

*Université des Sciences et de la Technologie Houari Boumediène
Faculté d'Electronique et d'Informatique*



MEMOIRE
Présenté pour l'obtention du diplôme de MAGISTER
En Electrotechnique

Spécialité : Systèmes Electro-énergétiques

Par : Omar SID

THEME

**Diagnostic de défauts de la machine asynchrone à cage
par les réseaux de neurones**

Soutenu Publiquement le : 12-07-2011, devant le jury composé de :

O. TOUHAMI	Professeur, ENP Alger	Président
M. MENAA	Maître de Conférences/A, à l'USTHB	Directeur de Mémoire
M. BOUDOUR	Professeur, à l'USTHB	Examineur
A. NAITSEGHIR	Maître de Conférences/A, à l'USTHB	Examineur
S. HAMDANI	Maître Assistant/A, à l'USTHB	Invité

*A ma famille et à mes amis
Pour la patience et le dévouement dont ils ont fait preuve*

Les travaux de recherches présentés dans ce mémoire ont été réalisés au laboratoire des Systèmes Electriques et Industriels (L.S.E.I) de la faculté d'Electronique et d'Informatique, USTHB.

Je tiens à remercier Monsieur Omar TOUHAMI, Professeur à l'Ecole Nationale Polytechnique d'Alger, pour m'avoir fait l'honneur de présider mon ce jury.

Je remecie vivement Monsieur Mohamed BOUDOUR, Professeur à l'USTHB, de m'avoir accueilli au sein de son laboratoire et de m'avoir fait l'honneur de faire partie du jury.

Je tiens également à remercier Monsieur Amirouche NAITSEGHIR, Maitre de conférences « A » à l'USTHB, pour l'honneur qu'il m'a fait, en acceptant d'examiner ce travail.

Je tiens à exprimer ma profonde gratitude à Monsieur Mohamed MENAA, Maître de conférences « A » à l'USTHB, pour avoir accepter de dirriger ce travail, pour les nombreuses discussions scientifiques, ses remarques pertinentes, pour le temps qu'il a su me consacrer tout au long de ces années passées au sein du Laboratoire des Systèmes Eléctriques et Industriels, pour le respect et la sympathie dont je fus témoin et m'avoir montré l'importance de ce sujet de recherche dans notre domaine.

Je ne pourrai jamais remercier suffisamment Monsieur Samir HAMDANI, Maître Assistant « A » à l'USTHB, pour avoir co-diriger ce travail, pour sa gentillesse, son soutien moral, scientifique et sa disponibilité. Les discussions, les remarques et les commentaires de Monsieur Samir HAMDANI ont été sources d'idées et ont contribué au développement et à l'amélioration de ce travail.

Je ne peux oublier les personnes qui ont su m'aider à un moment ou à un autre.

Merci aussi à tous mes collègues de travail et mes amis de Département Électrotechnique. Je leur exprime ma profonde sympathie et leur souhaite beaucoup de chance pour les années futures.

Un grand merci à toute ma famille et plus particulièrement à mon père, ma mère, mes sœurs et mes frères (MOUSSA, AISSA, BOUBKER et ISMAIL) pour m'avoir soutenu et aidé tout au long de mes études.

Résumé

Dans cette étude, nous avons utilisé une méthode dédiée à la détection des défauts rotoriques dans les machines asynchrones à cage. Cette méthode est basée sur l'analyse spectrale du signal du courant statorique pour déterminer les deux groupes de paramètres spécifiques aux défauts étudiés selon que le rang d'harmonique $k=1$ ou $k=2$ dans l'équation mathématique $(1 \pm 2.k.g).f_s$ avec l'ensemble des états de fonctionnement de la machine tel que : état sain, une barre cassée, deux barres cassées et une portion d'anneau de court circuit cassée.

Pour la classification des différents états de la machine, deux types de réseaux de neurones artificiels (RNA) sont utilisés individuellement:

Le premier est le réseau Feedforward de trois couches à apprentissage supervisé avec l'algorithme d'apprentissage rétropropagation du gradient. Pour ce réseau, nous avons présenté et comparé plusieurs architectures et nous avons montré les résultats détaillés relatifs à la meilleure architecture. Le deuxième réseau à apprentissage non supervisé est la carte auto-organisatrice de Kohonen (ou encore, Self Organizing Mapping) pour laquelle nous avons présenté les résultats de la meilleure carte.

Les performances de la classification ont été examinées avec les données d'apprentissage et de test d'apprentissage en considérant les deux groupes de paramètres comme des entrées aux réseaux de neurones. L'effet des différentes architectures du réseau et la taille de données d'apprentissage sur la performance du réseau sont discutées.

En comparant les différents résultats, nous pouvons conclure que le réseau Feedforward est plus performant par rapport au réseau SOM.

Mots clés : Moteurs à induction, Cassure des barres rotoriques, Diagnostic et détection des défauts rotoriques, Classification, Réseaux de neurones Feedforward, Carte auto-organisatrice.

Abstract

In this study, we used a method dedicated to the detection of rotor faults in induction motors cage. This method is based on spectral analysis signal of stator current to determine the two groups of parameters specific to faults studied by the range harmonic $k=1$ or $k=2$ in the mathematical equation $(1 \pm 2.k.g).f_s$ with all states of working conditions machine such as: healthy state, a one broken rotor bar, two broken rotor bars and a end-ring portion of the short circuit broken.

For the diagnosis of electric motor rotor faults we used two kinds of Artificial Neural Networks (ANN):

The first network is a Feedforward of three layers with backpropagation algorithm based on supervised learning. For tis network we presented and compared the differents structures, and we showed the results of the best structure. The second network based on unsupervised learning is the Self Organizing maping (SOM) of kohonen, we presented the best dimension of the map. The ANNs were trained and tested using measurement data from stator currents, when we considere th two groups of parameters as inputs of ANNs. The effects of different network structures and the training set sizes on the performance of the ANNs are discussed.

The results shows that Feedforward ANN is the more efficient campared to SOM network.

Keywords: *Induction motors, broken rotor bars, Diagnosis and detection of rotor faults, clustering, Feedforward neural network, Self-organizing maping.*

SOMMAIRE

SOMMAIRE

Liste des Figures et Tableaux

Introduction Générale.....	01
Chapitre I. Généralité sur les défaillances dans la machine asynchrone à cage	
I. Introduction.....	04
II. Eléments de constitution de la machine asynchrone.....	04
II.1 Stator.....	04
II.2 Rotor.....	05
II.3 Paliers.....	05
III. Constitution de l'alimentation d'un moteur asynchrone.....	06
IV. Présentation des différentes défaillances du moteur asynchrone à cage.....	06
IV.1 Défaillances d'ordre électrique.....	07
IV.1.1 Défaillances des circuits électriques statoriques.....	07
IV.1.2 Défaillances des circuits électriques rotoriques.....	09
IV.2 Défaillances d'ordre mécanique.....	12
IV.2.1 Défaillances des roulements.....	12
IV.2.2 Défaillances du flasque.....	13
IV.2.3 Défaillances de l'arbre.....	13
V. Présentations des Défaillances sur un convertisseur de puissance et sa commande.....	13
VI. Récapitulation des causes de défauts.....	14
VII. Conclusion.....	14
Chapitre II. Les différentes méthodes et approches de diagnostic	
I. Introduction.....	15
II. Extraction des signatures.....	15
II.1 Extraction à partir des méthodes internes (connaissance à priori).....	15
II.2 Extraction à partir de méthodes externes (sans connaissance à priori).....	19
III. Méthodes classiques d'estimation de la densité spectrale de puissance.....	24
III.1 Transformée de Fourier discrète.....	24
III.2 Transformée de Fourier rapide.....	25
IV. Périodogramme.....	25
IV.1 Périodogramme simple.....	25
IV.2 Périodogramme modifié.....	26
IV.3 Biais et variance du périodogramme.....	26
V. Estimateurs spectraux à variance réduite.....	27
V.1 Méthode de Bartlett.....	27

V.2	Méthode de Welch.....	27
V.3	Analyse spectrale en ligne.....	28
V.3.1	Transformée de Fourier glissante.....	28
VI.	Outils d'analyse fréquentielle liés au traitement de l'information.....	29
VII.	Vers des approches modernes de diagnostic.....	29
VII.1	Approches à base de systèmes experts.....	30
VII.2	Approches à base d'arbres de défaillances.....	30
VII.3	Approches à base de reconnaissance des Formes (RdF).....	31
VII.4	Approches à base de réseaux de neurones artificiels.....	32
VIII.	Conclusion.....	32
Chapitre III. Généralités sur les réseaux de neurones artificiels		
I.	Introduction.....	34
II.	Présentation des réseaux de neurones artificiels.....	34
II.1	Brèf historique.....	34
II.2	Modèles mathématiques.....	35
III.	Fonctions de transfert.....	36
IV	Structures d'interconnexion.....	37
IV.1	Réseaux multicouches.....	37
IV.2	Réseau à connexions locales.....	37
IV.3	Réseau à connexions récurrentes.....	38
IV.4	Réseau à connexion complète.....	38
V.	Apprentissage.....	38
V.1	Réseaux statiques (Apprentissage par « paquet » et Réseaux dynamiques Apprentissage « séquentiel »).....	39
V.2	Règle de HEBB.....	39
V.3	Règle du DELTA (ou Règle de Widrow Hoff).....	39
VI.	Principaux types de réseaux de neurones.....	40
VI.1	Réseau PMC (Perceptron Multi Couches).....	40
VI.1.1	Structure.....	40
VI.1.2	Apprentissage.....	40
VI.1.3	Algorithme de la rétropropagation du gradient.....	41
VI.2	Réseaux de neurones compétitif ou cartes auto organisatrices.....	43
VI.2.1	Réseaux de neurone compétitif ou réseaux de Kohonen.....	44
VI.2.2	Réseaux de neurones LVQ.....	44
VI.2.3	Cartes auto-organisatrices de Kohonen.....	44

VI.3	Réseaux de neurones à fonctions de base radiales (Radial Basis Network).....	46
VI.3.1	Réseaux de neurones à régression généralisée.....	47
VI.3.2	Réseaux de neurones probabilistes (Probabilistic Neural Networks).....	47
VI.4	Réseaux récurrents.....	47
VI.4.1	Réseaux de Elman.....	47
VI.4.2	Réseaux de Hopfield.....	47
VI.5	Réseau à Architecture évolutive, ART.....	47
VII.	Conclusion.....	48
Chapitre IV. Méthodologie de diagnostic par les réseaux de neurones		
I.	Introduction.....	49
II.	Construction de la base de données.....	50
II.1	Détermination de la fréquence fondamentale.....	51
II.2	Recherche automatique du glissement pour une alimentation à partir du réseau.....	52
II.2.1	Calcul de la fréquence de rotation du rotor “ <i>fr</i> ”.....	53
II.2.2	Calcul du glissement “ <i>g</i> ”.....	53
II.3	Recherche automatique du glissement pour un variateur de vitesse.....	54
III.	Normalisation des données.....	56
III.1	Codage des machines.....	57
III.2	Taux de réussite.....	57
III.3	Performance de la classification.....	57
IV.	Application des réseaux de neurones pour la classification des défauts.....	58
IV.1	Réseau de neurone à apprentissage supervisé.....	59
IV.1.1	Étapes d'apprentissage de l'algorithme de rétropropagation.....	60
IV.1.2	Initialisation des poids.....	60
IV.1.3	Fonctions de performance.....	61
IV.2	Réseau de neurone à apprentissage non supervisé	60
IV.2.1	Apprentissage du réseau SOM.....	61
IV.2.2	Étiquetage de la carte du réseau SOM.....	63
IV.2.3	Regroupement de la carte du réseau SOM.....	64
IV.2.4	Principe de SOM_ToolBox.....	64
V.	Conclusion.....	65

Chapitre V. Résultats de diagnostic par les réseaux de neurones

I.	Introduction.....	66
II.	Description du banc d'essai.....	66
II.1	Alimentation.....	66
II.2	Machines asynchrones à cage d'écureuil.....	67
II.3	Génératrice à courant continu.....	68
II.4	Génératrice Tachymétrique.....	68
II.5	Capteurs de courant et de tension.....	68
II.6	Acquisitions des données.....	68
II.7	Déroulement des essais expérimentaux.....	69
III.	Analyse spectrale du courant statorique.....	69
IV.	Résultats de classification des défauts par les réseaux de neurones.....	72
IV.1	Réseau de neurone à apprentissage supervisé.....	72
IV.1.1	Résultats avec le premier groupe de paramètres pour $k=1$	72
IV.1.2	Résultats avec le second groupe de paramètres pour $k=2$	75
IV.1.3	Comparaison et analyse des résultats.....	78
IV.2	Réseau de neurone à apprentissage non supervisé.....	79
IV.2.1	Résultats avec le premier groupe de paramètres pour $k=1$	79
IV.2.2	Résultats avec le second groupe de paramètres pour $k=2$	84
IV.2.3	Comparaison et analyse des résultats.....	87
V.	Conclusion.....	87
	Conclusion générale et Perspectives.....	88
	Bibliographie	
	Annexes	

Liste des figures et tableaux

Liste des Figures

Figure I.1	Eléments de constitutions d'une machine asynchrone à cage d'écureuil.....	06
Figure I.2	Proportion des défauts.....	07
Figure I.3	Défaut d'une barre cassée.....	10
Figure I.4	Rupture d'une portion d'anneau de court-circuit.....	10
Figure I.5	Différents types de la dissymétrie de l'entrefer.....	12
Figure II.1	Approche physique : utilisation des observateurs.....	17
Figure II.2	Vecteur de Park des courants statoriques pour 100% de charge avec une alimentation non sinusoïdale.....	19
Figure II.3	Spectre fréquentiel du module du vecteur de Park des courants statoriques pour 100% de charge.....	19
Figure II.4	Spectre de la tension du neutre.....	21
Figure II.5	Spectre de la puissance instantanée.....	22
Figure II.6	Mesures vibratoires sur la machine asynchrone.....	22
Figure II.7	Spectre du courant statorique.....	23
Figure III.1	Représentation d'un neurone artificiel.....	35
Figure III.2	Définition des couches d'un réseau multicouche.....	37
Figure III.3	Réseau à connexions locales.....	37
Figure III.4	Réseau à connexions récurrente.....	38
Figure III.5	Réseau à connexions complète.....	38
Figure III.6	Recherche de la zone minimale dans l'espace de configuration des poids.....	41
Figure III.7	Un réseau multi-couches comportant 2 neurones d'entrés, 4 neurones cachés.....	42
Figure III.8	Mise en correspondance de l'espace d'entrée avec l'espace du réseau.....	45
Figure III.9	Architecture d'une carte auto-organisatrice (réseau 2D).....	45
Figure IV.1	Spectre du courant statorique de la machine saine et avec défaut.....	50
Figure IV.2	Spectre du courant statorique pour le rang d'harmonique $k=1$ et $k=2$	51
Figure IV.3	Spectre fréquentiel du courant statorique.....	52
Figure IV.4	Spectre du courant autour de la fréquence caractéristique $f_s + f_r$	53
Figure IV.5.a	Détection du glissement pour une alimentation par variateur de vitesse.....	54
Figure IV.5.b	Méthode de calcul des paramètres représentatifs de défauts.....	55
Figure IV.6	Représentation schématique de fonctionnement dépendant du niveau de charge...	56
Figure IV.7	Représentation schématique de fonctionnement indépendant du niveau de charge	56
Figure IV.8	Réseau Feedforward à une couche cachée.....	59
Figure IV.9	Architecture d'une carte de Kohonen.....	62

Figure IV.10	Méthode d'apprentissage de la carte auto-organisatrice.....	63
Figure V.1	Présentation de banc d'essai.....	66
Figure V.2	Variateur de vitesse.....	67
Figure V.3	Différents types de rotors.....	67
Figure V.4	Machines utilisées avec les différentes charges.....	68
Figure V.5	Carte pour le conditionnement des signaux	68
Figure V.6	Spectres du courant statorique.....	70
Figure V.7	Spectre du courant statorique à faible charge.....	71
Figure V.8	Classification de deux états de la machine.....	81
Figure V.9	Classification de trois états de la machine.....	82
Figure V.10	Classification de quatre états de la machine.....	83
Figure V.11	Classification de deux états de la machine.....	84
Figure V.12	Classification de trois états de la machine.....	85
Figure V.13	Classification de quatre états de la machine.....	86

Liste des Tableaux

Tableau III.1	Différents types de fonctions de transfert pour le neurone artificiel.....	36
Tableau IV.1	Fonctions de performance.....	61
Tableau V.1	Résultats de performance et de pourcentage avec différentes architectures du réseau FFBN pour le test d'apprentissage.....	73
Tableau V.2	Spécification des résultats de diagnostic de l'architecture [6x8x2] du réseau FFBN.....	73
Tableau V.3	Résultats de performance et de pourcentage avec différentes architectures du réseau FFBN pour le test d'apprentissage.....	74
Tableau V.4	Spécification des résultats de diagnostic de l'architecture [6 x 20 x 3] du réseau FFBN.....	74
Tableau V.5	Résultats de performance et de pourcentage avec différentes architectures du réseau FFBN pour le test d'apprentissage.....	75
Tableau V.6	Spécification des résultats de diagnostic de l'architecture [6 x13x4] du réseau FFBN.....	75
Tableau V.7	Résultats de performance et de pourcentage avec différentes architectures du réseau FFBN pour le test d'apprentissage.....	76
Tableau V.9	Résultats de performance et de pourcentage avec différentes architectures du réseau FFBN pour le test d'apprentissage.....	77
Tableau V.10	Spécification des résultats de diagnostic de l'architecture [10x19x3] du réseau FFBN.....	77
Tableau V.11	Résultats de performance et de pourcentage avec différentes architectures du réseau FFBN pour le test d'apprentissage.....	78
Tableau V.12	Spécification des résultats de diagnostic de l'architecture [10x16x4] du réseau FFBN.....	78
Tableau V.13	Comparaison entre les meilleures architectures du réseau Feedforward.....	79
Tableau V.14	Performance de classification pour deux états avec le réseau [8x8].....	81
Tableau V.15	Performance de classification pour trois états avec le réseau [8x8].....	82
Tableau V.16	Performance de classification pour quatre états avec le réseau [8x8].....	83
Tableau V.17	Performance de classification pour deux états avec le réseau [10x5].....	84
Tableau V.18	Performance de classification pour trois états avec réseau [11x5].....	85
Tableau V.19	Performance de classification pour quatre états avec réseau [10x5].....	86

Introduction générale

Introduction générale

Dans de nombreux secteurs industriels, la sûreté de fonctionnement est un enjeu majeur pour assurer une compétitivité optimale de l'outil de production. Les gains de productivité représentent un souci quotidien pour les dirigeants des entreprises. La compétitivité de ce secteur passe par la maîtrise indispensable de la disponibilité de l'outil de production, l'amélioration de son fonctionnement, la sécurité de ses utilisateurs et la réduction des coûts d'entretien [1].

Les machines asynchrones, de par leur robustesse et leur rapport poids/puissance, sont largement utilisées en milieu industriel. Assurer leur continuité de fonctionnement nécessite la mise en place de programmes de maintenances préventives et curatives. En effet, la fiabilité et la sûreté de leur fonctionnement permettent en partie d'assurer la sécurité des personnes, la qualité du service et la rentabilité des installations. Malheureusement, les contraintes nouvelles et l'intégration de ces machines dans des systèmes de conversion d'énergie de plus en plus complexes rendent le diagnostic plus difficile [2].

Pour effectuer le diagnostic d'une installation industrielle, les opérateurs de la maintenance analysent un certain nombre de signaux issus de la machine. En effet l'évolution temporelle et fréquentielle de ces signaux, peuvent être exploités pour détecter les anomalies qui affectent le bon fonctionnement de la machine. D'après la littérature, les principaux signaux de la machine utilisés pour obtenir des informations sur l'état de la machine sont : le courant statorique, le couple électromagnétique, les vibrations mécaniques et la puissance instantanée statorique. La détection des défauts est plus aisée sur le courant statorique que sur la vitesse ou sur le couple. Ce choix de constatation s'explique en partie par le fait que le courant statorique est plus accessible et mesurable extérieurement au moteur et en plus, l'harmonique de ce courant est plus sensible à la sévérité du défaut que celle du couple ou de la vitesse [3].

Ces dernières années, la surveillance et la détection de défaut des machines électriques se sont éloignées des techniques traditionnelles pour s'orienter vers des techniques dites d'intelligence artificielle (IA). Ces techniques apportent aux systèmes de diagnostic des moteurs électriques la fiabilité, l'automatisation, la praticité et la sensibilité. Parmi ces techniques, nous pouvons citer les systèmes experts, la logique floue, la reconnaissance des formes et les réseaux neurones, qui font l'objet de notre étude.

Dans ce qui suit, nous allons présenter un état de l'art non exhaustif sur les réseaux de neurones artificiels ainsi que leurs applications dans le domaine du diagnostic des défauts rotoriques des machines asynchrones.

Un réseau de neurones peut être considéré comme une boîte noire, il n'est pas nécessaire de construire un modèle du système, contrairement aux méthodes d'analyses des signaux vibratoires. Cependant, l'inconvénient majeur est d'arriver à déterminer une méthodologie pour maîtriser les problèmes inhérents, qui sont principalement le choix de la structure, de la taille du réseau et des algorithmes d'apprentissage pour un problème précis. Par contre, la principale raison de leur intérêt en diagnostic industriel est leur faculté d'apprentissage et la mémorisation d'un grand volume d'information [3].

L'utilisation des réseaux de neurones artificiels (ANN) par l'analyse et le traitement du courant statorique et les vibrations du moteur est particulièrement attrayante en raison des caractéristiques remarquables de traitement des informations telles que : la non-linéarité, la robustesse, la capacité d'apprendre et la capacité de traiter une information imprécise et floue [4].

L'utilisation des réseaux de neurones artificiels, pour la détection des défauts électriques du moteur à induction a été proposée pour la première fois par **Chow et al** [5-7]. Ils ont proposé une structure du réseau de neurones typique de rétropropagation (noté BP pour Back- Propagation) pour le diagnostic de défauts naissants du moteur. Les défauts naissants sont basés tour à tour sur les défauts d'isolement et de l'usure des paliers.

Filippetti et al [8] ont utilisé avec succès une structure similaire d'un réseau de neurone artificiel de rétropropagation BP pour le diagnostic en ligne des défauts rotoriques et en particulier la détection et le comptage du nombre de barres cassées.

Samanta et Al-Balushi [9] ont étudié le diagnostic des défauts d'élément de roulements à l'aide d'un réseau BP. Les signatures caractéristiques dans le domaine temporel des vibrations de la machine avec des roulements sains et défectueux ont été utilisées comme entrées aux réseaux de neurones. Le taux de réussite obtenu pour le test d'apprentissage est de l'ordre de 98%. **Li et al** [10] ont présenté une approche en utilisant les réseaux de neurones BP pour détecter l'ensemble des défauts de roulement à partir des données de vibration du moteur. Les résultats ont montré que les réseaux de neurones peuvent être un agent efficace pour la détection de différents défauts du moteur par la mesure et l'interprétation des signaux de vibration.

Kolla et al [11] ont étudié les défauts du moteur y compris les surcharges, en monophasé, le déséquilibre de la tension d'alimentation, rotor bloqué, défaut à la terre, les surtensions et les sous-tensions en utilisant des méthodes de détection basées sur le réseau de neurones Feedforward.

On peut encore citer **Hamdani et al** [12] qui ont classifié les défauts rotoriques du moteur à induction à cage de 4 kW, 4 pôles, 3 phases par le réseau de neurone Feedforward de perceptron multicouche à apprentissage supervisé à rétropropagation du gradient. Deux types de défauts ont été étudiés la cassure des barres et l'excentricité mécanique. Les signatures caractéristiques issues de l'analyse spectrale du courant statorique de la machine avec un rotor sain et défectueux ont été utilisées comme entrées aux réseaux de neurones. Outre que l'apprentissage supervisé des réseaux de neurones BP, l'apprentissage non supervisé des réseaux de neurones a été également utilisé dans le diagnostic de défauts du moteur.

Penman et Jin [13] ont appliqué la carte auto-organisatrice de Kohonen SOM (Self Organizing Mapping) pour classer les défauts multiples dans un moteur à induction à cage de 3 kW, 4 pôles, 3 phases. Deux types de défauts ont été pris en compte dans leurs documents : le déséquilibre de la tension d'alimentation et l'excentricité mécanique dans les fixations du moteur.

Schoen et al [14] ont utilisé un réseau de neurone à apprentissage non supervisé pour apprendre les caractéristiques spectrales d'un moteur sain. Il a été constaté que l'apprentissage par les spectres caractéristiques peut contenir de nombreuses harmoniques en raison de différentes charges, ce qui correspond aux différents états de fonctionnement sain.

Kowalski et al [15] ont étudié les problèmes de diagnostic des moteurs à induction (défauts électriques et mécaniques) à l'aide des réseaux perceptron multicouche et la carte auto-organisatrice des réseaux de Kohonen, et ils ont appliqué les différents réseaux pour la détection des différents défauts.

En passant en revue les travaux antérieurs, il est à noter que la plupart des recherches ont porté sur la détection de défauts électriques du moteur à cage en utilisant soit des réseaux de neurones Feedforward BP ou les cartes auto-organisatrices séparément pour des défauts spécifiques. Quelques travaux de recherches ont été réalisés en combinant les réseaux de neurones Feedforward BP et la carte auto-organisatrice pour le diagnostic de défauts du moteur.

L'objectif de notre travail de mémoire est la classification des défauts électriques apparaissant au rotor de la machine asynchrone à cage à savoir : la cassure de barres et la rupture d'une portion d'anneau de court circuit en utilisant soit des réseaux de neurones Feedforward BP ou les cartes auto-organisatrices séparément. Méthodologiquement, notre travail s'inscrit dans le cadre des méthodes sans modèles, qualifiées de méthodes sans connaissances a priori. Elles visent le suivi de l'amplitude des composantes (signatures) caractéristiques dans le spectre du courant statorique qui permettent de renseigner sur l'état de la cage rotorique. Pour atteindre cet objectif, nous avons scindé notre mémoire en cinq chapitres.

Le premier présente les différentes défaillances (électriques, mécaniques, etc...) qui peuvent se produire sur la machine asynchrone et l'effet de chaque défaut sur le comportement de la machine.

Le deuxième chapitre est consacré aux différentes méthodes d'estimation de la densité spectrale utilisées pour le diagnostic des défauts des machines électriques, ainsi que les différentes techniques de surveillance issues de l'intelligence artificielle appliquées au diagnostic des machines électriques.

Le troisième chapitre a pour objet de présenter les notions de base des réseaux de neurones comme les modes d'apprentissage, les différentes structures de réseau et les fonctions de transfert.

Le quatrième chapitre se décompose en trois sections, la première section de ce chapitre est consacrée au choix de l'ensemble des signatures possibles caractéristiques des défaillances du système. Nous analysons la grandeur temporelle du courant statorique de la machine asynchrone dans le domaine fréquentiel en utilisant les méthodes d'analyses fréquentielles pour construire une base de données pour les RNA. La deuxième section présente le principe des deux modèles des RNA. Le premier est le modèle à apprentissage supervisé constitué de perceptron multicouche d'une architecture Feedforward Backpropagation, tandis que le deuxième modèle à apprentissage non supervisé est la carte auto-organisatrice de Kohonen SOM (Self Organizing Mapping). La dernière section est relative au codage et la normalisation des données.

Le cinquième chapitre est consacré à l'application des méthodes développées à base des RNA au diagnostic des machines asynchrones à cage en exploitant des essais expérimentaux. Et nous terminons ce mémoire par une conclusion et une présentation des perspectives de recherche qui peuvent être envisagées.

Chapitre I

Généralité sur les défaillances dans la machine asynchrone à cage

I. Introduction

Le moteur asynchrone est un des plus utilisés dans le domaine des puissances supérieures à quelques kilowatts car il présente de nombreux avantages tels que sa puissance massique, sa robustesse, sa facilité de mise en œuvre, son faible coût, etc., l'apparition dans les années quatre vingt des variateurs permettant de faire varier la fréquence de rotation dans une large gamme a grandement favorisé son développement. En effet, il entre dans la conception de nombreux procédés industriels associant des convertisseurs statiques et des machines électriques (traction électrique, laminoirs, levage, pompage, etc...) [1].

Ce premier chapitre porte sur des généralités des défauts qui sont susceptibles de présenter ces systèmes. Nous allons dans un premier temps rappeler les éléments de constitution de cette machine, Ensuite les défaillances les plus courantes pouvant apparaître dans ce type de machine et son alimentation seront énumérées. Ces défaillances peuvent provoquer des pannes et par conséquent des arrêts intempestifs préjudiciables au bon fonctionnement du système ainsi qu'à la sécurité des personnes.

II. Eléments de constitution de la machine asynchrone

Nous proposons dans cette partie, de donner quelques précisions sur les éléments de constitution des machines asynchrones. Cette description va nous permettre de comprendre de quelle façon le système est réalisé physiquement. Les machines asynchrones triphasées peuvent se décomposer, du point de vue mécanique, en trois parties distinctes :

- le stator, partie fixe de la machine où est connectée l'alimentation électrique;
- le rotor, partie tournante qui permet de mettre en rotation la charge mécanique;
- les paliers, partie mécanique qui permet la mise en rotation de l'arbre moteur.

II.1 Stator

Le stator de la machine asynchrone est constitué de tôles d'acier dans lesquelles sont placés les bobinages statoriques. Ces tôles sont, pour les petites machines, découpées en une seule pièce alors qu'elles sont, pour les machines de puissance plus importantes, découpées par sections. Elles sont habituellement recouvertes de vernis pour limiter l'effet des courants de Foucault. Au final, elles sont assemblées les unes aux autres à l'aide de boulons ou de soudures pour former le circuit magnétique statorique.

Une fois cette étape d'assemblage terminée, les enroulements statoriques sont placés dans les encoches prévues à cet effet. Ces enroulements peuvent être insérés de manière imbriqués, ondulés ou encore concentriques. L'enroulement concentrique est très souvent utilisé lorsque le bobinage de la machine asynchrone est effectué mécaniquement. Pour les grosses machines, les enroulements sont faits de méplats de cuivre de différentes sections insérés directement dans les encoches. L'isolation entre les enroulements électriques et les tôles d'acier s'effectue à l'aide de matériaux isolants qui peuvent être de différents types suivant l'utilisation de la machine asynchrone.

