

Université Mohamed Khider – Biskra
Faculté des Sciences et de la Technologie
Département : Génie Electrique
Ref :.....



جامعة محمد خيضر بسكرة
كلية العلوم و التكنولوجيا
قسم: الهندسة الكهربائية
المرجع:.....

Thèse présentée en vue de l'obtention
Du diplôme de
Doctorat en sciences
Spécialité (Option) : **Electrotechnique**

Détection des défauts dans la machine à induction par des techniques avancées

Présentée par :

Hakima CHERIF

Soutenu publiquement le : 01 Juillet 2021

Devant le Jury composé de :

Dr. ZOUZOU Salah Eddine	Professeur	Président	Université de Biskra
Dr. BENAÏCHA Abdelhamid	Professeur	Rapporteur	Université de Biskra
Dr. NACERI Farid	Professeur	Examineur	Université de Batna 2
Dr. NAIT SAID Mohammed Said	Professeur	Examineur	Université de Batna 2
Dr. BETKA Achour	Professeur	Examineur	Université de Biskra
Dr. BENDIB Samir	MCA	Examineur	Université de Batna 2

Remerciements

*Je remercie tout d'abord **ALLAH** Tout Puissant de m'avoir donné le courage, la force et la persévérance d'achever ce travail.*

*Les travaux de recherche présentés dans cette thèse ont été réalisés au sein du Laboratoire de Génie Electrique de Biskra (LGEB) dirigé par professeur **ZOUZOU Salaheddine**.*

*J'aimerais remercier également mes Directeurs de thèse, **BENAKCHA Abdelhamid** et **MENACER Arezki** (Que Dieu bénisse son âme), professeurs à l'Université de Biskra, pour avoir dirigé ce travail, pour la confiance, l'intérêt et la motivation qu'ils ont témoignés tout au long de la réalisation de ce travail.*

J'adresse également mes meilleurs sentiments de gratitude aux honorables membres du Jury qui ont accepté de participer et juger ce travail.

*Je remercie professeur **ZOUZOU Salaheddine** de l'Université de Biskra, qui m'a fait l'honneur de présider le Jury de cette thèse.*

*J'adresse mes respectueux remerciements à Monsieur **BETKA Achour**, professeur à l'Université de Biskra, pour avoir accepté d'examiner ce travail.*

*Je tiens également à remercier vivement les membres du Jury : Monsieur **NACERI Farid** et Monsieur **NAIT SAID Mohammed Said** Professeurs à l'Université de Batna, Monsieur **BENDIB Samir**, Maître de Conférences (A) à l'Université de Batna, d'avoir bien voulu participer au Jury et d'évaluer ce travail.*

*Je remercie tous les membres du personnel enseignants et administratifs du laboratoire de génie électrique de Biskra (LGEB) et je remercie aussi tous mes collègues et amies en particulier **Madiha MAAMIR**, **Marwa MEISSA**, **Hania ABOUB**, **Sassia BOUALAM**, **Ismail LAIB**, **Seif Eddine CHEHAIDIA**, **Noussieba ALLG**, **Djamila BERRA**, **Aïcha GHERBI**, **Nassima ABOUZID**, **Khaled Bilila**, et **Abedrahmen KHACHKHOUCHE**.*

Du fond du cœur, je remercie toutes les personnes m'ayant aidé de près ou de loin à mener ce travail.

Dédicaces

Je dédie ce modeste travail

A ma mère avec toute mon affection.

A mon père avec toute ma reconnaissance.

A mes frères et mes sœurs.

A ma famille.

A tous mes amis.

Hakima CHERIF



Résumé

L'objectif de cette thèse est d'apporter une contribution dans le domaine de la surveillance et du diagnostic des défauts des moteurs à induction. Les défauts pris en compte sont du type: court-circuits entre spires et rupture de barres rotoriques. Deux techniques sont utilisées pour détecter les défauts: l'une se base sur l'analyse spectrale de l'enveloppe du courant statorique (HFFT) pour diagnostiquer un défaut de rupture de barres rotoriques et l'autre se base sur les trois rapports d'énergie d'ondelette discrète (REOD) des courants statoriques pour diagnostiquer un défaut de court-circuits entre spires.

Un système de surveillance automatique et intelligente pour détecter et localiser des défauts sous différentes conditions de fonctionnement du moteur est conçu par l'utilisation des techniques avancées intelligentes à base des réseaux de neurones (RN) et des réseaux neuro-flous de type ANFIS (système d'inférence flou à base de réseaux de neurones adaptatifs) dont la base de connaissance est déduite de l'utilisation des indicateurs issus les deux techniques (HFFT et REOD) du courant statorique du moteur. Ceci permet, en plus de la détection, la détermination du nombre de barres en défaut au rotor et la localisation de la phase de défaut de court-circuit entre spires.

Mots clés : moteur à induction, défaut rotorique, cassure de barres, court-circuit entre-spires, diagnostic, FFT, Ondelette, Réseaux de Neurones (RN), Réseau Neuro-Flou.

