cas, la MAS fonctionne sous 06 conditions de charge sont: $c_r = 1.5, 2.5, 3.5, 4.5, 5.5, 6.5 Nm$. Donc, la base de données obtenue est de 18 échantillons ($18 = 6 \times 3$).

4.2.2 Résultats de classification par MLAs pour détecter une rupture des barres

Pour évaluer les modèles de classification de chaque MLA utilisés pour détecter le statut de la MAS, quatre critères sont considérés pour sélectionner la meilleure classification. Ces critères sont la précision d'apprentissage et de test ((En anglais: Accuracy), le temps de classification, l'erreur quadratique moyenne (MSE) et l'erreur absolue moyenne (MAE). La précision de classification est égale à la proportion des échantillons correctement classés par rapport à tous les échantillons [Konar and Chattopadhyay, 2011, Chen and Ou, 2011]:

$$Precision(\%) = \frac{S_c}{N} \times 100 \quad (4.34)$$

où S_c est les échantillons correctement classés.

L'MSE mesure la moyenne carré entre chaque point de données réel observé (la cible) et la valeur prévue y_e (valeur estimée):

$$MSE = \frac{1}{N} \sum_{N=i}^N (y_e - y_c)^2 \quad (4.35)$$




Figure 4.6: Base de données d'apprentissage et leur sortie correspondante- MAS saine et en rupture des barres




Figure 4.7: Base de données de test- MAS saine et en rupture des barres

Table 4.1: Configuration de MLPNN

Type de MLPNN	MLPNN feed-forward
Algorithme d'apprentissage	Levenberg-Marquardt
Nombre de couches	03
Nombre de neurones	Couche d'entrée: 02 neurones
	Couche cachée: 3, 4, 5 neurones
	Couche de sortie: 01 neurone
Fonctions d'activation	Couche cachée: Logsig, Tansig
	Couche de sortie: Linéaire (purelin)
Mu initial	0.001
Performance	0
Mu maximum	10
Gradient de performance minimum	10^{-7}

L'MAE est la moyenne des erreurs absolues ($\|e_i\|$):

$$MAE = \frac{|e_i|}{N} = \frac{\sum_{N=i}^N |y_e - y_c|}{N} \quad (4.36)$$

4.2.2.1 Application de MLPNN pour détecter une rupture des barres rotatives

Pour l'application du MLPNN, une rétro-propagation multicouche a été utilisée dans ce cas. Le tableau 4.1 montre la structure des modèles de MLPNN sélectionnés. Tous les modèles de MLPNN contiennent trois couches: couche d'entrée, une seule couche cachée et une couche de sortie.

Dans ce cas, une seule couche cachée est choisie car la base de données d'apprentissage n'est pas volumineuse. Pour obtenir le meilleur modèle de classification, une augmentation progressive entre 3 et 5 est appliqué au nombre de neurones dans la couche cachée. De plus, nous appliquons deux types de fonctions d'activation (Log-sig et Tans-sig) dans cette couche (la couche cachée). On peut noter que nous avons entraîné chaque modèle de MLA individuellement plusieurs fois pour obtenir la meilleure classification.

Comme le montre le tableau 4.2, il existe de grandes similitudes dans les résultats obtenus par les six modèles de MLPNN, que ce soit en utilisant une fonction Logsig ou Tansig. Mêmes avec l'ajustement du nombre de neurones dans la couche cachée, les résultats

étaient similaires. Cinq modèles appliqués ont donné une classification de 100% dans l'apprentissage et dans le test. Le modèle restant (une couche cachée avec: 04 neurones, Tansig) a donné des résultats inférieurs à ceux des cinq autres modèles. Ce modèle a donné 94% dans la phase de test.

En comparant le temps d'apprentissage et de test, tous les modèles ont environ 0,03 et 3s. Cependant, la petite différence de temps entre les modèles n'est pas importante puisque l'apprentissage et le test sont effectués hors ligne.

En particulier, nous pouvons remarquer que le modèle de MLPNN pour cinq (05) neurones avec une fonction Tansig a donné les meilleures performances pour un MSE de 5.91×10^{-13} et un MAE égale a 5.45×10^{-07} .

En utilisant ce modèle (une couche cachée avec 05 neurones, Tansig), la figure 4.8 montre la sortie estimée par ce modèle par rapport à la sortie réelle (cible). Nous pouvons donc remarquer qu'il existe une grande similarité entre la sortie réelle (cible) et la sortie estimée. Par conséquent, les résultats de ce modèle seront gardés pour être comparés

Table 4.2: Performance de MLPNN pour détecter une rupture des barres rotoriques

Fonction d'activation	Nombre de neurones	Précision d'apprentissage (%)	Précision de test (%)	Durée de l'apprentissage (s)	Durée de test (s)	MSE	MAE
Logsig	3	100	100	0.76	0.03	4.19×10^{-12}	1.5×10^{-06}
	4	100	100	0.56	0.03	5.38×10^{-12}	1.66×10^{-06}
	5	100	100	1.86	0.06	1.42×10^{-12}	5.78×10^{-07}
Tansig	3	100	100	2.99	0.027	0.01	0.07
	4	100	94.44	0.85	0.028	5.23×10^{-13}	5.12×10^{-07}
	5	100	100	0.87	0.28	5.91×10^{-13}	5.45×10^{-07}

avec les résultats des quatre autres classificateurs (RBFNN, ELM, SVM, kNN).

4.2.2.2 Application de RBFNN pour détecter une rupture des barres rotoriques

L'algorithme de RBFNN peut être utilisé pour approximer les fonctions, ce classificateur est basé sur une seule couche cachée avec une fonction d'activation du type gaussienne (Annexe A.2). RBFNN s'appuie donc sur l'ajustement de nombre de neurones au niveau de la couche cachée jusqu'à atteindre la cible (i.e: $MSE = 0$). Donc, le tableau 4.3 présente la configuration de RBFNN utilisée dans cette partie. Par conséquent, nous avons examiné quatre modèles de RBFNN pour 6, 7, 8, 9 neurones dans la couche cachée.

Donc, le tableau 4.4 montre les résultats de la chaque modèle. Il peut être observé qu'il y avait trois modèles (pour 7, 8, 9 neurones) qui ont fourni les mêmes résultats où la précision




Figure 4.8: Sortie de MLPNN (Tansig, 05 neurones)- rupture des barres rotoriques

d'apprentissage était de 100%. Cependant, la phase de test n'a pas réussi complètement, atteignant seulement 94.44%. Dans ce cas, on peut également remarquer que les valeurs prises par le MSE et le MAE sont généralement grandes, ($MSE = 0.05$, $MAE = 0.18$).

Les résultats de la classification montrent donc que le modèle de RBFNNs pour 07 neurones donne la meilleure classification par rapport les autres modèles. Ce modèle a donné une précision d'apprentissage de 100%, une précision de test de 94.44, $MSE = 0.05$ et un $MAE = 0.18$. En conséquence, nous avons choisi ce modèle (RBFNN avec 07 neurones) comme meilleur modèle de RBFNN pour détecter la rupture des barres rotorique. Selon ce modèle, la figure 4.9 présente la sortie estimée par le RBFNN par rapport à la sortie réelle. Dans ce cas, la sortie estimée de RBFNN dans la phase de l'apprentissage montre 21/21 échantillons classés correctement. Par contre, les résultats du test montrent une instances (01) classée incorrectement. Donc, nous garderons les résultats de cette RBFNN pour une comparaison ultérieure avec les résultats d'autres algorithmes.

4.2.2.3 Application d'ELM pour détecter une rupture des barres rotoriques

L'algorithme d'ELM consiste principalement en une seule couche cachée, le nombre de neurones de cette couche est progressivement ajusté jusqu'à ce que la meilleure classification soit trouvée.

Par conséquent, le tableau 4.5 présente quatre modèles (04) d'ELM utilisant 5, 6, 7, 8 neurones dans la couche cachée. Donc, nous pouvons remarquer qu'il existe trois modèles qui ont donné des résultats complets, où le taux d'apprentissage et de test était de 100%.

Table 4.3: Configuration de RBFNN

Type de RBFNN	Feed-forward
Algorithme d'apprentissage	Lenverberg-Marquardt
Nombre de couches	03
Nombre de neurones dans chaque couche	Couche d'entrée: 03 Couche cachée: 6, 7, 8, 9 Couche de sortie: 01
Fonction d'activation	Couche cachée: Gaussienne Couche de sortie: Linéaire (purelin)
L'écart constant	01
L'objectif (goal)	0

Table 4.4: Performance de RBFNN pour détecter une rupture des barres rotoriques

Nombre de neurones	Précision d'apprentissage (%)	Précision de test(%)	Durée d'apprentissage(s)	Durée de test	MSE	MAE
6	95.24	94.44	0.25	0.04	0.06	0.18
7	100	94.44	0.26	0.04	0.05	0.18
8	100	94.44	0.23	0.03	0.05	0.17
9	100	94.44	0.25	0.03	0.05	0.18




Figure 4.9: Sortie de RBFNN a (07 neurones)- rupture des barres rotoriques

Cependant, on peut voir que les valeurs d'erreur MSE et MAE sont un peu considérables. Par conséquent, nous avons sélectionné le modèle d'ELM de six (06) neurones comme le meilleur modèle d'ELM pour détecter la rupture des barres rotoriques. Selon ce modèle,

Table 4.5: Performance d'ELM pour détecter une rupture des barres rotoriques

Nombre de neurones	Précision de l'apprentissage (%)	Précision de test(%)	Durée d'apprentissage(s)	Durée de test	MSE	MAE
5	94.87	94.44	0.08	0.04	0.06	0.19
6	100	100	0.09	0.03	0.06	0.18
7	100	100	0.1	0.04	0.06	0.19
8	100	100	0.09	0.03	0.06	0.19

figure 4.10 montre la sortie réelle et la sortie estimée par l'ELM. On peut noter donc qu'il existe une similitude entre tous les échantillons réels et les échantillons estimés par l'ELM, que ce soit dans l'apprentissage ou dans le test. Par conséquent, nous garderons ce modèle comme le meilleur modèle d'ELM pour détecter la rupture des barres rotoriques.




Figure 4.10: Sortie d'ELM avec (06 neurones)- rupture des barres rotoriques

4.2.2.4 Application de SVM pour détecter une rupture des barres rotoriques

Afin de transformer les données non séparables en séparables données, les fonctions noyau sont largement appliquées dans le SVM pour transformer les données d'entrée en espace de grandes dimensions. Il existe différents types de fonctions de noyau tel que le noyau

linéaire, le noyau polynomial, ou gaussien (ou radial). Plus de détails dans l'annexe A.3. Dans cette partie, le SVM est entraînée à l'aide de différentes fonctions noyau (Kerenel functions): linéaire, gaussienne, polynomiale, avec des stratégies de OVO et OVA. Par conséquent, six modèles de SVM (06) sont appliqués pour obtenir les meilleures performances. Le tableau 4.6 montre les résultats obtenus par chaque modèle de SVM. On peut noter donc qu'il existe deux modèles présentant les meilleurs résultats soit dans l'apprentissage (100%), soit dans le test (100%). Le MSE et MAE étaient nulles ($MSE = 0$, $MAE = 0$), par conséquent, la classification a réussi à 100%. Ces deux modèles sont basés sur une fonction polynomiale. Nous pouvons choisir le modèle basé sur la fonction polynomiale avec la stratégie de OVA comme le meilleur modèle de SVM pour détecter la rupture des barres rotoriques. Pour cela, la figure 4.11 montre les sorties correspondant à l'apprentissage et au test de ce modèle. Il est clair qu'il existe une égalité entre la sortie estimée par le modèle de SVM et la sortie réelle (la cible).

Table 4.6: Performance de SVM pour détecter une rupture des barres rotoriques

Stratégie	Fonction noyau	Précision d'apprentissage(%)	Précision de test(%)	Durée d'apprentissage(s)	Durée du test (s)	MSE	MAE
OVO	Linéaire	95.24	100	0.84	0.03	0.04	0.04
	Gaussien	95.24	100	0.79	0.03	0.04	0.04
	Polynomiale	100	100	0.76	0.03	0	0
OVA	Linéaire	95.24	94.44	1.16	0.03	0.04	0.04
	Gaussienne	95.24	100	0.79	0.05	0.04	0.04
	Polynomiale	100	100	0.80	0.03	0	0




Figure 4.11: Sortie de SVM (OVO, Polynomiale)- rupture des barres rotoriques

Table 4.7: Performance de kNN pour détecter une rupture des barres rotoriques

Distance	Nombre de voisins K	Précision d'apprentissage(%)	Précision de test(%)	Durée d'apprentissage(s)	Durée de test (s)	MSE	MAE
Cosinus	1	100	44.44	0.62	0.031	0	0
	2	100	44.44	0.47	0.03	0	0
	3	100	50	0.52	0.05	0	0
Euclidien	1	100	44.44	0.57	0.03	0	0
	2	100	44.44	0.56	0.03	0	0
	3	100	72.22	0.55	0.5	0	0
City block	1	100	100	2.61	0.02	0	0
	2	100	100	0.86	0.03	0	0
	3	100	100	0.68	0.03	0	0

4.2.2.5 Application de kNN pour détecter une rupture des barres rotoriques

Comme mentionné précédemment (ss.sec 4.1.5), le kNN dépend principalement de deux paramètres sont: la distance métrique qui est utilisée pour calculer la distance entre deux points, et le nombre de voisins k . La valeur de k décide de la forme de la frontière de décision. Généralement, de petites valeurs de k entraînent une condition aux limites strictes, mais elles donnent toujours un ajustement plus flexible avec un biais faible et une variance élevée. Par conséquent, le tableau 4.7 présente neuf modèles (09) de kNN utilisant un nombre différent de k ($k = 1, 2, 3$) et trois fonctions pour calculer la distance métrique: cosinus, euclidien et city-block. Plus de détails dans l'annexe A.4.

À partir les résultats obtenus (Tab.4.7), nous pouvons noter que les six premiers modèles de kNN (types: Cosinus et Euclidien) ont montré un échec significatif dans le diagnostic du nombre de barres cassées. Au contraire, les trois derniers modèles (type: city-block) ont été très efficace, où le taux d'apprentissage et de test a atteint 100%. De plus, le MSE et le MAE sont nuls. Donc, la figure 4.12 montre la sortie de modèle pour $k = 3$ et une fonction city-block. Il peut être clairement noté que la sortie estimée par ce modèle et la cible sont les mêmes.

4.2.2.6 Application de NB pour détecter une rupture des barres rotoriques

De manière générale, la performance de NB dépendant du choix de la fonction de distribution des données. Dans cette partie, nous appliquerons deux types de fonctions de distribution: kernel et gaussienne (Annexe A.5). Donc, le tableau 4.8 présente le résultat obtenu par chaque modèle de NB. Selon les résultats obtenus, on peut choisir le modèle NB-Gaussien comme meilleur modèle pour détecter le nombre de barres cassées. Ce




Figure 4.12: Sortie de kNN (City-block, $k=3$)- rupture des barres rotoriques

Table 4.8: Performance de NB pour détecter une rupture des barres rotoriques

Fonction de distribution	Précision d'apprentissage(%)	Précision de test(%)	Durée d'apprentissage(s)	Durée de test (s)	MSE	MAE
Gaussian	100	88.88	0.03	0.03	0	0
Kernel	90.47	94.44	0.03	0.03	0	0

modèle donne un taux d'apprentissage de 100% et de 88.88% pour le test. De plus, le MSE et le MAE sont nuls. Donc, la figure 4.13 montre la sortie du modèle NB pour une




Figure 4.13: Sortie de NB gaussienne- rupture des barres rotoriques

fonction du type Gaussienne. Dans le cas de l'apprentissage, il peut être clairement noté que la sortie estimée par ce modèle (NB-Gaussienne) et la cible sont les mêmes (18/18).