Le stator d'une machine asynchrone est aussi pourvu d'une boîte à bornes à laquelle est reliée l'alimentation électrique. Nous représentons sur la Figure I.1 les différentes parties de

constitution du stator d'une machine asynchrone. Nous pouvons visualiser la présence d'ailettes de ventilation assurant le refroidissement de la machine lorsque celle-ci fonctionne en charge.

II.2 Rotor

Tout comme le stator, le circuit magnétique rotorique est constitué de tôles d'acier qui sont, en général, de même origine que celles utilisées pour la construction du stator. Les rotors de machines asynchrones peuvent être de deux types : bobinés ou à cage d'écureuil. Les rotors bobinés sont construits de la même manière que le bobinage statorique (insertion des enroulements dans les encoches rotoriques). Les phases rotoriques sont alors disponibles grâce à un système de bagues-balais positionné sur l'arbre de la machine. En ce qui concerne les rotors à cage d'écureuil, les enroulements sont constitués de barres de cuivre pour les gros moteurs ou d'aluminium pour les petits. Ces barres sont court-circuitées à chaque extrémité par deux anneaux dit "de court-circuit", eux aussi fabriqués en cuivre ou en aluminium.

Il existe différentes structures de rotor à cage qui dépendent principalement de la taille du moteur et de l'application qu'il en sera faite. Nous donnons à la Figure I.1 les différents éléments de constitution d'un rotor à cage d'écureuil. Nous pouvons visualiser l'arbre sur lequel les tôles sont empilées, les deux anneaux de court-circuit ainsi que les barres d'aluminium formant la cage d'écureuil. Très souvent, ces barres sont uniformément inclinées pour limiter les harmoniques et ainsi diminuer très fortement le bruit lors de l'accélération de la machine asynchrone. L'isolation des barres avec les tôles magnétiques n'est en général pas nécessaire du fait de la faible tension induite aux bornes de chacune d'entre elles.

De plus, la résistivité de l'alliage utilisé pour la construction de cette cage est suffisamment faible pour que les courants ne circulent pas à travers les tôles magnétiques, sauf lorsque la cage rotorique présente une rupture de barre. Le rotor de la machine asynchrone est aussi pourvu d'ailettes de ventilation pour permettre un refroidissement de la cage le plus efficace possible comme le montre la Figure I.1.

II.3 Paliers

Les paliers, qui permettent de supporter et de mettre en rotation l'arbre rotorique, sont constitués de flasques et de roulements à billes insérés à chaud sur l'arbre. Les flasques, moulés en fonte, sont fixés sur le carter statorique grâce à des boulons ou des tiges de serrage comme nous pouvons le visualiser sur la Figure I.1. L'ensemble ainsi établi constitue alors la machine asynchrone à cage d'écureuil [16].

Afin d'assurer la variation de vitesse des moteurs électriques mais aussi la conversion de l'énergie, de nombreuses machines se voient associer un convertisseur. Ainsi, de nos jours, on trouve dans un grand nombre de procédés industriels, des associations entre des convertisseurs statiques et des machines électriques (pompage, levage,...). Cela permet de fournir aux moteurs des tensions et des courants de fréquence variable servant à commander la machine en couple ou en vitesse.




Figure I.1: Eléments de constitutions d'une machine asynchrone à cage d'écureuil.

III. Constitution de l'alimentation d'un moteur asynchrone

Dans le cas des moteurs asynchrones, la vitesse de rotation du rotor dépend de la fréquence statorique f_s (fréquence de la tension d'alimentation du moteur) et de la fréquence des courants rotoriques (donc de la charge). Un convertisseur statique permet de faire varier l'amplitude et la fréquence de la tension d'alimentation et donc de faire varier la vitesse de la machine. Plusieurs stratégies de commandes peuvent être utilisées, les commandes scalaires dont une version assure un rapport — constant (avec la fréquence des courants statoriques et U la tension efficace d'alimentation), les commandes vectorielles à flux orienté.

IV. Présentation des différentes défaillances du moteur asynchrone à cage

Les défaillances peuvent être d'origines diverses, électriques, mécaniques ou bien encore magnétiques. Une étude statistique, effectuée en 1988 par une compagnie d'assurance allemande de systèmes industriels sur les pannes des machines asynchrones de moyenne puissance (de 50 kW à 200kW) a donné les résultats suivants (Figure I.2) :




Figure I.2 : Proportion des défauts.

D'autre part les mêmes études montrent qu'entre 1973 et 1988 les pannes au stator sont passées de 78% à 60% et au rotor de 12% à 22%. Ces variations sont dues à l'amélioration des isolants sur cette période. La répartition des pannes dans les différentes parties du moteur est comme suit :

Enroulements stator:	51 %	Tôlerie stator:	9 %
Défauts au rotor:	22 %	Roulements:	8 %
Autres:	10 %		

Une autre étude statistique faite sur des machines de grande puissance (de 100 kW à 1 MW) donne les résultats suivants:

Enroulements stator:	13 %	Couplage mécanique:	4 %
Défauts au rotor:	8 %	Roulements:	41 %
Autres:	34 %		

Les contraintes mécaniques sont plus grandes pour ces types de machines ce qui explique le taux élevé des pannes dues aux roulements. Celles-ci exigent une maintenance mécanique accrue [17].

IV.1 Défaillances d'ordre électrique

Les défaillances d'origine électrique peuvent, dans certain cas, être la cause d'un arrêt de la machine (au même titre que les défaillances d'ordre mécanique). Ces défaillances se séparent en deux catégories bien distinctes. Nous pouvons citer les défauts qui apparaissent au niveau des circuits électriques statoriques et ceux qui apparaissent au niveau des circuits électriques rotoriques.

IV.1.1 Défaillances des circuits électriques statoriques

L'apparition d'un défaut au niveau des circuits électriques statoriques de la machine asynchrone peut avoir des origines diverses. Nous pouvons citer, par exemple, les défauts de type court-circuits inter-spires qui apparaissent à l'intérieur des encoches statoriques. Ce type de défaut peut être causé par une dégradation des isolants des spires du bobinage statorique. Nous pouvons citer aussi les court-circuits apparaissant entre une phase et le neutre, entre une phase et la

carcasse métallique de la machine ou encore entre deux phases statoriques. Ces défauts ont le plus souvent une cause d'origine mécanique. En effet, des vibrations excessives peuvent mener à un desserrement des boulons de la plaque à bornes de la machine créant ainsi le court-circuit. Une cosse mal serrée à la jonction du câble d'alimentation et des bornes de la machine peut être à l'origine d'une ouverture de phase. Le défaut le plus couramment rencontré reste encore la fusion d'un fusible de protection. Ces défauts peuvent être détectés par une analyse harmonique des courants absorbés par la machine [16].

IV.1.1.1 Défauts d'isolant dans un enroulement

La dégradation des isolants dans les enroulements peut provoquer des court-circuits. En effet, les différentes pertes (Joule, fer, mécanique,...) engendrent des phénomènes thermiques se traduisant par une augmentation de la température des différents constituants du moteur. Or les matériaux d'isolation ont une limite de température, de tension et mécanique. De ce fait, si l'environnement de travail d'un matériau d'isolation dépasse une de ces limites, ce matériau se dégrade de manière prématurée ou accélérée, puis finit par ne plus assurer sa fonction. Dans ce cas, un court-circuit peut apparaître dans l'enroulement concerné.

IV.1.1.2 Court-circuit entre spires

Un court-circuit entre spires de la même phase est un défaut assez fréquent. Cette défaillance a pour origine un ou plusieurs défauts d'isolant dans l'enroulement concerné. Il entraîne une augmentation des courants statoriques dans la phase affectée, une légère variation de l'amplitude sur les autres phases, modifie le facteur de puissance et amplifie les courants dans le circuit rotorique. Ceci a pour conséquence une augmentation de la température au niveau du bobinage et, de ce fait, une dégradation accélérée des isolants, pouvant provoquer ainsi, un défaut en chaîne (apparition d'un 2ème court-circuit). Par contre, le couple électromagnétique moyen délivré par la machine reste sensiblement identique hormis une augmentation des oscillations proportionnelle au défaut [1].

Lorsqu'un court-circuit entre spires apparaît, l'application du théorème d'Ampère montre qu'il se crée en plus du champ principal, une excitation magnétique de pulsation Ω_s due au nouveau bobinage court-circuité, parcouru par un courant de court-circuit. C'est l'interaction de ce champ avec celui issu du bobinage statorique qui crée les ondulations de couple et qui induit au stator des forces magnétomotrices de fréquence $2fs$, d'où les courants statoriques comportent ces composantes, par conséquent, des courants de fréquences $3fs$ selon le même processus. Ainsi, des composantes aux fréquences kfs (k :entier positif) se retrouvent dans les courants statoriques [18].

IV.1.1.3 Décharge partielle

Ce phénomène naturel dû aux décharges dans les isolants entre conducteurs ou entre conducteurs et la masse s'amplifie avec le vieillissement des isolants. Il est pratiquement imperceptible dans les isolants neufs par les moyens de mesures classiques car son effet n'est pas discernable par rapport aux bruits de mesure. Sa présence précède l'apparition des court-circuits entre phases ou entre phase et masse lorsque ces décharges partielles ont suffisamment détérioré les isolants [17].

IV.1.1.4 Court-circuit entre phases

Ce type de défaillance peut arriver en tout point du bobinage, cependant les répercussions ne seront pas les mêmes selon la localisation. Cette caractéristique rend difficile une analyse de l'incidence de ce défaut sur le système.

L'apparition d'un court-circuit entre phases proche de l'alimentation, induirait des courants très élevés qui conduiraient à la fusion des conducteurs de l'alimentation et/ou à la disjonction par les protections. D'autre part, un court-circuit entre deux phases proche du neutre engendre un déséquilibre sans provoquer la fusion des conducteurs.

Les courants statoriques sont totalement déséquilibrés et ce déséquilibre est proportionnel au défaut qui apparaît. Les courants dans les barres ainsi que dans les anneaux sont augmentés lors de l'apparition de ce défaut. La détection de ce type de défaut peut reposer sur le déséquilibre des courants de phases.

IV.1.1.5 Court-circuit phase/bâti

Le bâti a généralement un potentiel flottant, mais pour des raisons de liaisons mécaniques, il est souvent relié à la masse. Si le potentiel est flottant, un court-circuit entre l'enroulement et le bâti n'a pas d'importance du point de vue matériel, excepté les effets capacitifs, le bâti prend alors le potentiel de l'enroulement à l'endroit du court-circuit. Par contre, au niveau de la sécurité des personnes, ce type de défaut peut être très dangereux et il est alors nécessaire de mettre en place des dispositifs de protection (disjoncteurs différentiels). En présence de ce type de défaillance, la tension de la phase concernée ne change pas. Cependant le courant circulant dans cette phase augmente avec la réduction de la résistance et de l'inductance. Cette augmentation du courant se traduit par une augmentation de la température pouvant entraîner des défauts d'isolant dans l'enroulement. De plus, cette défaillance va générer une composante homopolaire entraînant l'apparition d'un couple pulsatoire. Une mesure du courant de fuite pourrait permettre de détecter ce type de défaut [1].

IV.1.2 Défaillances des circuits électriques rotoriques

Deux types de défaillances peuvent apparaître au rotor d'une machine asynchrone à cage d'écureuil. La cage étant composée de barres et d'anneaux de court-circuit en aluminium ou en cuivre, une rupture partielle ou totale d'un de ces composants peut être considérée comme un défaut électrique rotorique. L'apparition de ce type de défaut peut être d'origine diverse. En effet, la rupture d'une barre ou d'un segment d'anneau de court-circuit peut être due à plusieurs phénomènes qui sont souvent indépendants les uns des autres. Nous pouvons citer par exemple une mauvaise utilisation de la machine asynchrone (charge trop importante) ou encore l'environnement hostile dans lequel elle fonctionne. Une défaillance au niveau de la cage rotorique se situe généralement à la jointure entre une barre et un anneau de court-circuit. En effet, les barres rotoriques et les anneaux de court-circuit ne pouvant pas être construits d'un seul bloc (sauf pour les machines de petites puissances), une soudure est pratiquée aux extrémités de chaque barre pour relier ces dernières aux deux anneaux de court-circuit. La fragilité de ces soudures, par rapport aux barres et aux anneaux fabriqués d'un seul bloc, provoque, à ces endroits précis, une fragilité de la cage d'écureuil [16].

IV.1.2.1 Cassure des barres

La cassure ou rupture de barre est un des défauts les plus fréquents au rotor. Elle peut se situer soit au niveau de son encoche soit à l'extrémité qui la relie à l'anneau rotorique. La détérioration des barres réduit la valeur moyenne du couple électromagnétique et augmente l'amplitude des oscillations, qui elles-mêmes provoquent des oscillations de la vitesse de rotation de la machine. Ce qui engendre des vibrations mécaniques donc un fonctionnement anormal de la machine qui génère des défauts mécaniques en plus dans la machine. La grande amplitude de ces oscillations accélère la détérioration de la machine, Ainsi, le couple diminue sensiblement avec le nombre de barres cassées induisant un effet cumulatif de la défaillance. L'effet d'une cassure de barre croît rapidement avec le nombre de barres cassées.



Figure I.3: Défaut d'une barre cassée.

IV.1.2.2 Rupture d'anneaux de court circuit

La rupture d'une portion d'anneau est un défaut qui apparaît aussi fréquemment que la cassure de barres. Ces ruptures sont dues soit à des bulles de coulées ou aux dilatations différentielles entre les barres et les anneaux. La rupture d'une portion d'anneau déséquilibre la répartition des courants dans les barres rotoriques et de ce fait, engendre un effet de modulation d'amplitude sur les courants statoriques similaire à celui provoqué par la cassure de barres. Comme il est difficile de le détecter, ce défaut est généralement groupé, voir confondu, avec La rupture de barres dans les études statistiques. Ces portions d'anneaux de court-circuit véhiculent des courants plus importants que ceux des barres rotoriques. De ce fait, un mauvais dimensionnement des anneaux, une détérioration des conditions de fonctionnement (température, humidité,...) ou une surcharge de couple et donc de courants, peuvent entraîner leur cassure [1].




Figure I.4: Rupture d'une portion d'anneau de court-circuit.

IV.1.2.3 Origine des raies dues aux défauts cassures de barres et portion d'anneau

Comme le mentionne Filippetti [19], nous savons que la rupture d'une barre de la cage rotorique induit dans le spectre du courant statorique une composante de fréquence $(1 \pm 2g)f_s$. En effet, la rupture d'une barre rotorique crée, dans l'entrefer de la machine, un champ tournant inverse de fréquence gf_s . L'interaction de ce champ tournant avec la vitesse rotorique crée une composante de fréquence $(1 - 2g)f_s$ dans le spectre du courant statorique. La présence de cette modulation dans le courant statorique induit une oscillation sur le couple électromagnétique de la machine de fréquence $2gf_s$. Cette oscillation de couple crée inévitablement une oscillation de la vitesse rotorique à la même fréquence. Cette oscillation de vitesse induit une nouvelle composante de fréquence $(1 + 2g)f_s$ dans le spectre du courant statorique. Cette composante crée dans l'entrefer un nouveau champ tournant inverse de fréquence $3gf_s$. En utilisant la même approche, ce champ tournant induit une nouvelle composante de fréquence $(1 - 4g)f_s$ dans le spectre du courant statorique. Le couple électromagnétique ainsi que la vitesse rotorique laissent paraître une nouvelle oscillation ayant pour fréquence $4gf_s$. Cette oscillation crée dans le courant statorique une nouvelle composante de fréquence $(1 + 4g)f_s$. Cette nouvelle modulation crée un nouveau champ tournant inverse dans l'entrefer de la machine de fréquence $6gf_s$. Comme nous l'avons précédemment mentionné, la rupture d'une barre de la cage rotorique ne doit induire qu'une seule composante dans le spectre basse fréquence du courant statorique. Les autres composantes étant dues à l'interaction de la vitesse avec les champs tournants inverses présents dans l'entrefer de la machine. La rupture d'une portion d'anneau de court-circuit peut aussi être détectée en utilisant ces composantes car, tout comme la rupture d'une barre de la cage, ce défaut rotorique induit lui aussi un champ tournant inverse de fréquence gf_s dans l'entrefer de la machine asynchrone, produisant ainsi les mêmes composantes dans le spectre fréquentiel du courant statorique [19].

IV.1.2.4 Excentricité statique et dynamique

Parfois, la machine électrique peut être soumise à un décentrement du rotor, se traduisant par des oscillations de couple (décalage entre le centre de rotation de l'arbre et le centre du rotor). Ce phénomène est appelé excentricité (statique et dynamique) dont l'origine peut être liée à un positionnement incorrect des paliers lors de l'assemblage, à un défaut roulement (usure), à un défaut de charge, ou à un défaut de fabrication (usinage). Ceux-ci provoquent la variation de l'entrefer dans le moteur, la répartition non homogène des courants dans le rotor et le déséquilibre des courants statoriques. Le déséquilibre des efforts sur les barres génère un couple global non constant. La géométrie du rotor peut présenter des dissymétries d'ordre naturel. Celles-ci relèvent de trois catégories d'excentricité de l'entrefer (Figure I.6) à savoir :

- L'excentricité statique : lorsque l'axe du stator coïncide avec l'axe de rotation et non avec l'axe du rotor.
- L'excentricité dynamique : lorsque l'axe de rotation du rotor ne coïncide pas avec l'axe de symétrie du stator.
- L'excentricité mixte : lorsque l'axe de rotation du rotor ne coïncide pas avec les axes de symétrie du rotor et du stator.




Figure I.5: Différents types de la dissymétrie de l'entrefer.

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

Ce défaut modifie le comportement magnétique ainsi que mécanique de la machine. En effet, l'augmentation de l'excentricité dans l'entrefer induit une augmentation des forces électromagnétiques qui agissent directement sur le noyau statorique ainsi que l'enroulement correspondant, ce qui engendre une dégradation de son isolation. D'autre part, cette augmentation peut avoir comme conséquence des frottements entre le stator et le rotor en raison des forces d'attraction magnétique qui déséquilibrent le système. Ceci donne naissance à des niveaux de vibration considérables dans les enroulements [1].

IV.2 Défaillances d'ordre mécanique

Les défaillances d'ordre mécaniques sont, en général, les plus rencontrées parmi tous les défauts que compte la machine asynchrone. Ces défauts peuvent apparaître au niveau des roulements à billes, des flasques ou encore de l'arbre moteur. Nous énumérons, dans la suite certains de ces défauts :

IV.2.1 Défaillances des roulements

Les roulements à billes jouent un rôle très important dans le fonctionnement de tout type de machines électriques. Les défauts de roulements peuvent être causés par un mauvais choix de matériau à l'étape de fabrication. Les problèmes de rotation au sein de la culasse du roulement, causés par un roulement abîmé, écaillé ou fissuré, peuvent créer des perturbations au sein de la machine. Nous savons que des courants électriques circulent au niveau des roulements d'une machine asynchrone ce qui, pour des vitesses importantes, peut provoquer la détérioration de ces derniers. La graisse, qui permet la lubrification et la bonne rotation des roulements peut, dans certaines applications, se rigidifier et causer une résistance à la rotation. L'analyse vibratoire de la machine ou l'analyse harmonique des courants statoriques permet de détecter ce type de défaillances.

IV.2.2 Défaillances du flasque

Les défauts créés par les flasques de la machine asynchrone sont le plus généralement causés à l'étape de fabrications. En effet, un mauvais positionnement des flasques provoque un désalignement des roulements à billes, ce qui induit une excentricité au niveau de l'arbre de la machine. Il est possible de détecter ce type de défaillance par une analyse vibratoire ou une analyse harmonique des courants absorbés par la machine.

IV.2.3 Défaillances de l'arbre

L'arbre de la machine peut laisser apparaître une fissure due à l'utilisation d'un mauvais matériau lors de sa construction. A court ou à long terme, cette fissure peut mener à une fracture nette de l'arbre provoquant ainsi un arrêt immédiat de la machine asynchrone. Les milieux corrosifs peuvent aussi affaiblir la robustesse de l'arbre de la machine. Par exemple, l'humidité peut provoquer des microfissures et conduire à une destruction complète de la machine. Une excentricité statique, dynamique ou mixte peut induire des efforts considérables sur l'arbre moteur, amenant ainsi à une fatigue supplémentaire. Une analyse vibratoire, une analyse par ultrason, une analyse fréquentielle des courants absorbés ou simplement une analyse visuelle de l'arbre de la machine permet de détecter ce type de défaillance [16].

IV.2.4 Autres défaillances mécaniques

Au stator, il n'y a pas de pièces mobiles donc a priori pas de défaillances mécaniques. Cependant, il peut apparaître des phénomènes d'oxydation liés à l'environnement de la machine et plus précisément au taux de salinité qui influe sur l'étanchéité et les contacteurs [1].

V. Présentations des Défaillances sur un convertisseur de puissance et sa commande

Le convertisseur de puissance est à base d'un onduleur de trois bras à transistors et pour le contrôle de vitesse, trois capteurs de courant et un capteur de position sont nécessaires. Le point faible de cette architecture réside dans le fait qu'un défaut sur un des composants de la chaîne de conversion d'énergie entraîne la perte de contrôle totale ou partielle de l'actionneur. En pratique, le défaut peut concerner le réseau, le redresseur, l'onduleur, la machine ou l'un des capteurs. Parmi ces défauts, ceux concernant l'onduleur et sa commande rapprochée peuvent être considérés comme étant les plus probables. Ces défauts conduisent à la perte de contrôle de courant et à l'apparition des ondulations de couple d'amplitude importante. Il a été montré que les composants présentant le taux de défaillance le plus élevé sont généralement les condensateurs électrolytiques [20].

VI. Récapitulation des causes de défauts

Les causes des défauts sont multiples et peuvent se classer en trois groupes [17] :

- Les générateurs de pannes ou initiateurs de défauts : surchauffe du moteur, défaut électrique (court-circuit), survoltage d'alimentation, problème d'isolation électrique, usure des éléments mécaniques (roulements à billes), rupture de fixations, etc.
- Les amplificateurs de défauts : surcharge fréquente, vibrations mécaniques, environnement humide, échauffement permanent, mauvais graissage, vieillissement, etc.
- Les vices de fabrication et les erreurs humaines : défauts de fabrication, composants défectueux, protections inadaptées, mauvais dimensionnement de la machine, etc.

VII. Conclusion

Ce chapitre présente les différentes défaillances pouvant se produire sur la machine asynchrone à cage d'écureuil. Après avoir rappelé succinctement la constitution du moteur asynchrone et de son alimentation, nous nous sommes intéressés à répertorier les principales défaillances se produisant sur les différentes parties de la machine ainsi que les causes et les conséquences de leur apparition, des études statistiques ont montrés que les contraintes mécaniques sont les plus grandes et par la suite les défauts de roulements sont plus nombreux que ceux des défauts électriques.

Dans le chapitre suivant, nous allons nous intéresser aux signatures caractéristiques de ces défaillances, déterminées à partir de modèles analytiques et/ou de mesures vibratoires, électriques et électromagnétiques. Ces signatures nous serviront pour la détection, l'identification ou la localisation des défaillances précédemment citées.

Chapitre II

Les différentes méthodes et approches de diagnostic

I. Introduction

La recherche de signatures ou indicateurs de défauts a pour but de caractériser le fonctionnement du système en identifiant le type et l'origine de chacun des défauts. Ceci permet d'assurer une bonne discrimination des pannes ou anomalies survenant aux différents niveaux du processus.

L'apparition d'un défaut au niveau de la machine modifie le fonctionnement de cette dernière, ce qui affecte ses performances. Etant donné la diversité de ces défauts et la complexité des relations de cause à effet, de nombreuses méthodes permettant de réaliser une démarche de diagnostic et de prévenir au mieux la dégradation du système surveillé, ont été développées.

Ainsi lorsque les observations issues du système sont de type numérique, et que l'on dispose d'un modèle mathématique du système, l'approche par modèle mathématique (méthode interne) est privilégiée pour le diagnostic de systèmes dynamiques. En revanche lorsqu'on ne peut construire un modèle analytique du système ou si sa complexité le rend inexploitable, une alternative est l'approche sans modèle (aucune connaissance *a priori*) [1].

Dans ce chapitre, nous allons faire une présentation des différentes méthodes de détection ainsi que des signatures qui en découlent. Ces méthodes sont classées en deux grandes familles, analytique ou heuristique, en fonction de la forme prise par la connaissance du comportement du système, et par conséquent, de la méthode d'analyse qui en découle. La distinction est donc faite entre, les méthodes qui effectuent l'analyse des signaux d'acquisitions sans connaissance *a priori*, qualifiées de diagnostic externe par [21], et celles qui nécessitent la formulation d'un modèle mathématique du système, qualifiées de diagnostic interne par ce même auteur. Toutes ces méthodes permettent de générer une information pertinente (paramètres, vecteur forme, règles, etc...) pour l'élaboration des indicateurs de défauts au système. Le choix d'une méthode se fera en fonction de la nature de ces indicateurs de défauts.

II. Extraction des signatures

II.1 Extraction à partir des méthodes internes (connaissance *a priori*)

Ces méthodes sont issues principalement de l'automatique et supposent une *connaissance a priori* du système. Elles s'appuient sur le suivi d'évolution des paramètres caractéristiques du système étudié ou sur la différence entre le modèle et le processus (méthode des résidus). Une comparaison entre les paramètres mesurés ou calculés et ceux associés à un mode de fonctionnement normal (sain) nous renseigne sur la présence éventuelle d'un défaut.

II.1.1 Méthodes de diagnostic basées sur des modèles paramétriques

Deux approches peuvent être utilisées pour diagnostiquer les défauts à partir des modèles paramétriques. La première repose sur le suivi des paramètres électriques caractérisant les modèles. Il s'agit de détecter un écart entre l'évolution des grandeurs physiques au cours d'un fonctionnement sain et celle suivie par le système en présence de défauts. L'identification des paramètres peut se faire hors ligne. Elle se base alors sur un algorithme d'optimisation de l'erreur entre les paramètres du modèle et ceux du système étudié. Les paramètres peuvent aussi être identifiés en cours de fonctionnement à l'aide d'observateurs étendus.

Le plus couramment utilisé est le Filtre de Kalman. La deuxième approche consiste à analyser les résidus générés à partir d'un modèle proche du système à surveiller. Le modèle de processus est constitué de relations de contraintes dynamiques liant deux types de variables : des variables inconnues (variables internes, perturbations, entrées inconnues, ...) et des variables connues (consignes, variables mesurées). Les résidus sont théoriquement nuls en fonctionnement normal et différents de zéro lorsqu'une défaillance survient. Plusieurs méthodes sont utilisées pour faire ressortir un résidu significatif de la présence de défaut (gradient, Newton-Raphson, Levenberg-Marquardt). La difficulté majeure consiste à faire la liaison entre le résidu établi et un défaut particulier.

Dans la section suivante, nous présentons de façon succincte et non exhaustive, les modèles de comportement dynamique de la machine asynchrone destinés soit à la recherche des signatures des défauts, soit à l'analyse de fonctionnement en présence de défaut, et les paramètres permettant de détecter l'apparition de défauts [1].

II.1.1.1. Utilisation des observateurs

La synthèse des observateurs par retour d'état a connu un grand essor dans l'élaboration des techniques de commande des machines tournantes et continue à connaître de l'essor dans le contexte de diagnostic des entraînements électriques. En effet, leur application à la détection et la localisation des défauts des entraînements électromécaniques date de peu. Cependant, la conception de ces observateurs en vue du diagnostic est effectuée dans le but d'observer des combinaisons linéaires des variables d'état et, contrairement aux observateurs dédiés à la commande, ne met pas en œuvre de rebouclage sur le système diagnostiqué. On peut citer les observateurs de Luenberger, les observateurs généralisés, les observateurs à entrées inconnues ou les filtres de Kalman. Cette approche suppose les paramètres du modèle connus.

L'utilisation de tels observateurs de variables d'état permet de comparer en ligne les sorties (ou une combinaison de ces sorties) reconstituées à partir de données accessibles (signaux de commande, mesures) aux valeurs réelles des sorties mesurées. On génère alors à partir de l'écart obtenu de cette comparaison, des résidus qui, comparés à des seuils de détection préétablis ou adaptatifs, permettent l'élaboration d'indicateurs de défauts (Figure II.1). En effet, le vecteur des résidus est naturellement nul en cas de fonctionnement normal du processus. Mais si l'écart est bien supérieur au seuil de détection, on confirme qu'il y a présence d'un défaut. L'absence de défaut sera affirmée, le cas échéant. Ces mêmes résidus peuvent très bien être générés dans le domaine fréquentiel (cas des observateurs généralisés). En présence de bruit, l'observateur sera remplacé par un filtre de Kalman.




Figure II.1 : Approche physique : utilisation des observateurs.

II.1.1.2 Méthodes utilisant la redondance analytique ou les équations de parité

Ce sont des méthodes qui cherchent à générer des relations produisant des informations redondantes, afin de rendre fiable la détection en vue de la localisation des défauts. Elles utilisent, comme représentation de modèles, les fonctions de transfert ou des modèles analytiques décrivant le système et permettent de reconstruire des erreurs d'équations et des erreurs de sortie. Comme les méthodes précédentes, elles se basent sur des paramètres connus du modèle considéré.

II.1.1.3. Estimation des paramètres

Cette méthode de diagnostic utilise les paramètres structuraux d'un modèle de connaissance et extrait par la suite les paramètres du système à partir des lois de connaissance pour détecter et localiser les défaillances. Le point essentiel dans l'efficacité de cette méthode est le choix du modèle de connaissance. En effet, le type de défaut que l'on voudra détecter sera fonction du modèle utilisé.

Les premiers travaux relatant de l'estimation de paramètres ont débuté avec des modèles relativement simples (modèle de Park par exemple) utilisés depuis plusieurs années pour la commande des machines électriques. Ces modèles n'ont besoin que de quatre paramètres pour effectuer le diagnostic de défaut ce qui, dans certain cas, ne permet pas de localiser avec précision la défaillance. L'étape suivante est donc nécessairement le passage à un modèle de connaissance plus fin de la machine, tout en gardant la possibilité d'identifier les paramètres souhaités. Ces modèles peuvent être des modèles triphasés, qui s'affranchissent de l'hypothèse d'une machine magnétiquement équilibrée, ou encore des modèles à n phases, capables de refléter le fonctionnement de la machine sur une large bande de fréquences.

Des algorithmes spécifiques ont été élaborés pour l'estimation séquentielle de paramètres. Le filtre de Kalman apparaît comme le plus adéquat de tous mais aussi le plus délicat à mettre en oeuvre. Tout d'abord, en tant qu'algorithme d'identification en temps réel, le filtre de Kalman étendu délivre un modèle adaptatif, capable de prendre en compte les évolutions normales des paramètres de la machine telles que la variation des résistances [3].

II.1.1.4 Diagnostic des défauts par analyse du vecteur de Park

Une représentation en deux dimensions peut être utilisée pour décrire le phénomène des moteurs asynchrones triphasés. Une des plus connues et des plus appropriées repose sur le calcul des courants dits de Park. En fonction des courants de phase $i_{sa}(t)$, $i_{sb}(t)$ et $i_{sc}(t)$, les courants de Park $i_d(t)$ et $i_q(t)$ peuvent être calculés grâce aux deux relations suivantes

$$i_d(t) = \sqrt{\frac{2}{3}} i_{sa}(t) - \frac{1}{\sqrt{6}} i_{sb}(t) - \frac{1}{\sqrt{6}} i_{sc}(t) \quad (\text{II.1})$$

$$i_q(t) = \frac{1}{\sqrt{2}} i_{sb}(t) - \frac{1}{\sqrt{2}} i_{sc}(t) \quad (\text{II.2})$$

Nous représentons sur les figures II.2(a) et II.2(b) le tracé du courant $i_d(t)$ en fonction du courant $i_q(t)$ pour un fonctionnement de la machine avec un rotor sain et un rotor défaillant (une barre cassée). Nous apercevons que le défaut rotorique induit un épaississement du contour du cercle, ce qui permet d'établir un diagnostic de défaut en effectuant une surveillance des déviations de ce cercle par rapport au modèle de base.

Cette méthode de détection donne des résultats satisfaisants lorsque la machine fonctionne à son couple nominal. Dans le cas d'un fonctionnement à vide, les courbes obtenues ne permettent pas de diagnostiquer un défaut rotorique car l'épaississement créé par la rupture d'une ou plusieurs barres ne modifie quasiment pas l'épaisseur du cercle de base.

En 1998, une nouvelle implantation de l'approche par vecteur de Park a été proposée. En présence d'une barre cassée, le courant absorbé par le moteur asynchrone contient des composantes latérales de part et d'autre de sa composante fondamentale dont les fréquences sont données par la relation $(1 \pm 2kg)f_s$. Dans cette relation, g représente le glissement de la machine et f_s la fréquence fondamentale des courants statoriques). Ces composantes seront, par conséquent, aussi présentes dans les courants de Park $i_d(t)$ et $i_q(t)$ (donnés par les équations II.1 et II.2). Dans ces conditions, il est très simple de montrer que le spectre du module des courants de Park ($\sqrt{i_d(t)^2 + i_q(t)^2}$) contient une composante continue générée par la composante fondamentale du courant statorique plus des composantes de fréquence $2kgf_s$. De cette façon, le spectre des courants de Park, en éliminant préalablement la composante continue, ne contiendra que les composantes spécifiques au défaut de la machine. Il sera alors plus facile de détecter ces composantes et de diagnostiquer la présence d'un défaut rotorique. La figure II.3(a) montre qu'en absence de défaut, le spectre du module du vecteur de Park est caractérisé par l'absence de composantes spectrales significatives. En revanche, l'analyse du spectre fréquentiel de ce vecteur lorsque la cage d'écureuil est défaillante (figure II.3(b)) montre la présence des composantes spécifiques au défaut rotorique aux fréquences $2kgf_s$ [16].




Figure II.2 : Vecteur de Park des courants statoriques pour 100% de charge avec une alimentation non sinusoïdale.




Figure II.3 : Spectre fréquentiel du module du vecteur de Park des courants statoriques pour 100% de charge.

Les méthodes de diagnostic avec modèle présentent l'avantage de permettre l'observation de grandeurs difficilement, ou voire même parfois non mesurables. De plus, ces méthodes effectuent un filtrage des signaux d'acquisitions, ce qui entraîne une perte d'information.

Nous allons compléter cette étude en introduisant d'autres signaux (les courants, le flux, la tension de neutre, le couple électromagnétique, la vitesse rotorique et les vibrations). Ces signaux sont souvent analysés à partir de mesures directes (capteurs), ce qui introduit l'autre grande famille des méthodes de diagnostic, à savoir les méthodes de diagnostic sans modèle.

II.2 Extraction à partir de méthodes externes (sans connaissance à priori)

Nous avons vu que la première famille de méthodes nécessite la connaissance du comportement dynamique de la machine asynchrone. Dans cette deuxième partie, nous nous intéressons aux résultats obtenus à partir du suivi direct des grandeurs telles que les courants, le couple estimé ou mesuré, les flux ou encore les vibrations. Ces méthodes dites 'sans modèles' se basent sur l'analyse des signaux d'acquisitions. Elles ont l'avantage de l'indépendance de l'analyse par rapport aux fluctuations internes du système. D'autre part, l'information contenue dans les signaux, n'étant pas filtrée par la modélisation, elle reste intacte [1].

II.2.1 Diagnostic des défauts par le suivi des grandeurs mesurables

A ce jour, c'est l'analyse fréquentielle des grandeurs mesurables qui est le plus souvent utilisée pour le diagnostic de défaut rotorique. Les grandeurs accessibles et mesurables d'une machine asynchrone peuvent être :

- Les courants absorbés;
- Le flux de dispersion;
- La tension d'alimentation;
- La tension du neutre (neutre alimentation - neutre machine);
- Le couple électromagnétique ;
- La vitesse rotorique ;
- Les vibrations.

II.2.1.1 Analyse fréquentielle du flux de dispersion

Certains auteurs se sont penchés sur l'analyse du flux de dispersion de la machine asynchrone pour la détection des court-circuits entre spires statoriques. Ils ont montré que l'apparition de ce type de défaut induisait des composantes additionnelles dans le spectre fréquentiel du flux de dispersion. Cette nouvelle approche permet de détecter, tant un défaut statorique, qu'un défaut rotorique en utilisant un capteur de flux relativement peu coûteux.

II.2.1.2 Analyse fréquentielle du couple électromagnétique et de la vitesse rotorique

Lorsqu'une rupture de barre apparaît, les spectres fréquentiels de la vitesse rotorique et du couple électromagnétique laissent paraître des composantes supplémentaires situées aux fréquences $2kf_s$. Cependant, il s'est avéré que l'analyse de ces composantes ne nous renseigne ni sur le défaut rotorique ni sur celles présentes dans le spectre du courant statorique (augmentation des amplitudes moins significative). De plus, l'acquisition de ces deux signaux nécessite un équipement assez coûteux par rapport à un simple capteur de courant, ce qui limite leur utilisation pour le diagnostic de défauts des machines asynchrones. Certains systèmes reconstruisent une image du couple électromagnétique à partir des tensions et des courants mesurés sur la machine, mais cette approche reste moins efficace que les méthodes précédemment citées [16].

II.2.1.3 Analyse fréquentielle de la tension du neutre

En 1998, Cash[22] a utilisé la tension présente entre le neutre de la source d'alimentation et le neutre de la machine asynchrone pour détecter des courts-circuits entre spires dans le bobinage statorique. Une analyse similaire a été effectuée par [16] dans le but de détecter un défaut rotorique dans les machines asynchrones. Il a été montré que l'information donnée par la tension présente entre les deux neutres était pertinente pour le diagnostic des défauts rotoriques. L'information la plus significative pour permettre un diagnostic fiable de la cage rotorique se situe au niveau des composantes harmoniques de fréquence $f_{bt}^{\pm} = [3(1 - g) \pm g]f_s$.

Les figures II.4 (a) et II.4(b) présentent le spectre fréquentiel de cette tension lorsque la machine asynchrone fonctionne avec une cage saine et une cage présentant une barre cassée.




Figure II.4 : Spectre de la tension du neutre.

Il a été remarqué, à partir des essais expérimentaux, que l'augmentation de l'amplitude de ces composantes est plus significative que celle présente à la fréquence $(1 - 2g)f_s$ dans le spectre fréquentiel du courant statorique lorsque le défaut rotorique apparaît. De plus, l'acquisition de ce signal reste aussi simple que le courant statorique. Cependant, il est préférable que le neutre de la source d'alimentation ne doit pas être trop éloigné de celui de la machine.

II.2.1.4 Analyse fréquentielle de la puissance instantanée

La quantité d'information donnée par la puissance instantanée d'une phase, qui n'est autre que le produit de la tension d'alimentation et du courant absorbé par le moteur, est plus importante que l'analyse du courant seul. En effet, en plus de la composante fondamentale et des deux composantes latérales, le spectre de la puissance instantanée contient une composante additionnelle «pso» située à la fréquence de défaut comme le montre la relation suivante :

$$p_s(t) = p_{s0}(t) + \frac{mV_{LL}I_L}{2} \left[\cos \left((2\omega_s - \omega_f)t - \varphi - \frac{\pi}{6} \right) + \cos \left((2\omega_s + \omega_f)t - \varphi - \frac{\pi}{6} \right) + 2 \cos \left(\varphi + \frac{\pi}{6} \right) \cos(\omega_f t) \right] \quad (\text{II.3})$$

avec :

$$p_{s0}(t) = V_{LL}I_L \left[\cos \left(2\omega_s t - \varphi - \frac{\pi}{6} \right) + \cos \left(\varphi + \frac{\pi}{6} \right) \right] \quad (\text{II.4})$$

Dans cette expression, $p_s(t)$ représente la puissance instantanée d'une phase statorique, m l'indice de modulation, V_{LL} la valeur moyenne de la tension entre phase, I_L le courant de ligne et ω_f la pulsation d'oscillation (pulsation de défaut) exprimée en radians/seconde. Les termes ω_s et φ représentent respectivement la pulsation des courants d'alimentation exprimée en radians et l'angle de déphasage entre le courant absorbé par le moteur et la tension.

Les figures II.5(a) et II.5(b) montrent clairement la présence de ces composantes basses fréquences lorsque la cage de la machine présente une défaillance. Le fait de retrouver ces composantes dans une bande fréquentielle bornée facilite leur détection et permet donc

d'améliorer le diagnostic de défaut. Cette représentation rappelle celle obtenue avec l'analyse fréquentielle du module du vecteur de Park mais la différence, avec l'analyse de la puissance, réside dans le fait que seule l'acquisition d'un courant et d'une tension est nécessaire. Ce type de signal est aussi utilisé pour détecter les défauts d'origine mécanique (variation du couple de charge par exemple) ou encore les courts-circuits entre spires statoriques.




Figure II.5 : Spectre de la puissance instantanée.

II.2.1.5 Analyse vibratoire de la machine

Beaucoup de travaux ont été effectués sur les vibrations de la machine asynchrone. La plupart des défauts connus peuvent être détectés avec ce type d'approche. Cependant, l'équipement nécessaire pour l'acquisition des signaux reste encore coûteux [16]. L'analyse vibratoire de la machine asynchrone peut être menée grâce à des accéléromètres placés sur les paliers dans les directions verticales, axiales et radiales [2].




Figure II.6 : Mesures vibratoires sur la machine asynchrone.

II.2.1.6 Intérêts de l'analyse des défauts par le courant statorique

La détectabilité et l'isolabilité des défauts par les signaux évoqués précédemment nécessitent la mise en place d'un grand nombre de capteurs (capteurs de flux, thermocouple, transducteurs, couplétre, capteur de vitesse, microphones, imagerie, etc...), lesquels capteurs sont parfois onéreux et délicats à placer dans des environnements souvent hostiles.

La surveillance de l'état de santé de la machine peut nécessiter également la mise en œuvre de méthodes d'estimation ou d'observation pour reconstituer les variables de surveillance, tel que le flux et le couple électromagnétique.

Beaucoup d'études ont montré que l'analyse du spectre du courant statorique permet de révéler naturellement l'existence de la quasi majorité des défauts électriques et électromagnétiques survenant au niveau du moteur asynchrone: déséquilibres de phase, court-circuit de spires, rupture de barres rotoriques, excentricité d'entrefer, défauts de modes communs, etc... Cette approche de surveillance des machines électriques est connue sous le nom de MCSA (Motor Current Signature Analysis) et a fait l'objet de plusieurs publications pendant ces dix dernières années. Le premier avantage de cette analyse est qu'elle permet, de part les potentialités du courant statorique, la localisation d'un grand nombre de défauts mécaniques sans ajout de capteurs supplémentaires spécifiques à des grandeurs mécaniques ou relatives aux vibrations. En effet, ceci a été mis en évidence par la comparaison du signal courant et d'un signal vibratoire, dans des conditions de fonctionnement en présence de défauts. Le deuxième avantage est que les capteurs de courants sont désormais présents dans tous les systèmes de commande des entraînements électriques et offrent un accès à la mesure aisé [3].

Nous savons que le suivi de l'amplitude des composantes caractéristiques de fréquences $(1 \pm 2k_g)f_s$ dans le spectre du courant permet de se renseigner sur l'état de la cage rotorique. A titre d'exemple, nous présentons sur les figures II.7(a) et II.7(b) le spectre du courant statorique lorsque la machine fonctionne avec un rotor sain et un rotor défaillant (une barre cassée). Nous apercevons une nette augmentation de l'amplitude de ces composantes, ce qui traduit la présence d'un défaut au sein de la cage d'écureuil [16].




Figure II.7: Spectre du courant statorique.

Nous présentons ici les méthodes classiques d'estimation de la Densité Spectrale de Puissance d'un signal, notée DSP, fondées sur la transformée de Fourier discrète. Nous donnons par la suite les caractéristiques importantes d'un estimateur que sont le biais et la variance ainsi que leur impact sur le spectre fréquentiel résultant. Cela nous amène à présenter quelques méthodes permettant de diminuer la variance pour obtenir une meilleure estimation de la densité spectrale de puissance du signal observé. Rappelons, au préalable, que toutes les méthodes présentées font partie de la famille des méthodes d'estimation spectrale non-paramétriques.

III. Méthodes classiques d'estimation de la densité spectrale de puissance

Toute anomalie affectant une partie de la machine se traduit par l'apparition et/ou la modification d'harmoniques au niveau des spectres des signaux. Ces harmoniques possèdent des fréquences qui correspondent aux fréquences d'apparition des forces qui les induisent.

Beaucoup d'outils de traitement du signal sont utilisés afin de caractériser et d'identifier les origines des défauts à partir des spectres harmoniques. La méthode classique la plus utilisée est la Transformée de Fourier (FFT). C'est une technique non paramétrique qui se prête bien à l'analyse des phénomènes stationnaires. L'application d'une FFT sur un signal temporel permet de visualiser l'état de la machine en fournissant la composition du spectre du signal traité et de la comparer à la composition du spectre de référence [3].

III.1 Transformée de Fourier discrète

La transformée de Fourier discrète, généralement notée TFD, d'une suite finie de P échantillons $\{ps(0), ps(1), \dots, ps(P-1)\}$ se calcul grâce à la relation:

$$F(k) = \frac{1}{N} \sum_{n=0}^{N-1} p_s(n) e^{-\frac{j2\pi nk}{N}} \quad (\text{II.5})$$

Pour $k=0, \dots, N-1$

Où le terme N représente le nombre de points de calcul de la TFD. Ce terme joue sur la précision du tracé alors que le terme P est lié à ce que l'on appelle la résolution en fréquence. En pratique, on essaye d'avoir un nombre de point P de la suite $ps(n)$ supérieur ou égal au nombre de point de la TFD ($P \geq N$). Si ce n'est pas le cas, on utilise une technique appelée *zéro-padding* qui consiste à compléter la suite $ps(n)$ avec $(N-P)$ zéros, ce qui permet d'obtenir autant de point pour la suite temporelle que le suite fréquentielle.

La transformée de Fourier Inverse, notée ITFD, se calcul grâce à la relation :

$$p_s(n) = \sum_{k=0}^{N-1} F(k) e^{\frac{j2\pi nk}{N}} \quad (\text{II.6})$$

En décomposant l'exponentielle de l'équation II.5, le nombre complexe $F(k)$ peut se mettre sous la forme :

$$F(k) = \frac{1}{N} \sum_{n=0}^{N-1} p_s(n) \cos\left(\frac{2\pi \cdot n \cdot k}{N}\right) - j \frac{1}{N} \sum_{n=0}^{N-1} p_s(n) \sin\left(\frac{2\pi \cdot n \cdot k}{N}\right) \quad (\text{II.7})$$

Cette équation nous permet ainsi de définir la transformée de Fourier en cosinus, notée TDF-cos grâce à l'équation suivante:

$$F_c(k) = \frac{1}{N} \sum_{n=0}^{N-1} p_s(n) \cos\left(\frac{2\pi \cdot n \cdot k}{N}\right) \quad (\text{II.8})$$

Ainsi que la transformée de Fourier en sinus, notée TFD-sin, calculée avec l'équation :

$$F_s(k) = \frac{1}{N} \sum_{n=0}^{N-1} p_s(n) \sin\left(\frac{2\pi \cdot n \cdot k}{N}\right) \quad (\text{II.9})$$

Ces deux transformées permettent d'obtenir des temps de calcul réduits lorsqu'elles sont implantées dans un algorithme de calcul.

III.2 Transformée de Fourier rapide

La transformée de Fourier rapide, notée FFT, est un algorithme de calcul rapide de la TFD élaborée en 1965 par [23]. L'algorithme de base de cette transformée utilise un nombre de points N égal à une puissance de 2, ce qui permet d'obtenir un gain en temps de calcul, par rapport à un calcul avec la TFD, de :

$$\text{Gain} = \frac{N}{\log_2(N)} \quad (\text{II.10})$$

Cette transformée de Fourier rapide est très utilisée lorsqu'il est indispensable d'obtenir une analyse fréquentielle "en ligne" dans certains processus à travers une fenêtre glissante d'observation.

IV. Périodogramme

IV.1 Périodogramme simple

En considérant une suite de variables aléatoires réelle de longueur quelconque $p_s(n)$, nous pouvons montrer que la densité spectrale de puissance $\hat{p}_{p_s}(f)$ de la suite $p_s(n)$, sous l'hypothèse d'ergodicité, repose sur l'équation :

$$\hat{p}_{p_s}(f) = \lim_{N \rightarrow \infty} E \left[\frac{1}{(2N+1)} \left| \sum_{n=-N}^N p_s(n) e^{-\frac{j2\pi f n}{N}} \right|^2 \right] \quad (\text{II.11})$$

Avec : $-\frac{1}{2T} \leq f \leq +\frac{1}{2T}$ et T la période d'échantillonnage. La nécessité d'appliquer l'espérance mathématique E provient du caractère aléatoire des signaux. En pratique, pour un ensemble de données $p_s(n)$ disponibles de $n = 0$ à $N - 1$, le calcul de la DSP s'effectue avec la relation suivante :

$$\hat{p}_{p_s}(f) = \frac{1}{N} \left| \sum_{n=0}^{N-1} p_s(n) e^{-\frac{j2\pi f n}{N}} \right|^2 \quad (\text{II.12})$$

Cet estimateur est appelé périodogramme. Nous pouvons noter qu'il est proportionnel au carré de l'amplitude de la TFD de la séquence observée (équation II.6). L'estimation de la DSP peut être vue comme un filtrage du signal d'entrée par un banc de filtres du type passe-bande, dont

chaque filtre élémentaire possède la réponse fréquentielle $H(f)$ suivante :

$$H(f) = \frac{\sin(N\pi(f-f_0))}{N \sin(\pi(f-f_0))} e^{j(N-1)\pi(f-f_0)} \quad (\text{II.13})$$

Le signal de sortie d'un filtre élémentaire est ensuite échantillonné et son amplitude est élevée au carré pour déterminer la puissance de sa bande spectrale. La largeur de bande à -3dB de ces filtres est d'environ $\frac{1}{N}$. Lorsque N tend vers l'infini, la puissance de sortie du filtre correspond à celle d'une composante spectrale de fréquence f_0 du signal d'entrée. Dans ce cas, l'estimateur est non biaisé, ce qui n'est pas le cas lorsque le nombre d'échantillons N est connu.

IV.2 Périodogramme modifié

Le fait de se limiter à un nombre d'échantillons N peut être vu comme la multiplication terme à terme de la totalité du signal par la suite $\omega(n) = I\{0, \dots, N-1\}(n)$. On donne à cette dernière le nom de fenêtre rectangulaire. Ce fenêtrage introduit des ondulations parasites (noyau de Dirichlet) dans le spectre fréquentiel résultant. Il est donc très courant d'utiliser des fenêtres dites de pondération pour permettre une meilleure visualisation des composantes du spectre fréquentiel. En conséquence, l'expression de la DSP donnée à l'équation II.12 devient :

$$\hat{p}_s(f) = \frac{1}{N} \left| \sum_{n=0}^{N-1} \omega(n) p_s(n) e^{-j2\pi f n} \right|^2 \quad (\text{II.14})$$

Le terme $\omega(n)$ rajouté dans l'équation représente l'expression mathématique de la fenêtre de pondération choisie. Les fenêtres de pondération les plus connues sont la fenêtre de Hanning, celle de Hamming ou encore celle de Blackman. Chacune d'elle permet de choisir le rapport souhaité entre la largeur du lobe principal et l'atténuation de la hauteur du plus grand lobe secondaire du spectre fréquentiel. Le périodogramme ou le périodogramme modifié comporte deux caractéristiques importantes : le biais et la variance. Ces deux caractéristiques, décrites ci-après, jouent un rôle très important dans l'estimation du spectre fréquentiel.

IV.3 Biais et variance du périodogramme

Pour un nombre d'échantillons N limité, nous savons que la largeur de bande d'un filtre élémentaire est déterminée. Il se produit alors un biais entre la localisation de la composante sur le spectre et la fréquence réelle de celle-ci. L'espérance mathématique du périodogramme qui permet de déterminer le biais ou le décalage peut être calculée selon :

$$E[\hat{p}_s(f)] = \int_{-\frac{1}{2}}^{\frac{1}{2}} \omega_{\text{tri}}(f-g) p_s(f) dg \quad (\text{II.15})$$

Elle est obtenue par convolution de la DSP réelle avec la transformée de Fourier à temps discret de la fenêtre triangulaire, notée ω_{tri} dans l'équation précédente. Cette équation permet de nous rendre compte que le périodogramme est un estimateur biaisé car l'espérance mathématique de $\hat{p}_s(f)$ n'est pas la vraie DSP.

La variance est la seconde caractéristique importante d'un estimateur spectral. D'après [24], le calcul de celle du périodogramme, dans le cas particulier d'un bruit blanc gaussien, conduit à la relation suivante :

$$\text{var}[\hat{p}_{p_s}(f)] \approx P_{pp}(f)^2 \left[1 + \left(\frac{\sin(2N\pi f)}{N \sin(2\pi f)} \right)^2 \right] \quad (\text{II.16})$$

Ce qui nous amène, pour toute fréquence $f = \frac{1}{N}$, à la relation :

$$[\hat{p}_{p_s}(f)] \approx P_{pp}(f)^2 \quad (\text{II.17})$$

La variance du périodogramme est alors indépendante du nombre de point N . D'une autre façon, lorsque le nombre de points N augmente, le biais du périodogramme diminue mais sa variance reste identique, ce qui donne des spectres relativement bruités. Pour se prémunir de cette contrainte, il est possible d'utiliser des estimateurs spectraux à variance réduite.

V. Estimateurs spectraux à variance réduite

Nous avons vu précédemment que le nombre de points N du signal n'avait aucune influence sur la variance du périodogramme. une solution à ce problème est l'utilisation d'estimateurs spectraux à variance réduite tels que le périodogramme de Bartlett ou encore le périodogramme de Welch dont nous présentons les caractéristiques ci-après.

V.1 Méthode de Bartlett

Le signal de taille N est divisé en S sections de M échantillons. On évalue sur chaque section S l'estimateur spectral par la méthode du périodogramme modifié (équation II.14) grâce à la relation:

$$\hat{p}_{p_s}^s(f) = \frac{1}{M} \left| \sum_{n=0}^{M-1} \omega(n) p_s(n) e^{-j2\pi f n} \right|^2 \quad (\text{II.18})$$

L'estimation moyennée est alors :

$$\widehat{p}_{p_s}^{\text{bar}}(f) = \frac{1}{S} \sum_{n=0}^{S-1} \hat{p}_{p_s}^s(f) \quad (\text{II.19})$$

Dans ce cas, la variance est approximativement égale à celle du périodogramme divisée par le nombre de sections " S ". Si, pour un nombre de points " N " constant, nous augmentons le nombre de sections " S ", nous constatons que la variance du périodogramme de Bartlett diminue. L'utilisation de cette méthode implique une résolution fréquentielle plus faible par rapport à un calcul avec le périodogramme modifié.

V.2 Méthode de Welch

La méthode de Welch est un autre type d'estimateur qui exploite le périodogramme modifié [23]. Elle est basée sur la même idée que la méthode de Bartlett. Cependant, la différence réside dans le fait que les segments S peuvent se chevaucher dans un rapport allant généralement de 50% à 75%. Le calcul du périodogramme de chaque section S s'effectue grâce à la relation mathématique suivante :

$$\hat{p}_{p_s}^s(f) = \frac{1}{M} \left| \sum_{n=0}^{M-1} \omega(n) p_s(n + (s-1)C) e^{-j2\pi f n} \right|^2 \quad (\text{II.20})$$

avec $1 \leq s \leq S$, et C le nombre d'échantillons permettant le chevauchement avec $C \leq M$.

L'estimateur de Welch se calcule ensuite avec la relation :

$$\widehat{P}_{p_s}^{\text{wel}}(f) = \frac{1}{S} \sum_{n=0}^{S-1} \widehat{p}_{p_s}^s(f) \quad (\text{II.21})$$

En autorisant le recouvrement des séquences, nous pouvons augmenter le nombre de segments S pour une taille N donnée. Cette solution permet non seulement de réduire la variance de l'estimateur mais aussi d'augmenter la résolution en fréquence en choisissant un nombre d'échantillons M plus grand que celui utilisé avec la méthode de Bartlett. Il a été montré que, si le chevauchement des segments est de 50%, la variance de l'estimateur de Welch est approximativement égale à $9/16$ de la variance de l'estimateur de Bartlett. Cette méthode est très utilisée de nos jours et beaucoup d'auteurs ont montré l'intérêt et l'efficacité [25]. Il existe d'autres estimateurs pour calculer la densité spectrale de puissance d'un signal. Nous pouvons citer par exemple le corrélogramme qui nécessite l'estimation de la séquence d'auto-corrélation du signal à analyser avant le calcul de la DSP, ou encore la méthode de Blackman-Tukey.

V.3 Analyse spectrale en ligne

L'analyse en ligne ("on-line") de certains processus devient indispensable de nos jours. En effet, une détection précoce et surtout rapide de la défaillance permet ainsi d'éviter au système d'évoluer vers un mode dangereux qui peut être fatal pour l'installation dans laquelle il fonctionne. L'analyse spectrale en ligne est basée sur la transformée de Fourier discrète glissante.

V.3.1 Transformée de Fourier glissante

Le principal inconvénient, en ce qui concerne le calcul de la TFD d'un signal, est qu'il est nécessaire d'avoir les N échantillons pour commencer le traitement des données. Pour obtenir un calcul rapide il est souvent nécessaire d'utiliser la FFT, ce qui permet de limiter le nombre de calculs pour obtenir le spectre fréquentiel du signal à analyser. Comme nous l'avons vu précédemment, ce type de transformée impose un nombre d'échantillons égal à une puissance de 2, ce qui fixe la précision du tracé à $\Delta f = \frac{F_e}{N}$. Par conséquent, cette précision dépend en grande partie de la fréquence d'échantillonnage F_e utilisée. Ces deux inconvénients peuvent être en partie éliminés en utilisant une technique qui se base sur une approche glissante. Cette méthode "glissante" permet de calculer la TFD à l'arrivée de chaque échantillon en prenant en compte la transformée précédente. La seule contrainte de cette technique concerne la durée du calcul qui doit rester inférieure à la période d'échantillonnage du signal. Cette condition respectée, l'algorithme conduit alors à une analyse spectrale du signal dite en temps réel.

Nous ne donnerons pas les différentes équations relatives à l'implantation de cette méthode car beaucoup de travaux ont déjà été effectués sur le sujet [16].

VI. Outils d'analyse fréquentielle liés au traitement de l'information

La transformée de Fourier présente des limites quant au traitement des signaux impulsionnels (chocs, frottements, etc...) ou l'analyse des signaux en régime transitoire. En effet, quand il s'agit d'un défaut se manifestant par des signaux riches en harmoniques (échelons, impulsions), on perd l'information dans le domaine temporel.

D'autres outils viennent compléter l'analyse par FFT pour pallier ses inconvénients quant au traitement des signaux non stationnaires. Parmi ces outils figure l'analyse d'enveloppe qui permet de caractériser les chocs cycliques tels que ceux produits par les roulements ou de caractériser les oscillations de rotation produites par exemple par un jeu au niveau des engrenages. Certaines études se basent sur l'analyse par bispectre qui s'intéresse à la fois à l'amplitude et à la fréquence. La mise au point de certains autres outils a émané du principe de calcul de la FFT. Nous citons à titre d'exemple l'analyse cepstrale, outil très utilisé dans un diagnostic se basant sur des signaux vibratoires complexes des structures mécaniques. Elle se définit comme la transformée de Fourier du logarithme du spectre de puissance du signal à traiter.

D'autres méthodes ont été développées pour représenter les signaux dans le plan temps – fréquence et sont connues sous le nom de «Transformées de Wigner – Ville ». Elles permettent de déterminer la fréquence instantanée d'un signal et donc d'analyser des signaux fortement non – stationnaires ou des phénomènes transitoires qui sont la conséquence de défauts dans la chaîne et qui présentent des variations spectrales complexes.