Table 4.9: Performance de DT pour détecter une rupture des barres rotoriques

Critère de Split	Précision d'apprentissage(%)	Précision de test(%)	Durée d'apprentissage(s)	Durée de test (s)	MSE	MAE
deviance	100	88.88	0.03	0.09	0	0
twoing	100	88.88	0.04	0.1	0	0
gdi	100	88.88	0.09	0.03	0	0

Dans le test, ce modèle n'a pas réussi à classer deux instances (16/18).

4.2.2.7 Application de DT pour détecter une rupture des barres rotoriques

Généralement, l'algorithme de DT dépend de deux critères: le critère de fractionnement (split criteria), et le nombre maximal de nœuds fractionnés. Dans cette partie, nous appliquons trois critères de fractionnement: déviance, twoing, gdi (Gini's diversity index) (Annexe A.5). Après plusieurs issues, nous avons fixé le nombre nœuds maximale de nœuds fractionnés à cinq (05). Donc, le tableau 4.9 présente les résultats obtenus par chaque modèle de DT. On peut donc remarquer que les trois modèles utilisés donnent les mêmes performances, tels que, le taux d'apprentissage est 100%, le taux de test est 88%, le MSE et le MAE sont nuls. Cependant, nous avons choisi le modèle de DT-gdi comme meilleur modèle de DT pour détecter la rupture des barres. Selon ce modèle, la figure 4.14




Figure 4.14: Sortie de DT gdi- rupture des barres rotoriques

montre la sortie de DT-gdi par rapport à la sortie réel. On peut clairement noter que la sortie estimée par ce modèle et la cible sont les mêmes dans la phase d'apprentissage. Mais dans le test, il y a deux instances mal classées.

Table 4.10: Performance de RF pour détecter une rupture des barres rotoriques

Nombre de cycles d'apprenants	Précision d'apprentissage(%)	Précision de test(%)	Durée d'apprentissage (s)	Durée de test (s)	MSE	MAE
25	100	88.88	0.06	0.07	0	0
28	100	88.88	0.06	0.07	0	0
30	100	88.88	0.06	0.12	0	0

4.2.2.8 Application de RF pour détecter une rupture des barres rotoriques

La forêt aléatoire (RF) [Breiman, 2001] se compose d'un grand nombre d'arbres de décision individuels qui fonctionnent comme un ensemble. Chaque arbre individuel dans la RF crache une prédiction de classe et la classe avec le plus de votes devient la prédiction de modèle. Plus de détails disponibles dans [Genuer and Poggi, 2017]. Par conséquent, le nombre d'échantillons/arbres est la condition la plus importante pour obtenir une bonne classification basée sur cet algorithme. Généralement, le nombre d'arbres est sélectionné en fonction de la taille et de la nature de données. Le nombre optimal d'arbres peut-être trouvé en observe la sortie estimée par la RF [Genuer and Poggi, 2017]. Dans cette partie, nous avons choisi 25, 28, 30 arbres. Donc, le tableau 4.10 présente les résultats obtenus par chaque modèle de RF. On peut remarquer donc que les trois modèles appliques donnent le même résultat. Nous avons choisi donc le modèle de RF avec 25 arbres.

De plus, nous pouvons remarquer que le résultat obtenu par l'algorithme de RF (Tab.4.10) est le même résultat obtenu par la DT (Tab.4.9). Donc, la figure 4.15 montre la sortie




Figure 4.15: Sortie de RF de 25 arbres- rupture des barres rotoriques

du modèle de RF pour 25 cycles d'apprenants (25 arbres). Comme le montre cette figure

Table 4.11: Performance de DA pour détecter une rupture des barres rotoriques

Type de DA	Précision d'apprentissage(%)	Précision de test(%)	Durée d'apprentissage(s)	Durée de test (s)	MSE	MAE
linéaire	80.95	88.88	0.03	0.07	0.19	0.19
Quadratique	95.23	94.44	0.03	0.07	0.04	0.04
Diago-quadratic	100	88.88	0.03	0.07	0	0

(Fig.4.15), l'apprentissage a été effectué avec succès, mais dans le test, deux instances mal classées.

4.2.2.9 Application de DA pour détecter une rupture des barres rotoriques

L'DA trouve un ensemble d'équations de prédiction basées sur des variables indépendantes qui sont utilisées pour classer les individus en groupes. L'DA a deux objectifs possibles: trouver une équation prédictive pour classer de nouveaux individus ou interpréter l'équation prédictive pour mieux comprendre les relations qui peuvent exister entre les variables. L'DA est une méthode de classification. Il suppose que différentes classes génèrent des données basées sur différentes distributions gaussiennes. On peut trouver plusieurs types de DA tels que linéaire, quadratique, diago-quadratique (Annexe A.7). Donc, le tableau 4.11 présente le résultat obtenu par trois modèles de DA. Donc, selon les résultats obtenus, nous avons choisis le modèle de DA diago-quadratique comme le meilleurs modèle pour détecter la rupture des barres de rotor. Ce modèle donne un taux d'apprentissage de 100% et de 88.88% pour le test. De plus le MSE et MAE sont nuls.

Alors, la figure 4.16 montre la sortie du modèle DA diago-quadratique. Donc, on peut remarque que toutes les instances de l'apprentissage sont classées correctement, mais il y deux instances mal classées dans le test.

4.2.3 Discussion des résultats de MLAs pour détecter une rupture des barres rotoriques

Selon les figures 4.8-4.12, il est montré que la sortie estimée (apprentissage et test) par le MLPNN (Fig.4.8), l'ELM (Fig.4.10), le SVM (Fig.4.11) et le kNN (Fig.4.12) est similaire à la sortie réelle (la cible), et donc le nombre d'instances correctement classée est de 21/21 pour l'apprentissage et 18/18 pour le test. Concernant le modèle de RBFNN sélectionner (Fig.4.9), on constate qu'il était capable d'identifier tous les échantillons d'apprentissage (21/21), mais dans le test, il a réussi à classer 17/18 échantillons et n'a pas réussi à classer




Figure 4.16: Sortie de DA diago-quadratique- rupture des barres rotoriques

un échantillon car il le considèrerait comme rupture une barre au lieu de la catégoriser comme deux barres cassées.

Selon les figures 4.13-4.16, nous pouvons remarquer que les quatre classificateurs (NB, DT, RF, DA) ont réussi à classer toutes les instances d'apprentissage, mais ils ne réussissent pas à classer deux instances dans le test.

Selon les tableaux 4.2-4.7, nous pouvons conclure ce qui suit:

Le SVM (Tab.4.6) et le kNN (Tab.4.7) ont montré une grande performance telles que le $MSE = 0$ et $MAE = 0$, le MLPNN (Tab.4.2) donne un $MSE = 1.42 \times 10^{-12}$ et $MAE = 5.78 \times 10^{-7}$. Bien que l'ELM (Tab.4.5) ait montré un taux d'apprentissage et de test de 100%, mais on peut noter que les valeurs de $MSE = 0.06$ et $MAE = 0.18$ étaient considérables. Même constat pour le modèle de RBFNN, où les valeurs de MSE et MAE sont considérables.

Les quatre algorithmes (NB, DT, RF, et DA)(Tab.4.8,4.9,4.10,4.11) ont présenté un MSE et MAE nuls, mais le taux de test n'a pas atteint 100% (taux de test= 88%).

Comme résumé, le tableau 4.12 présente un arrangement descendant pour le meilleur modèle sélectionné pour chaque algorithme. Donc, le SVM est le premier, suivi de kNN puis de MLPNN. On retrouvera l'ELM et le RBFNN aux quatrième et cinquième rangs. De plus, NB, DT, RF et DA sont, respectivement, dans les derniers classements.

Après avoir terminé l'analyse des performances de neuf MLAs (MLPNN, RBFNN, ELM, SVM, kNN, NB, DT, RF, DA) utilisés pour détecter la défaillance des barres rotoriques, nous répéterons les mêmes étapes ci-dessous, mais cette fois pour détecter et localiser un court-circuit entre les spires dans l'une des phases de stator. Avant cela, nous allons compiler une base de données pour une MAS saine et en court entre les spires, puis

Table 4.12: Arrangement des MLAs appliques pour détecter une rupture des barres rotoriques

Rang	classificateur	Précision d'apprentissage (%)	Précision de test (%)	Durée d'apprentissage (s)	Durée de test (s)	MSE	MAE
1	SVM	100	100	0.44	0.03	0	0
2	kNN	100	100	0.68	0.03	0	0
3	MLPNN	100	100	1.86	0.06	1.42×10^{-12}	5.78×10^{-07}
4	ELM	100	100	0.09	0.03	0.06	0.18
5	RBFNN	100	94.44	0.26	0.04	0.05	0.18
6	NB	100	89.88	0.03	0.03	0	0
7	DT	100	88.88	0.03	0.09	0	0
8	RF	100	88.88	0.06	0.07	0	0
9	DA	100	88.88	0.03	0.07	0	0

nous la diviserons en deux parties pour l'apprentissage et le test.

4.3 MLAs pour détecter un court-circuit entre spires

Comme nous l'avons mentionné précédemment (Sec.4.1), la première étape du processus de diagnostic et de classification des défauts à l'aide des MLAs est d'extraire la base de données. Par conséquent, nous allons collecter les changements de déphasage entre les trois tensions statoriques (v_{sa}, v_{sb}, v_{sc}) et leurs courants (i_{sa}, i_{sb}, i_{sc}). On obtiendra donc trois entrées pour entraîner les MLAs afin de détecter le défaut de court-circuit entre spires. La figure 4.17 montre un exemple de déphasage entre le signal de tension statorique et le courant correspondant. La figure 4.18 montre le diagramme schématique du processus de diagnostic utilisant les MLAs pour détecter un court-circuit entre spires. Donc, la première étape que nous prendrons est le processus de collecte d'une base de données suffisante pour obtenir un système de diagnostic performant.

4.3.1 Extraction d'une base de données en cas de court-circuit entre spires

Dans ce cas, les déphasages tension-courant ont été collectés pour une MAS saine et en court-circuit entre spires. Dans le cas de défaut, le nombre de spires court-circuitées sera sélectionné entre 2 et 20 spires. Le total des données obtenues a été divisé en deux parties: la première partie utilisée pour l'apprentissage des MLAs et le reste pour leur tester. Dans l'état sain, nous ajustons uniquement le couple de charge entre 1 et $7Nm$.




Figure 4.17: Déphasage entre tension v_{sa} et courant i_{sa}

Par conséquent, la base de données d'apprentissage (Fig.4.19) est collectée pour une MAS saine et en défaut de 3, 5, 7, 9, 11, 13, 15, 17, 19 spires court-circuitées (09 cas) sous quatre (04) conditions de charge de 1, 3, 5 et $7Nm$. Donc, la base de données de l'apprentissage totale est égale à 112 échantillons. Mathématiquement: $112 = 4(\text{saine}) + 9(09\text{cas}) \times 4(04\text{charges}) \times 3(03\text{phases})$.

La base de données de test (Fig. 4.20) est collectée pour une MAS saine et en défaut de 2, 4, 6, 8, 10, 12, 14, 16, 18, 20 spires court-circuitées (10 cas) sous trois (03) conditions de charge de 2, 4 et $6Nm$. Par conséquent, on obtient: $93 = 3(\text{saine}) + 10 \times 3 \times 3$.

La sortie de chaque classificateur sélectionné peut prendre l'une de ces étiquettes 0, 1, 2, 3, où 0 représente une machine saine. 1, 2 et 3 pour un défaut de court-circuit se produit dans la phase a , b , ou c , respectivement.

4.3.2 Résultats de classification par MLAs pour détecter un court-circuit entre spires

Pour évaluer les modèles de chaque classificateur (MLPNN, RBFNN, ELM, SVM, kNN, NB, DT, RF, DA), les quatre critères précédents (précision, et temps d'apprentissage et de test, MSE et MAE) ont été choisis pour sélectionner le meilleur classificateur. Pour chaque MLA, nous allons essayer plusieurs modèles pour obtenir la meilleure classification.




Figure 4.18: Représentation schématique pour détecter un court-circuit entre spires à l'aide des MLAs

4.3.2.1 Application de MLPNN pour détecter un court-circuit entre spires

Afin de détecter et localiser le court-circuit entre spires, nous garderons la même structure représentée dans le tableau précédent (Tab.4.1), ce qui signifie trois couches (couche d'entrée, couche cachée et couche de sortie). De plus, nous utilisons les deux fonctions d'activation de Logsig et Tansig au niveau de la couche cachée, et le nombre de neurones est ajusté entre 3 et 5.

Comme le montre le tableau 4.13, il existe de grandes similitudes dans les résultats obtenus entre les modèles de MLPNN utilisés, que ce soit en utilisant une fonction Logsig ou Tansig. Même avec l'ajustement du nombre de neurones dans la couche cachée, les résultats étaient similaires. Tous les modèles appliqués ont donné une classification correcte dans

l'apprentissage et dans le test (précision = 100%). En comparant le temps d'apprentissage et de test, tous les modèles ont pris environ 0,03 et 3s.

En particulier, nous pouvons remarquer que le modèle de MLPNN pour cinq neurones avec une fonction Tansig a donné les meilleures performances. ce modèle offre un MSE égale à 6.37×10^{-15} et un MAE de 2.18×10^{-08} . Par conséquent, la figure 4.21 montre la

Table 4.13: Performance de MLPNN pour détecter un court-circuit entre spires

Fonction d'activation	Nombre de neurones	Précision d'apprentissage (%)	Précision de test(%)	Durée d'apprentissage(s)	Durée de test (s)	MSE	MAE
Logsig	3	100	100	0.05	0.04	3.03×10^{-06}	6.1×10^{-04}
	4	100	100	0.03	0.03	7.11×10^{-08}	8.75×10^{-05}
	5	100	100	0.03	0.03	1.39×10^{-12}	5.96×10^{-07}
Tansig	3	100	100	0.36	0.15	5.98×10^{-12}	1.05×10^{-06}
	4	100	100	0.22	0.04	3.91×10^{-14}	6.06×10^{-08}
	5	100	100	0.05	0.04	6.37×10^{-15}	2.18×10^{-08}

sortie estimée par ce modèle par rapport à la sortie réelle (cible). On peut noter donc qu'il existe une similitude entre la sortie estimée et la cible. Donc, ce modèle est sélectionné




Figure 4.19: Base de données d'apprentissage et leur sortie correspondant pour une MAS saine et en court-circuit entre les spires




Figure 4.20: Base de données de test pour une machine saine et en court-circuit entre les spires

comme le meilleur MLPNN pour détecter le court-circuit entre spires.




Figure 4.21: Sortie de MLPNN (Tansig, 05 neurones)- court circuit entre spires

4.3.2.2 Application de RBFNN pour détecter un court-circuit entre spires

Comme mentionné précédemment, la structure de RBFNN est fixe, elle se compose de trois couches, une couche d'entrée et une couche de sortie et une couche cachée avec une fonction d'activation du type gaussienne. Par conséquent, dans ce cas, nous modifions uniquement le nombre de neurones au niveau de la couche cachée pour prendre les valeurs 15, 18, 20, 25. Donc, les résultats obtenus (Tab.4.14) montrent que le modèle de RBFNNs avec 18 neurones donne la meilleure classification par rapport les autres modèles. Ce modèle a donné un taux d'apprentissage de 91.07% et 89.24 dans le test. De plus, $MSE = 0,13$ et $MAE = 0,2$. Selon ce modèle, la figure 4.22 montre la sortie de RBFNN

Table 4.14: Performance de RBFNN pour détecter un court-circuit entre spires

Nombre de neurones	Précision d'apprentissage (%)	Précision de test(%)	Durée de l'apprentissage(s)	Durée de test	MSE	MAE
15	90.17	89.24	0.30	0.02	0.15	0.23
18	91.07	89.24	0.33	0.02	0.13	0.20
20	92.85	88.17	0.31	0.02	0.13	0.2
25	92.85	83.87	0.33	0.02	0.12	0.19

par rapport à la sortie réelle. Dans ce cas, la sortie estimée par RBFNN dans la phase de l'apprentissage montre six cas (08) mal classés. De plus, la phase de test montre neuf instances (11) classées incorrectement.