Adaptée aux signaux présentant de multiples échelles de temps, la décomposition en ondelettes est une technique de traitement du signal qui consiste à concentrer l'information dans des coefficients en nombre restreint, ce qui permet de synthétiser le signal original avec une bonne qualité et permet de révéler l'occurrence de défauts avec une possibilité de les localiser dans le temps. Cette analyse revêt un caractère "multirésolution" et permet ainsi d'obtenir une bonne résolution à la fois fréquentielle en basse fréquence et temporelle pour les hautes fréquences. Il en découle une bonne adaptation de cette technique à la détection et à la localisation des défauts se présentant sous la forme de phénomènes transitoires tels que les chocs, les claquages d'isolants, etc...

Toutes ces techniques semblent être prometteuses pour la surveillance et le diagnostic des machines électriques à vitesse variable. Mais les interprétations qui en découlent ne seront pertinentes que si le signal est efficacement mesuré et riche en informations [3].

VII. Vers des approches modernes de diagnostic

En dépit des diverses techniques mentionnées précédemment (diagnostic interne et externe), ces dernières années, la surveillance et la détection de défaut des machines électriques se sont éloignées des techniques traditionnelles pour s'orienter vers des techniques dites d'intelligence artificielle (IA). Ces techniques apportent aux systèmes de diagnostic des moteurs électriques la fiabilité, l'automatisation, la praticité et la sensibilité.

Ces méthodes ne sont pas en concurrence avec les méthodes citées dans le chapitre précédent. Elles exploitent les signatures avec ou sans modèle, décrites précédemment, pour réaliser la supervision et le diagnostic du système. Elles possèdent, par ailleurs, de grandes

facultés d'apprentissage. En effet, les récents développements dans le matériel et le logiciel permettent de produire un système pour la surveillance automatique des moteurs asynchrones en utilisant des techniques de traitement des signaux et des techniques de classification non supervisée pour le diagnostic des défauts.

Parmi ces méthodes, nous pouvons citer les systèmes experts, la logique floue, les réseaux neurones, la reconnaissance des formes, etc.... Dans cette partie, nous allons présenter quelques unes de ces techniques ainsi que leur application dans le domaine du diagnostic de la machine électrique.

VII.1 Approches à base de systèmes experts

Les systèmes experts sont des outils conçus pour pouvoir modéliser l'approche des experts dans un domaine spécifique. Ils permettent de formaliser leurs connaissances et fournissent un mécanisme pour les exploiter. Lorsque le mode de représentation de la connaissance est de type symbolique, l'approche par système expert est favorisée. Dans ce cadre, la connaissance a priori sur le système est représentée par un ensemble de règles et de faits (données manipulées par les règles) qui constituent ce qu'on appelle la base de connaissance. Cette base est construite à l'aide d'outils d'aide à la formalisation, ces outils sont fortement liés à l'application. L'architecture générale d'un système expert se compose principalement de deux éléments : une base de connaissance et un moteur d'inférence. Le moteur d'inférence représente l'organe de résolution, son fonctionnement est basé sur des méthodes de résolution indépendantes du contexte. Une méthode de résolution inclut en général les étapes suivantes :

- la sélection de règles dans la base de connaissance en fonction des faits établis ;
- la résolution des conflits entre les règles sélectionnées ;
- l'exécution en indiquant les conditions de déclenchement et les conséquences jusqu'à ce que le but recherché soit atteint, par exemple le diagnostic.

En diagnostic, ce type d'approche est adapté aux problèmes nécessitant la manipulation d'une quantité importante de données non homogènes. Ils ont beaucoup été utilisés dans le diagnostic des systèmes statiques. Pour des systèmes dynamiques, ce type d'approche est peu adapté pour des problèmes de temps-réel et de gestion dynamique de l'information. Pour des applications industrielles, on pourra se référer à [26]. On peut aussi faire référence à quelques articles traitant le problème du diagnostic des moteurs électriques à partir de ces systèmes [27].

VII.2 Approches à base d'arbres de défaillances

Il s'agit d'une méthode déductive qui vise à identifier pour chaque événement indésirable, l'ensemble des événements élémentaires qui peuvent contribuer à son apparition. Cette méthode est très employée dans les domaines de l'automobile, du nucléaire, de la chimie, de l'aéronautique, etc... pour évaluer la fiabilité d'un système. Elle consiste en une recherche exhaustive des combinaisons possibles d'événements qui conduisent à un défaut de fonctionnement ou une panne. La représentation la plus utilisée est celle qui associe à chaque événement indésirable la liste de tous les enchaînements logiques des événements jusqu'à arriver à des événements de base qui ne nécessitent pas de développements plus poussés. Quand l'arbre est établi et les probabilités des événements élémentaires connues, la probabilité de l'événement indésirable et les combinaisons les plus probables conduisant à son apparition peuvent être déterminées. Cette méthode présente différents avantages :

- Elle permet d'analyser toutes les causes possibles d'un défaut et donc d'améliorer la conception du système.
- La décomposition arborescente permet un diagnostic relativement rapide des défauts.

Cependant, cette méthode présente plusieurs inconvénients :

- Le principal vient de l'exhaustivité nécessaire pour établir le diagnostic : uniquement les causes prévues peuvent être déduites. La difficulté réside en la lourdeur de la mise en œuvre de la méthode pour un système complexe.
- Connaître jusqu'à quel niveau de décomposition l'analyse peut être menée.
- La méthode est difficile à utiliser pour des systèmes complexes fortement interconnectés. Une étude exhaustive de tous les défauts et de leurs combinaisons s'avère rédhibitoire pour un entraînement.

Dans le domaine des entraînements, des arbres de défaillances ont été utilisés pour analyser les pannes de cartes analogiques de commande. L'idée était d'analyser les causes de quelques combinaisons de signaux logiques issus de protections pour donner à l'utilisateur une indication sur la carte à changer après un défaut. L'expérience a montré que ces arbres étaient lourds à mettre en œuvre et difficiles à modifier. De plus, comme ils étaient basés sur un nombre restreint de signaux logiques, les indications données étaient très succinctes.

VII.3 Approches à base de reconnaissance des formes (RdF)

Lorsque les observations sont de type numérique, l'approche par reconnaissance des formes peut être employée. Sur des problèmes complexes tels que le nucléaire, l'industrie automobile, le comportement humain, les réseaux téléphoniques, etc... où la modélisation du procédé est souvent difficile à mettre en œuvre, cette approche est privilégiée. De nombreux travaux ont permis de montrer l'intérêt de ce type d'approche. Dans le domaine du diagnostic des machines électriques, cette approche, quoique plus rarement utilisée, a été mise en œuvre avec succès par [28], par exemple.

Pour anticiper l'apparition d'un dysfonctionnement, soit pour les éviter, soit pour en limiter les conséquences, quelques études ont utilisées l'association de la RdF et la théorie des ensembles flous. Il est parfois important de détecter l'évolution du système à diagnostiquer, notamment pour détecter la transition entre les modes de fonctionnement normal et anormal.

La RdF peut servir de base à la conception d'un système de diagnostic, et l'avantage essentiel qu'elle présente par rapport aux autres approches. Cette méthode procure au système de diagnostic des moyens d'appréhender la connaissance a priori incomplète des modes de fonctionnement du processus et ainsi, va permettre la mise en place d'une méthode de diagnostic évolutive.

VII.4 Approches à base de réseaux de neurones artificiels

Un réseau de neurone est un modèle de calcul dont la conception est très schématiquement inspirée du fonctionnement de vrais neurones humains. Cette technique est placée dans la famille des méthodes de l'intelligence artificielle qu'ils enrichissent en permettant de prendre des décisions s'appuyant davantage sur la perception que sur le raisonnement logique formel. Dans les années 1940, les neurologues Warren Sturgis

McCulloch et Walter Pitt s menèrent les premiers travaux sur les réseaux de neurones. Ils constituèrent un modèle simplifié de neurone biologique communément appelé neurone formel. Ils montrèrent également théoriquement que des réseaux de neurones formels simples peuvent réaliser des fonctions logiques, arithmétiques complexes [3].

Issus de la recherche en neurophysiologie et en informatique, cette approche fait l'objet de recherches dans beaucoup de domaines tels que la compréhension et la synthétisation de la langue naturelle, la classification, le diagnostic, etc. Cette technologie comporte des caractéristiques très intéressantes comme la faculté d'apprentissage et d'auto-organisation. Elle présente des perspectives d'applications particulièrement intéressantes pour l'aide au diagnostic avec signatures externes. En effet, le calcul neuromimétique possède des propriétés similaires à celles de la reconnaissance des formes pour la classification automatique de signatures. Pour identifier des défauts dans un système, le diagnostic réalisé par réseaux de neurones doit disposer d'un nombre suffisant d'exemples de bon fonctionnement et de défauts pour pouvoir les apprendre. Pendant la phase d'apprentissage, les exemples sont présentés au réseau en entrée avec les diagnostics correspondants à la sortie.

Le réseau de la carte auto-organisatrice, apprenant à relier les exemples montrés aux diagnostics. Après l'apprentissage, le réseau ne reconnaît pas seulement les exemples appris mais également des paradigmes leur ressemblant, ce qui correspond à une certaine robustesse par rapport aux déformations de signaux par le bruit.

Pour un traitement par réseau de neurones, les exemples doivent être mis en forme pour être entrés dans le réseau. Ce sont des grandeurs caractéristiques des défauts à diagnostiquer, filtrées et prétraitées (transformée de Fourier) [3].

VIII. Conclusion

L'objectif de ce chapitre était de présenter les différentes méthodes de diagnostic ainsi que les différentes signatures de défaillances extraites à partir de ces méthodes.

Dans un premier temps nous nous sommes intéressés aux méthodes de diagnostic dites internes (avec connaissance a priori). Si le comportement électrique et dynamique de la machine est parfaitement connu, les modèles utilisés peuvent fournir une estimation fiable des grandeurs difficilement mesurables. Les signaux et paramètres de sortie sont alors utilisés pour la surveillance et le diagnostic. Par la suite, nous avons présenté les méthodes dites externes (sans connaissance a priori) basées sur la mesure de signaux vibratoires, électriques, électromagnétiques rendant directement compte de l'état de la machine.

Ces deux types de méthodes donnent un large éventail de signatures plus ou moins pertinentes vis-à-vis des différents défauts pouvant se produire sur un moteur électrique. Ces méthodes ne doivent pas être mises en concurrence, mais au contraire peuvent être utilisées de manière complémentaire pour tirer partie de leurs avantages respectifs.

Les résultats des signatures des défauts peuvent servir de point de départ pour la recherche de la signature nécessaire aux réseaux de neurones. En effet, pour être appliquée au diagnostic, le réseau de neurone nécessite un nombre important d'exemples de bon fonctionnement sans et avec défauts pour pouvoir les apprendre.

Chapitre III

Généralités sur les réseaux de neurones artificiels

I. Introduction

Les réseaux de neurones sont composés d'éléments simples (ou neurones) fonctionnant en parallèle. Ces éléments sont fortement inspirés du système nerveux biologique. Comme dans la nature, le fonctionnement du réseau (de neurone) est fortement influencé par la connexion des éléments entre eux. Les réseaux de neurones en reprennent quelques grands principes :

- Le **parallélisme** : les neurones sont des entités réalisant une fonction très simple, mais ils sont très fortement interconnectés entre eux, ce qui rend le traitement du signal massivement parallèle.
- Les **poids synaptiques** : les connexions entre les neurones ont des poids variables, qui déterminent la force de l'interaction entre chaque paire de neurones.
- L'**apprentissage** : ces coefficients synaptiques sont modifiables lors de l'apprentissage, dans le but de faire réaliser au réseau la fonction désirée. La fonction que réalise un réseau dépend de sa structure (connexions et forces des connexions) ainsi que de l'opération effectuée par les neurones [29].

L'objectif de ce chapitre est de présenter les grands types de réseaux de neurones, leurs applications et éventuellement les règles et algorithmes d'apprentissage. On s'attardera un petit plus sur le perceptron multicouche de réseau Feedforward et la carte auto organisatrice de Kohonen, ce sont les deux types que nous allons utiliser dans notre application pour la classification des différents défauts de la machine asynchrone.

II. Présentation des réseaux de neurones artificiels

II.1 Brève histoire

Le champ des réseaux de neurones va démarrer par la présentation en 1943 par W. McCulloch et W. Pitts du neurone formel qui est une abstraction du neurone physiologique. Le retentissement va être énorme. Par cette présentation, ils veulent démontrer que le cerveau est équivalent à une machine de Turing. La pensée devient alors purement des mécanismes matériels et logiques. Une machine de Turing se résume à une tête de lecture comportant un nombre fini d'états internes et à un ruban. La puissance de l'analyse de Turing (1912-1954) tient au fait que sa tête de lecture ne lit qu'un seul symbole à la fois, et que cette lecture, associée à la table d'états adéquate, suffit à effectuer toutes les opérations possibles. La machine de Turing est toutes fois une machine imaginaire, abstraite, et idéale. Elle n'a pu être construite. Son fonctionnement implique en effet d'avoir un ruban extensible à volonté donc infini ! la combinaison de cette mémoire infinie et d'un nombre d'états fini a cependant apporté la preuve que, si un problème est calculable, alors il existe une machine pour le résoudre. Dès lors, une machine, reprenant les règles de toutes les autres, est universelle.

En 1949, D. Hebb présente dans son ouvrage « The Organization of Behavior » une règle d'apprentissage. De nombreux modèles de réseaux de neurones aujourd'hui s'inspirent encore de la règle de Hebb.

En 1958, F. Rosenblatt développe le modèle de perceptron. C'est un réseau de neurones inspiré du système visuel. Il possède deux couches de neurones : une couche de perception et une couche liée à la prise de décision. C'est le premier système artificiel capable d'apprendre

par expérience. A la même période, le modèle de L'Adaline (ADActive LINear Element) a été présenté par B.Widrow et Hoff. Ce modèle sera par la suite le modèle de base des réseaux multicouches.

En 1969, M.Minsky et S.Papert publient une critique des propriétés du Perceptron. Cela va avoir une grande incidence sur la recherche dans ce domaine. Elle va fortement diminuer jusqu'en 1972, où T.Kohonen présente ses travaux sur les mémoires associatives et propose des applications à la reconnaissance de formes. C'est en 1982, que J.Hopfield présente son étude d'un réseau complètement rebouclé, dont il analyse la dynamique.

En 1985, Rumelhart popularise l'algorithme de rétropropagation du gradient, conçu par Werbos, qui permet d'entraîner les couches cachées des réseaux de neurones [29].

II.2 Modèles mathématiques

Les réseaux de neurones biologiques réalisent facilement un certain nombre d'applications telles que la reconnaissance de formes, le traitement du signal, l'apprentissage par l'exemple, la mémorisation, la généralisation. Ces applications sont pourtant, malgré tous les efforts déployés en algorithmique et en intelligence artificielle, à la limite des possibilités actuelles. C'est à partir de l'hypothèse que le comportement intelligent émerge de la structure et du comportement des éléments de base du cerveau que les réseaux de neurones artificiels se sont développés [30].

II.2.1 Neurone artificiel général

Un neurone artificiel peut être représenté comme ceci (Figure III.1):




Figure III.1 : Représentation d'un neurone artificiel.

Chaque neurone possède plusieurs entrées (I_n), à chacune desquelles est affecté un poids (*Weight*). L'entrée fixée à 1 de poids b est facultative et représente le seuil (ou biais). A chaque entrée peuvent être connectées plusieurs sorties d'autres neurones. La sortie est calculée à partir des entrées et des poids synaptiques :






- une **fonction d'entrée** évalue la stimulation reçue en calculant le potentiel V du neurone. Elle est très souvent la somme pondérée (par les poids synaptiques) des entrées, augmentée d'un seuil.

- une **fonction de transfert** (ou fonction d'activation) génère alors la sortie grâce à ce potentiel. Cette fonction de transfert est très importante, et détermine le fonctionnement du neurone et du réseau. Elle peut prendre de nombreuses formes comme nous allons le voir dans la section suivante.

III. Fonctions de transfert

Il existe de nombreuses formes possibles pour la fonction de transfert. les plus courantes sont présentées par le tableau ci-dessous. Nous constatons que les équations décrivant le comportement des neurones artificiels n'introduisent pas la notion de temps. En effet, et c'est le cas pour la plupart des modèles actuels de réseaux de neurones.

Tableau III.1: Différents types de fonctions de transfert pour le neurone artificiel.

Catégorie	Type	Relation	Allure	Dérivées
Seuil	Binaire (fonction de Heavside)	$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1 & \text{si } x \geq 0 \end{cases}$		-
	Signe	$f(x) = \begin{cases} -1 & \text{si } x < 0 \\ 1 & \text{si } x \geq 0 \end{cases}$		-
	Stochastique (binaire ou signe)	$f(x, T) = 1$ Avec la probabilité $\frac{1}{1 + e^{-\frac{x}{T}}}$	-	-
Linéaire	Identité	$f(x, k) = kx$		$f'(x, k) = kx$
	Saturé positif	$f(x, k) = \begin{cases} -1 & \text{si } x < 0 \\ 1 & \text{si } x \geq \frac{1}{k} \\ k \cdot x & \text{si } 0 \leq x < \frac{1}{k} \end{cases}$		$f'(x, k) = \begin{cases} 0 & \text{si } x < 0 \\ 0 & \text{si } x \geq \frac{1}{k} \\ k & \text{si } 0 \leq x < \frac{1}{k} \end{cases}$
	Saturé symétrique	$f(x, k) = \begin{cases} -1 & \text{si } x < -\frac{1}{k} \\ 1 & \text{si } x \geq \frac{1}{k} \\ k \cdot x & \text{si } -\frac{1}{k} \leq x < \frac{1}{k} \end{cases}$		$f'(x, k) = \begin{cases} 0 & \text{si } x < -\frac{1}{k} \\ 0 & \text{si } x \geq \frac{1}{k} \\ k & \text{si } -\frac{1}{k} \leq x < \frac{1}{k} \end{cases}$
Sigmode	Positive (type logistique)	$f(x, k) = \frac{1}{1 + e^{-k \cdot x}}$		$f'(x, k) = \frac{k}{2 + e^{-k \cdot x} + e^{k \cdot x}}$
	Symétrique (type tanh)	$f(x, k) = \frac{1}{1 + e^{-k \cdot x}} - 1$		$f'(x, k) = \frac{2 \cdot k}{2 + e^{-k \cdot x} + e^{k \cdot x}}$

Plus généralement, une fonction est dite sigmoïdale si elle est infiniment dérivable, non linéaire, bornée, croissante et que sa dérivée admet un et un seul maximum global.

Nous pouvons également considérer qu'il s'agit d'une approximation infiniment dérivable de la fonction à seuil de Heaviside. Il faut cependant être prudent avec les fonctions sigmoïdes, car pour des entrées grandes la fonction exponentielle peut provoquer un débordement (over flow), et il peut être nécessaire de vérifier que l'entrée n'est pas trop grande avant d'appliquer l'équation générale. Il est bien sûr possible de discrétiser ces

fonctions (afin de stocker des entiers). On peut appliquer un coefficient additif à la fonction, et simuler un seuil comme vu plus haut avec une entrée supplémentaire fixe au réseau. Les fonctions de transferts doivent donc être différentiables, c'est pourquoi on utilise des fonctions sigmoïdes, qui sont des approximations infiniment dérivables de la fonction à seuil de Heaviside [29].

IV. Structures d'interconnexion

Les connexions entre les neurones qui composent le réseau décrivent la topologie du modèle. Elle peut être quelconque, mais le plus souvent il est possible de distinguer une certaine régularité.

IV.1 Réseaux multicouches

Les neurones sont arrangés par couche. Il n'y a pas de connexion entre les neurones d'une même couche et les connexions ne se font qu'avec les neurones des couches avales (Figure III.2). Habituellement, chaque neurone d'une couche est connecté à tous les neurones de la couche suivante et à celle-ci seulement. Ceci nous permet d'introduire la notion de sens de parcours de l'information (de l'activation) au sein d'un réseau et donc définir les concepts de neurone d'entrée, neurone de sortie. Par extension, on appelle couche d'entrée l'ensemble des neurones d'entrée, couche de sortie l'ensemble des neurones de sortie. Les couches intermédiaires n'ayant aucun contact avec l'extérieur sont appelés couches cachées.




Figure III.2 : Définition des couches d'un réseau multicouche.

IV.2 Réseau à connexions locales

Il s'agit d'une structure multicouche, mais qui à l'image de la rétine, conserve une certaine topologie. Chaque neurone entretient des relations avec un nombre réduit et localisé de neurones de la couche avale (figure III.3). Les connexions sont donc moins nombreuses que dans le cas d'un réseau multicouche classique.




Figure III.3 : Réseau à connexions locales.

IV.3 Réseau à connexions récurrentes

Les connexions récurrentes ramènent l'information en arrière par rapport au sens de propagation défini dans un réseau multicouche. Ces connexions sont le plus souvent locales (Figure.III.4).




Figure III.4 : Réseau à connexions récurrentes.

IV.4 Réseau à connexion complète

C'est la structure d'interconnexion la plus générale (Figure III.5). Chaque neurone est connecté à tous les neurones du réseau (et à lui-même). Chaque vecteur d'activation représente la réponse du réseau à une date particulière.




Figure III.5 : Réseau à connexions complète.

V. Apprentissage

L'apprentissage est vraisemblablement la propriété la plus intéressante des réseaux de neurones. Elle ne concerne cependant pas tous les modèles, mais les plus utilisés. Dans le cas des réseaux de neurones artificiels, on ajoute souvent à la description du modèle l'algorithme d'apprentissage. Le modèle sans apprentissage présente en effet peu d'intérêt. Dans la majorité des algorithmes actuels, les variables modifiées pendant l'apprentissage sont les poids des connexions. Il est souvent impossible de décider à priori des valeurs des poids des connexions d'un réseau pour une application donnée.

A l'issue de l'apprentissage, les poids sont fixés : c'est alors la phase d'utilisation. Certains modèles de réseaux sont improprement dénommés à apprentissage permanent. Dans ce cas il est vrai que l'apprentissage ne s'arrête jamais, cependant on peut toujours distinguer une phase d'apprentissage (en fait de remise à jour du comportement) et une phase d'utilisation. Cette technique permet de conserver au réseau un comportement adapté malgré les fluctuations dans les données d'entrées.

Au niveau des algorithmes d'apprentissage, il a été défini deux grandes classes selon que l'apprentissage est dit supervisé ou non supervisé. Cette distinction repose sur la forme des exemples d'apprentissage. Dans le cas de l'apprentissage supervisé, les exemples sont des couples (Entrée, Sortie associée) alors que l'on ne dispose que des valeurs (Entrée) pour l'apprentissage non supervisé. Remarquons cependant que les modèles à apprentissage non supervisé nécessitent avant la phase d'utilisation une étape de labélisation effectuée par l'opérateur, qui n'est pas autre chose qu'une part de supervision [30].

V.1 Réseaux statiques (Apprentissage par « paquet » et Réseaux dynamiques Apprentissage « séquentiel »)

Le format des données va affecter l'évolution des poids et biais des réseaux de neurones lors de leur apprentissage. Un réseau dit statique est un réseau qui ne contient pas de connexion arrière (feedback or delay). Par conséquent, nous pouvons lui présenter les données en entrée dans n'importe quel ordre, cela n'influencera pas l'évolution de ses poids lors de la phase d'apprentissage. Il est alors préférable de lui donner tout le jeu de données en un seul coup lors de la phase d'apprentissage, on parle alors d'apprentissage par paquet (« batch training »).

Les réseaux « Feedforward » ne peuvent pas simuler des processus dépendant du temps. Par contre, si l'on veut simuler un processus qui dépend du temps, alors on pourra utiliser un réseau de neurones contenant des connexions arrières. L'ordre de présentation du jeu de données au réseau de neurone sera alors primordial. On parle alors d'apprentissage séquentiel.

V.2 Règle de HEBB

C'est la méthode d'apprentissage la plus ancienne (1949), elle est inspirée de la biologie. Le principe est de renforcer les connexions entre deux neurones lorsque ceux-ci sont actifs simultanément. Cette règle peut être classée comme apprentissage non supervisé, ou supervisé car on sait calculer directement les poids correspondant à l'apprentissage d'un certain nombre d'exemples.

V.3 Règle du DELTA (ou Règle de Widrow Hoff)

Son but est de faire évoluer le réseau vers le minimum de sa fonction d'erreur (erreur commise sur l'ensemble des exemples). Elle est utilisée dans le modèle de l'ADALINE. L'apprentissage est réalisé par itération (les poids sont modifiés après chaque exemple présenté), et on obtient le poids à l'instant $(t+1)$ par la formule :

$$W(t+1) = W(t) + \eta \cdot (T - O) \cdot E \quad (\text{III.1})$$

si W est le poids, T la sortie théorique et O la sortie réelle, E l'entrée et η un coefficient d'apprentissage (entre 0 et 1) que l'on peut diminuer au cours de l'apprentissage. Cette règle s'interprète par le fait que l'on modifie le poids proportionnellement à l'erreur (différence entre sortie théorique et sortie donnée) et à l'état d'excitation de l'entrée gérée par le poids. Ainsi le poids ne sera pas modifié si la sortie est celle voulue, ou si le poids n'a joué aucun rôle dans le résultat. C'est en fait un cas particulier de l'algorithme de rétropropagation du gradient pour un réseau à une couche [29].

VI. Principaux types de réseaux de neurones

Il existe de nombreux modèles de réseaux de neurones artificiels, nous en présentons successivement quelques uns choisis principalement selon des critères de nature pédagogique. Le Perceptron est historiquement le premier modèle. De fait, il demeure un modèle de base pour le Perceptron multicouche, de même que les cartes auto organisatrices plus vraisemblables d'un point de vue biologique. Ces deux modèles nous permettent d'introduire les concepts d'apprentissage supervisé et non supervisé. Leur fonctionnement est particulièrement intéressant pour la suite de notre application. Des modèles plus élaborés sont étudiés par la suite tant au niveau de leur architectures que des techniques d'apprentissage. Ce sont les réseaux récurrents, le réseau à fonction de base radiale et le réseau ART [30].

VI.1 Réseau PMC (Perceptron Multi Couches)

Le réseau MLP (*Multi-Layer Perceptron*) est un modèle de réseau comprenant une ou plusieurs couches cachées, dont les connexions sont directes et totales entre les couches. Les MLP, forment la très grande majorité des réseaux. Ils sont intemporels (ce sont des réseaux statiques et non dynamiques) [21]. Apparus en 1985, les réseaux multicouches sont aujourd'hui les modèles les plus employés. Plusieurs couches de traitement leurs permettent de réaliser des associations non linéaires entre l'entrée et la sortie. Ils sont ainsi capables de résoudre le cas du "ou exclusif" (Perceptron) [30]. Il a été démontré que moyennant le choix d'une architecture appropriée (i.e. nombre de neurones cachés), les réseaux multicouches sont capable d'approcher n'importe quelle fonction. On parle d'*approximateurs universels de fonctions*. Cependant un certain nombre de problème sont liés à l'utilisation de ce type de réseau (et de manière plus générale de la majeure partie des RNA). On peut remarquer notamment la lenteur de l'apprentissage et surtout l'absence de résultat théoriques garantissant sa convergence. On constate souvent des problèmes liés au blocage de l'apprentissage dans des minima locaux de la fonction d'erreur. Ce point qui est souvent cité comme l'inconvénient principal des réseaux de neurones multicouches doit cependant être tempéré par l'existence de nombreuses approches permettant d'éviter de tels minima [31].

VI.1.1 Structure

Les neurones sont organisés en couches : chaque neurone est connecté à toutes les sorties des neurones de la couche précédente, et nourrit de sa sortie tous les neurones de la couche suivante (ces réseaux sont d'ailleurs qualifiés de "Feedforward" : "nourrit devant"). Pour la première couche ses entrées sont l'entrée du réseau. D'ailleurs une couche est souvent rajoutée pour constituer les entrées, appelée couche d'entrée, mais elle n'en est pas une puisqu'elle ne réalise aucun traitement. Les fonctions d'entrée et de transfert sont les mêmes pour les neurones d'une même couche, mais peuvent différer selon la couche [29].

VI.1.2 Apprentissage

L'algorithme le plus utilisé pour l'apprentissage de ce type de réseau porte le nom de « Error back propagation » ou algorithme de rétropropagation du gradient de l'erreur. Cet algorithme modifie les paramètres de poids et de biais, en allant de la couche de sortie vers la couche d'entrée en propageant l'erreur se trouvant à la couche de sortie vers chacune des couches précédentes, l'erreur de sortie étant obtenue par comparaison de la sortie réelle avec la sortie désirée.

L'apprentissage classique de ce réseau est conduit par une méthode de descente du gradient. Les poids sont initialisés aléatoirement et sont modifiés selon une directive qui minimise une fonction d'erreur.

Partons de la règle de Widrow-Hoff et généralisons celle-ci pour un réseau à une couche cachée à connexions directes et totales entre les couches. À la couche d'entrée, la fonction d'activation est une fonction de type non-linéaire ou linéaire, tout dépendant des données que l'on veut présenter à la couche cachée.

La fonction d'activation des couches cachées et des couches de sorties est une fonction d'activation non-linéaire. On utilise habituellement le sigmoïde. Cette fonction d'activation est très fréquemment rencontrée dans les réseaux MLP et sa dérivée est très simple.

La librairie «network» de MATLAB contient plusieurs variantes de l'algorithme de rétropropagation du gradient de l'erreur, la variante la plus intéressante étant l'algorithme de Levenberg-Marquardt communément appelé «faster propagation» [32].

VI.1.3 Algorithme de la rétropropagation du gradient

Depuis les années soixante, les possibilités de traitement des réseaux multicouches sont supérieures à celle du Perceptron, cependant l'algorithme d'apprentissage manquait. Pour la couche de sortie, on peut appliquer l'apprentissage du Perceptron, mais comment modifier les poids pour les connexions qui ne sont pas en relation avec un neurone de sortie ?