Figure 4.22: Sortie de RBFNN pour 18 neurones- court-circuit entre spires

4.3.2.3 Application d'ELM pour détecter un court-circuit entre spires

Dans ce cas, nous appliquerons cinq modèles d'ELM pour détecter le court-circuit entre spires. Donc, le tableau 4.15 présente le résultat obtenu par les quatre modèles (04) pour 20, 22, 25, 27 neurones dans la couche cachée.

Donc, les résultats d'apprentissage et de test montrent que le modèle défini par 25 neurones a fourni la meilleure classification par rapport aux quatre autres modèles. Dans ce cas, la précision de l'apprentissage et de test est, respectivement, est 91.21% et 90, 32%. De plus, le MSE et le MAE prennent respectivement des valeurs significatives de 0, 14 et 0, 21. La figure 4.23 présent la sortie de ELM pour 25 neurones dans la couche cachée. Dans la phase d'apprentissage, il y a huit instances 08 où l'ELM n'a pas pu identifier leur sortie

Table 4.15: Performance de ELM pour détecter un court-circuit entre spires

Nombre de neurones	Précision de l'apprentissage (%)	Précision de test(%)	Durée de l'apprentissage (s)	Durée de test	MSE	MAE
20	89.75	87.09	0.09	0.05	0.15	0.22
22	89.26	84.94	0.10	0.03	0.13	0.19
25	91.21	90.32	0.11	0.04	0.14	0.21
27	88.29	82.87	0.09	0.03	0.12	0.18

correspondante. De plus, seize instances 16 sont incorrectement classées dans la phase de test.




Figure 4.23: Sortie d'ELM de 25 neurones- court-circuit entre spires

4.3.2.4 Application de SVM pour détecter un court-circuit entre spires

Donc, nous appliquerons à nouveau six modèles de SVM pour détecter le défaut de court-circuit entre les spires. Nous allons donc appliquer trois modèles avec la stratégie OVO et le reste avec la stratégie de OVA. Pour chaque stratégie, nous appliquons trois fonctions de noyau: Linéaire, gaussienne et polynomiale. Le tableau 4.16 montre les résultats obtenus par chaque modèle.

On peut constater qu'il existe deux modèles -SVM polynomiale avec les deux stratégies OVO et OVA- qui ont donné des résultats complets en apprentissage et en test. Les deux modèles ont montré des performances élevées ($MSE = 0$ et $MAE = 0$). Parmi ces deux modèles, nous avons sélectionné le SVM-polynomial avec stratégie de OVA comme le meilleur modèle de SVM pour détecter le court-circuit entre les pires. Nous garderons

Table 4.16: Performance de SVM pour détecter un court-circuit entre spires

Stratégie	Fonction de noyau	Précision d'apprentissage(%)	Précision de test(%)	Durée de l'apprentissage(s)	Durée de test (s)	MSE	MAE
OVO	Linéaire	99.1	100	0.05	0.04	0.03	0.01
	Gaussienne	100	64.5	0.05	0.04	0	0
	Polynomiale	100	100	0.05	0.05	0	0
OVA	Linéaire	99.11	100	0.06	0.05	0.03	0.01
	Gaussienne	100	64.51	0.06	0.06	0	0
	Polynomiale	100	100	0.04	0.04	0	0

les résultats de ce modèle pour les comparer avec les résultats d'autres classificateurs (MLPNN, RBFNN, kNN,...). Selon ce modèle de SVM, la figure 4.24 présente la sortie estimée par rapport la sortie réelle. On peut noter qu'il existe une grande similitude entre la sortie estimée par SVM et la sortie réelle. Le SVM a donc réussi à détecter tous les échantillons d'apprentissage (112/112) et de test (93/93).




Figure 4.24: Sortie de SVM (OVA, polynomiale)- court-circuit entre spires

4.3.2.5 Application de kNN pour détecter un court-circuit entre spires

Dans ce cas, nous appliquerons neuf modèles de kNN pour trouver le meilleur modèle en fonction des résultats de classification obtenus. Nous allons donc appliquer trois méthodes pour calculer la distance métrique (cosinus, euclidien, city-block). Dans chaque cas, nous changeons le k entre 1 et 3. Par conséquent, le tableau 4.17 présente les résultats obtenus en appliquant les neuf (09) modèles sélectionnées. On peut donc noter que les trois premiers modèles de kNN (kNN-cosinus) ont réussi à détecter l'état de la MAS avec une

grande précision (précision = 100%, le MSE et le MAE sont nuls). Les six autres modèles ont réussi la phase d'apprentissage, mais n'ont pas réussi à classer correctement tous les échantillons de tests. Par conséquent, nous choisirons le modèle de kNN-cosinus pour $k=3$ comme meilleur modèle de kNN pour détecter le défaut de court-circuit entre les spires. Selon ce modèle, la figure 4.25 montre la sortie estimée par le kNN et la sortie réelle dans la phase de l'apprentissage et de test. On peut noter que la sortie estimée par kNN est complètement identique à la sortie réelle, que ce soit dans l'apprentissage (122/112) ou dans le test (93/93).

Table 4.17: Performance de kNN pour détecter un court-circuit entre spires

Distance	Nombre de voisins K	Précision d'apprentissage(%)	Précision de test(%)	Durée de l'apprentissage(s)	Durée de test (s)	MSE	MAE
Cosinus	1	100	100	0.11	0.03	0	0
	2	100	100	0.15	0.04	0	0
	3	100	100	0.09	0.03	0	0
Euclidien	1	100	80.64	0.09	0.03	0	0
	2	100	80.64	0.09	0.06	0	0
	3	100	96.77	0.09	0.04	0	0
City-block	1	100	83.87	0.08	0.03	0	0
	2	100	83.87	0.11	0.04	0	0
	3	100	94.62	0.09	0.03	0	0




Figure 4.25: Sortie de kNN (cosinus, $k=3$)- court circuit entre spires

Table 4.18: Performance de NB pour détecter un court-circuit entre spires

Fonction de distribution	Précision d'apprentissage(%)	Précision de test(%)	Durée de l'apprentissage(s)	Durée de test (s)	MSE	MAE
Gaussienne	94.64	96.77	0.03	0.03	0.32	0.12
Kernel	96.42	64.51	0.04	0.04	0.25	0.12

4.3.2.6 Application de NB pour détecter un court-circuit entre spires

Dans cette partie, l'algorithme de NB est appliqué pour détecter le défaut de court-circuit entre les spires. Pour cela, nous appliquons deux modèles de NB: NB-gaussienne et NB-kernel. Le tableau 4.18 présente le résultat obtenu par les deux modèles. En comparant les résultats obtenus, nous pouvons choisir le NB-gaussienne comme meilleur classificateur. Ce modèle donne un taux d'apprentissage de 96,64% et 96,77% pour le test. De plus, le MSE = 0,32 et MAE = 0,12. Donc, la figure 4.26 montre la sortie estimée par NB




Figure 4.26: Sortie de NB gaussienne- court-circuit entre spires

gaussienne par rapport à la sortie réelle (la cible). Il y a donc quatre instances classées incorrectement dans la phase d'apprentissage. Dans le test, trois instances mal classées.

4.3.2.7 Application de DT pour détecter un court-circuit entre spires

Dans cette partie, nous avons appliqué le DT pour détecter le défaut de court-circuit entre les spires. Par conséquent, le tableau 4.19 montre les résultats obtenus par les trois modèles de DT basés sur trois fonctions de distribution.

On peut donc remarquer que les trois modèles utilisés donnent les mêmes performances où le taux d'apprentissage est 94.42%, et 66.66% pour le test, le MSE = 0.08 et MAE = 0.05.

Table 4.19: Performance de DT pour détecter un court-circuit entre spires

Fonction de distribution	Précision d'apprentissage(%)	Précision de test(%)	Durée de l'apprentissage(s)	Durée de test (s)	MSE	MAE
deviance	94.64	61.29	0.03	0.03	0.13	0.08
twoing	91.64	62.36	0.03	0.03	0.13	0.08
gdi	94.42	66.66	0.05	0.03	0.08	0.05

Donc, la figure 4.27 montre la sortie de DT-gdi par rapport à la sortie réelle. On peut




Figure 4.27: Sortie de DT gdi- court-circuit entre spires

noter donc qu'il y a 04 instances qui ne sont pas correctement classés dans la phase d'apprentissage et aussi 31 instances qui sont mal classés dans le test. Par conséquent, on peut conclure que la technique DT s'est révélée dans ce cas inefficace pour détecter le court-circuit entre les spires.

4.3.2.8 Application de RF pour détecter un court-circuit entre spires

De la même manière ci-dessus (ss.sec.4.2.2.8), nous avons choisi trois modèles de RF avec 25, 28, 30 arbres pour détecter le court-circuit entre les spires. Donc, le tableau 4.20 montre les résultats obtenus. En conséquence, nous avons choisi le RF avec 25 arbres (apprenants) comme meilleur modèle de détection. La figure 4.28 montre la sortie de RF pour 25 cycles d'apprenants. Nous pouvons noter que ce modèle a réussi à classer les 112 instances d'apprentissage, mais il n'a pas réussi à classer 12 instances dans le test.

Table 4.20: Performance de RF pour détecter un court-circuit entre spires

Nombre de cycles d'apprenants	Précision d'apprentissage(%)	Précision de test(%)	Durée de l'apprentissage(s)	Durée de test (s)	MSE	MAE
25	100	87.09	0.06	0.06	0	0
28	100	86.02	0.06	0.06	0	0
30	100	86.02	0.06	0.07	0	0




Figure 4.28: Sortie de RF (25 arbres)- court-circuit entre spires

4.3.2.9 Application de DA pour détecter un court-circuit entre spires

Dans cette partie, nous avons appliqué trois modèles de DA pour détecter et localiser le court-circuit entre les spires. Par conséquent, le tableau 4.21 présente le résultat de classification de chaque modèle.

Sur la base de ces résultats, nous pouvons choisir l'DA-linéaire et l'DA-quadratique comme les meilleurs modèles pour détecter le court-circuit entre les spires. Parmi ces deux modèles, on choisit donc l'DA-quadratique. Ce modèle a fourni un taux d'apprentissage de 100% et 100% pour le test. De plus, le MSE et MAE sont nuls.

Table 4.21: Performance de DA pour détecter un court-circuit entre spires

Type de discriminant	Précision d'apprentissage(%)	Précision de test(%)	Durée de l'apprentissage(s)	Durée de test (s)	MSE	MAE
Linéaire	100	100	0.03	0.03	0	0
Quadratic	100	100	0.03	0.03	0	0
Diagquadratic	96.77	96.64	0.03	0.03	0.32	0.12




Figure 4.29: Sortie de DA quadratique- court-circuit entre spires

La figure 4.29 montre la sortie de DA-quadratique par rapport à la sortie réelle. Donc, toutes les instances d'apprentissage 112/112 ont été classées correctement. De plus, 93/93 instances sont classées correctement dans le test.

4.3.3 Discussion des résultats de MLAs pour détecter un court-circuit entre spires

Selon les figures 4.21-4.29, il est montré que la sortie estimée par le MLPNN, le SVM et le kNN et l'DA est similaire à la sortie réelle (la cible), et donc le nombre d'instances correctement classée est de 112/112 pour l'apprentissage et 93/93 pour le test. En particulier, le SVM, kNN et l'DA ont montré des performances élevées ($MSE = 0$ et $MAE = 0$) par rapport au le MLPNN que donne un $MSE = 6.37 \times 10^{-15}$.

Le RBFNN et l'ELM ont réussi à classer juste 104 échantillons dans la phase d'apprentissage. Dans le test, le RBFNN a réussi à classer juste 82 échantillons et 77 par l'ELM.

L'algorithme de NB n'a pas réussi à classifier 05 instances d'apprentissage et 03 instances de test. L'DT a montré une performance faible par rapport à d'autres algorithmes, car il y a 04 instances mal classées dans la phase d'apprentissage et également 31 instances mal classées dans la phase de test. La RF a réussi à classer toutes les instances d'apprentissage (112/112) mais il n'a pas réussi à classer 12 instances de test.

Comme résumé, le tableau 4.22 présente un arrangement décroissant des meilleurs classificateurs utilisés. Donc, le SVM, kNN, et l'DA sont présentés comme les meilleurs classificateurs pour détecter le court-circuit entre spires. Dans la quatrième range, on retrouve le MLPNN. Dans les dernières ranges, on retrouve respectivement le NB, ELM,

RBFNN, RF et DT.

Table 4.22: Arrangement des MLAs appliqués pour détecter un court-circuit entre spires

Rang	Classificateur	Précision d'apprentissage (%)	Précision de test (%)	Durée d'apprentissage (s)	Durée de test (s)	MSE	MAE
1	SVM	100	100	0.04	0.04	0	0
2	DA	100	100	0.03	0.03	0	0
3	kNN	100	100	0.09	0.03	0	0
4	MLPNN	100	100	0.05	0.04	6.37×10^{-15}	2.18×10^{-08}
5	NB	94.64	96.77	0.03	0.03	0.32	0.12
6	ELM	91.21	90.32	0.11	0.04	0.14	0.21
7	RBFNN	91.07	89.24	0.33	0.02	0.13	0.2
8	RF	100	87.09	0.06	0.06	0	0
9	DT	94.42	66.66	0.05	0.03	0.08	0.05

Dans ce qui suit, nous présenterons un système de diagnostic capable de détecter différents types de défauts, qu'il s'agisse de barres cassées, d'un court-circuit entre spires ou d'un défaut simultané.

4.4 MLAs pour détecter un défaut simultané

Dans la section précédente (Sec.4.2), le système conçu (Fig.4.3) permet de détecter si la MAS est saine ou une MAS avec des barres cassées. Ce système ne peut pas détecter s'il y a ou non un défaut de court-circuit, ni ne peut détecter un défaut simultané. Il en va de même pour la Sec.4.3, le système de diagnostic (Fig.4.18) ne peut détecter que si la MAS est saine ou en court-circuit entre spires dans l'une de ses trois phases statoriques. Par conséquent, un système de diagnostic complémentaire doit être conçu pour permettre le diagnostic d'un défaut simultané. Donc, dans cette section, nous allons concevoir un système capable de détecter un défaut simultané (rupture des barres et court-circuit entre spires).

La première étape qui sera franchie est le processus de collecte de données à utiliser pour l'apprentissage et le test de chaque algorithme. Par conséquent, dans ce cas, trois caractéristiques seront utilisées comme entrées pour tous les MLAs. Ces caractéristiques sont la fréquence $2gf_s$ et son amplitude $A2gf_s$ ainsi que l'amplitude $A2f_s$ correspondant à fréquence $2f_s$. Donc, ces entrées seront extraites en appliquant une analyse spectrale par FFT de l'enveloppe de Hilbert de i_{sa} .

La figure 4.30 montre les étapes principales dans la détection de l'état de MAS de

l'extraction et de traitement de signaux, puis l'apprentissage et le test de chaque MLA séparément.




Figure 4.30: Représentation schématique pour détecter un défaut simultané à l'aide des MLAs

4.4.1 Extraction d'une base de données en cas de défaut simultané

Dans cette partie, les fréquences $2gf_s$ et leur amplitude $A2gf_s$, en plus de l'amplitude $2f_s$ correspondant aux fréquences $2f_s$, sont extraites par la FFT de l'enveloppe de courant statorique-phase a (HM de i_{sa}) et utilisées comme entrées pour entraîner les neuf MLAs précédents. Ces entrées seront extraites dans différentes conditions de fonctionnement soit

une MAS saine, en rupture des barres, en court-circuit entre spires, ou MAS en défaut simultané.