Le problème est ramené à l'obtention d'une estimation de la valeur désirée pour chaque neurone de la couche cachée. La rétropropagation du gradient est une solution à ce problème. Le principe utilisé par la rétropropagation ("backpropagation") du gradient est la minimisation d'une fonction dépendante de l'erreur. Il s'agit d'une méthode générale, largement employée dans d'autres domaines tels que la physique. Elle consiste simplement en une descente du gradient, qui est une méthode d'optimisation universelle. On cherche à minimiser une fonction d'énergie d'erreur (qui représente l'erreur entre la sortie désirée et la sortie obtenue), en suivant les lignes de plus grande pente. Une fonction d'erreur rapportée à une dimension peut se représenter ainsi :




Figure III.6 : Recherche de la zone minimal dans l'espace de configuration des poids du réseau (ramener ici en deux dimensions) pour les exemples de la base d'apprentissage.

On peut représenter la descente du gradient comme une bille que l'on poserait sur la courbe, et qui descendrait logiquement la pente (le gradient représente la pente selon chaque dimension). L'inconvénient de cette méthode est qu'elle va s'arrêter dans le premier minimum local rencontré [30].

Nous allons présenter brièvement la méthode d'obtention de ce gradient, qui se base sur le calcul des dérivées partielles successives de fonctions composées. La mesure de performance utilisée est l'erreur quadratique :

$$Q = \frac{1}{2} \sum_i (a_i - s_i)^2 \quad (\text{III.2})$$

Où i parcourt les indices des neurones de sortie, et a_i et s_i représentent respectivement l'activation mesurée et l'activation désirée pour ces neurones. Les poids du réseau sont modifiés en suivant la règle :

$$\Delta W_{ij} = -n \frac{\partial Q}{\partial w_{ij}} \quad (\text{III.3})$$

Où n est une constante positive appelée pas du gradient. Le calcul de la quantité $\frac{\partial Q}{\partial w_{ij}}$ se fait en partant de la couche de sortie et en se déplaçant vers la couche d'entrée. Cette propagation, suivant le sens inverse de celui de l'activation des neurones du réseau.




Figure III.7 : Un réseau multicouches comportant 2 neurones d'entrés, 4 neurones cachés et un neurone de sortie.

Justifie le nom de l'algorithme. Le calcul est de la manière suivante :

$$\frac{\partial Q}{\partial w_{ij}} = \frac{\partial Q}{\partial a_i} \frac{\partial a_i}{\partial e_i} \frac{\partial e_i}{\partial w_{ij}} \quad (\text{III.4})$$

En posant, $\delta_i = \frac{\partial Q}{\partial a_i} \frac{\partial a_i}{\partial e_i}$ on obtient :

$$\frac{\partial Q}{\partial w_{ij}} = \delta_i \frac{\partial e_i}{\partial w_{ij}} \quad (\text{III.5})$$

Et puisque $\frac{\partial e_i}{\partial w_{ij}} = a_j$

$$\Delta W_{ij} = -n\delta_i a_j \quad (\text{III.6})$$

La quantité δ_i est appelé contribution à l'erreur du neurone i . Dans le cas où i est l'indice d'un neurone de sortie, on obtient :

$$\frac{\partial Q}{\partial a_i} = (a_i - s_i), \frac{\partial Q}{\partial a_i} = g'(e_i),$$

Et donc :

$$\delta_i = g'(e_i)(a_i - s_i) \quad (\text{III.7})$$

Dans le cas où i est l'indice d'un neurone caché, on pose $\frac{\partial Q}{\partial a_i} = \sum_k \frac{\partial Q}{\partial a_k} \frac{\partial a_k}{\partial a_i}$

Où k parcourt les indices de tous les neurones vers les quels le neurone i envoie une connexion. Le calcul nous donne :

$$\frac{\partial Q}{\partial a_k} \frac{\partial a_k}{\partial a_i} = \frac{\partial Q}{\partial a_k} \frac{\partial a_k}{\partial e_k} \frac{\partial e_k}{\partial a_i} = \delta_k W_{ij}$$

Nous obtenons donc $\frac{\partial Q}{\partial a_i} = \sum_k \delta_k W_{ij}$, et :

$$\delta_i = g'(e_i) \sum_k \delta_k W_{ij} \quad (\text{III.8})$$

Cet algorithme, présenté ici dans sa version la plus simple, possède de nombreuses variantes. Elles correspondent généralement à l'utilisation de valeurs variables pour la constante n , ou à l'utilisation de méthodes du deuxième ordre pour le calcul du gradient.

On utilise souvent une version légèrement différente de l'équation III.7 pour calculer la quantité dont doivent être modifiés les poids :

$$\Delta W_{ij} = -n \frac{\partial Q}{\partial w_{ij}} + \mu \Delta W_{ij}(t-1) \quad (\text{III.9})$$

Où μ est une constante appelée momentum, et t représente le temps. Cette version introduit un deuxième terme proportionnel à la dernière adaptation de W_{ij} .

Les modifications des poids peuvent intervenir après chaque présentation d'un patron (poids du réseau), ou après la présentation de l'ensemble de la base d'exemples. L'apprentissage nécessite dans tous les cas un grand nombre de présentations de la totalité de ces exemples pour obtenir un résultat satisfaisant [31].

VI.2 Réseaux de neurones compétitif ou cartes auto organisatrices

Ces réseaux peuvent détecter des régularités et des corrélations dans les données d'entrées et peuvent adapter leurs réponses en fonction de ces entrées. Les neurones de ces réseaux peuvent reconnaître des groupes dans les vecteurs d'entrée. Les cartes auto organisatrices peuvent apprendre à reconnaître des groupes de vecteurs similaires, ce qui entraîne que les neurones, physiquement proches les uns des autres dans la couche de neurones, à répondre à ces vecteurs d'entrée similaires.

La LVQ méthode (Learning Vector Quantization) permet d'entraîner les réseaux de neurones compétitifs de manière supervisée. Comme la classification se fait par le calcul de distance entre les poids des vecteurs d'entrée, il n'y a pas de mécanisme strict qui permettent de définir si les vecteurs d'entrées sont dans la même classe ou non. Celles-ci peuvent être imposées par l'utilisateur.

VI.2.1 Réseaux de neurone compétitif ou réseaux de Kohonen (loi d'apprentissage de Kohonen)

Les poids des neurones vainqueurs sont ajustés suivant la loi de Kohonen qui impose que le poids d'un neurone qui est proche des données d'entrée sera ajusté à la prochaine étape. Ainsi, ce type de réseau est capable d'apprendre à catégoriser des vecteurs d'entrée. L'évolution de la colonne i de la matrice des poids du réseau est dictée par la règle de Kohonen :

$$W_i(q) = W_i(q-1) + \alpha [p(q) - W_i(q-1)] \quad (\text{III.10})$$

Ainsi, s'il y a assez d'exemples et de neurones, il se peut même que la sortie des neurones vainqueurs soit "1" et celle des autres "0".

VI.2.2 Réseaux de neurones LVQ

Les réseaux LVQ ont une première couche de neurones compétitifs et une seconde constituée de neurone à fonction de transfert linéaire. Ce type de réseaux apprend à classifier mais grâce à la seconde couche, ce réseau classera selon les critères de classification imposés par l'utilisateur.

VI.2.3 Cartes auto-organisatrices de Kohonen

Ce modèle de carte auto-organisatrice appartient à la classe des réseaux à compétition. Les neurones de la couche de sortie entrent en compétition, de telle façon qu'habituellement, un seul neurone de sortie est activé pour une entrée donnée. Cette compétition entre les neurones est réalisée grâce à des connexions latérales inhibitrices. Les cartes auto-organisatrices sont depuis longtemps connues (1977), mais ce n'est que très récemment (1990) que des applications les utilisent : carte phonétique, diagnostic de pannes, compression d'images, robotique, etc. Ces cartes s'organisent par rapport aux exemples d'entrée présentés en respectant les contraintes topologiques de l'espace d'entrée. Il y a mise en correspondance de l'espace d'entrée avec l'espace du réseau. Les zones voisines de l'espace d'entrée sont voisines sur la carte auto organisatrice (Figure III.8) [30].




Figure III.8 : Mise en correspondance de l'espace d'entrée avec l'espace du réseau.

L'espace d'entrée avec les exemples (points) d'apprentissage est représenté à gauche de la figure III.8. A l'issue de l'apprentissage, chacun des 9 neurones de la carte auto-organisatrice correspond à une zone de l'espace d'entrée (aussi nommée champ récepteur) en bas à droite. Tout point tiré dans un champ récepteur active le neurone correspondant et lui seul[22]. Tous les neurones sont interconnectés, mais seuls les neurones proches ont de l'influence, selon une fonction DOG (Difference Of Gaussian) en forme de "chapeau mexicain" : les neurones les plus proches sont excitateurs, ceux un peu plus éloignés inhibiteurs et les plus éloignés ont une influence nulle. La fonction d'entrée est de type sigmoïde, et le réseau présente la particularité de n'avoir qu'un seul neurone actif à la fois [29].

VI.2.3.1 Structure

La Figure.III.9 décrit le réseau organisé en une couche à deux dimensions. Chaque neurone N_k est connecté à un nombre ' n ' d'entrées au travers de ' n ' connexions de poids respectifs w . Il existe aussi des connexions latérales de poids fixes, excitatrices dans un proche voisinage. Chaque neurone est connecté à ses 4 plus proches voisins. Ces connexions sont de poids fixes. Tous les neurones sont connectés aux entrées par des connexions plastiques.




Figure III.9: Architecture d'une carte auto-organisatrice (réseau 2D).

VI.2.3.2 Fonctionnement

A la présentation d'une entrée, un neurone sur la carte est sélectionné. Il correspond le plus possible à cette entrée (minimisation d'une distance). On peut ainsi réaliser des classifications ou de la reconnaissance de formes. Le modèle de réseau neuronal proposé par Kohonen montre des propriétés d'auto-organisation et de représentation topologique de l'espace d'entrée (espace afférent).

VI.2.3.3 Apprentissage

La loi de modification des poids des connexions (poids synaptiques) est dérivée de celle de Hebb. Dans le cas où les exemples d'entrées sont des vecteurs à deux composantes, l'algorithme d'apprentissage est le suivant :

- 1/ Initialisation des poids à des valeurs aléatoires.
- 2/ Présentation d'une entrée $E_1 = (e_1, e_2)$.
- 3/ Calcul de la distance de chacun des neurones par rapport à e_1 et e_2 ($x_j = |w_{j1} - e_1| + |w_{j2} - e_2|$)
- 4/ Sélection du neurone le plus proche : $Min(x) = x_i$
- 5/ Modification des poids pour le neurone choisi (i) et ses 4 plus proches voisins (k).

μ et β sont deux paramètres correspondant au pas de modification des poids. μ pour le neurone choisi et β pour ceux du voisinage.

$$w_{i1} = w_{i1} + \mu \cdot (e_1 - w_{i1}) \quad w_{i2} = w_{i2} + \mu \cdot (e_2 - w_{i2})$$

$$w_{k1} = w_{k1} + \beta \cdot (e_1 - w_{k1}) \quad w_{k2} = w_{k2} + \beta \cdot (e_2 - w_{k2})$$

- 6/ Tant que les performances sont insuffisantes : Retour à l'étape 2 et sélection de l'exemple suivant dans la base d'apprentissage.

VI.3 Réseaux de neurones à fonctions de base radiales (Radial Basis Network)

Ces réseaux, appelés réseaux RBF (Radial Basis Functions) sont des réseaux multicouches, à une couche cachée. Cependant, contrairement aux perceptrons multicouches, les fonctions de transfert de la couche cachée dépendent de la distance entre le vecteur d'entrée et un vecteur centre. Dans la pratique cette fonction de transfert est souvent le noyau gaussien:

$$s = \exp \left[- \left[\frac{|e - c|}{\sigma} \right]^2 \right] \quad (\text{III.11})$$

Où σ est le facteur de largeur et c le vecteur centre. Ici, la fonction de transfert est une exponentielle. L'opérateur sommation disparaît au profit de l'opération multiplication (élément par élément des matrices). Les réseaux à bases radiales nécessitent beaucoup plus de neurones qu'un réseau Feedforward [30].

La fonction d'activation de la couche de sortie est quant à elle une fonction linéaire. Les

trois types de paramètres - centres, largeurs, poids - sont optimisés indépendamment afin d'éviter une lourdeur excessive des calculs [29].

VI.3.1 Réseaux de neurones à régression généralisée (Generalized Regression Networks)

Dans un réseau à régression généralisée (GRNN), il y a un réseau à base radiale auquel on ajoute une couche de sortie constituée d'une fonction de transfert linéaire. Ces réseaux sont aussi utilisés en tant qu'approximation de fonction, mais sont plus lourds d'utilisation que les perceptrons multicouches.

VI.3.2 Réseaux de neurones probabilistes (Probabilistic Neural Networks)

Ces réseaux sont généralement utilisés pour des problèmes de classification. La première couche qui est un réseau à base radiale, donne une information sur la ressemblance entre la donnée d'entrée et le jeu de données utilisé lors de l'apprentissage. La deuxième couche produit comme sortie un vecteur de probabilité. Finalement, une fonction de transfert compétitive produit 1 ou 0.

VI.4 Réseaux récurrents

VI.4.1 Réseaux de Elman

Le réseau de Elman a des neurones tansig dans sa couche cachée récurrente et un neurone linéaire dans sa couche de sortie. Ce type de réseau peut aussi approximer n'importe quel type de fonction pourvu que la couche cachée ait assez de neurones. Puisque ce réseau peut enregistrer de l'information pour une référence future, il est capable d'apprendre des associations aussi bien temporelles que spatiales.

VI.4.2 Réseaux de Hopfield

Le modèle de Hopfield est une mémoire auto-associative dont la réponse des neurones est asynchrone, et dont les neurones ont pour fonction de transfert la fonction signe, c'est-à-dire dont la réponse est binaire. Les fondements mathématiques de ces réseaux sont très bien compris, et il est possible réaliser l'apprentissage par un calcul direct à partir des exemples à mémoriser grâce à la règle de Hebb généralisée. Ces réseaux sont des réseaux récursifs, un peu plus complexes que les perceptrons multicouches. Chaque cellule est connectée à toutes les autres et les changements de valeurs de cellules s'enchaînent en cascade jusqu'à un état stable. Ces réseaux sont bien adaptés à la reconnaissance de formes.

VI.5 Réseau à Architecture évolutive, ART

ART (Adaptive Resonance Theory) est un modèle de réseau de neurones à architecture évolutive développé en 1987 par Carpenter et Grossberg. Dans la plupart des réseaux de neurones, deux étapes sont considérées. La première est la phase d'apprentissage : les poids des connexions sont modifiés selon une règle d'apprentissage.

La deuxième est la phase d'exécution où les poids ne sont plus modifiés. Avec le réseau ART, ces deux étapes sont réalisées simultanément. Le réseau en phase de test, s'adapte à des entrées inconnues en construisant de nouvelles classes (ajout de neurones) tout en dégradant au minimum les informations déjà mémorisées. Il existe plusieurs versions de réseaux (ART1, ART2, ART3), le réseau ART1 est un réseau à entrées binaires [30].

VII. Conclusion

Nous avons établi dans ce chapitre un modèle simplifié de neurone biologique, de synapses et quelques topologies pour l'organisation en réseaux, ainsi que les différentes fonctions de transfert. Nous avons vu que l'apprentissage implique des modifications physiques des connexions entre les neurones.

Nous avons détaillé le fonctionnement des deux modèles de réseaux de neurones à savoir : le perceptron multicouche et les cartes auto organisatrice et leurs propriétés d'apprentissage.

Nous avons consacré une partie à l'algorithme d'apprentissage des réseaux de neurones multicouches. L'algorithme d'apprentissage de la rétropropagation du gradient, bien que très simple à implanter, nécessite un certain savoir-faire pour une utilisation efficace. En effet, la convergence de l'algorithme n'est pas prouvée et de multiples variables sont à ajuster précisément en fonction du problème traité. Parmi ces variables à fixer, citons par exemple : les paramètres apparaissant dans les différentes équations (gain de la procédure du gradient, pente de la fonction sigmoïde), la sélection des exemples pour l'apprentissage et le test, l'ordre de présentation et les distributions relatives des exemples dans la base d'apprentissage, le choix du codage des informations en entrée et en sortie, la structure du réseau (présence éventuelle de connexions directes de la couche d'entrée sur la couche de sortie pour traiter à ce niveau la partie linéaire du problème, limitation pratique du nombre de couches, taille de la couche cachée), la configuration initiale des poids, le nombre d'itérations d'apprentissage, ...

Dans le chapitre suivant, nous allons montrer comment ces deux modèles sont utilisés pour la classification des défauts électriques rotoriques de la machine asynchrone à cage.

Chapitre IV

Méthodologie de diagnostic par les réseaux de neurones

I. Introduction

La rupture d'une ou plusieurs barres de la cage rotorique provoque l'apparition et l'augmentation des composantes dont les fréquences sont rappelées à l'équation $(1 \pm 2kg)f_s$. Cette augmentation est visible pour une cage rotorique défailante en comparaison avec une machine asynchrone fonctionnant avec un rotor sain comme cela est représenté par la Figure IV.1. Plus le défaut rotorique est important (cassure de plusieurs barres adjacentes par exemple), plus les amplitudes des composantes latérales autour de la fréquence fondamentale seront élevées. Par conséquent, l'évaluation de ces différentes amplitudes peut être vue comme une méthode sûre et efficace pour la détection et le diagnostic des cassures des barres de la cage rotorique [16].

La première section de ce chapitre est basée sur le choix de l'ensemble des signatures possibles caractéristiques des défaillances du système. Nous allons ensuite étudier la grandeur temporelle de la machine asynchrone dans le domaine fréquentiel en utilisant les méthodes d'analyses décrites dans le chapitre II pour construire la base de données pour les réseaux de neurones. L'approche de l'analyse par l'estimation de la densité spectrale de puissance nous permet d'identifier les signatures fréquentielles causées par la rupture d'une ou plusieurs barres de la cage rotorique. Kliman [33], Thomson [34], Filippetti [35] et Nandy [36] ont utilisé la méthode de l'analyse spectral du courant statorique MCSA (Motor Current Signature Analysis) pour la détection de défauts de cassures des barres par l'évaluation de l'amplitude des composantes spectrales créées par le défaut rotorique autour de la fréquence fondamentale.

La deuxième section est consacrée au codage et à la normalisation des données initiales par rapport à la charge. Cette procédure permet de diminuer la dispersion causée par la charge. De ce fait, seule la variation due aux différents modes de fonctionnements (sain, défectueux) sera visible. Des exemples de données normalisées et non normalisées seront présentés et comparés pour montrer l'apport de cette normalisation.

Les deux sections suivantes portent sur une brève présentation de quelques notions générales sur les deux modèles des RNA utilisés dans notre travail pour la classification des défauts des machines asynchrones à cage d'écureuil, le premier modèle à apprentissage supervisé est le perceptron multicouches d'une architecture Feedforward Backpropagation, tant dit que le deuxième modèle à apprentissage non supervisé est la carte auto-organisatrice de Kohonen SOM (Self Organizing Mapping).




Figure IV.1 : Spectre du courant statorique de la machine saine et avec défaut.

II. Construction de la base de données

Dans notre travail, les paramètres sont choisis selon l'équation $(1 \pm 2kg)f_s$. pour cela, nous avons obtenu six ou dix paramètres selon le rang k dans l'équation précédente (Figure IV.2).

Pour $k=1$, le vecteur de données contient les paramètres suivants :

- La fréquence du fondamentale f_s ;
- Le glissement (calculé automatiquement) ;
- L'amplitude du premier pic à gauche du fondamental du courant $(1 - 2g)f_s$;
- La fréquence du premier pic à gauche du fondamental du courant $(1 - 2g)f_s$;
- L'amplitude du premier pic à droite du fondamental du courant $(1 + 2g)f_s$;
- La fréquence du premier pic à droite du fondamental du courant $(1 + 2g)f_s$.

Pour $k=2$, en plus des six paramètres précédents, le vecteur de données contient également :

- La fréquence du deuxième pic à gauche du fondamental du courant $(1 - 4g)f_s$;
- L'amplitude du deuxième pic à gauche du fondamental du courant $(1 - 4g)f_s$;
- La fréquence du deuxième pic à droite du fondamental du courant $(1 + 4g)f_s$;
- L'amplitude du deuxième pic à droite du fondamental du courant $(1 + 4g)f_s$.

Pour l'extraction de ces paramètres, nous avons développé un programme sous MATLAB permettant de les calculer d'une manière automatique à partir du spectre du courant statorique.




Figure IV.2 : Spectre du courant statorique pour le rang d'harmonique $k=1$ et $k=2$.

La difficulté dans la méthodologie présentée est l'évaluation avec une grande précision de l'amplitude des composantes spectrales créées par le défaut rotorique afin d'obtenir les indices d'amplitude les plus précises possibles.

Pour évaluer l'amplitude d'une composante, nous devons tout d'abord connaître la fréquence qui lui est associée. Dans le cas d'un défaut de barre, nous savons où se situent ces composantes en calculant, grâce à l'équation $(1 \pm 2kg)f_s$, la valeur de leurs fréquences.

La principale difficulté réside dans le fait que ces fréquences varient avec le glissement «g» de la machine. Pour un point de fonctionnement nominal, ce glissement vaut quelques pour-cent, ce qui permet de discerner ces composantes de la composante fondamentale " f_s ". Par contre, lorsque le glissement est très proche de zéro (fonctionnement à faible charge ou à vide), ces composantes sont relativement proches de la composante fondamentale " f_s ", ce qui rend leur détection beaucoup plus difficile.

II.1 Détermination de la fréquence fondamentale

Une approche par l'analyse fréquentielle du signal est possible pour déterminer cette fréquence.

II.1.1 Analyse fréquentielle

A partir d'une FFT réalisé sur le signal du courant, l'amplitude la plus importante, qui correspond à la fréquence fondamentale du signal, est recherchée.




Figure IV.3 : Spectre fréquentiel du courant statorique.

II.2 Recherche automatique du glissement pour une alimentation à partir du réseau

La connaissance du glissement est indispensable pour le calcul des paramètres fréquentiels formant le vecteur de données. Le glissement de la machine asynchrone a pour expression :

$$g = \frac{(n_s - n)}{n_s} \quad (\text{IV.1})$$

Avec :

n_s : vitesse de synchronisme en tr/min ;

n : vitesse de rotation de la machine en tr/min ;

Où bien encore :

$$g = 1 - \frac{p \cdot f_r}{f_s} \quad (\text{IV.2})$$

Avec :

f_s : fréquence du fondamental ;

f_r : fréquence de rotation du rotor ;

p : nombre de paires de pôles ;

Ainsi, pour déterminer le glissement il est nécessaire de rechercher automatiquement les fréquences f_s et f_r .

II.2.1 Calcul de la fréquence de rotation du rotor f_r

Connaissant f_s , il reste à déterminer la fréquence de rotation f_r qui a pour expression :

$$f_r = \frac{(1-g)*f_s}{p} \quad (IV.3)$$

Par conséquent, pour déterminer f_r , il faut donc connaître au préalable la valeur du glissement g . Pour résoudre ce problème, nous avons choisi de rechercher la valeur de la fréquence Caractéristique $f_s + f_r$ sur le spectre du courant. Pour retrouver la valeur de cette fréquence caractéristique, il est nécessaire de connaître une valeur approximative de f_r et, de ce fait, pouvoir définir une plage de variation autour de cette fréquence. Pour cela, on définit une valeur du glissement maximale $g_{\max}$ et minimale $g_{\min}$. Ainsi nous pouvons calculer une valeur maximale et minimale de f_r .

$$f_{r\max} = \frac{(1-g_{\min})*f_s}{p} \quad (IV.4)$$

$$f_{r\min} = \frac{(1-g_{\max})*f_s}{p} \quad (IV.5)$$

Tenant compte de ces valeurs, nous disposons d'une plage fréquentielle suffisante permettant de déterminer la fréquence caractéristique $f_s + f_r$ sur le spectre du signal mesuré. Ainsi, La composante qui a la plus grande amplitude dans cette plage de fréquence, est alors recherchée.




Figure IV.4 : Spectre du courant autour de la fréquence caractéristique $f_s + f_r$.

II.2.2 Calcul du glissement "g"

Connaissant les fréquences f_s et f_r , le glissement peut être déduit d'après l'équation :

$$g = 1 - \frac{p*f_r}{f_s} \quad (IV.6)$$

Pour vérifier l'exactitude du résultat trouvé, il suffit de calculer la vitesse de rotation du moteur à partir de la valeur du glissement obtenue, et ensuite la comparer à la valeur de la vitesse donné par un capteur disposé sur le système lors de l'acquisition.

II.3 Recherche automatique du glissement pour une alimentation à partir d'un variateur de vitesse

Une méthode classique pour l'évaluation du glissement de la machine est l'utilisation des composantes de fréquence $\left[\frac{N_r}{p} (1 - g) \pm 1\right] f_s$ créées par les encoches de la cage rotorique dans le spectre du courant statorique. Ces composantes sont toujours présentes dans ce spectre, que ce soit pour un rotor sain ou un rotor défaillant. Des auteurs utilisent souvent ces composantes pour estimer la vitesse rotorique de la machine asynchrone [37][38]. Cependant, la détection de ces composantes lorsque la machine fonctionne à faible charge reste difficile. De plus, la composante de fréquence $\left[\frac{N_r}{p} (1 - g) + 1\right] f_s$ a une amplitude beaucoup plus significative que la composante de fréquence $\left[\frac{N_r}{p} (1 - g) - 1\right] f_s$ ce qui facilitera sa détection. La connaissance précise de la fréquence de cette composante permet donc de connaître la valeur du glissement de la machine.

Nous pouvons, par la suite, calculer la valeur des fréquences ayant pour relation $(1 \pm 2kg)f_s$ en vue de déterminer les amplitudes et les fréquences correspondantes en suivant les mêmes démarches que pour l'alimentation réseau. Nous présentons sur la Figure IV.5.a les composantes de fréquence $\left[\frac{N_r}{p} (1 - g) + 1\right] f_s$.





Figure IV.5.a : Détection du glissement pour une alimentation par variateur de vitesse.

Pour récapituler la méthode de détermination des paramètres représentatifs du défaut (g , f_s , $(1 \pm 2kg)f_s$), nous donnons ci-dessous l'organigramme (Figure IV.5.b) utilisé pour le calcul de ces paramètres.

**Figure IV.5.b** : Méthode de calcul des paramètres représentatifs de défauts.

III. Normalisation des données

Pour rendre plus simple et plus efficace la phase de décision, la normalisation des données initiales est réalisée. En effet, avant cette normalisation, un mode de fonctionnement présente une grande dispersion de ses vecteurs, due à la variation de la charge. Ce mode de fonctionnement est représenté par plusieurs classes [1-2],[39]. Ces différentes classes correspondent à plusieurs niveaux de charge de la machine. En normalisant, c'est-à-dire en s'affranchissant de ce niveau de charge, un mode de fonctionnement est représenté par une seule classe regroupant toutes les variations de charge. Schématisons simplement cette approche :




Figure IV.6 : Représentation schématique de modes de fonctionnement dépendant du niveau de charge.

Sur la Figure IV. 6 trois différents modes de fonctionnement sont représentés. Chaque mode est composé de quatre classes correspondant à 4 niveaux de charge. Le but est d'obtenir la configuration suivante (Figure IV.7), en s'affranchissant du niveau de charge:




Figure IV. 7 : Représentation schématique de modes de fonctionnement indépendant du niveau de charge.

Dans notre travail les données sont normalisées dans l'intervalle $[-1,1]$. Pour cela, nous avons utilisé la fonction donnée par l'équation IV.7. Le choix de l'intervalle provient du choix de la fonction d'activation des couches du RNA choisi. En outre, si des fonctions d'activation sigmoïdes (logsig) ou tan-sigmoïdes (tansig) sont utilisées, elles sont particulièrement utilisées avec une plage de données se trouvant dans l'intervalle $[0,1]$ et $[-1, 1]$ respectivement.

$$y = \frac{(y_{max}-y_{min})(x-x_{min})}{(x_{max}-x_{min})} + y_{min} \quad (IV.7)$$

Tel que :

- $y_{max}=1$;
- $y_{min}=-1$;
- x_{max} : la valeur maximale du vecteur x ;
- x_{min} : la valeur minimale du vecteur x .

III.1 Codage des machines

Le codage des machines est effectué selon le type de classification qu'on veut réaliser. Pour cela, deux types de classifications ont été examinés :

- Classification à deux classes : pour ce cas d'étude, on distingue entre une machine saine et une machine défectueuse sans tenir compte du type de défaut. Les codes attribués pour ce genre de classification est :
 - o [1 0] pour la machine saine ;
 - o [0 1] pour la machine défectueuse.
- Classification multi classes : où la séparation sera faite entre une machine saine, une machine avec une barre cassée, une machine avec deux barres cassées et une machine avec une portion d'anneau de court-circuit cassée. Les codes attribués pour ce genre de classification est :
 - o [1 0 0 0] pour la machine saine ;
 - o [0 1 0 0] pour une machine avec une barre cassée ;
 - o [0 0 1 0] pour la machine avec deux barres cassées ;
 - o [0 0 0 1] pour une machine avec une portion d'anneau de court-circuit cassée.

III.2 Taux de réussite

C'est un paramètre qui indique le pourcentage de réussite en classification des différents états de la machine ciblés selon la procédure suivante :

- Si la valeur absolue de la différence entre la valeur désirée et celle simulée est supérieur à une tolérance de 50 % c'est une erreur de classification. Sinon c'est une réussite de classification et le résultat est bon.
- La sortie tend vers «0» si la condition spécifiée existe, sinon elle tend vers «1».
- La somme des états de réussite en classification par rapport aux nombres d'états total fourni donne un pourcentage représentant le taux de réussite.

III.3 Performance de la classification

La performance de la classification est basée sur l'erreur globale du vecteur test qui est déterminée à partir de la fonction de performance du RNA c-à-d l'Erreur Quadratique Moyenne (MSE).