Donc, une base de données pour l'apprentissage (Fig.4.31) est collectée pour une charge de 1, 2, 3, 4, 5, 6, 7Nm comme suivant:

- MAS saine (07 échantillons);
- MAS avec une et deux barres cassées (14 échantillons);
- MAS avec 2, 4, 8, 12 spires court-circuitées (28 échantillons);
- MAS avec 2, 4, 8, 12 spires court-circuitées et une ou deux barres cassées (56 échantillons);

La cible sélectionnée peut prendre l'un de ces libellés 0, 1, 2, 3, où 0 représente une machine saine. L'étiquette 1 pour un défaut de rupture des barres, 2 en cas de court-circuit entre les spires et 3 pour un défaut simultané. Donc, la base de données d'apprentissage totale est de 105, où $105 = 07 + 14 + 28 + 56$. Dans la même manière, la base de données de test (Fig.4.32) est collectée pour une charge de 1.5, 3.5, 5.5, 6.5Nm. Donc, on obtient le suivant:

- MAS saine (04 échantillons);
- MAS avec une et deux barres cassées (08 échantillons);
- MAS avec 3, 6, 10, 20 spires court-circuitées (16 échantillons);
- MAS avec 3, 6, 10, 20 spires court-circuitées et une ou deux barres cassées (32 échantillons);

Donc, la base de données totale de test est 60 échantillons, tels que: $60 = 04 + 08 + 16 + 32$. Après avoir terminé le processus de collecte de la base de données. Nous appliquons les neuf MLAs ci-dessous pour détecter la situation de la MAS, qu'elle s'agisse d'une machine saine ou défectueuse.

4.4.1.1 Application de MLPNN pour détecter un défaut simultané

Dans ce cas, nous maintenons la même structure de MLPNN que dans le tableau ci-dessus (Tab.4.1) c'est-à dire MLPNN avec une couche d'entrée, une couche cachée et une couche de sortie. De plus, deux fonctions d'activation de Logsig et Tansig sont appliquées dans la couche cachée, le nombre de neurones est ajusté entre 3 et 5 neurones.

Selon ces conditions, nous obtiendrons six modèles de MLPNN. Le tableau 4.23 montre




Figure 4.31: Base de données d'apprentissage et leur sortie correspondante pour un défaut simultané




Figure 4.32: Base de données de test pour un défaut simultané

Table 4.23: Performance de MLPNN pour détecter un défaut simultané

Fonction d'activation	Nombre de neurones	Précision d'apprentissage (%)	Précision de test (%)	Durée de l'apprentissage (s)	Durée de test (s)	MSE	MAE
Logsig	3	100	100	2.00	0.06	3.52×10^{-14}	7.86×10^{-08}
	4	100	100	2.23	0.05	5.61×10^{-14}	1.10×10^{-07}
	5	100	100	2.76	0.05	5.39×10^{-12}	1.67×10^{-06}
Tansig	3	100	100	0.98	0.05	1.11×10^{-14}	4.62×10^{-08}
	4	100	100	0.97	0.11	5.58×10^{-14}	6.21×10^{-08}
	5	100	100	4.25	0.06	1.33×10^{-09}	2.87×10^{-05}

les performances de chaque modèle. Les résultats obtenues montrent que les six modèles de MLPNN ont donné une précision de 100% d'apprentissage et de test. Le temps requis

pour l'apprentissage et les tests est également proche de tous les modèles. Pour le MSE et MAE, tous les modèles ont donné des résultats acceptables. Donc, nous avons sélectionné le modèle spécifique à trois neurones avec la fonction Tansig comme le meilleur modèle de MLPNN qui permet de détecter la situation de la MAS.

Par conséquent, la figure 4.33 montre la sortie estimée par le MLPNN par rapport à la sortie réelle (cible). On peut noter donc qu'il existe une similitude entre la sortie estimée et la cible, soit dans l'apprentissage soit dans le test.




Figure 4.33: Sortie de MLPNN (Tansig, 03 neurones)- défaut simultané

4.4.1.2 Application du RBFNN pour détecter un défaut simultané

Dans ce cas, nous modifions le nombre de neurones au niveau de la couche cachée pour prendre les valeurs 20, 21, 22, 25. Donc, les résultats obtenus dans le tableau 4.24 montrent

Table 4.24: Performance de RBFNN pour détecter un défaut simultané

Nombre de neurones	Précision d'apprentissage (%)	Précision de test(%)	Durée de l'apprentissage(s)	Durée de test	MSE	MAE
20	100	100	3.71	0.08	4.83×10^{-04}	0.01
21	100	100	1.10	0.07	3.89×10^{-04}	0.01
22	100	100	1.14	0.07	3.87×10^{-04}	0.01
25	100	100	1.02	0.07	3.55×10^{-4}	0.01

que le modèle de RBFNN avec 25 neurones donne la meilleure classification par rapport les autres modèles. Ce modèle a donné une précision d'apprentissage de 100%, une précision

de test de 100%, $MSE = 3.55 \times 10^{-4}$ et $MAE = 0,01$.

Selon ce modèle, la figure 4.22 montre la sortie de RBFNN par rapport à la sortie réelle. Dans ce cas, la sortie estimée par RBFNN dans la phase de l'apprentissage montre les échantillons sont classés correctement (105/105). Même chose pour la phase de test, tous les échantillons sont classés correctement (60/60).




Figure 4.34: Sortie de RBFNN pour 25 neurones- défaut simultané

4.4.1.3 Application de ELM pour détecter un défaut simultané

Le tableau 4.25 présente le résultat obtenu par les quatre modèles (04) selon le nombre de neurones de la couche cachée (20, 21, 22, 25). Donc, les résultats d'apprentissage et de test montrent que le modèle défini par 25 neurones a fourni la meilleure classification par rapport aux trois autres modèles. Ce modèle a une précision de 100% dans les deux phases (apprentissage et test). De plus, $MSE = 4.76 \times 10^{-4}$ et $MAE = 0,01$.

La figure 4.35 montre la sortie d'ELM pour 25 de neurones dans la couche cachée. Donc,

Table 4.25: Performance d'ELM pour détecter un défaut simultané

Nombre de neurones	Précision d'apprentissage (%)	Précision de test (%)	Durée de l'apprentissage (s)	Durée de test	MSE	MAE
20	100	100	0.25	0.11	4.98×10^{-04}	0.01
21	100	100	0.26	0.10	6.37×10^{-04}	0.01
22	100	100	0.29	0.10	4.92×10^{-04}	0.01
25	100	100	0.09	0.04	4.76×10^{-4}	0.01

on peut remarquer que tous les échantillons de l'apprentissage et de test sont classés correctement.




Figure 4.35: Sortie d'ELM pour 25 neurones- défaut simultané

4.4.1.4 Application de SVM pour détecter un défaut simultané

De la même manière que nous avons utilisé le SVM dans les deux sous-sections précédentes (ss-sect.4.2.2.4,4.3.2.4), nous appliquerons l’algorithme de SVM pour détecter l’état de la MAS dans cette partie. Nous allons donc appliquer trois modèles avec la stratégie de OVO et trois modèles avec la stratégie de OVA. Pour chaque stratégie, nous appliquons trois fonctions noyau: Linéaire, gaussienne et polynomiale. Le tableau 4.26 montre les résultats de chaque modèle.

Selon le tableau 4.26, nous pouvons noter que les six modèles ont donné des résultats

Table 4.26: Performance de SVM pour détecter un défaut simultané

Stratégie	Fonction de noyau	Précision d'apprentissage(%)	Précision de test(%)	Durée de l'apprentissage(s)	Durée de test (s)	MSE	MAE
OVO	Linéaire	100	100	1.43	0.06	0	0
	Gaussienne	100	100	1.4	0.12	0	0
	Polynomiale	100	100	1.81	0.07	0	0
OVA	Linéaire	100	100	1.07	0.06	0	0
	Gaussienne	100	100	1.4	0.12	0	0
	Polynomiale	100	100	0.96	0.05	0	0

complets dans le processus d'apprentissage et de test (100%) et (MSE = 0 et MAE = 0).

Parmi ces deux modèles, nous avons sélectionné le sixième modèle (SVM-polynomiale avec OVA) comme le meilleur modèle de SVM. Donc, la figure 4.36 présente la sortie estimée par ce modèle par rapport à la sortie réelle (la cible). On peut noter qu'il existe une grande similitude entre la sortie estimée et la sortie réelle. Le SVM a donc réussi à détecter tous les échantillons d'apprentissage (105/105) et de test (60/60).




Figure 4.36: Sortie de SVM (OVA, Polynomiale)- défaut simultané

4.4.1.5 Application de kNN pour détecter un défaut simultané

Dans ce cas, nous appliquerons neuf modèles de kNN. Nous allons donc appliquer trois méthodes pour calculer la distance métrique: cosinus, euclidien, city-block. Pour chaque méthode, on change le nombre de voisins K entre 1 et 3. Par conséquent, le tableau 4.27 présente le résultat obtenu de chaque modèle.

On peut noter donc que les neuf modèles de kNN ont réussi à détecter l'état de la MAS avec une grande performance (précision=100%, le MSE et MAE sont nuls).

Parmi ces modèles, le modèle défini par une fonction euclidienne et $k = 3$ a été sélectionné comme le meilleur classificateur de kNN pour détecter le défaut simultané.

Selon ce modèle, la figure 4.37 montre la sortie estimée par le kNN et la sortie réelle dans la phase de l'apprentissage et de test. On peut noter que la sortie estimée par kNN est complètement identique à la sortie réelle, que ce soit dans la phase d'apprentissage soit dans le test (100%).

Table 4.27: Performance de kNN pour détecter un défaut simultané

Distance	Nombre de voisins K1	Précision d'apprentissage(%)	Précision de test(%)	Durée de l'apprentissage(s)	Durée de test (s)	MSE	MAE
Cosinus	1	100	100	3.61	0.06	0	0
	2	100	100	0.99	0.06	0	0
	3	100	100	0.80	0.06	0	0
Euclidien	1	100	100	0.64	0.05	0	0
	2	100	100	0.60	0.05	0	0
	3	100	100	0.62	0.05	0	0
City-block	1	100	100	0.62	0.04	0	0
	2	100	100	1.09	0.09	0	0
	3	100	100	0.77	0.06	0	0




Figure 4.37: Sortie de kNN (Euclidien, K = 3)- défaut simultané

4.4.1.6 Application du NB pour détecter un défaut simultané

Dans ce cas, on applique deux modèles de NB pour détecter le défaut simultané. Comme le montre le tableau 4.28, les deux modèles de NB offrent de grandes performances dans la détection de ce type de défaut telle que le taux d'apprentissage est de test est égale a 100%, de plus le MSE = 0 et MAE = 0. Alors, parmi ces deux modèles, nous avons choisi le modèle de NB-gaussienne comme meilleur modèle pour détecter le défaut simultané.

Basé sur ce modèle, la figure 4.38 montre clairement que la sortie estimée par NB-Gaussienne est identique à la cible soit dans la phase d'apprentissage (105/105) soit dans le test (60/60).

Table 4.28: Performance de NB pour détecter un défaut simultané

Fonction de distribution	Précision d'apprentissage(%)	Précision de test(%)	Durée de l'apprentissage(s)	Durée de test (s)	MSE	MAE
Gaussienne	100	100	0.03	0.03	0	0
Kernel	100	100	0.04	0.04	0	0




Figure 4.38: Sorties de NB gaussienne- défaut simultané

4.4.1.7 Application de DT pour détecter pour détecter un défaut simultané

De la même manière, nous appliquons le DT avec trois types de fonctions de distribution pour détecter l'état de la MAS. Le nombre maximum de split est fixé à 5.

Le tableau 4.29 présente le résultat obtenu par chaque modèle de DT. Donc, les trois modèles appliqués donnent une grande performance telle que le taux d'apprentissage et de test est égal à 100%. De plus, le temps d'apprentissage et de test est très court 0.3s. Même le MSE et le MAE sont nuls dans les trois cas. Parmi ces modèles, nous avons choisi le modèle de DT-gdi. Donc, la figure 4.39 montre la sortie du modèle DT-gdi. On peut clairement noter que la production estimée par ce modèle et la cible sont identiques.

Table 4.29: Performance de DT pour détecter un défaut simultané

Fonction de distribution	Précision d'apprentissage(%)	Précision de test(%)	Durée de l'apprentissage(s)	Durée de test (s)	MSE	MAE
deviance	100	100	0.03	0.03	0	0
twoing	100	100	0.03	0.03	0	0
gdi	100	100	0.03	0.03	0	0




Figure 4.39: Sortie de DT gdi- défaut simultané

Table 4.30: Performance de RF pour détecter un défaut simultané

Nombre de cycles d'apprenants	Précision d'apprentissage(%)	Précision de test(%)	Durée de l'apprentissage(s)	Durée de test (s)	MSE	MAE
25	100	100	0.07	0.07	0	0
28	100	100	0.07	0.08	0	0
30	100	100	0.07	0.07	0	0

4.4.1.8 Application du RF pour détecter un défaut simultané

Pour détecter le défaut simultané, nous avons appliqué les trois modèles de RF précédents pour 25, 28 et 30 cycles d'apprenants. Alors, le tableau 4.30 présente le résultat classification de chaque modèle de RF. On peut noter donc que les trois modes offrent de grandes performances telles que le taux d'apprentissage et de test est 100%. De plus, le MSE et le MAE sont nuls. Parmi ces modèles, nous avons choisi le modèle de RF avec 25 cycles. Donc, la figure 4.40 montre la sortie de RF pour 25 cycles. On constate clairement que la sortie estimée (apprentissage et test) par ce modèle et la cible sont identiques.

4.4.1.9 Application du DA pour détecter un défaut simultané

Dans ce cas, nous appliquons les trois modèles de DA pour détecter le défaut simultané. Alors, le tableau 4.31 présente le résultat fournit par chaque modèle de DA. En conséquence, les trois modèles offrent une grande précision d'apprentissage et de test (100%). De plus, le MSE et le MAE sont nuls.

La figure 4.41 montre la sortie de DA-quadratique. Nous pouvons observer que toutes les




Figure 4.40: Sortie de RF (25 cycles)- défaut simultané

Table 4.31: Performance de DA pour détecter un défaut simultané

Type de discriminant	Précision d'apprentissage(%)	Précision de test(%)	Durée de l'apprentissage(s)	Durée de test (s)	MSE	MAE
Linéaire	100	100	0.06	0.04	0	0
Quadratique	100	100	0.03	0.03	0	0
Diago-quadratique	100	100	0.05	0.06	0	0.0




Figure 4.41: Sortie de DA quadratique- défaut simultané

instances d'apprentissage et de test sont correctement classées.

4.4.2 Discussion des résultats de MLAs pour détecter un défaut simultané

Selon les figures 4.33-4.41, on peut noter que tous les classificateurs sélectionnés ont réussi à classer tous les échantillons d'apprentissage et de test.

Selon les tableaux 4.26-4.31, nous pouvons conclure ce qui suit: le six modèles de SVM, kNN, NB, DT, RF et DA (Tab.4.26,4.27,4.28,4.29,4.30,4.31) ont montré de grandes performances pour $MSE = 0$ et $MAE = 0$.

le MLPNN (Tab.4.23) a donné un $MSE = 1.11 \times 10^{-14}$ et $MAE = 4.62 \times 10^{-08}$.

Les deux classifications RBFNN (Tab.4.24) et ELM (Tab.4.25) ont donné des résultats très similaires, $MSE = 3.55 \times 10^{-4}$ et $MAE = 0.01$

Nous pouvons remarquer que les algorithmes de NB, DT et DA ont montré un temps court dans le processus d'apprentissage et de test (0.03s) par rapport au reste des autres algorithmes. Pour cela, le tableau 4.32 présente un arrangement descendant pour le meilleur modèle sélectionné pour chaque algorithme. Donc, le NB est en premier rang, suivi de DT et le DA. En quatrième rang, nous trouvons le RF, suivi par le kNN et le SVM. Dans le dernier rangs, nous trouvons le MLPNN, RBFNN et l'ELM.