IV. Application des réseaux de neurones pour la classification des défauts

Les réseaux de neurones constituent une classe d'algorithmes d'une très grande flexibilité. Cette flexibilité est liée à plusieurs facteurs, entre autres l'architecture, les connexions et les poids. Les nombreux modèles de réseaux de neurones disponibles aujourd'hui peuvent être classés selon le type d'opération effectuée ou selon le type d'applications. Les réseaux peuvent se distinguer selon qu'ils sont supervisés ou non supervisés. Les réseaux supervisés nécessitent une intervention extérieure pour modifier les poids des neurones. Par contre, les systèmes non supervisés sont autonomes, ils peuvent donc fonctionner plus facilement en temps réel dans des situations où l'environnement à traiter évolue rapidement.

Dans le cas de notre application, nous désirons effectuer une classification par un réseau de neurone à apprentissage supervisé et à apprentissage non supervisé qui sont respectivement le Perceptron Multicouches (PMC) avec l'architecture Feedforward et la carte auto-organisatrice (Self-Organizing-Mapping, ou encore SOM). Dans ce qui suit, nous décrivons le fonctionnement des deux différentes méthodes de classification considérées.

IV.1 Réseau de neurone à apprentissage supervisé

Afin d'appliquer le RNA Feedforward, il est nécessaire d'examiner de manière approfondie ces caractéristiques. Il y a quatre éléments que comporte l'architecture d'un RNA Feedforward :

- Le nombre de couches ;
- Le nombre de neurones dans chaque couche ;
- La fonction d'activation de chaque couche ;
- L'algorithme d'apprentissage.

Concernant le nombre de couches, la seule certitude c'est qu'il devrait y avoir une couche d'entrée et une couche de sortie afin de pouvoir présenter et obtenir des données au/du RNA, respectivement (Figure IV.8). Le nombre de neurones dans chacune des deux couches est spécifié par le nombre de paramètres d'entrée et de sortie qui sont employés pour définir le problème examiné. Ainsi, ils sont aisément déterminés. Par conséquent, l'objectif est de trouver le nombre de couches cachées et le nombre de neurones dans chaque couche cachée. Malheureusement, il n'est pas possible de déterminer théoriquement le nombre de couches cachées ou le nombre de neurones dans chaque couche cachée.




Figure IV.8 : Réseau Feedforward à une couche cachée.

Les fonctions d'activation sont choisies en se basant sur le type de données qui sont disponibles (binaire, bipolaire, décimal, etc.) et le type de couche. Par exemple, la fonction d'identité est presque toujours employée dans la couche d'entrée, alors que des fonctions sigmoïdes non linéaires continues sont employées dans les couches cachées (habituellement la fonction tangente hyperbolique). L'influence de l'algorithme d'apprentissage est surtout apparente sur la vitesse d'apprentissage, sur l'exécution d'un RNA (erreur d'apprentissage) ou sur la puissance de calcul nécessaire, plutôt que sur l'architecture elle-même. En conséquence, les éléments les plus critiques d'une architecture Feedforward RNA sont le nombre de couches cachées et les neurones cachés.

Le réseau à rétropropagation concerne les réseaux de neurones multicouches qui utilisent l'algorithme de rétropropagation pour l'apprentissage. Plus souvent, des réseaux de neurones Feedforward multicouches sont utilisés pour l'algorithme de rétropropagation. Dans ce cas beaucoup de versions de l'algorithme de rétropropagation existent. (Tous ces algorithmes contribuent principalement à un apprentissage plus rapide), nous citons comme exemple :

- Variable Learning Rate ;
- Resilient Backpropagation ;
- Conjugate Gradient Algorithm ;
- Quasi-Newton Algorithm ;
- Levenberg-Marquardt Algorithm ;
- Reduced Memory Levenberg-Marquardt Algorithm.

L'algorithme de rétropropagation est l'un des algorithmes les plus connus pour prévoir les poids de réseau de neurone. Il a été développé par « David Rumelhart », Geoff Hinton et R.J. Williams en 1986 (Rumelhart et autres 1986). C'est l'un des algorithmes d'apprentissage les plus populaire à cause de sa simplicité et d'applicabilité [40].

L'algorithme de rétropropagation se compose deux phases : Phase d'apprentissage et phase de rappel. Dans la phase d'apprentissage, les poids sont initialisés au hasard puis les sorties sont calculés et comparés aux sorties désirées. Par la suite, l'erreur du réseau est calculée et utilisée pour régler les poids de la couche de sortie. D'une manière similaire, l'erreur du réseau est propagée vers l'arrière et employé pour mettre à jour les poids des couches précédentes. La phase d'apprentissage sera terminée quand la valeur d'erreur est moins que la valeur réglée par le superviseur. Pendant la phase de rappel, le réseau avec les poids finaux résultant du procédé d'apprentissage sont utilisés.

L'algorithme de rétropropagation est l'extension de la « règle delta » utilisée dans l'apprentissage des réseaux de neurones à une couche (perceptron) [41-42].

IV.1.1 Étapes d'apprentissage de l'algorithme de rétropropagation

L'apprentissage est une phase du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré. Le temps d'apprentissage peut être long, par contre, après apprentissage, le calcul des sorties à partir d'un vecteur d'entrée est rapide. Le processus d'apprentissage peut se faire selon les étapes suivantes :

1. Initialisation aléatoire des poids ;
2. Choisir la structure du réseau ;
3. Choisir les fonctions d'activations des neurones ;
4. Sélectionner le sous-ensemble d'apprentissage et l'appliquer au réseau ;
5. Calculer les sorties du réseau en se basant sur les poids initiaux et les entrées ;
6. Calculer l'erreur entre les sorties calculées et les sorties désirées ;
7. Propager l'erreur vers l'arrière et ajuster les poids de tel sorte à minimiser l'erreur de sortie, et cela en allant de la couche de sortie vers la couche d'entrée ;
8. Répéter les étapes 4-7 jusqu'à ce que l'erreur soit inférieure au minimum prédéfini.

Après plusieurs répétitions de ces opérations, l'erreur entre les sorties réelles et les sorties de cible devraient être réduites à une valeur acceptable, et le réseau est dit appris. A ce moment, le réseau peut être utilisé dans les phases de rappel (test) ou de « généralisation » où les poids ne sont pas changés.

L'erreur d'apprentissage est directement liée à la capacité de la mémorisation du RNA, ce qui le rend un index très important. La formule employée pour calculer l'erreur d'apprentissage est l'Erreur Quadratique Moyenne, ce choix est relié directement au type de données introduit au RNA qui sont dans notre cas normalisées.

IV.1.2 Initialisation des poids

Si les poids initiaux du réseau de neurone sont proches du zéro, la sortie produira une valeur plutôt basse, c'est pour cela qu'on n'aura jamais la possibilité de représenter des systèmes non linéaire; car le réseau va tendre vers un système linéaire, les poids sont pratiquement initialisés suivant une loi aléatoire tel que la fonction de «Nyguen-Widrow» [40].

IV.1.3 Fonctions de performance

Ces fonctions sont utilisées pour calculer l'erreur d'apprentissage des réseaux de neurones. Les fonctions suivantes sont inspirées de l'environnement MATLAB [41].

Tableau IV.1 : Fonctions de performance.

Fonction	Désignations	Formule
MSE	Mean Square Error (Erreur quadratique moyenne)	$\frac{1}{n} \sum_1^n (t_i - a_i)^2$
MSW	Mean Square Weight (Poids quadratique moyen)	$\frac{1}{n} \sum (W_i)^2$
MSEREG	Mean Square Error Regularization (Erreur quadratique moyenne Régularisée)	MSEREG = γ MSE + (1- γ)MSW Où γ est un paramètre d'optimisation
SSE	Sum Square Error (Erreur quadratique sommée)	$\sum_1^n (t_i - a_i)^2$
MAE	Mean Absolute Error (Erreur Absolue moyenne)	$\frac{1}{n} \sum_1^n t_i - a_i $

IV.2 Réseau de neurone à apprentissage non supervisé

Les cartes de Kohonen sont aussi appelées cartes topologiques auto-organisatrices. Les réseaux de Kohonen n'ont pas besoins d'un apprentissage supervisé, contrairement à tout ce que l'on a présenté au sujet des réseaux de neurones jusqu'à maintenant, et c'est ce qui fait leur principal intérêt. En effet le réseau de Kohonen va de lui même s'auto-adapter aux excitations en entrée de façon à n'activer qu'un seul neurone en sortie. Il se comporte ainsi comme un classifieur (i.e. qu'il est capable de classer les données qui lui sont présentées en entrée) et c'est l'une des raisons pour lesquelles les réseaux de Kohonen sont utilisés en analyse des données et en classification automatique. Ils ont d'ailleurs de très nombreux domaines d'application et en général donne de bons résultats.

Une carte de Kohonen est un réseau de neurones constitué de deux couches (Figure IV.9). La couche d'entrée prend la valeur du vecteur d'entrée et sert uniquement à la présentation des observations à classer, la seconde est une grille régulière à 1, 2 ou 3 dimensions (généralement 2D).

Il est peu évident de donner une description intuitive du fonctionnement d'un tel réseau. On peut essayer en disant que la topologie du réseau (et sa méthode d'auto apprentissage) est choisie de façon à mettre les neurones en concurrence. Lorsqu'un groupe de neurones est excité l'apprentissage va modifier les poids synaptique de façon à valoriser l'activité des neurones associés. Ainsi, si différentes classes sont présentées au réseau alors différentes régions d'activation vont se construire dans la carte [43].




Figure IV.9: Architecture d'une carte de Kohonen.

IV.2.1 Apprentissage du réseau SOM

L'apprentissage du réseau SOM se fait d'une manière itérative. Il utilise une variable d'itération "t" et initialise tous les poids W_{ij} de ses neurones avec de petites valeurs aléatoires. Lors du traitement avec SOM, les entrées "x" sont successivement comparées avec tous les prototypes (poids du neurone). Cette comparaison est faite sur la base de la distance Euclidienne (la distance entre les données d'entrées et tous les vecteurs prototypes de la SOM est calculée). Le neurone dont le vecteur poids du réseau est proche du vecteur d'entrée est appelé le neurone gagnant (Best-Matching-Unit), souvent notée «BMU». L'argument c du neurone j le plus proche est alors conservé, soit:

$$\|\vec{x} - \vec{W}_c\| = \min_j \{\|\vec{x} - \vec{W}_j\|\} \rightarrow c = \arg \min \{\|\vec{x} - \vec{W}_j\|\} \quad (\text{IV.9})$$

Où W_c est le neurone gagnant du vecteur de poids.

Par la suite, tous les prototypes sont mis à jour en fonction du neurone gagnant (le plus proche) et du rayon séparant les paires de prototypes de la façon suivante:

$$\vec{W}_j(t+1) = \vec{W}_j(t) + h_{cj} [\vec{x} - \vec{W}_j(t)] \quad (\text{IV.10})$$

$[\vec{x} - \vec{W}_j(t)]$ est l'écart entre l'entrée et le vecteur de poids associé au neurone j. Le nouveau vecteur de poids correspond donc à son ancienne valeur ajoutée à cet écart afin de se rapprocher de "x" comme cela est illustré par la Figure IV.10.

Avec: h_{cj} représente la fonction de voisinage associée au neurone gagnant "c" (fonction décroissante du temps et doit être comprise entre 0 et 1).

$$h_{cj} = \alpha(t) \cdot e^{\left(\frac{-(\|r_c - r_j\|)^2}{2 \cdot \sigma^2(t)}\right)} \quad (\text{IV.11})$$

$\|r_c - r_j\|^2$ est le rayon séparant le prototype à mettre à jour et le neurone gagnant W_c . Le paramètre $\alpha(t)$ est un facteur d'apprentissage et $\sigma(t)$ est une région de convergence.

Tous deux, $\alpha(t)$ et $\sigma(t)$ décroissent en fonction de la variable d'itération "t", c'est à dire de la progression du traitement.




Figure IV.10 : Méthode d'apprentissage de la carte auto organisatrice

L'algorithme d'apprentissage se déroule ainsi :

1. Initialisation des vecteurs poids (neurones) de la carte de Kohonen ;
2. On présente un vecteur d'entrée à la carte ;
3. On calcule la distance entre ce vecteur d'entrée et tous les vecteurs poids de la carte : c'est la phase de compétition entre tous les neurones de la carte ;
4. On détermine le neurone gagnant ;
5. On modifie le vecteur poids du neurone gagnant ainsi que ceux des neurones de son voisinage de tel sorte que ceux-ci se rapproche encore plus du vecteur d'entrée ;
6. On retourne à l'étape 2.

IV.2.2 Étiquetage de la carte du réseau SOM

L'apprentissage n'y étant pas supervisé, il convient, pour résoudre un problème de classification, d'effectuer la correspondance entre les cellules et les données d'entrées auxquelles elles répondent. Cette phase d'étiquetage consiste à attribuer à chaque cellule une étiquette qui correspond à la classe d'entrée dont elle est la plus proche. Dans ce but, l'ensemble des vecteurs de caractéristiques des individus d'apprentissage sont à nouveau présentés au système, et la fréquence avec laquelle chaque neurone est le plus proche d'une classe particulière est calculée. A la fin de cette étape, chaque neurone est associé à la classe pour laquelle il a été le plus fréquemment choisi. A l'issue de la procédure d'étiquetage, la carte auto-organisatrice peut être utilisée en classifieur. Un vecteur de caractéristiques est présenté à l'entrée du réseau et la classe reconnue est celle qui est associée au neurone dont le vecteur de poids est le plus proche du vecteur d'entrée.

L'inconvénient de l'apprentissage non supervisé décrit précédemment est que les poids des neurones sont organisés de manière à minimiser une erreur de quantification, alors que l'objectif réel est de reconnaître la classe du vecteur d'entrée. Seules les frontières entre les classes importent donc vraiment.

IV.2.3 Regroupement de la carte du réseau SOM

Quand il n'y a pas assez de données étiquetées, l'approche précédente ne fonctionnera pas. A ce moment là, pour faciliter l'analyse de la carte et les données, les unités similaires doivent être regroupées afin de réduire le nombre de groupes. La carte groupée peut être étiquetée. L'avantage principal de cette approche consiste à utiliser des données plus marquées à attribuer à chaque groupe une étiquette et faciliter l'analyse des groupes a révélé [44].

Plusieurs méthodes [45-46] sont souvent utilisées pour effectuer cette tâche. Nous avons choisi d'utiliser la méthode des « numéros » à regrouper nos cartes.

Dans notre travail le réseau SOM a été appris en utilisant une boîte à outils «SOM_ToolBox» implémentée dans le logiciel Matlab, cette boîte à outils est développée par l'équipe «SOM_ToolBox» de l'Université de Technologie d'Helsinki [47-48].

IV.2.4 Principe de SOM_ToolBox

Le «SOM Toolbox» permet de réaliser des classements par carte auto-organisatrices rapidement et efficacement. Il est composé d'un jeu de fonctions complet permettant d'initialiser une SOM (Self-Organizing Mapping), de l'entraîner, de la représenter, ainsi qu'une grande panoplie de fonctions auxiliaires offrant la possibilité de normaliser les vecteurs d'entrées et d'obtenir un grand nombre de résultats intermédiaires. Afin de nous permettre d'obtenir une carte topologique à partir des fonctions disponibles sur le SOM_ToolBox, les instructions suivantes doivent être exécutées une à une pour comprendre les différentes étapes de l'apprentissage.

a) Définition de la Structure de Données

La fonction `som_data_struct` a été utilisée pour définir la base de données constituée de :

- Les paramètres du vecteur d'entrée ;
- Le nombre de ces paramètres ;
- Le nom du fichier de la base de données ;
- Le code de la machine.

b) Normalisation des données

Afin que le réseau de neurone puisse traiter des données vers l'unité, nous avons utilisé une normalisation linéaire vers l'unité par la fonction ***som_normalize***.

c) Initialisation de la structure de la carte topologique et apprentissage

Cette étape consiste à définir la taille de la carte de dimension $[m \times n]$ et la forme de la carte 'hexagonale' ou 'rectangulaire'. Il ya deux types d'initialisation : aléatoire ou linéaire et deux algorithmes d'apprentissage : séquentiel et par paquet, La manière la plus simple pour initialiser et apprendre le SOM est d'utiliser la fonction ***som_make***. Par défaut l'initialisation linéaire et l'algorithme par paquet 'batch training' sont utilisés.

d) Étiquetage des neurones de la carte en utilisant le vote majoritaire

Cette phase est assurée par la fonction ***som_autolabel***. Elle consiste à attribuer à chaque cellule de la carte une étiquette qui correspond à la classe d'entrée dont elle est la plus proche de la manière suivante :

- o [0] pour une machine saine ;
- o [1] pour une machine avec une barre cassée ;
- o [2] pour une machine avec deux barres cassées ;
- o [3] pour une machine à une portion d'anneau de court-circuit enlevée.

e) Visualisation et analyse des données de la carte obtenue après apprentissage

A la fin de la phase d'apprentissage, la carte SOM obtenue peut être visualisée de différentes manières en utilisant la fonction **som_show** et **som_show_add**.

- Pour la visualisation directe des propriétés des cellules de la carte, la fonction **som_show** montre l'association des valeurs des unités. On note que cette visualisation travaille seulement en 1 ou 2 dimensions de la carte, par défaut elle montre la U-matrice et sa base de calcul de toutes les variables.
 - La matrice de distance des unités **U-matrice** (Unified distance matrix) : visualise les distances entre les unités voisines de la carte et permet de voir la structure de groupes de la carte en utilisant différentes couleurs pour les différencier;
- Pour la visualisation des données étiquetées obtenues après apprentissage, nous avons utilisé la fonction **som_show_add** en respectant ce qui suit :
 - Pour afficher le neurone majoritaire étiqueté sur la carte, nous avons utilisé la fonction **som_show_add** à condition que la fonction **som_autolabel** doit être associée avec l'option **"vote"** ;
 - Pour faciliter le calcul de la performance et faire des statistiques sur le réseau SOM, nous avons utilisé la fonction **som_show_add** à condition que la fonction **som_autolabel** doit associer les options suivantes : **"freq"**, **"add"** et **"add1"** [40].

V. Conclusion

Dans ce chapitre, nous avons présenté la méthodologie adoptée dans notre travail : nous avons énuméré dans un premier temps les paramètres représentatifs de défaillances nécessaires à la construction d'une base de données. Ensuite nous avons montré comment déterminer ces paramètres à partir d'une analyse fréquentielle du courant statorique. Enfin nous avons donné un bref aperçu sur les deux classificateurs à base de réseau de neurones artificiels (leurs propriétés, leurs paramètres et leurs fonctions) qui vont être utilisés dans le chapitre suivant.

Chapitre V

Résultats de diagnostic par les réseaux de neurones

I. Introduction

Ce chapitre porte sur l'application de l'analyse spectrale du courant statorique pour la détection des défauts rotoriques étudiés. Cela sera suivi par l'examen des résultats de classification obtenus par les réseaux de neurones artificiels. Mais avant d'examiner cela, nous présentons dans la première partie de ce chapitre le banc d'essai existant au niveau de l'école nationale polytechnique sur lequel des essais expérimentaux ont été effectués.

Dans la deuxième partie, nous présentons les résultats de l'analyse spectrale du courant statorique pour différents modes d'alimentation (réseau et variateur de vitesse) afin d'examiner l'influence des harmoniques générés par le variateur sur l'application de la méthode de diagnostic.

L'analyse spectrale permet également de construire la base de données qui sera utilisée dans la phase de classification par les réseaux de neurones.

II. Description du banc d'essai

Le banc expérimental utilisé pour effectuer nos essais expérimentaux a été conçu et monté au Laboratoire de Recherche en Électrotechnique de l'ENP par [49]. Le banc est constitué principalement d'un système électromécanique (moteur avec son alimentation plus la charge à entraîner), d'une chaîne de mesure représentée par un ensemble de capteurs (de courant, de tension et de vitesse) et une carte d'acquisition permettant l'adaptation et l'enregistrement des mesures recueillis par ces capteurs. La Figure V.1 illustre la photo du banc d'essais.



Figure V.1 : Présentation de banc d'essai [49].

II.1 Alimentation

Pour alimenter la machine asynchrone, nous disposons d'un réseau triphasé équilibré 127/220V. Afin d'effectuer le raccordement direct de la machine à ce réseau, les enroulements statoriques doivent être couplés en triangle. La machine asynchrone peut être également alimentée à partir d'un variateur de vitesse (Figure V.2) fonctionnant à U/f constant faisant varier la fréquence des courants d'alimentation de 0 à 50Hz. Ce variateur délivre une tension entre phase de 380V ce qui signifie que cette fois-ci les enroulements statoriques seront couplés en étoile.



Figure V.2 : Variateur de vitesse [49].

II.2 Machines asynchrones à cage d'écureuil

Dans le laboratoire nous disposons de quatre machines asynchrones industrielles identiques. La première est saine (sans défaut). Sur les trois autres, nous avons créé des défauts à savoir :

- Une barre rotorique cassée ;
- Deux barres rotoriques cassées en adjacence ;
- Une portion d'anneau de court-circuit cassée.


La Figure V.3 montre les différents rotors avec les défauts créés. Les caractéristiques techniques de ces machines sont données en Annexe A.



a) Les quatre rotors.



b) Rotor avec une barre cassée.



c) Rotor avec deux barres cassées.



d) Rotor avec une portion d'anneau cassée.

Figure V.3 : Différents types de rotors [50].

II.3 Génératrice à courant continu

Afin d'avoir un fonctionnement en charge, nous avons utilisé une génératrice à courant continu afin d'obtenir un couple résistant. La génératrice a une puissance utile de 2,4kW, ce qui limite la charge maximale aux environs de 70% de la charge nominale de la machine asynchrone utilisée.




Figure V.4 : Les machines utilisées avec les différentes charges [50].

II.4 Génératrice Tachymétrique

Pour mesurer la vitesse de rotation nous avons utilisé une génératrice Tachymétrique montée directement sur l'arbre de la machine à courant continu.

II.5 Capteurs de courant et de tension

Les capteurs de courant et de tension sont de type effet Hall très sensibles qui sont destinés à capter des signaux avec des fréquences qui peuvent atteindre 200kHz. L'utilisation de ces capteurs nécessite la connaissance de leurs caractéristiques surtout les valeurs maximales du courant et de la tension à relever. Pour ce faire, le conditionnement du signal est fortement recommandé afin de protéger les capteurs. La Figure V.5 présente la carte de mesure réalisée en vue de conditionner et rassembler les différents signaux.




Figure V.5 : Carte pour le conditionnement des signaux [49].

II.6 Acquisition des données

Le système d'acquisition est construit autour d'une carte de type IOTEQ/DAQ séries 1005 ayant une fréquence d'échantillonnage de 200kHz avec 16 entrées analogiques et 16 entrées digitales. Cette carte est installée dans un ordinateur et connectée à la carte de conditionnement

par un câble série pour le transfert des données. La carte est fournie avec son logiciel de pilotage appelé DAQVIEW. Ce dernier permet la variation de la fréquence d'échantillonnage, la variation du nombre de points à relever, l'enregistrement des fichiers de données sur différents formats (MAT, ASCII, DAT,...etc), la visualisation des signaux en temps réel ainsi que l'analyse fréquentielle de signaux.

II.7 Déroulement des essais expérimentaux


En exploitant le banc décrit précédemment, nous avons effectué des tests expérimentaux sur les quatre machines. Durant ces essais, nous avons enregistré :

- Les trois courants statoriques ;
- Les trois tensions d'alimentation de la machine ;
- La vitesse de rotation.


Dans le cas où les machines sont alimentées à partir de variateur de vitesse, d'autres essais ont été effectués avec des fréquences de 25, 40 et 50 Hz. Pour les deux types d'alimentation (réseau et variateur de vitesse), la charge appliquée aux machines varie de 0 à 78% de la charge nominale. L'acquisition des données a été effectuée avec une fréquence d'échantillonnage de 10kHz sur une durée de 10 secondes. Ce choix permet d'avoir une résolution en fréquence de l'ordre de 0,1Hz.

III. Analyse spectrale du courant statorique


L'analyse spectrale du courant statorique a été effectuée en utilisant le périodogramme de Welch avec des acquisitions de 100000 points et un recouvrement de 50% et en considérant la fenêtre de Blackman de longueur $N/2$. La Figure V.6 représente la densité spectrale de puissance du courant statorique pour les quatre machines. Nous constatons clairement la présence de plusieurs composantes dont les fréquences obéissent à la relation $(1 \pm 2k) f_s$.




a) Machine saine.



b) Machine avec une barre cassée.




c) Machine avec deux barres cassées.




d) Machine avec une portion d'anneau cassée.

Figure V.6 : Spectres du courant statorique.


Il est à noter que même pour une machine saine, il existe des composantes de faibles amplitudes de fréquence $(1 \pm 2g)f_s$. Cela peut être dû à la présence d'une faible asymétrie rotorique, cette asymétrie induit une légère modification de la distribution du flux magnétique dans l'entrefer de la machine, le spectre fréquentiel du courant statorique contient des composantes de faibles amplitudes dont les fréquences sont identiques à celles créées par une rupture de barre. Afin d'examiner l'influence de la charge sur la méthode de diagnostic, nous avons effectué d'autres essais à des niveaux de charge très faible. La Figure V.7 représente le spectre du courant statorique pour les quatre types de machines. Nous constatons que la localisation des composantes représentatives de défaut est très difficile pour ce niveau de charge. Pour cela, ces essais ne seront pas représentés dans la base de données destinée à la classification car les amplitudes calculées dans le cas d'un rotor défaillant ne diffèrent pas de ceux obtenues avec un rotor sain rendant ainsi la tâche de classification très difficile.




a) Machine saine.



b) Machine avec une barre cassée.



c) Machine avec deux barres cassées.



d) Machine avec une portion d'anneau cassée.

Figure V.7 : Spectre du courant statorique à faible charge.

IV. Résultats de classification des défauts par les réseaux de neurones

IV.1 Réseau de neurone à apprentissage supervisé

La base de données disponible a été divisée en deux sous-ensembles : le premier qui représente (2/3) des données sert pour l'apprentissage du réseau de neurone, alors que le second sous-ensemble est employé pour tester le fonctionnement du réseau. Nous avons utilisé également le réseau de neurone à rétro-propagation multicouches « Feedforward » comme classificateur dont les paramètres sont indiqués ci-dessous :

- Le réseau de neurone est constitué de trois couches : une couche d'entrée, une couche cachée et une couche de sortie ;
- La fonction d'activation pour la couche d'entrée est 'tangente sigmoïde' ou « **tansig** », la fonction d'activation pour la couche cachée est 'tangente sigmoïde' alors que la fonction d'activation pour la couche de sortie est 'sigmoïde' ou « **logsig** » ;
- L'algorithme d'apprentissage est celui de Levenberg-Marquardt;
- Le nombre d'époques d'apprentissage est fixé à 500 ;
- La performance de l'apprentissage est prise égale à 10^{-5} ;

Le nombre de neurones dans la couche de sortie est spécifié par le nombre d'état de la machine. Pour cela deux cas ont été étudiés :

- Classification à deux classes où le nombre de neurones dans la couche de sortie est fixé à 2.
- Classification multi classes où le nombre de neurones dans la couche de sortie est fixé à 3 puis à 4.

L'objectif des simulations est de trouver le nombre de neurones dans la couche cachée permettant une meilleure classification. Ainsi, l'architecture recherchée peut se mettre sous la forme [E x i x S].

IV.1.1 Résultats avec le premier groupe de paramètres pour k=1

Pour k=1, le nombre de paramètres dans le vecteur de donnée sera fixé à six. Ainsi, la couche d'entrée du réseau Feedforward contient six neurones. Le sous-ensemble de données destiné pour l'apprentissage contient 56 éléments, chaque élément est constitué de 6 paramètres. (Vecteur de 56x6). Pour le sous ensemble de test, il contient 28 éléments.

- **Classification à deux classes (machine saine et défectueuse)**

Le tableau V.1 montre les résultats obtenus pour ce type de classification. Nous avons indiqué dans ce tableau les différentes architectures simulées, la valeur de la performance après la phase d'apprentissage, le taux de réussite après la phase de test, le nombre d'erreur de classification. Nous constatons que l'augmentation de nombre de

neurone dans la couche cachée ne conduit pas obligatoirement à l'amélioration de la performance du réseau. Cette dernière dépend essentiellement de la taille des données d'apprentissage. Ce tableau montre que les résultats de classification varient entre 89.28% à 96.42% et que le meilleur résultat est obtenu pour l'architecture [6x8x2] pour laquelle nous avons enregistré uniquement une seule erreur de classification (voir détail sur le tableau V.2).

Tableau V.1 : Résultats de performance et de pourcentage avec différentes architectures du réseau FFBN pour le test d'apprentissage.

Architecture [6 i 2]	Performance	Pourcentage de test d'apprentissage (%)	Nombre d'Erreurs	Machine Saine en Défaut	Machine Défaut en Saine
[6 1 2]	0.00693	89.2875	03	03	00
[6 6 2]	0.00693	89.2875	03	03	00
[6 7 2]	0.00213	96.4286	01	00	01
[6 8 2]	0.00029	96.4286	01	00	01
[6 9 2]	0.00693	89.2875	03	02	01
[6 10 2]	0.00474	92.8571	02	02	00
[6 12 2]	0.00893	89.2875	03	02	01
[6 19 2]	0.00474	92.8571	02	01	01
[6 22 2]	0.00474	92.8571	02	01	01
[6 25 2]	0.00893	89.2875	03	01	02

Tableau V.2 : Spécification des résultats de diagnostic de l'architecture [6x8x2] du réseau FFBN (Voir détail des résultats avec codage en Annexe B).

Etats de fonctionnement des machines	Différents échantillons	Résultats du diagnostic	
		Machine Saine	Machine en défaut
Machine Saine	6	6	0
Machine en défaut	22	1	21
Total	28	7	21

• Classification multi classes

Le tableau V.3 montre les résultats obtenus pour la classification entre trois types de machines : machine saine, machine avec une barre cassée et machine avec deux barres cassées. Pour ce cas d'étude, le nombre de neurones dans la couche de sortie est fixé à trois. Nous remarquons que le taux de réussite de classification varie de 80.95% à 95.23% lorsque on fait varier le nombre de neurones dans la couche cachée. L'architecture [6x20x3] dont les résultats sont illustrés par le tableau V.4 qui donne le meilleur pourcentage de réussite avec uniquement une seule erreur de classification où une machine avec une barre cassée est considéré comme étant saine.