Table 4.32: Arrangement des MLAs appliques pour détecter un défaut simultané

Rang	Classificateur	Précision d'apprentissage (%)	Précision de test (%)	Durée d'apprentissage (s)	Durée de test (s)	MSE	MAE
1	NB	100	100	0.03	0.03	0	0
2	DT	100	100	0.03	0.03	0	0
3	DA	100	100	0.03	0.03	0	0
4	RF	100	100	0.07	0.07	0	0
5	kNN	100	100	0.62	0.05	0	0
6	SVM	100	100	0.96	0.05	0	0
7	MLPNN	100	100	0.98	0.05	1.11×10^{-14}	4.62×10^{-08}
8	RBFNN	100	100	1.02	0.07	3.55×10^{-4}	0.01
9	ELM	100	100	0.09	0.04	4.76×10^{-4}	0.01

Remarque: Il est important de noter que tous les MLAs qui seront présentés dans cette section (Sec.4.4) sont des algorithmes permettant de détecter uniquement le type de défaut (Fig.4.30). Cela signifie que ces algorithmes ne sont pas conçus pour identifier le nombre de barres cassées ou la phase où un court-circuit se produit. L'avantage de ces classificateurs est qu'ils permettent de détecter le défaut simultané.

Par conséquent, l'objectif principal de l'application de ces classificateurs est de définir uniquement la nature du défaut, soit un défaut rotorique, un défaut statorique ou un

défaut simultané.

Dans ce cas, les MLAs conçus dans les deux tableaux précédents (Tab.4.12 et Tab.4.22) doit être conservé pour déterminer le nombre de barres cassées et localisé le court-circuit entre les spires. Donc, si le système de diagnostic indique l'occurrence d'une rupture des barres, alors nous utilisons le système spécifié dans la figure 4.3, mais s'il indique l'occurrence d'un court-circuit, nous actionnons le système de diagnostic qui permet de localiser le court-circuit (Fig.4.18). S'il indique un défaut simultané, les deux systèmes fonctionnent simultanément pour définir le nombre de barres cassées et l'emplacement du court-circuit entre les spires.

4.5 Système global de détection des défauts statoriques-rotoriques de la machine

Il est de noter que parmi les neuf MLAs utilisés pour détecter la rupture des barres rotoriques (Sec.4.2), le court-circuit entre spires (Sec.4.3), ou pour détecter le défaut simultané (Sec.4.4), nous pouvons noter que le classificateur du type SVM-polynomial avec une stratégie de OVA a fourni une excellente performance ($MSE = 0$ et $MAE = 0$). Cela peut être remarqué dans les tableaux 4.6, 4.16 et 4.26. Par conséquent, nous pouvons construire un système de diagnostic basé sur un seul modèle de SVM pour simplifier le processus de diagnostic (Fig.4.42).

4.6 Conclusion

Dans ce chapitre, nous avons appliqué neuf MLAs pour détecter l'état de la MAS, que ce soit une MAS saine ou défaillante.

Dans la première partie du chapitre, nous avons rassemblé une base de données contenant plusieurs exemples d'un rotor en état sain et en défaut. Ces données ont été utilisées pour entraîner et évaluer les performances des MLAs utilisées pour la détection. Les résultats de simulation obtenus montrent que les algorithmes de SVM, kNN et le MLPNN sont plus précises dans le diagnostic du défaut de rupture de barres que les autres algorithmes (RBFNN, ELM, NB, DT, RF et DA).

Dans la deuxième partie du chapitre, nous avons appliqué les neuf MLAs précédents pour détecter les défauts de court-circuit entre spires. Nous avons donc entraîné et testé ces algorithmes via une nouvelle base de données. Encore une fois, le SVM, le kNN et le




Figure 4.42: Système global basé sur SVM (polynomiale, OVA) pour détecter un court-circuit entre spires et / ou une rupture des barres du rotor

MLPNN ont maintenu leurs hautes précisions en détectant l'occurrence d'un court-circuit entre les spires dans l'une des phases statoriques. L'DA a également montré de grandes performances dans la détection des courts-circuits entre les spires. Les autres algorithmes (RBFNN, ELM, NB, DT, RF) ont montré moins précision car il y avait des échantillons

mal classés.

Dans la dernière partie du chapitre, nous avons conçu un système de diagnostic basé sur une autre base de données pour détecter le défaut simultané des barres cassées et court-circuit entre spires. Tous les algorithmes appliqués ont montré de grandes performances dans la détection de la situation de la machine.

Pour simplifier le processus de diagnostic, nous avons construit un système de diagnostic automatique basé sur un seul modèle de SVM pour détecter l'état de la MAS.

Conclusion générale

Cette thèse a traité de la détection de défauts électriques internes d'une MAS à cage d'écureuil à l'aide de techniques d'intelligence artificielle (IA) dont l'objectif principal est de construire un système automatique pour détecter, identifier et localiser chaque type de défaut.

Une revue de la littérature des méthodes souvent utilisées pour suivre l'état des MAS et détecter leurs défauts a été discutée dans le premier chapitre. De plus, nous avons énuméré les avantages et les inconvénients de chacune des méthodes écrites. Il a été conclu que la majorité des méthodes de diagnostic des défauts de MAS se concentrent sur l'étude du signal de courant statorique. En outre, il a été constaté qu'il y a eu une augmentation substantielle de l'incorporation de l'IA dans le domaine du diagnostic et du contrôle des MASs.

Dans le deuxième chapitre, nous avons vérifié le comportement du MAS et ses caractéristiques mécaniques (vitesse de rotor, couple électromagnétique) et électriques (courants statoriques) dans des conditions normales et en cas de rupture des barres du rotor et en cas de court-circuit entre les spires. Pour ce faire, nous avons appuyé sur un modèle mathématique simple (modèle réduit) qui permet de simuler chaque défaut indépendamment ou simultanément. Il a été conclu de ce chapitre que la défaillance d'une partie du MAS entraîne un déséquilibre dans le comportement de ses grandeurs mesurables. De plus, nous avons confirmé que l'effet des barres cassées sur les signaux de MAS est limité par rapport à l'effet du court-circuit entre les spires, il est donc souvent conseillé d'analyser le spectre courant statorique (analyse spectrale) pour évaluer la situation du MAS. Étant donné que le signal de courant du stator est le signal le plus utile pour surveiller et détecter l'état du MAS, une étude d'investigation basée sur l'analyse du courant statorique a été présentée au chapitre trois pour détecter la rupture des barres rotoriques et de court-circuit entre les spires. Pour ce faire, nous avons utilisé trois méthodes de diagnostic: FFT, MUSIC et DWT.

Les résultats de ce chapitre permettent de conclure que l'analyse spectrale (FFT ou MU-

SIC) de l'enveloppe de courant statorique a augmenté l'efficacité et la résolution du diagnostic. Nous pouvons également conclure que la technique de MUSIC présente des avantages par rapport à la FFT. MUSIC élimine les fréquences résultant du bruit du signal. Cependant, le contrôle de ses paramètres est plus complexe que la technique de FFT.

En outre, les résultats obtenus confirment également que la FFT est restée l'une des techniques de spectroscopie les plus efficaces et réussies à ce jour. Cette technique peut fournir des performances acceptables et rapides si la taille du signal analysé est suffisante. Par conséquent, dans le quatrième chapitre, nous avons choisi cette technique (FFT) pour analyser le signal de courant du stator et son enveloppe afin d'extraire des entrées de techniques d'IA.

La DWT s'est également avérée efficace pour détecter l'état du MAS. La surveillance de l'énergie stockée dans les coefficients de détails nous permet également d'indiquer l'état de la MAS. Après avoir extrait les données en appliquant la FFT à l'enveloppe de courant statorique pour différentes conditions des barres du rotor, les neuf algorithmes ont été testés pour détecter l'état des barres, qu'elles soient saines ou cassées. Ces algorithmes ont montré de bonnes performances pour déterminer le nombre de barres cassées. En particulier, les techniques de SVM et KNN et MLPNN ont démontré des performances élevées.

Après cela, une base de données (le déphasage entre les courants statoriques et leurs tensions) a été compilée où il y a un court-circuit entre les spires dans l'une des phases statoriques pour tester l'efficacité de ces algorithmes. En conséquence, des performances élevées ont été démontrées par les SVM, DA, KNN et MLPNN pour détecter ce type de défaut.

Ces algorithmes ont ensuite été appliqués pour détecter le type de défaut lorsqu'un défaut séparé ou un défaut simultané s'est produit. En conséquence, tous les algorithmes utilisés (MLPNN, RBFNN, ELM, SVM, KNN, NB, DT, RF, EM et DA) ont montré des performances élevées.

À la fin du chapitre, un système d'autodiagnostic basé sur SVM a été recommandé. Ce système est basé sur un modèle de SVM unique capable de détecter le défaut simultané, le court-circuit entre spires, et la rupture de barres de rotor. Ce système est basé sur le traitement des signaux de courant statorique afin d'extraire les caractéristiques de chaque défaut ($2gf_s$, $A2gf_s$ et $A2f_s$ et déphasage tension-courant (φ_{sabc}).

– Perspectives

Il est important de noter que ce travail s’est concentré uniquement sur la détection des défauts électriques internes de la MAS. Il est donc recommandé d’étendre ce travail au diagnostic des défauts mécanique (usure des roulements, etc.) ou des défauts externes, tels que les déséquilibres des tensions d’alimentation, etc.

En pratique, la phase de détection et de localisation d’un ou plusieurs défauts est importante mais pas suffisante pour assurer la continuité du fonctionnement du MAS, et il est donc nécessaire d’ajouter des lois de contrôle pour assurer sa continuité et maintenir son efficacité. Par conséquent, nous vous recommandons d’étendre ce travail pour inclure la commande tolérant des défauts de MAS. Généralement, la structure de cette commande incorpore ensemble des blocs de détection et de contrôle.

De plus, les techniques d’AI peuvent être utilisées pour contrôler le fonctionnement du MAS en remplaçant les régulateurs traditionnels (régulateurs PID) par des régulateurs d’AI. D’autre part, nous prévoyons que l’apprentissage profond (DL) remplacera progressivement les méthodes traditionnelles d’algorithmes d’apprentissage automatique (MLAs) pour détecter les défauts des MASs.

Annexe

A.1 Fonctions d'activation de MLPNN

Les fonctions d'activation sont des équations mathématiques qui déterminent la sortie de MLPNN. La fonction est attachée à chaque neurone du réseau et détermine s'il doit être activé ou non, selon que l'entrée de chaque neurone est pertinente pour la prédiction du modèle. Les fonctions d'activation les plus utilisées dans MLPNN sont Tansig, Logsig et purelin.

Ces trois fonctions sont données par ce qui suit [[Dorofki et al., 2012](#), [Konar and Chattopadhyay, 2011](#), [Liu et al., 2018](#)]:

$$\text{Logsig}(x) = \frac{1}{1 + e^{-x}} \quad (4.37)$$

$$\text{Tansig}(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (4.38)$$

$$\text{Purelin}(x) = x \quad (4.39)$$

Selon les équations (4.37), (4.38) et (4.39), on peut noter que quelle que soit la valeur de x , la sortie de la fonction Logsig(x) prend une valeur comprise entre 0 et 1 et prend une valeur entre -1 et 1 pour une fonction Tansig. De plus, la sortie de Purelin(x) est égal de x . Par exemple, si $x = 1000$, Purelin(1000) = 1000.

La figure [A.1](#) présente la courbe de chaque fonction d'activation pour une variable x .

A.2 Fonction gaussienne

Pour l'algorithme de RBFNN, différentes fonctions ont été évaluées en tant que fonctions d'activation. Dans les applications de classification, la fonction gaussienne est la plus utilisée [[Orr et al., 1996](#)].




Figure A.1: Fonctions d'activation de MLPNN

La sortie de la i ème fonction d'activation ϕ_i dans la couche cachée de RBFNN peut être calculée à l'aide de l'équation 4.40 basé sur la distance entre l'entrée x et le centre i .

$$\phi_i(\|x - c_i\|) = e^{\left(-\frac{\|x - c_i\|^2}{2r_j^2}\right)} \quad (4.40)$$

où $\|\cdot\|$ est la norme euclidienne, c_j est le centre et r_j le rayon de neurone caché j .

Ensuite, la sortie du nœud k de la couche de sortie du réseau peut être calculée comme suit:

$$y_k = \sum_{j=1}^n \omega_{jk} \phi_j(x) \quad (4.41)$$

La figure A.2 présente la courbe de fonction gaussienne pour une variable x , $c = 0$ et $r = 1$. Cette fonction a une forme caractéristique de courbe en cloche.

A.3 Fonction noyau de SVM

L'algorithme de SVM utilise un ensemble de fonctions mathématiques définies comme le noyau (Kernel functions). La fonction noyau est de prendre les données en entrée et de les transformer sous la forme requise. Ces fonctions peuvent être de types différents. Par exemple, linéaire, polynomiale, fonction de base radiale (RBF) et sigmoïde [Ali et al., 2019].

La fonction linéaire est la fonction de noyau la plus simple. Elle est donnée par le produit interne (x, y) plus une constante facultative C .

$$k(x, y) = x^T y + C \quad (4.42)$$




Figure A.2: Fonction gaussienne

La fonction polynomiale est une fonction non stationnaire, bien adapté aux problèmes où toutes les données d'apprentissage sont normalisées. Le degré le plus courant est $d = 2$ (quadratique) et $d = 3$ (cubique), car un degré plus élevé a tendance à s'adapter aux problèmes d'apprentissage automatique.

$$k(x, y) = (\alpha x^T y + C)^d \quad (4.43)$$

où $\alpha \geq 0$ est le multiplicateur de Lagrange associés aux contraintes. $C \geq 0$ est une constante qui permet de contrôler le compromis entre nombre d'erreurs de classement, et la largeur de la marge. d c'est le degré polynomial. Ces critères sont ajustés en fonction de la sortie de SVM.

Dans le noyau gaussien (Eq.4.44), λ joue un rôle majeur dans les performances du noyau. Si elle est surestimée, l'exponentielle se comportera presque linéairement et la projection dimensionnelle supérieure commencera à perdre sa puissance non linéaire.

$$k(x, y) = e^{(-\lambda \|x-y\|^2)} \quad (4.44)$$

où, $\lambda = \frac{1}{\sigma^2}$ est un paramètre réglable et $x - y$ est noté comme la distance euclidienne au carré entre les deux vecteurs de caractéristiques.

A.4 Mesures de distance pour kNN

Pour déterminer lesquelles des instances k de l'ensemble de données d'apprentissage sont les plus similaires à une nouvelle entrée, une mesure de distance est utilisée. La mesure

de distance la plus populaire est la distance euclidienne. Cependant, cette fonction (euclidienne) n'est pas applicable à tous les problèmes. Par conséquent, d'autres fonctions de distance incluent telles que: le distance cosinus, Mahalanobis, Minkowski, corrélation, city-block [Bonet et al., 2008]. La figure A.3 montre comment la distance entre deux points peut être mesurée en utilisant la distance euclidienne.

Soit A et B représentés par les vecteurs de caractéristiques $A = (x_1, x_2, \dots, x_m)$ et




Figure A.3: Distance euclidienne entre deux points

$B = (y_1, y_2, \dots, y_m)$, où m est la dimensionnalité de l'espace des caractéristiques. Pour calculer la distance entre A et B, la distance euclidienne normalisée est généralement donnée par:

$$dist(A, B) = \sqrt{\sum_{i=1}^m (x_i - y_i)^2} \quad (4.45)$$

La formule de distance cosinus peut être dérivée de l'équation des produits scalaires:

$$dist(A, B) = \frac{\vec{x}_i \cdot \vec{y}_i}{|\vec{x}_i| |\vec{y}_i|} \quad (4.46)$$

La distance Manhattan (appelée city Block) entre deux points, A et B, avec m dimensions est calculée comme suit:

$$dist(A, B) = \sum_{i=1}^m |x_i - y_i| \quad (4.47)$$

La distance city block, est toujours supérieure ou égale à zéro. La distance est nulle pour des points identiques et élevée pour les points qui présentent peu de similitude.

La distance de Hamming représente le total des différentes positions entre deux séquences. Il mesure le nombre de substitutions minimum nécessaire pour transformer une séquence en l'autre.

$$d(A, B) = \sum_{i=1}^m d(x_i, y_i) \quad d(x_i, y_i) = \begin{cases} 0 \Rightarrow x_i = y_i \\ 1 \Rightarrow x_i \neq y_i \end{cases} \quad (4.48)$$

A.5 Fonctions de distribution pour NB

Pour l'algorithme de NB, la distribution montre essentiellement comment les valeurs sont dispersées en série et à quelle fréquence elles apparaissent dans cette série.

La densité de probabilité de la distribution normale peut être calculée comme [Pérez et al., 2009]:

$$f(x|\mu, \sigma^2) = \frac{1}{\sqrt{2\sigma^2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (4.49)$$

où μ est la moyenne de distribution, σ l'écart-type et σ^2 est la variance. Une distribution gaussienne est illustrée dans la figure A.4.

La distribution du noyau (Kernel en anglais) pondère une densité définie autour de




Figure A.4: Distribution gaussienne

chaque observation x_i également en premier. Pour cela, différentes fonctions du noyau sont utilisées comme distribution normale, triangulaire, Epanechnikov et uniforme.

La probabilité conditionnelle $P(x|C = c_i) = f(x)$ peut être écrite comme une estimation de la densité du noyau pour la classe c_i :

$$P(x|C = c_i) = f(x) \quad (4.50)$$

où:

$$f_i(x) = \sum_{i=1}^N K_i(x, x_i)$$

x_i sont les échantillons d'apprentissage et $K_i(x, x_i)$ est une fonction du noyau.

A.6 Critère de fractionnement de CART

Le fractionnement (en anglais: splitting) est un processus de division d'un nœud en deux sous-nœuds ou plus (Figure 1.22). Le critère de fractionnement (critère de Split) dans une arborescence est spécifié en choisissant la meilleure variable de fractionnement et son seuil pour la division ultérieure [Rokach and Maimon, 2005, Al-Hegami, 2007]. Le fractionnement (en anglais: splitting) est un processus de division d'un nœud en deux ou plusieurs sous-nœuds (Fig.1.22). Le critère de fractionnement dans une structure arborescente est spécifié en choisissant la meilleure variable de fractionnement et son seuil pour le fractionnement ultérieur [Rokach and Maimon, 2005, Al-Hegami, 2007].

Différents critères de fractionnement ont été proposés et utilisés dans différents algorithmes d'arbre de décision tels que l'entropie, le gain d'information, l'indice de diversité de Gini (gdi), towing, la déviance. Dans la classification utilisant l'arbre de décision basé sur l'algorithme de CART (en anglais: Classification And Regression Trees, CART) [Breiman et al., 1984], le critère de fractionnement est l'une des trois mesures suivantes: gdi, towing, ou déviance. en régression, le fractionnement peut être sélectionné pour minimiser le MSE des prédictions par rapport aux données d'apprentissage [Rokach and Maimon, 2005, Al-Hegami, 2007].

Donc, le critère de towing peut être défini comme suivant:

$$\Phi = \frac{P_L P_R}{4} \left[\sum_{j=1}^k |P(c_j/T_L) - P(c_j/T_R)| \right]^2 \quad (4.51)$$

où $P(c_j/T_L)$ et $P(c_j/T_R)$ sont des proportions de points de données dans T_L et T_R qui appartiennent à la classe c_j . La règle de towing est plus appropriée pour les données, qui ont un grand nombre de classes différentes.

Le critère de déviance est donnée par:

$$D(y_i) = -2 \sum_j^k i_{ij} \log(p_j) \quad (4.52)$$

De plus, l'indice de Gini est un critère basé sur les impuretés qui mesure les écarts entre les distributions de probabilité des valeurs de l'attribut cible. Il définit par:

$$Gini(x) = \sum_{j \neq 1} p_j p_i = 1 - \sum_{j=1}^k p_j^2 \quad (4.53)$$

En général, le fractionnement est arrêté lorsque l'une des conditions suivantes est maintenue: Le nœud est pur. Pour la classification, un nœud est pur s'il ne contient que

des observations d'une classe. Pour la régression, un nœud est pur si l'erreur quadratique moyenne (MSE) pour la réponse observée dans ce nœud tombe en dessous de la MSE pour la réponse observée dans l'ensemble de données multipliées par la tolérance sur l'erreur quadratique par nœud. De plus, nous pouvons spécifier le fractionnement maximal pour protéger l'algorithme du sur-apprentissage.

Plus de détails sont disponibles dans [Rokach and Maimon, 2005, Al-Hegami, 2007, Genuer and Poggi, 2017].

A.7 Analyse discriminante linéaire et quadratique

L'objectif de l'Analyse Discriminante (DA) est de produire un nouvel espace de représentation qui permet de distinguer le mieux les M groupes.

Nous supposons que x un vecteur des p variables explicatives sur un nouvel individu que nous voulons classer. La règle géométrique est de calculer la distance de x à chaque m centres de gravité $g_1, \dots, g_m$ et pour affecter x au groupe le plus proche. La règle la plus utilisée est celle de Mahalanobis-Fisher qui consiste à prendre la métrique W^{-1} .

Selon cette règle, la distance entre le nouvel individu et le groupe m est donnée par [Chavent, 2015]:

$$d^2(x, g_m) = (x - g_m)' W^{-1} (x - g_m) \quad (4.54)$$

La règle de géométrie classe une nouvelle observation x dans groupe m^* telle que:

$$\begin{aligned} m^* &= \arg_{m=1, \dots, M} \min d^2(x, g_m) \\ &= \arg_{m=1, \dots, M} \min L_m(x) \end{aligned} \quad (4.55)$$

où, $L_m(x)$ est appelée la fonction linéaire discriminante du groupe m :

$$L_m(x) = x' W^{-1} g_m - \frac{1}{2} g_m' W^{-1} g_m \quad (4.56)$$

De plus, on obtient la règle de classification de l'analyse discriminante quadratique par ce qui suit:

$$m^* = \arg_{m=1, \dots, M} \min Q_m(x) \quad (4.57)$$

où $Q_m(x)$ est appelée la fonction quadratique discriminante du groupe m :

$$Q_m(x) = (x - g_m)' V_m^{-1} (x - g_m) - 2 \ln(\pi_m) + \ln(\det(V_m)) \quad (4.58)$$

où, V^{-1} est équivalent à W^{-1} .

Bibliographie

- [Abed, 2002] Abed, A. (2002). *Contribution à l'Etude et au Diagnostic de la Machine Asynchrone*. PhD thesis, Nancy 1.
- [Abu-Rub et al., 2010] Abu-Rub, H., Ahmed, S. M., Iqbal, A., Rahimian, M., and Toliyat, H. (2010). Incipient bearing fault diagnostics for inverter fed induction motor drive using anfis. In *The XIX International Conference on Electrical Machines-ICEM 2010*, pages 1–5. IEEE.
- [Al-Hegami, 2007] Al-Hegami, A. S. (2007). Classical and incremental classification in data mining process. *Int. J. Comput. Sci. Netw. Security*, 7(12):179–187.
- [Alazard, 2006] Alazard, D. (2006). Introduction au filtre de kalman.
- [Ali et al., 2019] Ali, M. Z., Shabbir, M. N. S. K., Liang, X., Zhang, Y., and Hu, T. (2019). Machine learning-based fault diagnosis for single-and multi-faults in induction motors using measured stator currents and vibration signals. *IEEE Transactions on Industry Applications*, 55(3):2378–2391.
- [Alonge et al., 1998] Alonge, F., D'Ippolito, F., Ferrante, G., and Raimondi, F. (1998). Parameter identification of induction motor model using genetic algorithms. *IEEE Proceedings-Control Theory and Applications*, 145(6):587–593.
- [Ayhan et al., 2006] Ayhan, B., Chow, M.-Y., and Song, M.-H. (2006). Multiple discriminant analysis and neural-network-based monolith and partition fault-detection schemes for broken rotor bar in induction motors. *IEEE Transactions on Industrial Electronics*, 53(4):1298–1308.
- [Bachir, 2002] Bachir, S. (2002). *Contribution au diagnostic de la machine asynchrone par estimation paramétrique*. PhD thesis, Poitiers.

- [Bachir et al., 2006] Bachir, S., Tnani, S., Trigeassou, J.-C., and Champenois, G. (2006). Diagnosis by parameter estimation of stator and rotor faults occurring in induction machines. *IEEE Transactions on Industrial Electronics*, 53(3):963–973.
- [Baghli, 1999] Baghli, L. (1999). *Contribution à la commande de la machine asynchrone, utilisation de la logique floue, des réseaux de neurones et des algorithmes génétiques*. PhD thesis.
- [Ballal et al., 2007] Ballal, M. S., Khan, Z. J., Suryawanshi, H. M., and Sonolikar, R. L. (2007). Adaptive neural fuzzy inference system for the detection of inter-turn insulation and bearing wear faults in induction motor. *IEEE Transactions on Industrial Electronics*, 54(1):250–258.
- [Bellini et al., 2008] Bellini, A., Immovilli, F., Rubini, R., and Tassoni, C. (2008). Diagnosis of bearing faults of induction machines by vibration or current signals: A critical comparison. In *2008 IEEE Industry Applications Society Annual Meeting*, pages 1–8. IEEE.
- [Benbouzid and Nejjari, 2001] Benbouzid, M. and Nejjari, H. (2001). A simple fuzzy logic approach for induction motors stator condition monitoring. In *IEMDC 2001. IEEE International Electric Machines and Drives Conference (Cat. No. 01EX485)*, pages 634–639. IEEE.
- [Benbouzid, 2000] Benbouzid, M. E. H. (2000). A review of induction motors signature analysis as a medium for faults detection. *IEEE transactions on industrial electronics*, 47(5):984–993.
- [Benbouzid and Kliman, 2003] Benbouzid, M. E. H. and Kliman, G. B. (2003). What stator current processing-based technique to use for induction motor rotor faults diagnosis? *IEEE Transactions on Energy Conversion*, 18(2):238–244.
- [Bensaoucha et al., 2018] Bensaoucha, S., Ameer, A., Bessedik, S., and Moati, Y. (2018). Artificial neural networks technique to detect and locate an interturn short-circuit fault in induction motor. In *International Conference in Artificial Intelligence in Renewable Energetic Systems*, pages 103–113. Springer.
- [Bensaoucha et al., 2020] Bensaoucha, S., Bessedik, S. A., Ameer, A., Moreau, S., and Teta, A. (2020). A comparative study for broken rotor bars fault detection in induction machine using dwt and music techniques. In *020 1st International Conference on*

- Communications, Control Systems and Signal Processing (CCSSP)*, pages 523–528. IEEE.
- [Bensaoucha et al., 2019] Bensaoucha, S., Bessedik, S. A., Ameer, A., and Teta, A. (2019). Induction motors broken rotor bars detection using rpvm and neural network. *COMPEL-The international journal for computation and mathematics in electrical and electronic engineering*.
- [Berrar, 2018] Berrar, D. (2018). Bayes’ theorem and naive bayes classifier. *Encyclopedia of Bioinformatics and Computational Biology: ABC of Bioinformatics*, page 403.
- [Bishop and Richards, 1990] Bishop, R. R. and Richards, G. G. (1990). Identifying induction machine parameters using a genetic optimization algorithm. In *IEEE Proceedings on Southeastcon*, pages 476–479. IEEE.
- [Blodt et al., 2008] Blodt, M., Granjon, P., Raison, B., and Rostaing, G. (2008). Models for bearing damage detection in induction motors using stator current monitoring. *IEEE transactions on industrial electronics*, 55(4):1813–1822.
- [Bonet et al., 2008] Bonet, I., Rodríguez, A., Grau, R., García, M. M., Saez, Y., and Nowé, A. (2008). Comparing distance measures with visual methods. In *Mexican International Conference on Artificial Intelligence*, pages 90–99. Springer.
- [Bose, 1994] Bose, B. K. (1994). Expert system, fuzzy logic, and neural network applications in power electronics and motion control. *Proceedings of the IEEE*, 82(8):1303–1323.
- [Bose, 2007] Bose, B. K. (2007). Neural network applications in power electronics and motor drives—an introduction and perspective. *IEEE Transactions on Industrial Electronics*, 54(1):14–33.
- [Boumegoura, 2001] Boumegoura, T. (2001). *Recherche de signature électromagnétique des défauts dans une machine synchrone et synthèse d’observateurs en vue du diagnostic*. PhD thesis, Ecully, Ecole centrale de Lyon.
- [Bouزيد, 2009] Bouزيد, M. (2009). Diagnostic de défaut de la machine asynchrone par réseaux de neurones. *These de doctorat, l’Ecole Nationale d’Ingénieurs de Tunis*.

- [Bouzid et al., 2008] Bouzid, M. B. K., Champenois, G., Bellaaj, N. M., Signac, L., and Jelassi, K. (2008). An effective neural approach for the automatic location of stator interturn faults in induction motor. *IEEE Transactions on Industrial Electronics*, 55(12):4277–4289.
- [Bouzida et al., 2010] Bouzida, A., Touhami, O., Ibtouen, R., Belouchrani, A., Fadel, M., and Rezzoug, A. (2010). Fault diagnosis in industrial induction machines through discrete wavelet transform. *IEEE Transactions on Industrial Electronics*, 58(9):4385–4395.
- [Breiman, 2001] Breiman, L. (2001). Random forests. *Machine learning*, 45(1):5–32.
- [Breiman et al., 1984] Breiman, L., Friedman, J., Stone, C. J., and Olshen, R. A. (1984). *Classification and regression trees*. CRC press.
- [Cameron et al., 1986] Cameron, J., Thomson, W., and Dow, A. (1986). Vibration and current monitoring for detecting airgap eccentricity in large induction motors. In *IEE Proceedings B (Electric Power Applications)*, volume 133, pages 155–163. IET.
- [Cao, 1997] Cao, M. T. (1997). *Commande numérique de machines asynchrones par logique floue*. Citeseer.
- [Cardoso et al., 1999] Cardoso, A. M., Cruz, S., and Fonseca, D. (1999). Inter-turn stator winding fault diagnosis in three-phase induction motors, by park’s vector approach. *IEEE Transactions on Energy Conversion*, 14(3):595–598.
- [Cardoso and Saraiva, 1993] Cardoso, A. M. and Saraiva, E. S. (1993). Computer-aided detection of airgap eccentricity in operating three-phase induction motors by park’s vector approach. *IEEE Transactions on Industry Applications*, 29(5):897–901.
- [Casimir, 2003] Casimir, R. (2003). *Diagnostic des défauts des machines asynchrones par reconnaissance des formes*. PhD thesis.
- [Chavent, 2015] Chavent, M. (2015). Analyse discriminante linéaire et quadratique.
- [Chen and Ou, 2011] Chen, F. and Ou, T. (2011). Sales forecasting system based on gray extreme learning machine with taguchi method in retail industry. *Expert Systems with Applications*, 38(3):1336–1345.