Tableau V.3 : Résultats de performance et de pourcentage avec différentes architectures du réseau FFBPN pour le test d'apprentissage.

Architecture [6 x i x 3]	Performance	Pourcentage de test d'apprentissage(%)	Nombre d'Erreurs	Résultats du diagnostic		
				S	B	BB
[6 6 3]	0.00794	80.9524	04	02(B)	(02)S	00
[6 8 3]	0.00428	90.4762	02	00	S	B
[6 9 3]	0.00701	85.7143	03	(03)B	00	00
[6 10 3]	0.00428	90.4762	02	(02)B	00	00
[6 14 3]	0.00794	80.9524	04	BB+B	BB	B
[6 15 3]	0.00794	80.9524	04	B	S+BB	B
[6 20 3]	0.00012	95.2381	01	(01)B	00	00

Tableau V.4 : Spécification des résultats de diagnostic de l'architecture [6x20x3] du réseau FFBPN (Voir détail des résultats avec codage en Annexe B).

Etats de fonctionnement des machines	Différents échantillons	Résultats du diagnostic		
		S	B	BB
Machine Saine	8	8	0	0
Machine d'une barre cassée	7	1	6	0
Machine de deux barres cassées	6	0	0	6
Total	21	9	6	6
Avec S : Machine Saine, B : Machine avec une Barre cassée, BB : Machine avec deux Barres cassées.				

En intégrant les données relatives au défaut de cassure d'une portion de l'anneau de court circuit, nous avons obtenu les résultats indiqués dans le tableau V.5. Le nombre de neurones dans la couche de sortie est fixé pour ce cas d'étude à quatre. Les résultats peuvent être considérés satisfaisants vu leur taux de réussite qui varie entre 60.71% et 82.14%.

L'architecture [6x13x4] donne le meilleur taux de réussite avec cinq erreurs de classification (voir détails dans le tableau V.6). Ces erreurs de classification peuvent être expliquées par le fait que les paramètres relatifs à une machine saine sont très proches de ceux relatifs à une machine avec une barre cassée ou une portion d'anneau de court circuit cassée. D'autre part, il est difficile de séparer entre une machine avec une barre cassée et celle avec une portion d'anneau de court circuit cassée.

Tableau V.5 : Résultats de performance et de pourcentage avec différentes architectures du réseau FFBN pour le test d'apprentissage.

Architecture [6 x i x 4]	Performance	Pourcentage de test d'apprentissage (%)	Nombre Erreurs	Résultats du diagnostic			
				S	B	BB	An
[6 7 4]	0.07446	60.7143	11	B	S+(03) An	B	(05)B
[6 8 4]	0.05446	64.2857	10	(05)B	(02)An+S	00	B+S
[6 9 4]	0.00856	67.8571	9	(03)B+An	(02)An	(03)An	00
[6 10 4]	0.00812	71.4286	8	B	(04)S	B	(02)B
[6 13 4]	0.00446	82.1429	5	(02)B	S+An	00	B
[6 14 4]	0.00405	75.0000	7	(02) B	(02)An	An	B+S
[6 16 4]	0.00753	78.5714	6	B+An	(02)An	00	(02)B
[6 19 4]	0.00753	78.5714	6	00	(02)S+An	00	S+(02)B
[6 21 4]	0.00753	78.5714	6	00	S+(02)An	00	S+(02)B
[6 28 4]	0.00408	75.0000	7	(03)B	S+BB+An	00	BB

Tableau V.6 : Spécification des résultats de diagnostic de l'architecture [6x13x4] du réseau FFBN (Voir détail des résultats avec codage en Annexe B).

Etats de fonctionnement des machines	Différents échantillons	Résultats du diagnostic			
		S	B	BB	An
Machine Saine	5	3	2	0	0
Machine d'une barre cassée	7	1	5	0	1
Machine de deux barres cassées	8	0	0	8	0
Machine avec une portion d'anneau de court circuit enlevée	8	0	1	0	7
Total	28	4	8	9	7
Avec S : Machine Saine, B : Machine avec une Barre cassée, BB : Machine avec deux Barres cassées, An : une portion d'anneau de court circuit enlevée.					

IV.1.2 Résultats avec le second groupe de paramètres pour $k=2$

Le 2^{ème} groupe de données correspond à $k=2$ contient dix paramètres ce qui permet de fixer le nombre de neurone dans la couche d'entrée. La base de données contient 84 éléments dont 2/3 sont destinés à la phase d'apprentissage et 1/3 à la phase de test.

- **Classification à deux classes**

Le tableau V.7 montre les résultats obtenus pour ce type de classification. En faisant varier le nombre de neurones dans la couche cachée de 6 à 29, nous remarquons que le taux de réussite varie entre 82.14% et 92.85% et l'architecture [10x10x2] est celle qui donne le meilleur taux de réussite avec uniquement deux erreurs de classification (voir détails dans le tableau V.8).

Tableau V.7 : Résultats de performance et de pourcentage avec différentes architectures du réseau FFBPN pour le test d'apprentissage.

Architecture [10x i x2]	Performance	Pourcentage de test d'apprentissage(%)	Résultats du diagnostic		
			Nombre d'Erreurs	Machine Saine en Défaut	Machine Défaut en Saine
[10 6 2]	0.01790	89.2857	03	00	03
[10 8 2]	0.03760	85.7143	04	03	01
[10 10 2]	0.00083	92.8571	02	00	02
[10 12 2]	0.00893	82.1429	05	01	04
[10 15 2]	0.00893	82.1429	05	01	04
[10 16 2]	0.03788	85.7143	04	02	02
[10 22 2]	0.01790	89.2857	03	01	02
[10 29 2]	0.00893	82.1429	05	01	04

Tableau V.8 : Spécification des résultats de diagnostic de l'architecture [10x10x2] du réseau FFBPN (Voir détail des résultats avec codage en Annexe B).

Etats de fonctionnement des machines	Différents échantillons	Résultats du diagnostic	
		Machine Saine	Machine en défaut
Sain	6	6	0
Défaut	22	2	20
Total	28	8	20

- **Classification multi classes**

Commençant d'abord à présenter les résultats pour la classification entre une machine saine et les machines ayant une et deux barres cassées. Dans ces conditions, la base de données contient 63 éléments et la couche de sortie du réseau contient trois neurones. Les résultats obtenus sont donnés au Tableau V.9 où nous avons fait varier le nombre de neurones dans la couche cachée de 5 à 26 jusqu'à ce qu'on obtient la meilleure architecture possible. Le taux de réussite de classification varie entre 80.95% et 85.71% et le maximum est atteint pour l'architecture [10x19x3] dont les spécifications des résultats de diagnostic pour cette architecture sont illustrées par le tableau V.10.

Tableau V.9 : Résultats de performance et de pourcentage avec différentes architectures du réseau FFBPN pour le test d'apprentissage.

Architecture [10x i x3]	Performance	Pourcentage de test d'apprentissage(%)	Nombre d'Erreurs	Résultats du diagnostic		
				S	B	BB
[10 5 3]	0.00358	85.7143	03	00	(02)S	B
[10 7 3]	0.00794	80.9524	04	(02)B	S+BB	00
[10 8 3]	0.00142	85.7143	03	(03)S	00	00
[10 10 3]	0.00794	80.9524	04	B	(03)S	00
[10 15 3]	0.00794	80.9524	04	(02)B	(02)S	00
[10 19 3]	0.00094	85.7143	03	(03)B	00	00
[10 26 3]	0.00794	80.9524	04	B	(02)S+B	00

Tableau V.10 : Spécification des résultats de diagnostic de l'architecture [10x19x3] du réseau FFBPN (Voir détail des résultats avec codage en Annexe B).

Etats de fonctionnement des machines	Différents échantillons	Résultats du diagnostic		
		S	B	BB
Machine Saine	5	5	0	0
Machine d'une barre cassée	9	3	6	0
Machine de deux barres cassées	7	0	0	7
Total	21	8	6	7
Avec S : Machine Saine, B : Machine avec une Barre cassée, BB : Machine avec deux Barres cassées				

En intégrant les données relatives au défaut de cassure d'une portion d'anneau de court circuit, la base de données contient 84 éléments et la couche de sortie a quatre neurones. Le tableau V.11 montre les meilleurs pourcentages obtenus avec différentes architectures du réseau dont le nombre de neurone dans la couche cachée varie de 5 à 24. Nous constatons que le taux de réussite varie de 64.28% à 82.14% et le maximum est atteint pour l'architecture [10x16x4] pour laquelle nous enregistrons cinq erreurs de classification dont les spécifications des résultats de diagnostic pour cette architecture sont illustrées par le tableau V.12.

Tableau V.11: Résultats de performance et de pourcentage avec différentes architectures du réseau FFBNP pour le test d'apprentissage.

Architecture [10 x i x 4]	Performance	Pourcentage de test d'apprentissage (%)	Nbr de Erreurs	Résultats du diagnostic			
				S	B	BB	An
[10 5 4]	0.07446	71.4286	08	B+An	(04)S	00	B+S
[10 7 4]	0.05446	71.4286	08	(02)B	BB+(02) An	S+B	S
[10 8 4]	0.00856	67.8571	09	(02)An	(02)S	(02)B	(2)B+S
[10 16 4]	0.00400	82.1400	05	B	S	00	(02)B+S
[10 18 4]	0.00810	71.4286	08	(02)B	(03)An+BB	00	S+B
[10 22 4]	0.00411	75.0000	07	00	(04)B+An	00	(02)S
[10 24 4]	0.00753	64.2857	10	(02)An	(03)An+(02)BB+S	00	S+B

Tableau V.12 : Spécification des résultats de diagnostic de l'architecture [10x16x4] du réseau FFBNP (Voir détail des résultats avec codage en Annexe B).

Etats de fonctionnement des machines	Différents échantillons	Résultats du diagnostic			
		S	B	BB	An
Machine Saine	7	5	1	0	1
Machine d'une barre cassée	8	1	5	0	2
Machine de deux barres cassées	6	0	0	6	0
Machine avec une portion d'anneau de court circuit cassée	7	0	0	7	0
Total	28	6	6	13	3
Avec S : Machine Saine, B : Machine avec une Barre cassée, BB : Machine avec deux Barres cassées, An : une portion d'anneau de court circuit cassée.					

IV.1.3 Comparaison et analyse des résultats

Le tableau V.13 présente une synthèse des meilleures architectures obtenues pour les différents types de classification. A partir de ces résultats nous pouvons constater ce qui suit :

- Le pourcentage de réussite de classification dépend de l'architecture du réseau de neurones. Ce dernier réussit toujours à classer deux états de la machine (machine saine ou défectueuse) avec un taux de réussite supérieur à 92% ;
- Le taux de réussite diminue au fur et à mesure que le nombre de défauts à classer (séparer) augmente. Ainsi, le réseau de neurones rencontre des difficultés à les classer en particulier lorsqu'on intègre le défaut sur l'anneau de court circuit qui présentent pratiquement des composantes de mêmes amplitudes que pour le défaut d'une barre rotorique cassée ;
- Lorsqu'on tient compte des deux composantes supplémentaires pour $k=2$, le taux de réussite diminue. Cela peut être expliqué par le fait que lorsqu'on s'éloigne de part et d'autre de la fréquence fondamentale, l'amplitude des composantes caractéristiques diminue. Cela est d'autant plus important pour le cas où $k=2$. Ainsi, ces nouvelles composantes ne contribuent pas à la bonne classification mais au contraire, elles entraînent des erreurs supplémentaires.

Tableau V.13 : Comparaison entre les meilleures architectures du réseau Feedforward.

Type des classifications des machines	Rang d'harmonique $k=1$		Rang d'harmonique $k=2$	
	Architecture	Pourcentage	Architecture	pourcentage
Classification à deux classes	[6 8 2]	96.4286	[10 10 2]	92.8571
Classification multi classes sans le défaut sur l'anneau de court circuit	[6 20 3]	95.2381	[10 19 3]	85.7143
Classification multi classes avec défaut sur l'anneau de court circuit	[6 13 4]	82.1429	[10 16 4]	78.5741

IV.2 Réseau de neurone à apprentissage non supervisé

Afin d'appliquer cette technique, une base de données constituée de 84 échantillons a été élaborée. Elle contient 21 échantillons représentant la machine saine et 63 échantillons représentant les machines avec défaut à savoir : la machine avec une barre cassée, deux barres cassées, et une portion de l'anneau de court circuit enlevée. Les résultats de classification sont obtenus en choisissant le classificateur SOM dont les caractéristiques sont indiquées ci-dessous :

- Le réseau SOM est constitué de deux couches : une couche d'entrée et une couche de sortie ;
- La couche de sortie est une carte à deux dimensions organisée dans un réseau de voisinage hexagonal ;
- Le SOM n'utilise pas les informations sur les classes au cours de la phase d'apprentissage. La carte des classes peut s'afficher comme une grille vide après l'achèvement d'apprentissage d'où l'intérêt de la phase d'étiquetage.

L'objectif des simulations est de trouver une dimension de la carte de la couche de sortie permettant une meilleure classification. Ainsi, la dimension recherchée peut se mettre sous la forme : $[m \times n]$. Pour cela deux cas ont été étudiés :

- Classification à deux classes où le vecteur de données est marqué avec deux étiquettes ;
- Classification multi classes où le vecteur de données est marqué avec trois puis quatre étiquettes.

IV.2.1 Résultats avec le premier groupe de paramètres pour $k=1$

Pour $k=1$, le nombre de paramètres dans le vecteur de données sera fixé à six. Ainsi, la couche d'entrée du réseau SOM contient six neurones. Le résultat du réseau SOM peut être interprété soit par une carte topologique à deux dimensions soit par une matrice de distance des unités (U-matrice), après la phase d'apprentissage. La première représentation offre une connaissance topologique de la projection de l'ensemble des données, alors que la deuxième fournit

une visualisation sur les distances entre unités voisines de la carte, elle est utilisée pour la détection des frontières des classes et particulièrement adapté pour l'estimation des distances interclasses. La matrice de distance des unités permet de voir aussi la structure de groupes de la carte tel que:

- Les hautes valeurs de U-matrice indiquent les limites des classes;
- Les faibles valeurs indiquent les classes eux-mêmes.

Tous les résultats de la matrice de distance des unités illustrés par les figures (V.8.b, V.9.b, V.10.b, V.11.b, V.12.b et V.13.b) montrent les distances entre les unités voisines de la carte pour différentes classes, en utilisant les niveaux de couleurs jaune vert clair et orange. La couleur orange représente des distances longues tandis que la couleur jaune vert clair représente les distances courtes.

A partir de ces résultats on peut conclure que la représentation par la matrice de distance des unités ne montre pas une séparation claire entre les machines, mais à partir de l'étiquette associée aux unités de la carte, il semble qu'ils correspondent à des différents sous groupes (classes).

- **Classification à deux classes**

La Figure V.8.a montre le résultat obtenu pour la classification entre deux types de machines : machine saine et machine défectueuse. Nous avons présenté dans cette figure une carte de 64 nœuds (neurones) [8x8], C'est la dimension optimale qui a été trouvée pour représenter les résultats où aucune erreur de classification n'a été visualisée. Nous constatons à partir de cette carte que :

- Les unités non marquées indiquent les frontières des groupes (classes) ;
- Les unités marquées dans les colonnes à gauche de la carte correspondent à une machine saine, alors que les unités marquées dans les colonnes à droite de la carte correspondent à une machine défectueuse, Ce qui permet de différencier clairement entre les deux classes.

L'augmentation du nombre de neurones dans la couche de sortie (dimension de la carte) par rapport à la quantité de données (84 vecteurs) présenté à l'entrée du réseau ne permet pas de conserver la bonne forme topologique et ne signifie pas l'amélioration de la performance du réseau. Cette dernière dépend essentiellement de la taille des données d'apprentissage.




Figure V.8 : Classification de deux états de la machine, a) carte de Kohonen, b) matrice de distance.

La visualisation directe de la carte n'indique pas exactement les erreurs de classification. Cela peut être obtenu en utilisant l'option de vote majoritaire pour chaque unité de la carte. Ainsi, les résultats sont représentés dans le tableau V.14 où un taux de réussite de 91.67% est obtenu avec uniquement sept erreurs de classification.

Tableau V.14: Performance de classification pour deux états avec le réseau [8x8]
(Voir détail des résultats en Annexe B).

Etats de fonctionnement des machines		Différents échantillons	Résultats du diagnostic		Nombre d'Erreurs	Pourcentage (%)
			Machine Saine	Machine en défaut		
k=1	Sain	21	19	2	02	90.48
	Défaut	63	5	58	05	92.06
	Total	84	24	60	07	91.67

• Classification multi classes

La Figure V.9.a montre les résultats obtenus pour une classification entre trois types de machines : machine saine, machine avec une barre cassée et machine avec deux barres cassées. Pour ce cas d'étude, trois étiquettes ont été associées aux unités de la carte pour représenter les données.

Le meilleur résultat est obtenu avec une dimension [8x8] qui confirme l'existence de trois groupes (classes) différents relatifs aux trois états de la machine, chaque groupe prend des colonnes sur la carte, avec uniquement une seule erreur de classification où une machine avec une barre cassée est classée comme étant saine.




Figure V.9 : Classification de trois états de la machine, a) carte de Kohonen, b) matrice de distance.

Les résultats du tableau V.15 montrent que le taux de réussite de la classification atteint 88.89% avec sept erreurs de classification. Nous constatons qu'une machine saine a été classée comme étant une machine à une barre cassée, cinq machines avec une barre cassée sont classées comme des machines saines et une machine avec deux barres cassées a été classée comme machine à une barre cassée.

Le taux de réussite pour ce cas d'étude est inférieur au premier type de classification (classification à deux classes) malgré qu'on a obtenu le même nombre d'erreurs, cela est expliqué par le fait que le nombre de données d'apprentissage n'est pas le même (63 dans ce cas contre 84 pour le cas précédent).

Tableau V.15: Performance de classification pour trois états avec le réseau [8x8]
(Voir détail des résultats en Annexe B).

Etats de fonctionnement des machines		Différents échantillons	Résultats du diagnostic			Nombre d'Erreurs	Pourcentage (%)
			S	B	BB		
k=1	S	21	20	1	0	01	95.24
	B	21	5	16	0	05	76.19
	BB	21	0	1	20	01	95.24
	Total	63	25	18	20	07	88.89
Avec S : Machine Saine, B : Machine avec une Barre cassée, BB : Machine avec deux Barres cassées							

Tenant compte des données relatives au défaut de l'anneau de court circuit, nous avons présenté sur la Figure V.10.a quatre étiquettes associées aux unités de la carte pour la classification de quatre types de machines : machine saine, une machine avec une barre cassée, une machine avec deux barres cassées et une machine avec cassure d'une portion d'anneau de court circuit.

Pour un réseau de neurones de même dimension (64 neurones), nous avons obtenu des résultats satisfaisants. Dans cette figure, nous pouvons voir que les colonnes à droite représentent la machine à deux barres cassées, celles qui viennent juste après représentent la machine à une barre cassée, ensuite les colonnes représentant la machine avec une portion d'anneau de court-circuit cassée et enfin les colonnes de la machine saine.

L'apparition des machines avec une barre cassée et une portion d'anneau de court circuit cassée sur les colonnes du milieu peut être expliquée par le fait que ce dernier défaut engendre un effet de modulation d'amplitude sur les courants statoriques similaire à celui provoqué par la cassure d'une barre. Il est difficile de séparer ces deux défauts, ils sont généralement toujours groupés, voir confondus sur la même colonne de la carte.




Figure V.10 : Classification de quatre états de la machine, a) carte de Kohonen, b) matrice de distance.

Le tableau V.16 montre les performances de classification pour ce réseau. Nous remarquons que le taux de réussite est relativement faible par rapport aux cas précédents, il atteint 79.76% avec un nombre d'erreurs plus important (17 erreurs).

Tableau V.16: Performance de classification pour quatre états avec le réseau [8x8]
(Voir détail des résultats en Annexe B).

Etats de Fonctionnement des machines		Différents échantillons	Résultats du diagnostic				Nombre d'Erreurs	Pourcentage (%)
			S	B	BB	An		
$k=1$	S	21	20	1	0	0	01	95.24
	B	21	6	13	0	2	08	61.90
	BB	21	0	0	21	0	00	100
	An	21	1	5	2	13	08	61.90
	Total	84	27	19	23	15	17	79.76
Avec S : Machine Saine, B : Machine avec une Barre cassée, BB : Machine avec deux Barres cassées, An : une portion d'anneau de court circuit cassée.								

IV.2.2 Résultats avec le second groupe de paramètres pour $k=2$

Le 2^{ème} groupe de données correspond à $k=2$ contient dix paramètres ce qui permet de fixer le nombre de neurone dans la couche d'entrée. La base de données destinée pour la phase d'apprentissage contient 84 éléments, chaque élément est constitué de 10 paramètres.

- **Classification à deux classes**

La Figure V.11.a montre les résultats obtenus pour une classification entre machine saine et machine défectueuse, sans spécification de la nature de défaut. En faisant varier le nombre de neurones de la carte, nous remarquons que la dimension [10x5] de 50 neurones est celle qui donne le meilleur résultat. L'analyse de la carte est basée sur les étiquettes, nous distinguons deux régions bien différentes :

- La région marquée par (0) correspond à une machine saine ;
- La région marquée par (1) correspond à une machine défectueuse.

Aussi, nous visualisons la présence des étiquettes (1) dans la région de la machine saine, ce qui donne 21 erreurs et le taux de la classification atteint 75% comme est montré sur le tableau V.17.




Figure V.11 : Classification de deux états de la machine, a) carte de Kohonen, b) matrice de distance.

Tableau V.17: Performance de classification pour deux états avec le réseau [10x5]
(Voir détail des résultats en Annexe B).

Etats de fonctionnement des machines		Différents échantillons	Résultats du diagnostic		Nombre d'Erreurs	Pourcentage (%)
			Machine Saine	Machine en défaut		
$k=2$	Sain	21	19	2	02	90.48
	défaut	63	19	44	19	69.84
	Total	84	36	48	21	<u>75.00</u>

• Classification multi classes

Pour la classification entre une machine saine et les machines ayant une et deux barres cassées, la base de données contient 63 éléments. Le meilleur résultat de classification est présenté par la Figure V.12.a qui montre une carte de 55 neurones de dimension [11x5] associée de trois étiquettes dans les régions suivantes :

- La région marquée par (0) occupe les colonnes du coin supérieur à gauche vers le coin inférieur à gauche et progresse un petit peu jusqu'au milieu;
- La région marquée par (1) occupe les colonnes du milieu ;
- La région marquée par (2) occupe la première colonne à droite.

A partir de cette inspection visuelle, on peut dire que la carte réussit toujours à séparer une machine à deux barres cassées des deux autres types de machines, mais la présence de deux étiquettes (1) dans la région de la machine saine et une étiquette (0) dans la région de la machine avec une barre cassée réduit la performance du réseau SOM en enregistrant neuf erreurs de la classification.




Figure V.12 : Classification de trois états de la machine, a) carte de Kohonen, b) matrice de distance.

Le tableau V.18 montre que le taux de réussite est inférieur comparativement au cas où $k=1$, il atteint environ 86% avec 9 erreurs enregistrées.

Tableau V.18: Performance de classification pour trois états avec réseau [11x5]
(Voir détail des résultats en Annexe B).

Etats de fonctionnement des machines		Différents échantillons	Résultats du diagnostic			Nombre d'Erreurs	Pourcentage (%)
			S	B	BB		
$k=2$	S	21	19	2	0	02	90.48
	B	21	6	14	1	07	66.67
	BB	21	0	0	21	00	100
	Total	63	25	16	22	09	85.71
Avec S : Machine Saine, B : Machine avec une Barre cassée, BB : Machine avec deux Barres cassées							

En intégrant les données relatives au défaut de cassure d'une portion d'anneau de court circuit, la base de données contient dans ce cas 84 éléments, la carte composée de 50 neurones [10x5] est celle qui donne le meilleur résultat pour ce type de classification où il y a lieu de séparer quatre types de machines. La Figure V.13.a montre clairement qu'il y a une mauvaise classification entre les quatre types de machines, pour laquelle les régions sont confondues les unes des autres et nous avons enregistré plusieurs erreurs de classification, réduisant ainsi le taux de réussite de classification.

La visualisation du réseau SOM pour $k=2$ montre qu'il est impossible d'isoler clairement les limites de classification et en particulier pour le cas de quatre états de la machine. Ainsi, Le pourcentage de classification est de 61.90% comme cela est illustré par le tableau V.19.




Figure V.13 : Classification de quatre états de la machine, a) carte de Kohonen, b) matrice de distance.

Tableau V.19: Performance de classification pour quatre états avec réseau [10x5]
(Voir détail des résultats en Annexe B).

États de Fonctionnement des machines		Différents échantillons	Résultats du diagnostic				Nombre d'Erreurs	Pourcentage (%)
			S	B	BB	An		
$k=2$	S	21	19	0	2	0	02	90.48
	B	21	10	6	3	2	15	28.57
	BB	21	4	1	16	00	05	76.19
	An	21	4	2	4	11	10	52.38
	Total	84	37	09	25	13	32	61.90
Avec S : Machine Saine, B : Machine avec une Barre cassée, BB : Machine avec deux Barres cassées, An : une portion d'anneau de court circuit cassée.								

IV.2.3 Comparaison et analyse des résultats

Le tableau V.20 présente une synthèse des meilleures architectures du réseau SOM obtenues pour les différents types de classification. A partir de ces architectures, nous pouvons constater ce qui suit :

- La classification par le réseau SOM entre deux états de la machine réduit le pourcentage de réussite de 91.67% pour $k=1$ à 75% pour $k=2$;
- Les résultats montrent que les défauts de cassure des barres du rotor peuvent toujours être distingués de la machine saine. Quelques erreurs de classification apparaissent à cause de la présence d'une asymétrie rotorique de fabrication ;
- Pour une classification entre plusieurs types de défaut, il est difficile de distinguer entre une machine ayant un défaut sur l'anneau avec celle qui a une barre rotorique cassée ;
- Pour tous les résultats, nous avons assuré un taux de réussite supérieur à 60% quelque soit le type de classification et quelque soit le nombre de paramètres à utiliser dans le vecteur de données.

Tableau V.20 : Comparaison entre les meilleures dimensions du réseau SOM.

Type des classifications des machines	Rang d'harmonique $k=1$		Rang d'harmonique $k=2$	
	Dimension de la carte	Pourcentage (%)	Dimension de la carte	Pourcentage (%)
Classification à deux classes	[8x8]	91.67	[10x5]	75.00
Classification multi classes sans le défaut sur l'anneau de court circuit	[8x8]	88.89	[11x5]	85.71
Classification multi classes avec défaut sur l'anneau de court circuit	[8x8]	79.76	[10x5]	61.90

V. Conclusion

Nous avons utilisé l'analyse spectrale du courant statorique pour déterminer les composantes spécifiques aux défauts étudiés afin de former une base de données fiable pour l'apprentissage de deux types des réseaux de neurones. Le premier est le réseau Feedforward de trois couches à apprentissage supervisé avec l'algorithme d'apprentissage rétropropagation du gradient. Pour ce réseau, nous avons présenté et comparé plusieurs architectures et nous avons montré les résultats détaillés relatifs à la meilleure architecture.

Le deuxième réseau à apprentissage non supervisé est la carte auto-organisatrice de Kohonen pour laquelle nous avons présenté les résultats de la meilleure carte. Les résultats obtenus sont très satisfaisants et les architectures trouvées ont montré leur efficacité pour la classification des défauts étudiés. En comparant les différents résultats, nous pouvons conclure que le réseau FeedForward est plus performant par rapport au réseau SOM.

Conclusion générale

Conclusion générale et Perspectives

Etant donné les fréquences d'utilisation des machines asynchrones dans diverses applications, une détection rapide et précoce de leurs défaillances est nécessaire. Leur association avec un convertisseur de puissance type onduleur de tension étant de plus en plus utilisée, il devient nécessaire de prendre en compte les interactions entre ces deux éléments. Le travail présenté dans ce mémoire expose l'apport des modèles de réseau de neurone au diagnostic et à la classification des défauts des machines asynchrones.

Pour aborder l'étude, nous avons établi un état de l'art des défauts pouvant intervenir dans la machine asynchrone et des méthodes classiques permettant de les identifier. Ce travail préliminaire a mis en évidence une approche en vue du diagnostic spécifique de la machine asynchrone. Cette approche consiste à analyser les signaux mesurés sur la machine en cours de fonctionnement. Les analyses sont réalisées, pour la plupart, dans le domaine fréquentiel et en régime permanent. Les informations issues de ces analyses permettent souvent une identification efficace des défaillances présentes au rotor. Cette approche fréquentielle trouve sa limite en présence d'importants bruits de mesure qui noient l'information pertinente. L'approche par l'analyse de la densité spectrale de puissance, nous a permis d'identifier les signatures fréquentielles causées par la rupture d'une ou plusieurs barres de la cage rotorique. Il s'est avéré que la surveillance de l'amplitude des composantes de fréquence $(1 \pm 2k)f_s$ présentes dans le spectre fréquentiel du courant statorique permet de détecter la présence d'un défaut au niveau de la cage rotorique de la machine. A partir de ces informations, il est alors possible de développer des méthodes de surveillance et de diagnostic en ligne appropriées.

La mise en place d'un tel système de diagnostic nécessite l'existence d'une base de données contenant les mesures réalisées sur le processus et totalement codées (étiquetées). Les paramètres constituant la base de données sont choisis selon l'équation $(1 \pm 2k)f_s$. Pour cela, nous avons obtenu six ou dix paramètres selon le rang k . Ces paramètres sont les fréquences associées avec ces amplitudes de part et d'autres de la fréquence fondamentale ainsi que le glissement de la machine et la fréquence fondamentale. La principale difficulté pour évaluer l'amplitude des composantes spectrales créées par le défaut rotorique réside dans le fait que les fréquences varient avec le glissement « g » de la machine. Pour un point de fonctionnement nominal, ce glissement vaut quelques pour-cent, ce qui permet de discerner ces composantes de la composante fondamentale « f_s ». Par contre, lorsque le glissement est très proche de zéro (fonctionnement à faible charge ou à vide), ces composantes sont relativement proches de la composante fondamentale « f_s », ce qui rend leur détection beaucoup plus difficile. De la base de données sont extraits un ensemble d'apprentissage et des ensembles de test, totalement disjoints.

Après avoir déterminé les paramètres relatifs aux défauts de la machine, nous avons procédé à la mise en œuvre d'un système (modèle) de décision basé sur les réseaux de neurones, le premier modèle à apprentissage supervisé est le perceptron multicouches d'une architecture Feedforward Backpropagation, tant dit que le deuxième modèle à apprentissage non supervisé est la carte auto-organisatrice de Kohonen SOM (Self Organizing Mapping).

Nous avons proposé dans notre travail un système automatisé pour le diagnostic et la classification des défauts des machines asynchrones à cage. Au niveau de notre application, sont considérés certains défauts créés au rotor. Les défauts étudiés sont les cassures de barres et la rupture d'une portion d'anneau de court circuit au rotor. La machine est alimentée à vide et à plusieurs niveaux de charge pour une alimentation prélevée soit sur le réseau, soit par le biais d'un onduleur de tension. Les mesures accessibles en direct sur la machine sont les courants, les tensions électriques et la vitesse. Deux bibliothèques de mesure ont été constituées une dans le cas sans onduleur et l'autre avec onduleur de fréquence 25, 40 et 50Hz.

Une normalisation des données a été réalisée. Elle permet de s'affranchir de la dispersion due à la variation de la charge. Ainsi, la seule dispersion existante représente les différents modes de fonctionnement. Cette normalisation facilite le diagnostic en optimisant le nombre de classes présentes dans la base de données.

Deux paramètres ont été choisis comme entrée aux réseaux de neurones, pour chaque paramètre choisis deux cas ont été étudiés pour la classification des défauts par les réseaux de neurones :

- ❖ Classification à deux classes pour ce cas d'étude, la séparation a été faite entre une machine saine et une machine défectueuse sans tenir compte du type de défaut, et le nombre de neurones dans la couche de sortie a été fixé à 2.
- ❖ Classification multi classes où la séparation a été faite entre une machine saine, une machine avec une barre cassée, une machine avec deux barres cassées et une machine avec une portion d'anneau de court-circuit cassée, et le nombre de neurones dans la couche de sortie a été fixé à 3 puis à 4.

L'objectif de l'application du premier modèle de réseaux de neurones Feedforward a été de trouver le nombre de neurones dans la couche cachée permettant une meilleure classification. Les résultats de simulations ont montré que :

- Le pourcentage de réussite de classification dépend de l'architecture du réseau de neurones. Ce dernier réussit toujours à classer deux états de la machine (machine saine ou défectueuse) avec un taux de réussite supérieur à 92% ;
- Le taux de réussite diminue au fur et à mesure que le nombre de défauts à séparer augmente. Ainsi, le réseau de neurones rencontre des difficultés pour les classer en particulier lorsqu'on intègre le défaut sur l'anneau de court circuit qui présentent pratiquement des composantes de mêmes amplitudes que pour le défaut d'une barre rotorique cassée ;
- Lorsqu'on tient compte des deux composantes supplémentaires pour $k=2$, le taux de réussite diminue. Cela peut être expliqué par le fait que lorsqu'on s'éloigne de part et d'autre de la fréquence fondamentale, l'amplitude des composantes caractéristiques diminue. Cela est d'autant plus important pour le cas où $k=2$. Ainsi, ces nouvelles composantes ne contribuent pas à la bonne classification mais au contraire, elles entraînent des erreurs supplémentaires.

Pour le deuxième réseau SOM, la même base de données a été utilisée afin de séparer les différents états de la machine à savoir : la machine saine, la machine avec une barre cassée, deux barres cassées, et une portion d'anneau de court circuit enlevée. Le réseau SOM est constitué de deux couches : une couche d'entrée et une couche de sortie, la couche de sortie est une carte à deux dimensions qui a été organisée dans un réseau de voisinage hexagonal. Ainsi l'objectif de l'application de ce réseau est de trouver une dimension de la carte de la couche de sortie permettant une meilleure classification. Le réseau SOM a été appris en utilisant une boîte à outils «SOM Toolbox» implémentée dans le logiciel libre Matlab-Package sous format SOM_PAK et développé par l'équipe «SOM Toolbox» de l'Université de Technologie d'Helsinki. Nous avons constaté ce qui suit :

- Les résultats de classification entre deux états de la machine réduit le pourcentage de réussite de 91.67% pour $k=1$ à 75% pour $k=2$;
- Les résultats montrent que les défauts de cassure des barres du rotor peuvent toujours être distingués de la machine saine. Quelques fautes de classification apparaissent à cause de la présence d'une asymétrie rotorique due à la fabrication ;
- Pour une classification entre plusieurs types de défaut, il est difficile de distinguer entre une machine ayant un défaut sur l'anneau avec celle qui a une barre rotorique cassée ;
- Pour tous les résultats, nous avons assuré un taux de réussite supérieur à 60% quelque soit le type de classification et quelque soit le nombre de paramètres à utiliser dans le vecteur de données.

Les résultats obtenus sont très satisfaisants et les architectures trouvées ont montré leur efficacité pour la classification des défauts étudiés. En comparant les différents résultats des deux modèles, nous pouvons conclure que le réseau Feedforward est plus performant par rapport au réseau SOM.

Perspectives

Les travaux réalisés dans le cadre de ce mémoire pourraient donner lieu à des études supplémentaires sur plusieurs points :

- Normaliser les mesures par rapport au niveau de charge ; au lieu d'avoir pour un mode de fonctionnement donné plusieurs classes correspondant aux différents niveaux de charge ;
- Calculer les paramètres avec des méthodes de traitement de signal plus performantes, pour améliorer la pertinence du vecteur de données. Et rechercher des signatures spécifiques au régime transitoire par la technique DWT (Discret Wavelet Transform) ;
- Utiliser des méthodes de détection de défauts autres que l'analyse spectrale du courant statorique à savoir : la méthode d'analyse par le vecteur de PARK et les composantes symétriques ;
- Remplacer la méthode d'analyse spectrale par un réseau de neurone pour la détection des paramètres représentatifs de défauts automatiquement et rendre tout le travail par les réseaux de neurones ;

- Améliorer les méthodes utilisées pour la recherche de nombre de couches cachées et le nombre de neurones dans chaque couche par l'algorithme génétique qui peut être utilisé pour rechercher dans l'espace de solution la « meilleure » architecture définie selon un ensemble de critères ;
- Combiner les deux types de réseaux de neurones (Feedforward et SOM) pour la classification des défauts étudiés.

Bibliographie

Bibliographie

- [1] O. Ondel, "Diagnostic par reconnaissance des formes : Application a un ensemble convertisseur machine asynchrone" *Thèse de doctorat en Génie Électrique, École Centrale de Lyon, France*, Octobre 2006.
- [2] R. Casimir, "Diagnostic des défauts des machines asynchrones par reconnaissance des formes" *Thèse de doctorat en Génie Electrique, Ecole Centrale De Lyon, France*, Décembre 2003.
- [3] H. Ben Attia "Détection et localisation de défauts mécaniques d'un entraînement électrique à vitesse variable" *Thèse de doctorat en Génie Electrique, Ecole nationale d'ingénieurs de Tunis*, Mars 2003.
- [4] I A. Basheer and M. Hajmeer, "Artificial neural networks: fundamentals, computing, design, and application" *Journal of Microbiological Methods*, N°43, pp.3–31, 2000.
- [5] M-Y Chow and S O Yee, "Using neural networks to detect incipient faults in Induction motors" *Journal of Neural Network Computing* N°2, pp.26-32, 1991.
- [6] M-Y Chow and S O Yee, "Methodology for on-line incipient fault detection in single-phase squirrel-cage induction motors using artificial neural networks" *IEEE Transactions on Energy Conversion*, Vol.6, pp.536-545, 1991.
- [7] M-Y Chow, R N Sharpe and J C Hung, "On the application and design of artificial neural networks for motor fault detection" *IEEE Transactions on Industrial Electronics*, Vol.40, pp.181-197, April 1993.
- [8] F. Filippetti, G. Franceschini, C. Tassoni, "Neural networks aided on-line diagnostics of induction motor rotor faults" *IEEE Transactions on Industry Applications*, Vol.31, Issue 4, pp.892-899, July/August 1995.
- [9] B. Samanta, and K.R. Al-Balushi, "Artificial neural network based fault diagnosis of rolling element bearing using time-domain features" *Mechanical Systems and Signal Processing*, Vol.17, N°2, pp.317-328, 2003.
- [10] B. Li, M. Y. Chow, Y. Tipsuwan and J.C.Hung, "Neural network-based motor rolling bearing fault diagnosis" *IEEE Transactions on Industrial Electronics*, Vol.47, N°5, pp.1070-1078, 2000.
- [11] S. Kolla and L. Varatharasa, "Identifying three-phase induction motor faults using artificial neural networks" *ISA Transactions*, Vol.39, pp.433-439, 2000.
- [12] S. Hamdani, O. Touhami, R. Ibtouen et M. Fadel, "Neural Network technique for induction motor rotor faults classification –Dynamic eccentricity and broken bar faults" *accepted for publication in IEEE Proceedings of the International Symposium on Diagnostics for Electrical Machines, Power Electronics & Drives*, September 2011.
- [13] J. Penman and C. M. Yin, "Feasibility of using unsupervised learning artificial neural networks for the condition monitoring of electrical machines" *IEEE Proceedings on Electric Power Applications*, Vol.141, Issue 6, pp.317–322, November 1994.

- [14] R.R. Schoen, B.K. Lin, T.G. Habetler, J.H. Schlag and S. Farag, "An unsupervised, on line system for induction motor fault detection using stator current monitoring" in *Conference, Rec, IEEE Transactions on Industry Applications*, Vol.31, issue 6, pp.1280-1286, November/December 1995.
- [15] C.T. Kowalski, T. Orłowska-Kowalska, "Neural networks application for induction motor faults diagnosis" *Mathematics and Computers in Simulation*, Vol.73, pp.435–448, 2003.
- [16] G. Didier, "Modélisation et diagnostic de la machine asynchrone en présence de défaillances" *Thèse de doctorat, Université Henri Poincaré - Nancy I*, Octobre 2004.
- [17] T. Boumeghoura, "Recherche de signature Electromagnétique des défauts dans une machine asynchrone et synthèse d'observateurs en vue du Diagnostic" *Thèse de doctorat en Génie Electrique, Ecole Centrale De Lyon, France*, Mars 2001.
- [18] R. Abdelli, "Perturbations singulières appliquées au modèle de machine asynchrone avec défauts au stator et au rotor" *Mémoire de magister en électrotechnique, Ecole national polytechnique d'Alger*, Juin 2007.
- [19] F. Filipetti, G. Franceschini, C. Tassoni, and P. Vas, "Impact of speed ripple on rotor fault diagnosis of induction machine" in *Proceeding of International Conference on Electrical Machines(ICEM'96)*, Vol.2, pp.452-457, Vigo, Spain, September 1996.
- [20] T. Benslimane, "Caractérisation précise des défauts d'un variateur de vitesse en vue d'élaborer un système automatique de surveillance et de diagnostic" *Thèse de doctorat, Université de Boumerdès*, Juin 2009.
- [21] G. Zwingelstein, "Diagnostic des défaillances: Théorie et pratique pour les Systèmes industriels" *Traité des nouvelles technologies - série Diagnostic et Maintenance*, Editions Hermès, Paris, 1995.
- [22] M. A. Cash, T. G. Habetler, and G. B. Kliman, "Insulation failure prediction in ac machines using line-neutral voltages" *IEEE Transactions on Industry Applications*, Vol. 34(6), pp.1234-1239, November/December 1998.
- [23] J. W. Cooley, P. A. W. Lewis, and P. D. Welch. Application of the fast fourier transform to computation of fourier intergrals, fourier series, and convolution integrals" *IEEE Transactions on Audio and Electroacoustics*, Vol. AU-15(2): pp.79-84, 1967.
- [24] S. M. Kay, "Modern spectral estimation, theory and application. Signal Processing" *Prentice-Hall, Englewood Cliffs - New Jersey*, 1988.
- [25] V. Schoneveld and J. Frijling, "Spectral analysis: On the usefulness of linear tapering for leackage suppression" *IEEE Transactions on Acoustics, Speech and Signal Processing*, Vol. ASSP-29(2), Avril 1981.
- [26] J. L. Alty, L. I. Mikulich, "Industrial applications of artificial intelligence" *2nd edition, Kluwer Academic Publisher, North Holland*, 1991.

- [27] F. Filippetti, G. Franceschini, M. Martelli, C. Tassoni, "An approach to knowledge representation about induction machine diagnostics in expert systems" in *Proceeding of International Conference on Electrical Machines (ICEM88)*, pp.289-296, Pisa, Italy, September 1988.
- [28] R. Casimir, E. Boutleux, G. Clerc, F. Chappuis, "Broken bars detection in an induction motor by pattern recognition" in *Proceeding. IEEE Power Tech'03 International Conference*, Vol.2, pp.282-288, 23-26, Bologna, Italy, June 2003.
- [29] R. Cyril "Prévision de la température par réseaux neurones" *Lycée victor hugo BESANCON, dossier, TIPE* 2003–2004.
- [30] C. Touzet "Les réseaux de neurones artificiels introduction au connexionnisme" Cours, Exercices et Travaux Pratiques, *Université des Sciences et Techniques du Languedoc, Montpellier, France*, Juillet 1992
- [31] E. Gauthier "Utilisation des réseaux de neurones artificiels pour la commande d'un Véhicule Autonome" *Thèse de doctorat en Informatique, Systèmes et Communications, Institut National Polytechnique de Grenoble, France*, 25 Janvier 1999.
- [32] R. Lepage "Reconnaissance d'algues toxiques par vision Artificielle et réseau de neurones" *Mémoire de recherche Université du Québec à Rimouski, Canada*, Septembre 2004.
- [33] G. B. Kliman and J. Stein, "Induction Motor Fault Detection Via Passive Current Monitoring" *Proceedings of International Conference in Electrical Machines (ICEM'90)*, Vol.1, pp.13-17, Massachusetts institute of Technology, Boston, Massachusetts, August 1990.
- [34] W. T. Thomson and R. J. Gilmore, "Motor current signature analysis to detect faults in induction motor drives fundamentals, data interpretation, and industrial case histories" *Proceedings of the thirty-second turbomachinery symposium*, pp.145-156, 2003.
- [35] F. Filippetti, G. Franceschini, C. Tassoni and P. Vas, "AI techniques in induction machines diagnosis including the speed ripple effect" *IEEE Transactions on Industry Applications*, Vol.34, N°1, pp.98-108, 1998.
- [36] S. Nandi and H.A. Toliyat, "Condition monitoring and fault diagnosis of electrical machines" *A review in Conf. Rec. IEEE-IAS Annual, Meeting, vol.1*, pp.197–204, Phoenix, AZ, 1999.
- [37] R. Blasco-Gimenez, G. M. Asher, M. Sumner, and K. J. Bradley, "Performance of FFT-rotor slot harmonic speed detector for sensorless induction motor drives Electric Power Applications" *IEEE Proceedings*, Vol. 143, pp.258-265, 1996.
- [38] A. Ferrah, K. G. Bradley, and G. M. Asher, "Sensorless speed detection of inverter fed induction motors using rotor slot harmonics and fast fourier transform" *Power Electronics Specialists Conference*, Vol. 1, 1992.

- [39] O. Ondel, "Un système adaptatif de diagnostic et suivi d'évolution: application aux machines asynchrones" *Conférence de Jeunes Chercheurs en Génie Electrique (JCGE'05)*, pp.30–35, Montpellier, France, 5 et 6 Juin 2005.
- [40] A. Ukil, "Intelligent Systems and Signal Processing in Power Engineering" *Springer-Verlag Berlin Heidelberg*, 2007.
- [41] A. Zilouchian and M. Jamshidi, "Intelligent control systems using soft computing methodologies" *livre, CRC Press LLC*, 2001.
- [42] T. Nguyen, Nadipuram R. Prasad, Carol L. Walker and Elbert A. Walker, "A First course in fuzzy and neural control" *livre, Chapman & Hall/CRC*, 2003.
- [43] Y. Evrard, "Reconnaissance d'objets par réseaux de neurones" *Travail de Diplôme, En collaboration avec le Laboratoire de Systèmes d'Informations et le groupe Viper du Centre Universitaire Informatique de Genève*, Décembre 2003.
- [44] T. Aroui, Y. Koubaa, A. Toumi, "Clustering of the Self-Organizing Map based Approach in Induction Machine Rotor Faults Diagnostics" *Leonardo Journal of Sciences, Issue 15*, pp.1-14 July-December 2009.
- [45] M. Samuelides, "Réseaux de neurones, une approche connexionniste de l'Intelligence Artificielle" *Edition TEKNEA*, 1991.
- [46] J. Vesanto, E. Alhoniemi, "Clustering of the self-organizing map" *IEEE Transactions on Neural Networks*, 11(3), pp.586-600, 2000.
- [47] J. Vesanto, J. Himberg, E. Alhoniemi, J. Parhankangas "Self-Organizing Map in Matlab : the SOM Toolbox, In Proceedings of the Matlab DSP" *Conference*, pp.35-40, Espoo, Finland, November 1999.
- [48] T. Kohonen, J. Hynninen, J. Kangas, J. Laaksonen, SOM_PAK: The Self-Organizing Map" *Program Package, Technical Report A57, Helsinki University of Technology, Finland*, April 2000.
- [49] S. Hamdani, A. Bouzida, O. Touhami et R. Ibtouen "Diagnosis of Rotor Faults in Induction Machine Using the MUSIC Analysis of the Terminal Voltage after Switch-off," *IEEE Proc. 18th International Conference on Electrical Machines ICEM*, Italy, pp. 1-5, 2008.
- [50] A. Bouzida "Diagnostic de la machine asynchrone à cage d'écureuil par la technique des ondelettes" *Mémoire de magister en électrotechnique, Ecole nationale polytechnique d'Alger*, Juin 2007.

Annexes

ANNEXE A

Caractéristiques techniques des machines Asynchrones utilisées

- La tension nominale entre phases : 220/380 V ;
- La fréquence d'alimentation : 50 Hz ;
- La vitesse nominale : 1435 tr/min ;
- La puissance utile nominale : 4 kW ;
- Le facteur de puissance : 0.83 ;
- Le courant nominal : 15.3/8.83 A ;
- Le nombre de paires de pôles : $p = 2$;
- Le nombre de barres rotoriques : $N_r = 28$;
- Le nombre d'encoches statoriques : $N_s = 36$.

Meilleur résultat pour la classification à quatre classes par l'architecture =[6x13x4]

La sortie calculée				La sortie désirée (codée)				Comparaison de deux sorties				Erreurs de classification
0.0000	0.0000	1.0000	0.0000	0	0	1	0	0.0000	0.0000	0.0000	0.0000	
0.0000	1.0000	0.0000	0.0000	1	0	0	0	1.0000	1.0000	0.0000	0.0000	Erreur de classification
0.0000	1.0000	0.0000	0.0000	1	0	0	0	1.0000	1.0000	0.0000	0.0000	Erreur de classification
0.0000	1.0000	0.0000	0.0000	0	1	0	0	0.0000	0.0000	0.0000	0.0000	
0.0000	0.1619	0.0000	0.6712	0	0	0	1	0.0000	0.1619	0.0000	0.3288	
0.0000	0.0000	1.0000	0.0000	0	0	1	0	0.0000	0.0000	0.0000	0.0000	
0.0000	1.0000	0.0000	0.0000	0	1	0	0	0.0000	0.0000	0.0000	0.0000	
0.0000	0.0000	0.0000	0.9906	0	0	0	1	0.0000	0.0000	0.0000	0.0094	
1.0000	0.0000	0.0000	0.0000	0	1	0	0	1.0000	1.0000	0.0000	0.0000	Erreur de classification
1.0000	0.0000	0.0000	0.0000	1	0	0	0	0.0000	0.0000	0.0000	0.0000	
0.0000	1.0000	0.0000	0.0000	0	0	0	1	0.0000	1.0000	0.0000	1.0000	Erreur de classification
0.0000	0.0000	1.0000	0.0000	0	0	1	0	0.0000	0.0000	0.0000	0.0000	
0.0000	1.0000	0.0000	0.0000	0	1	0	0	0.0000	0.0000	0.0000	0.0000	
0.0000	0.0000	0.0000	1.0000	0	0	0	1	0.0000	0.0000	0.0000	0.0000	
0.0000	0.0000	0.9973	0.0179	0	0	1	0	0.0000	0.0000	0.0027	0.0179	
0.0000	0.0000	0.0000	1.0000	0	1	0	0	0.0000	1.0000	0.0000	1.0000	Erreur de classification
1.0000	0.0000	0.0000	0.0000	1	0	0	0	0.0000	0.0000	0.0000	0.0000	
0.0000	0.0000	1.0000	0.0000	0	0	1	0	0.0000	0.0000	0.0000	0.0000	
0.0000	0.0000	1.0000	0.0000	0	0	1	0	0.0000	0.0000	0.0000	0.0000	
0.0000	0.0000	1.0000	0.0000	0	0	1	0	0.0000	0.0000	0.0000	0.0000	
0.0000	1.0000	0.0000	0.0000	0	1	0	0	0.0000	0.0000	0.0000	0.0000	
0.0006	0.0000	0.0000	0.5137	0	0	0	1	0.0006	0.0000	0.0000	0.4863	
1.0000	0.0000	0.0000	0.0000	1	0	0	0	0.0000	0.0000	0.0000	0.0000	
0.0000	0.0000	1.0000	0.0000	0	0	1	0	0.0000	0.0000	0.0000	0.0000	
0.0000	0.0000	0.0000	1.0000	0	0	0	1	0.0000	0.0000	0.0000	0.0000	
0.0000	0.0000	0.0000	1.0000	0	0	0	1	0.0000	0.0000	0.0000	0.0000	
0.0000	1.0000	0.0000	0.0000	0	1	0	0	0.0000	0.0000	0.0000	0.0000	
0.0000	0.0000	0.0000	1.0000	0	0	0	1	0.0000	0.0000	0.0000	0.0000	

B.1.2 Résultats avec le deuxième groupe de paramètres $k=2$ **Meilleur résultat pour la classification à deux classes par l'architecture =[10x10x2]**


La sortie calculée		La sortie désirée (codée)		Comparaison de deux sorties		Erreurs de classification
0.0000	1.0000	0	1	0.0000	0.0000	
0.0000	1.0000	0	1	0.0000	0.0000	
1.0000	0.0000	1	0	0.0000	0.0000	
0.0000	1.0000	0	1	0.0000	0.0000	
0.0000	1.0000	0	1	0.0000	0.0000	
0.9924	0.0326	1	0	0.0076	0.0326	
0.0000	1.0000	0	1	0.0000	0.0000	
0.0000	1.0000	0	1	0.0000	0.0000	
0.7689	0.0909	1	0	0.2311	0.0909	
0.0000	1.0000	0	1	0.0000	0.0000	
1.0000	0.0000	0	1	1.0000	1.0000	Erreur de classification
0.0000	1.0000	0	1	0.0000	0.0000	
0.0001	0.9999	0	1	0.0001	0.0001	
0.0000	1.0000	0	1	0.0000	0.0000	
0.0000	1.0000	0	1	0.0000	0.0000	
0.0000	1.0000	0	1	0.0000	0.0000	
0.0000	1.0000	0	1	0.0000	0.0000	
0.0000	1.0000	0	1	0.0000	0.0000	
1.0000	0.0000	1	0	0.0000	0.0000	
1.0000	0.0000	1	0	0.0000	0.0000	
0.0000	1.0000	0	1	0.0000	0.0000	
0.0001	0.9999	0	1	0.0001	0.0001	
0.0000	1.0000	0	1	0.0000	0.0000	
1.0000	0.0000	0	1	1.0000	1.0000	Erreur de classification
0.0000	1.0000	0	1	0.0000	0.0000	
0.0000	1.0000	0	1	0.0000	0.0000	
0.0006	0.9995	0	1	0.0006	0.0005	
1.0000	0.0000	1	0	0.0000	0.0000	

Meilleur résultat pour la classification à trois classes par l'architecture =[10x19x3]

La sortie calculée			La sortie désirée (codée)			Comparaison de deux sorties			Erreurs de classification
1.0000	0.0000	0.0000	1	0	0	0.0000	0.0000	0.0000	
1.0000	0.0000	0.0000	1	0	0	0.0000	0.0000	0.0000	
1.0000	0.0000	0.0000	1	0	0	0.0000	0.0000	0.0000	
0.0000	1.0000	0.0000	0	1	0	0.0000	0.0000	0.0000	
1.0000	0.0000	0.0000	1	0	0	0.0000	0.0000	0.0000	
0.0000	0.0000	1.0000	0	0	1	0.0000	0.0000	0.0000	
1.0000	0.0000	0.0000	0	1	0	1.0000	1.0000	0.0000	Erreur de classification
0.0000	0.0000	1.0000	0	0	1	0.0000	0.0000	0.0000	
0.0000	1.0000	0.0000	0	1	0	0.0000	0.0000	0.0000	
0.0000	1.0000	0.0000	0	1	0	0.0000	0.0000	0.0000	
1.0000	0.0000	0.0000	1	0	0	0.0000	0.0000	0.0000	
0.0000	0.0000	1.0000	0	0	1	0.0000	0.0000	0.0000	
0.1903	0.9532	0.0000	0	1	0	0.1903	0.0468	0.0000	
0.0000	0.0000	1.0000	0	0	1	0.0000	0.0000	0.0000	
0.0000	1.0000	0.0000	0	1	0	0.0000	0.0000	0.0000	
0.2574	0.0000	1.0000	0	0	1	0.2574	0.0000	0.0000	
0.0000	0.0000	1.0000	0	0	1	0.0000	0.0000	0.0000	
0.0000	0.0000	1.0000	0	0	1	0.0000	0.0000	0.0000	
0.0000	1.0000	0.0000	0	1	0	0.0000	0.0000	0.0000	
0.9405	0.0000	0.4029	0	1	0	0.9405	1.0000	0.4029	Erreur de classification
1.0000	0.0000	0.0000	0	1	0	1.0000	1.0000	0.0000	Erreur de classification


Meilleur résultat pour la classification à quatre classes par l'architecture =[10x16x4]

La sortie calculée				La sortie désirée (codée)				Comparaison de deux sorties				Erreurs de classification
0.0000	0.0355	0.9659	0.0000	0	0	1	0	0.0000	0.0355	0.0341	0.0000	
0.0079	0.0000	0.0000	0.9999	0	1	0	0	0.0079	1.0000	0.0000	0.9999	Erreur de classification
0.0239	0.0000	0.0000	0.9996	1	0	0	0	0.9761	0.0000	0.0000	0.9996	Erreur de classification
0.0000	1.0000	0.0000	0.0000	0	1	0	0	0.0000	0.0000	0.0000	0.0000	
0.0000	0.0000	0.0006	0.9962	0	1	0	0	0.0000	1.0000	0.0006	0.9962	Erreur de classification
0.0000	0.0105	0.0000	0.9918	0	0	0	1	0.0000	0.0105	0.0000	0.0082	
0.0000	0.0000	1.0000	0.0000	0	0	1	0	0.0000	0.0000	0.0000	0.0000	
0.0009	1.0000	0.0000	0.0000	0	1	0	0	0.0009	0.0000	0.0000	0.0000	
1.0000	0.0000	0.0000	0.0000	0	1	0	0	1.0000	1.0000	0.0000	0.0000	Erreur de classification
1.0000	0.0000	0.0000	0.0000	1	0	0	0	0.0000	0.0000	0.0000	0.0000	
1.0000	0.0000	0.0000	0.0001	1	0	0	0	0.0000	0.0000	0.0000	0.0001	
0.0000	0.0680	0.9918	0.0000	0	0	1	0	0.0000	0.0680	0.0082	0.0000	
0.0000	0.0000	1.0000	0.0000	0	0	1	0	0.0000	0.0000	0.0000	0.0000	
0.0000	0.0000	0.0000	1.0000	0	0	0	1	0.0000	0.0000	0.0000	0.0000	
0.0000	0.0000	1.0000	0.0000	0	0	1	0	0.0000	0.0000	0.0000	0.0000	
0.0000	0.0000	1.0000	0.0000	0	0	1	0	0.0000	0.0000	0.0000	0.0000	
0.0000	1.0000	0.0000	0.0000	0	1	0	0	0.0000	0.0000	0.0000	0.0000	
0.0000	0.0000	0.0000	1.0000	0	0	0	1	0.0000	0.0000	0.0000	0.0000	
0.0000	1.0000	0.0000	0.0000	1	0	0	0	1.0000	1.0000	0.0000	0.0000	Erreur de classification
1.0000	0.0000	0.0000	0.0000	1	0	0	0	0.0000	0.0000	0.0000	0.0000	
0.0000	0.0000	0.0000	1.0000	0	0	0	1	0.0000	0.0000	0.0000	0.0000	
1.0000	0.0000	0.0000	0.0000	1	0	0	0	0.0000	0.0000	0.0000	0.0000	
0.0000	0.0000	0.0000	1.0000	0	0	0	1	0.0000	0.0000	0.0000	0.0000	
0.0000	0.0000	0.0000	1.0000	0	0	0	1	0.0000	0.0000	0.0000	0.0000	
0.0000	0.0000	0.0000	1.0000	0	0	0	1	0.0000	0.0000	0.0000	0.0000	
1.0000	0.0000	0.0000	0.0000	1	0	0	0	0.0000	0.0000	0.0000	0.0000	
0.0000	1.0000	0.0000	0.0000	0	1	0	0	0.0000	0.0000	0.0000	0.0000	
0.0000	1.0000	0.0000	0.0696	0	1	0	0	0.0000	0.0000	0.0000	0.0696	




Classification de quatre états avec la carte du réseau [8x8]


B.2.2 Résultats avec le deuxième groupe de paramètres $k=2$



Classification de deux états de la carte du réseau [10x5]



Classification de trois états avec la carte du réseau [11x5]



Classification de quatre états avec la carte du réseau [10x5]