- [Chen et al., 2016] Chen, J., Li, Z., Pan, J., Chen, G., Zi, Y., Yuan, J., Chen, B., and He, Z. (2016). Wavelet transform based on inner product in fault diagnosis of rotating machinery: A review. *Mechanical systems and signal processing*, 70:1–35.
- [Cheriyadat, 2013] Cheriyadat, A. M. (2013). Unsupervised feature learning for aerial scene classification. *IEEE Transactions on Geoscience and Remote Sensing*, 52(1):439–451.
- [Choi et al., 2014] Choi, S., Pazouki, E., Baek, J., and Bahrami, H. R. (2014). Iterative condition monitoring and fault diagnosis scheme of electric motor for harsh industrial application. *IEEE Transactions on Industrial Electronics*, 62(3):1760–1769.
- [Choqueuse et al., 2015] Choqueuse, V., Benbouzid, M., et al. (2015). Induction machine faults detection using stator current parametric spectral estimation. *Mechanical Systems and Signal Processing*, 52:447–464.
- [Chow et al., 1993] Chow, M.-Y., Sharpe, R. N., and Hung, J. C. (1993). On the application and design of artificial neural networks for motor fault detection. ii. *IEEE Transactions on industrial electronics*, 40(2):189–196.
- [Chow and Yee, 1991] Chow, M.-y. and Yee, S. O. (1991). Methodology for on-line incipient fault detection in single-phase squirrel-cage induction motors using artificial neural networks. *IEEE Transactions on Energy Conversion*, 6(3):536–545.
- [Chudasama, 2016] Chudasama, K. J. (2016). To study induction motor external faults detection and classification using ann and fuzzy soft computing techniques. *Gujarat Technological University, Ahmedabad*.
- [Coirault et al., 1997] Coirault, P., Trigeassou, J., Gaubert, J., and Champenois, G. (1997). Parameter identification of an induction machine for diagnosis. *IFAC Proceedings Volumes*, 30(18):265–270.
- [Consoli et al., 1998] Consoli, A., Gennaro, F., Raciti, A., and Testa, A. (1998). Fuzzy logic application to pre-fault diagnoses of induction motors. In *Proceedings of the 1998 Second IEEE International Caracas Conference on Devices, Circuits and Systems. ICCDCS 98. On the 70th Anniversary of the MOSFET and 50th of the BJT.(Cat. No. 98TH8350)*, pages 249–254. IEEE.
- [Cortes and Vapnik, 1995] Cortes, C. and Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3):273–297.

- [Cruz and Cardoso, 2001] Cruz, S. M. and Cardoso, A. M. (2001). Stator winding fault diagnosis in three-phase synchronous and asynchronous motors, by the extended park’s vector approach. *IEEE Transactions on industry applications*, 37(5):1227–1233.
- [Cutler et al., 2012] Cutler, A., Cutler, D. R., and Stevens, J. R. (2012). Random forests. In *Ensemble machine learning*, pages 157–175. Springer.
- [Da Silva et al., 2008] Da Silva, A. M., Povinelli, R. J., and Demerdash, N. A. (2008). Induction machine broken bar and stator short-circuit fault diagnostics based on three-phase stator current envelopes. *IEEE Transactions on Industrial Electronics*, 55(3):1310–1318.
- [Dai et al., 2007] Dai, W., Xue, G.-R., Yang, Q., and Yu, Y. (2007). Transferring naive bayes classifiers for text classification. In *AAAI*, volume 7, pages 540–545.
- [Delforge-Delmotte and Lemaire-Semail, 1996] Delforge-Delmotte, C. and Lemaire-Semail, B. (1996). Modélisation d’une machine asynchrone par réseaux de perméances en vue de sa commande. *Journal de Physique III*, 6(12):1785–1809.
- [Delgado-Arredondo et al., 2015] Delgado-Arredondo, P. A., Garcia-Perez, A., Morinigo-Sotelo, D., Osornio-Rios, R. A., Avina-Cervantes, J. G., Rostro-Gonzalez, H., and Romero-Troncoso, R. d. J. (2015). Comparative study of time-frequency decomposition techniques for fault detection in induction motors using vibration analysis during startup transient. *Shock and Vibration*, 2015.
- [Delpha et al., 2008] Delpha, C., Diallo, D., Benbouzid, M. E. H., and Marchand, C. (2008). Application of classification methods in fault detection and diagnosis of inverter fed induction machine drive: a trend towards reliability. *The European Physical Journal-Applied Physics*, 43(2):245–251.
- [Didier, 2004] Didier, G. (2004). Modélisation et diagnostic de la machine asynchrone en présence de défaillances. *These de doctorat de l’université Henri Poincaré, Nancy-I*.
- [Dietterich, 2000] Dietterich, T. G. (2000). An experimental comparison of three methods for constructing ensembles of decision trees: Bagging, boosting, and randomization. *Machine learning*, 40(2):139–157.
- [Dorofki et al., 2012] Dorofki, M., Elshafie, A. H., Jaafar, O., Karim, O. A., and Mastura, S. (2012). Comparison of artificial neural network transfer functions abilities to

- simulate extreme runoff data. *International Proceedings of Chemical, Biological and Environmental Engineering*, 33:39–44.
- [Dou and Zhou, 2016] Dou, D. and Zhou, S. (2016). Comparison of four direct classification methods for intelligent fault diagnosis of rotating machinery. *Applied Soft Computing*, 46:459–468.
- [Elbouchikhi et al., 2017] Elbouchikhi, E., Choqueuse, V., Amirat, Y., Benbouzid, M. E. H., and Turri, S. (2017). An efficient hilbert–huang transform-based bearing faults detection in induction machines. *IEEE Transactions on Energy Conversion*, 32(2):401–413.
- [Eren and Devaney, 2004] Eren, L. and Devaney, M. J. (2004). Bearing damage detection via wavelet packet decomposition of the stator current. *IEEE Transactions on Instrumentation and measurement*, 53(2):431–436.
- [Filippetti et al., 2000] Filippetti, F., Franceschini, G., Tassoni, C., and Vas, P. (2000). Recent developments of induction motor drives fault diagnosis using ai techniques. *IEEE transactions on industrial electronics*, 47(5):994–1004.
- [Filippetti et al., 1992] Filippetti, F., Martelli, M., Franceschini, G., and Tassoni, C. (1992). Development of expert system knowledge base to on-line diagnosis of rotor electrical faults of induction motors. In *Conference Record of the 1992 IEEE Industry Applications Society Annual Meeting*, pages 92–99. IEEE.
- [Flandrin and Escudié, 1984] Flandrin, P. and Escudié, B. (1984). An interpretation of the pseudo-wigner-ville distribution. *Signal Processing*, 6(1):27–36.
- [Friedl and Brodley, 1997] Friedl, M. A. and Brodley, C. E. (1997). Decision tree classification of land cover from remotely sensed data. *Remote sensing of environment*, 61(3):399–409.
- [Friedman et al., 1997] Friedman, N., Geiger, D., and Goldszmidt, M. (1997). Bayesian network classifiers. *Machine learning*, 29(2-3):131–163.
- [Garcia-Perez et al., 2011] Garcia-Perez, A., de Jesus Romero-Troncoso, R., Cabal-Yepez, E., and Osornio-Rios, R. A. (2011). The application of high-resolution spectral analysis for identifying multiple combined faults in induction motors. *IEEE Transactions on Industrial Electronics*, 58(5):2002–2010.

- [Genuer and Poggi, 2017] Genuer, R. and Poggi, J.-M. (2017). Arbres cart et forêts aléatoires, importance et sélection de variables.
- [Gislason et al., 2006] Gislason, P. O., Benediktsson, J. A., and Sveinsson, J. R. (2006). Random forests for land cover classification. *Pattern Recognition Letters*, 27(4):294–300.
- [Goode and Chow, 1995] Goode, P. V. and Chow, M.-y. (1995). Using a neural/fuzzy system to extract heuristic knowledge of incipient faults in induction motors. part i- methodology. *IEEE Transactions on Industrial Electronics*, 42(2):131–138.
- [Hassan et al., 2018] Hassan, O. E., Amer, M., Abdelsalam, A. K., and Williams, B. W. (2018). Induction motor broken rotor bar fault detection techniques based on fault signature analysis—a review. *IET Electric Power Applications*, 12(7):895–907.
- [Hearst et al., 1998] Hearst, M. A., Dumais, S. T., Osuna, E., Platt, J., and Scholkopf, B. (1998). Support vector machines. *IEEE Intelligent Systems and their applications*, 13(4):18–28.
- [Huang et al., 2006] Huang, G.-B., Zhu, Q.-Y., and Siew, C.-K. (2006). Extreme learning machine: theory and applications. *Neurocomputing*, 70(1-3):489–501.
- [Immovilli et al., 2010] Immovilli, F., Bellini, A., Rubini, R., and Tassoni, C. (2010). Diagnosis of bearing faults in induction machines by vibration or current signals: A critical comparison. *IEEE Transactions on Industry Applications*, 46(4):1350–1359.
- [Jack and Nandi, 2002] Jack, L. and Nandi, A. (2002). Fault detection using support vector machines and artificial neural networks, augmented by genetic algorithms. *Mechanical systems and signal processing*, 16(2-3):373–390.
- [Jaksch, 2003] Jaksch, I. (2003). Faults diagnosis of three-phase induction motors using envelope analysis. In *4th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives, 2003. SDEMPED 2003.*, pages 289–293. IEEE.
- [Jamouli, 2003] Jamouli, H. (2003). *Génération de résidus directionnels pour le diagnostic des systèmes linéaires stochastiques et la commande tolérante aux défauts*. PhD thesis, Thèse de l’université Henri Poincaré, Nancy I.

- [Jang, 1993] Jang, J.-S. (1993). Anfis: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3):665–685.
- [Kankar et al., 2011] Kankar, P. K., Sharma, S. C., and Harsha, S. P. (2011). Fault diagnosis of ball bearings using machine learning methods. *Expert Systems with applications*, 38(3):1876–1886.
- [Karmakar et al., 2016] Karmakar, S., Chattopadhyay, S., Mitra, M., and Sengupta, S. (2016). Induction motor fault diagnosis: General discussion and research scope. In *Induction Motor Fault Diagnosis*, pages 153–158. Springer.
- [Karnavas et al., 2017] Karnavas, Y. L., Chasiotis, I. D., and Vrangas, A. (2017). Fault diagnosis of squirrel-cage induction motor broken bars based on a model identification method with subtractive clustering. In *2017 IEEE 11th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)*, pages 304–310. IEEE.
- [Khodja, 2007] Khodja, D. E. (2007). *Elaboration d’un système intelligent de surveillance et de diagnostic automatique en temps réel des défaillances des moteurs à induction*. PhD thesis, Ph. D. dissertation, Université M’hamed Bougara de Boumerdes.
- [Kia et al., 2007] Kia, S. H., Henao, H., and Capolino, G.-A. (2007). A high-resolution frequency estimation method for three-phase induction machine fault detection. *IEEE Transactions on Industrial Electronics*, 54(4):2305–2314.
- [Kim et al., 2012] Kim, Y.-H., Youn, Y.-W., Hwang, D.-H., Sun, J.-H., and Kang, D.-S. (2012). High-resolution parameter estimation method to identify broken rotor bar faults in induction motors. *IEEE Transactions on Industrial Electronics*, 60(9):4103–4117.
- [Knight and Bertani, 2005] Knight, A. M. and Bertani, S. P. (2005). Mechanical fault detection in a medium-sized induction motor using stator current monitoring. *IEEE Transactions on Energy Conversion*, 20(4):753–760.
- [Kolla and Varatharasa, 2000] Kolla, S. and Varatharasa, L. (2000). Identifying three-phase induction motor faults using artificial neural networks. *ISA transactions*, 39(4):433–439.
- [Konar and Chattopadhyay, 2011] Konar, P. and Chattopadhyay, P. (2011). Bearing fault detection of induction motor using wavelet and support vector machines (svms). *Applied Soft Computing*, 11(6):4203–4211.

- [Konar and Chattopadhyay, 2015] Konar, P. and Chattopadhyay, P. (2015). Multi-class fault diagnosis of induction motor using hilbert and wavelet transform. *Applied Soft Computing*, 30:341–352.
- [Koteich, 2016] Koteich, M. (2016). *Modélisation et observabilité des machines électriques en vue de la commande sans capteur mécanique*. PhD thesis.
- [Kowalski and Orłowska-Kowalska, 2003] Kowalski, C. T. and Orłowska-Kowalska, T. (2003). Neural networks application for induction motor faults diagnosis. *Mathematics and computers in simulation*, 63(3-5):435–448.
- [KÜÇÜKER and Bayrak, 2015] KÜÇÜKER, A. and Bayrak, M. (2015). Detection of stator winding fault in induction motor using instantaneous power signature analysis. *Turkish Journal of Electrical Engineering & Computer Sciences*, 23(5):1263–1271.
- [Laribi, 2016] Laribi, S. (2016). Contribution à la commande et diagnostic des défauts statoriques et rotoriques de la machine asynchrone à cage d’écureuil. *Thèse de Doctorat, Université des Sciences et de la Technologie d’Oran*.
- [Lewis, 1998] Lewis, D. D. (1998). Naive (bayes) at forty: The independence assumption in information retrieval. In *European conference on machine learning*, pages 4–15. Springer.
- [Li et al., 2000] Li, B., Chow, M.-Y., Tipsuwan, Y., and Hung, J. C. (2000). Neural-network-based motor rolling bearing fault diagnosis. *IEEE transactions on industrial electronics*, 47(5):1060–1069.
- [Liu et al., 2018] Liu, R., Yang, B., Zio, E., and Chen, X. (2018). Artificial intelligence for fault diagnosis of rotating machinery: A review. *Mechanical Systems and Signal Processing*, 108:33–47.
- [Liu and Bazzi, 2017] Liu, Y. and Bazzi, A. M. (2017). A review and comparison of fault detection and diagnosis methods for squirrel-cage induction motors: State of the art. *ISA transactions*, 70:400–409.
- [Loron and Laliberte, 1993] Loron, L. and Laliberte, G. (1993). Application of the extended kalman filter to parameters estimation of induction motors. In *1993 Fifth European Conference on Power Electronics and Applications*, pages 85–90. IET.

- [Martins et al., 2007] Martins, J. F., Pires, V. F., and Pires, A. (2007). Unsupervised neural-network-based algorithm for an on-line diagnosis of three-phase induction motor stator fault. *IEEE Transactions on Industrial Electronics*, 54(1):259–264.
- [Mechefske and Mathew, 1992] Mechefske, C. and Mathew, J. (1992). Fault detection and diagnosis in low speed rolling element bearings part ii: The use of nearest neighbour classification. *Mechanical Systems and Signal Processing*, 6(4):309–316.
- [Medjahed et al., 2013] Medjahed, S. A., Saadi, T. A., and Benyettou, A. (2013). Breast cancer diagnosis by using k-nearest neighbor with different distances and classification rules. *International Journal of Computer Applications*, 62(1).
- [Mehala and Dahiya, 2010] Mehala, N. and Dahiya, R. (2010). Condition monitoring and fault diagnosis of induction motor using motor current signature analysis. *A Ph. D Thesis submitted to the Electrical Engineering Department, National Institute of Technology, Kurushetra, India.*
- [Milgram et al., 2006] Milgram, J., Cheriet, M., and Sabourin, R. (2006). “one against one” or “one against all”: Which one is better for handwriting recognition with svms?
- [Moreau, 1999] Moreau, S. (1999). *Contribution à la modélisation et à l’estimation paramétrique des machines électriques à courant alternatif: Application au diagnostic.* PhD thesis, Poitiers.
- [Mustafa, 2015] Mustafa, M. O. (2015). *On fault detection, diagnosis and monitoring for induction motors.* PhD thesis, Luleå tekniska universitet.
- [Nandi and Toliyat, 1999] Nandi, S. and Toliyat, H. A. (1999). Fault diagnosis of electrical machines—a review. In *IEEE International Electric Machines and Drives Conference. IEMDC’99. Proceedings (Cat. No. 99EX272)*, pages 219–221. IEEE.
- [Nandi et al., 2005] Nandi, S., Toliyat, H. A., and Li, X. (2005). Condition monitoring and fault diagnosis of electrical motors—a review. *IEEE transactions on energy conversion*, 20(4):719–729.
- [Nanni and Lumini, 2009] Nanni, L. and Lumini, A. (2009). An experimental comparison of ensemble of classifiers for bankruptcy prediction and credit scoring. *Expert systems with applications*, 36(2):3028–3033.

- [Nemec et al., 2019] Nemec, M., Ambrožič, V., Fišer, R., Nedeljković, D., and Drobnič, K. (2019). Induction motor broken rotor bar detection based on rotor flux angle monitoring. *Energies*, 12(5):794.
- [Nguyen and Lee, 2010] Nguyen, N.-T. and Lee, H.-H. (2010). Induction motor fault diagnosis based on the k-nn and optimal feature selection. *International journal of electronics*, 97(9):1071–1081.
- [Ondel, 2006] Ondel, O. (2006). *Diagnostic par reconnaissance des formes: Application à un ensemble convertisseur-machine asynchrone*. PhD thesis.
- [Orr et al., 1996] Orr, M. J. et al. (1996). Introduction to radial basis function networks.
- [Oumaamar, 2012] Oumaamar, M. E. K. (2012). *Surveillance et diagnostic des défauts rotoriques et mécaniques de la machine asynchrone avec alimentation équilibrée ou déséquilibrée*. PhD thesis, Université de Lorraine.
- [Pachori and Nishad, 2016] Pachori, R. B. and Nishad, A. (2016). Cross-terms reduction in the wigner–ville distribution using tunable-q wavelet transform. *Signal Processing*, 120:288–304.
- [Patel and Giri, 2016] Patel, R. K. and Giri, V. (2016). Feature selection and classification of mechanical fault of an induction motor using random forest classifier. *Perspectives in Science*, 8:334–337.
- [Paya et al., 1997] Paya, B., Esat, I., and Badi, M. (1997). Artificial neural network based fault diagnostics of rotating machinery using wavelet transforms as a preprocessor. *Mechanical systems and signal processing*, 11(5):751–765.
- [Peng, 2006] Peng, Y. (2006). A novel ensemble machine learning for robust microarray data classification. *Computers in Biology and Medicine*, 36(6):553–573.
- [Pérez et al., 2009] Pérez, A., Larrañaga, P., and Inza, I. (2009). Bayesian classifiers based on kernel density estimation: Flexible classifiers. *International Journal of Approximate Reasoning*, 50(2):341–362.
- [Perez-Cruz et al., 2017] Perez-Cruz, J., Puche-Panadero, R., Pineda-Sanchez, M., Riera-Guasp, M., Martinez-Roman, J., and Sapena-Bano, A. (2017). Cost-effective on-line fault diagnosis of induction motors using the reduced modulus of the current park’s

- vector. In *2017 IEEE 11th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)*, pages 427–433. IEEE.
- [Pilloni et al., 2013] Pilloni, A., Pisano, A., Riera-Guasp, M., Puche-Panadero, R., and Pineda-Sanchez, M. (2013). Fault detection in induction motors. *AC electric motors control: Advanced Design Techniques and Applications*, pages 275–309.
- [Pons-Llinares et al., 2014] Pons-Llinares, J., Antonino-Daviu, J. A., Riera-Guasp, M., Lee, S. B., Kang, T.-J., and Yang, C. (2014). Advanced induction motor rotor fault diagnosis via continuous and discrete time–frequency tools. *IEEE Transactions on Industrial Electronics*, 62(3):1791–1802.
- [Puche-Panadero et al., 2009] Puche-Panadero, R., Pineda-Sanchez, M., Riera-Guasp, M., Roger-Folch, J., Hurtado-Perez, E., and Perez-Cruz, J. (2009). Improved resolution of the mcsa method via hilbert transform, enabling the diagnosis of rotor asymmetries at very low slip. *IEEE Transactions on Energy Conversion*, 24(1):52–59.
- [Ramayah et al., 2010] Ramayah, T., Ahmad, N. H., Halim, H. A., Zainal, S. R. M., and Lo, M.-C. (2010). Discriminant analysis: An illustrated example. *African journal of business management*, 4(9):1654–1667.
- [Razik et al., 2008] Razik, H., Corrêa, M., and Da Silva, E. (2008). An application of genetic algorithm and fuzzy logic for the induction motor diagnosis. In *2008 34th Annual Conference of IEEE Industrial Electronics*, pages 3067–3072. IEEE.
- [Riera-Guasp et al., 2014] Riera-Guasp, M., Antonino-Daviu, J. A., and Capolino, G.-A. (2014). Advances in electrical machine, power electronic, and drive condition monitoring and fault detection: state of the art. *IEEE Transactions on Industrial Electronics*, 62(3):1746–1759.
- [Riera-Guasp et al., 2008] Riera-Guasp, M., Antonino-Daviu, J. A., Pineda-Sanchez, M., Puche-Panadero, R., and Pérez-Cruz, J. (2008). A general approach for the transient detection of slip-dependent fault components based on the discrete wavelet transform. *IEEE transactions on Industrial electronics*, 55(12):4167–4180.
- [Rodríguez and Arkkio, 2008] Rodríguez, P. V. J. and Arkkio, A. (2008). Detection of stator winding fault in induction motor using fuzzy logic. *Applied Soft Computing*, 8(2):1112–1120.

- [Rokach and Maimon, 2005] Rokach, L. and Maimon, O. (2005). Decision trees. In *Data mining and knowledge discovery handbook*, pages 165–192. Springer.
- [Romero-Troncoso et al., 2011] Romero-Troncoso, R. J., Saucedo-Gallaga, R., Cabal-Yepez, E., Garcia-Perez, A., Osornio-Rios, R. A., Alvarez-Salas, R., Miranda-Vidales, H., and Huber, N. (2011). Fpga-based online detection of multiple combined faults in induction motors through information entropy and fuzzy inference. *IEEE Transactions on Industrial Electronics*, 58(11):5263–5270.
- [Saddam et al., 2018a] Saddam, B., Ahmed, B. S., Aissa, A., and Ali, T. (2018a). Squirrel cage induction motor under stator and rotor bars faults modeling and diagnosis. In *2018 International Conference on Communications and Electrical Engineering (IC-CEE)*, pages 1–6. IEEE.
- [Saddam et al., 2017] Saddam, B., Aissa, A., Ahmed, B. S., and Abdellatif, S. (2017). Detection of rotor faults based on hilbert transform and neural network for an induction machine. In *2017 5th International Conference on Electrical Engineering-Boumerdes (ICEE-B)*, pages 1–6. IEEE.
- [Saddam et al., 2018b] Saddam, B., Aissa, A., Ahmed, B. S., and Ali, T. (2018b). Comparative investigation of broken bar fault detectability in induction motor through fft and music techniques. In *2018 International Conference on Communications and Electrical Engineering (ICCEE)*, pages 1–5. IEEE.
- [Saleh and Ozkop, 2016] Saleh, S. and Ozkop, E. (2016). Phaselet-based method for detecting electric faults in 3ϕ induction motor drives—part i: Analysis and development. *IEEE Transactions on Industry Applications*, 53(3):2976–2987.
- [Salem et al., 2012] Salem, S. B., Bacha, K., and Chaari, A. (2012). Support vector machine based decision for mechanical fault condition monitoring in induction motor using an advanced hilbert-park transform. *ISA transactions*, 51(5):566–572.
- [Samanta, 2004] Samanta, B. (2004). Gear fault detection using artificial neural networks and support vector machines with genetic algorithms. *Mechanical systems and signal processing*, 18(3):625–644.
- [Samanta and Al-Balushi, 2003] Samanta, B. and Al-Balushi, K. (2003). Artificial neural network based fault diagnostics of rolling element bearings using time-domain features. *Mechanical systems and signal processing*, 17(2):317–328.

- [Schmidhuber, 2015] Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61:85–117.
- [Schoen et al., 1995] Schoen, R. R., Habetler, T. G., Kamran, F., and Bartfield, R. (1995). Motor bearing damage detection using stator current monitoring. *IEEE transactions on industry applications*, 31(6):1274–1279.
- [Shao et al., 2017a] Shao, H., Jiang, H., Zhang, H., and Liang, T. (2017a). Electric locomotive bearing fault diagnosis using a novel convolutional deep belief network. *IEEE Transactions on Industrial Electronics*, 65(3):2727–2736.
- [Shao et al., 2017b] Shao, S.-Y., Sun, W.-J., Yan, R.-Q., Wang, P., and Gao, R. X. (2017b). A deep learning approach for fault diagnosis of induction motors in manufacturing. *Chinese Journal of Mechanical Engineering*, 30(6):1347–1356.
- [Siddique et al., 2003] Siddique, A., Yadava, G., and Singh, B. (2003). Applications of artificial intelligence techniques for induction machine stator fault diagnostics. In *4th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives, 2003. SDEMPED 2003.*, pages 29–34. IEEE.
- [Silva et al., 2018] Silva, S., Costa, P., Gouvea, M., Lacerda, A., Alves, F., and Leite, D. (2018). High impedance fault detection in power distribution systems using wavelet transform and evolving neural network. *Electric Power Systems Research*, 154:474–483.
- [Simeón et al., 2010] Simeón, E. A., Álvares, A. J., and Gudwin, R. R. (2010). An expert system for fault diagnostics in condition based maintenance. In *ABCM Symp. Ser. Mechatron*, volume 4, pages 304–313.
- [Singh and Shaik, 2019] Singh, M. and Shaik, A. G. (2019). Faulty bearing detection, classification and location in a three-phase induction motor based on stockwell transform and support vector machine. *Measurement*, 131:524–533.
- [Smola and Schölkopf, 2004] Smola, A. J. and Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and computing*, 14(3):199–222.
- [Sobie et al., 2018] Sobie, C., Freitas, C., and Nicolai, M. (2018). Simulation-driven machine learning: Bearing fault classification. *Mechanical Systems and Signal Processing*, 99:403–419.

- [Song and Ying, 2015] Song, Y.-Y. and Ying, L. (2015). Decision tree methods: applications for classification and prediction. *Shanghai archives of psychiatry*, 27(2):130.
- [Sun et al., 2016] Sun, W., Shao, S., Zhao, R., Yan, R., Zhang, X., and Chen, X. (2016). A sparse auto-encoder-based deep neural network approach for induction motor faults classification. *Measurement*, 89:171–178.
- [Tallam et al., 2007] Tallam, R. M., Lee, S. B., Stone, G. C., Kliman, G. B., Yoo, J., Habetler, T. G., and Harley, R. G. (2007). A survey of methods for detection of stator-related faults in induction machines. *IEEE Transactions on Industry Applications*, 43(4):920–933.
- [Tang et al., 1996] Tang, K.-S., Man, K.-F., Kwong, S., and He, Q. (1996). Genetic algorithms and their applications. *IEEE signal processing magazine*, 13(6):22–37.
- [Thomson and Culbert, 2016] Thomson, W. T. and Culbert, I. (2016). Motor current signature analysis for induction motors. *Current signature analysis for condition monitoring of cage induction motors: Industrial application and case histories*, pages 1–37.
- [Thomson and Fenger, 2001] Thomson, W. T. and Fenger, M. (2001). Current signature analysis to detect induction motor faults. *IEEE Industry Applications Magazine*, 7(4):26–34.
- [Trachi, 2017] Trachi, Y. (2017). *On induction machine faults detection using advanced parametric signal processing techniques*. PhD thesis.
- [Tyagi, 2008] Tyagi, C. S. (2008). A comparative study of svm classifiers and artificial neural networks application for rolling element bearing fault diagnosis using wavelet transform preprocessing. *Neuron*, 1:309–317.
- [Vafaie and De Jong, 1992] Vafaie, H. and De Jong, K. A. (1992). Genetic algorithms as a tool for feature selection in machine learning. In *ICTAI*, pages 200–203.
- [Vapnik, 2013] Vapnik, V. (2013). *The nature of statistical learning theory*. Springer science & business media.
- [Vaseghi, 2009] Vaseghi, B. (2009). *Contribution à l’étude des machines électriques en présence de défaut entre-spores: Modélisation-Réduction du courant de défaut*. PhD thesis, Institut National Polytechnique de Lorraine.

- [Villani et al., 2018] Villani, C., Schoenauer, M., Bonnet, Y., Berthet, C., Cornut, A.-C., Levin, F., and Rondepierre, B. (2018). Donner un sens à l’intelligence artificielle.
- [Wang, 2016] Wang, D. (2016). K-nearest neighbors based methods for identification of different gear crack levels under different motor speeds and loads: Revisited. *Mechanical Systems and Signal Processing*, 70:201–208.
- [Weston and Watkins, 1998] Weston, J. and Watkins, C. (1998). Support vector machines for multi-class pattern recognition, department of computer science, royal holloway. *University of London*.
- [Whitley, 1994] Whitley, D. (1994). A genetic algorithm tutorial. *Statistics and computing*, 4(2):65–85.
- [Widodo and Yang, 2007] Widodo, A. and Yang, B.-S. (2007). Support vector machine in machine condition monitoring and fault diagnosis. *Mechanical systems and signal processing*, 21(6):2560–2574.
- [Wishart and Harley, 1995] Wishart, M. T. and Harley, R. G. (1995). Identification and control of induction machines using artificial neural networks. *IEEE Transactions on Industry Applications*, 31(3):612–619.
- [Xu et al., 2013] Xu, B., Sun, L., Xu, L., and Xu, G. (2013). Improvement of the hilbert method via esprit for detecting rotor fault in induction motors at low slip. *IEEE Transactions on Energy Conversion*, 28(1):225–233.
- [Yang et al., 2008] Yang, B.-S., Di, X., and Han, T. (2008). Random forests classifier for machine fault diagnosis. *Journal of mechanical science and technology*, 22(9):1716–1725.
- [Yang et al., 2009] Yang, B.-S., Oh, M.-S., Tan, A. C. C., et al. (2009). Fault diagnosis of induction motor based on decision trees and adaptive neuro-fuzzy inference. *Expert Systems with Applications*, 36(2):1840–1849.
- [Ye et al., 2001] Ye, Z., Wu, B., and Sadeghian, A. (2001). Electrical machine fault detection using adaptive neuro-fuzzy inference. In *Proceedings Joint 9th IFSA World Congress and 20th NAFIPS International Conference (Cat. No. 01TH8569)*, volume 1, pages 390–394. IEEE.
- [Zadeh, 1965] Zadeh, L. A. (1965). Fuzzy sets. *Information and control*, 8(3):338–353.

- [Zeraoulia et al., 2005] Zeraoulia, M., Mamoune, A., Mangel, H., and Benbouzid, M. (2005). A simple fuzzy logic approach for induction motors stator condition monitoring. *J. Electrical Systems*, 1(1):15–25.
- [Zhang et al., 2010] Zhang, P., Du, Y., Habetler, T. G., and Lu, B. (2010). A survey of condition monitoring and protection methods for medium-voltage induction motors. *IEEE Transactions on Industry Applications*, 47(1):34–46.
- [Zhang et al., 2020] Zhang, W., Ding, Y., Yan, X., and Jia, M. (2020). Weak multiple fault detection based on weighted morlet wavelet-overlapping group sparse for rolling bearing fault diagnosis. *Applied Sciences*, 10(6):2057.
- [Zidani et al., 2003] Zidani, F., Benbouzid, M. E. H., Diallo, D., and Naït-Saïd, M. S. (2003). Induction motor stator faults diagnosis by a current concordia pattern-based fuzzy decision system. *IEEE Transactions on Energy Conversion*, 18(4):469–475.
- [Zong et al., 2013] Zong, W., Huang, G.-B., and Chen, Y. (2013). Weighted extreme learning machine for imbalance learning. *Neurocomputing*, 101:229–242.