Abstract

The objective of this thesis is to make a contribution in the field of monitoring and diagnosis of induction motor faults. The faults considered are of the type : inter turns short circuit and broken rotor bars. Two techniques are used to detect faults: one is based on the spectral analysis of the stator current envelope (HFFT) to diagnose a broken rotor bar fault and the other is based on the three discrete wavelet energy ratios (DWER) of the stator currents to diagnose an inter-turn short circuit fault.

An automatic and intelligent monitoring system to detect and locate faults at different motor operating conditions is designed by using advanced intelligent techniques based on neural networks (NN) and ANFIS (adaptive neural network based fuzzy inference system) whose knowledge base is deduced from the use of indicators derived from the two techniques (HFFT and DWER) of the motor stator current. This allows, in addition to the detection, the determination of the number of bars in fault at the rotor and the localization of the inter turn short-circuit fault phase.

Keywords: Induction Motor (IM), broken rotor bars, inter-turn short-circuit, diagnosis, FFT, Wavelet, Neural Networks (RN), Adaptive Neuro-Fuzzy Inference System (ANFIS).

ملخص

الهدف من هذه الأطروحة هو المساهمة في مجال مراقبة و تشخيص أعطال المحركات الحثية . الاعطاب التي تم دراستها هي : كسر قضبان الدوار و الدارة القصيرة في الجزء الثابت. يتم استخدام طريقتين للكشف عن الأعطاب: الأولى تعتمد على التحليل الطيفي لمغلف تيار الجزء الثابت (HFFT) لتشخيص عطب كسر قضبان الدوار و الآخر يعتمد على النسب الثلاثة للطاقة الموجية المنفصلة (REOD) للتيارات الجزء الثابت لتشخيص عطب قصر الدارة بين حلقات الجزء الثابت. تم تصميم نظام المراقبة الأوتوماتيكي و الذكي لاكتشاف الأخطاء وتحديد موقعها في ظروف تشغيل مختلفة للمحرك من خلال استخدام تقنيات ذكية متقدمة تعتمد على الشبكات العصبية (RN) والشبكات العصبية الضبابية من النوع ANFIS (نظام الاستدلال الغامض على أساس الشبكات العصبية التكيفية) التي تعتمد قواعد بياناتها على استخدام مؤشرات الاعطاب من تقنيتين (HFFT و REOD) لتيار الجزء الثابت للمحرك. هذا يسمح، بالإضافة إلى الكشف، بتحديد عدد قضبان المعطوبة في الدوار و تحديد الطور الذي يحتوي على عطب الدارة القصيرة بين حلقات الجزء الثابت.

الكلمات المفتاحية :

المحرك الحثي ، كسر قضيب الدوار، الدارة القصيرة بين حلقات الجزء الثابت، تشخيص ، تحويل فوري، تحويل الموجات ، الشبكات العصبية الصناعية ، الشبكات العصبية الضبابية.

Sommaire

Remerciements	
Dédicaces	
Résumé	
Sommaire	
Liste des figures	I
Liste des Tableaux	IV
Liste notations et symboles	V
Introduction générale.....	1

Chapitre 1

Etat de l'art sur le diagnostic de défauts du moteur à induction

1.1 Introduction.....	8
1.2. Constitution du moteur à induction.....	8
1.2.1 Stator.....	9
1.2.2 Rotor	10
1.2.3 Organes mécaniques	11
1.3 Défaillances dans le moteur à induction	11
1.3.1 Défauts rotoriques.....	12
1.3.1.1 Défauts des barres cassées	12
1.3.1.2 Défauts des roulements	13
1.3.1.3 Défauts d'excentricité	14
1.3.2 Défauts statoriques.....	15
1.3.3 Etude statistique des défaillances.....	16
1.4 Méthodes de diagnostic des défauts dans le moteur à induction	16
1.4.1 Méthodes basées sur le modèle.....	17
1.4.2 Méthodes sans model.....	18
1.4.2.1 Méthodes basées sur le traitement de signaux	18
1.4.2.2 Méthodes basées sur l'intelligence artificielle.....	21
1.5 Conclusion	22
1.6 Bibliographie.....	23

Chapitre 2

Analyse et diagnostic des défauts rotoriques et statoriques de la machine à induction: Etude expérimentale

2.1 Introduction.....	28
2.2 Diagnostic du défaut rotorique du MI par la méthode Hilbert-FFT	28
2.2.1 Méthode Hilbert-FFT (HFFT)	28
2.2.2 Méthodologie générale proposée pour diagnostiquer le défaut cassure de barre rotorique.....	30
2.3 Diagnostic du défaut de court-circuit entre spires statoriques par la méthode du rapport d'énergie d'ondelette discrète (REOD) au MI	31
2.3.1 Méthode de Rapport d'Energie d'Ondelette Discrète (REOD).....	31
2.3.2 Méthodologie générale proposée pour diagnostiquer le défaut CCES	32
2.4 Description des bancs d'essais utilisés pour diagnostiquer les défauts rotoriques et statoriques	33
2.4.1 Premier banc d'essai	33
2.4.2 Deuxième banc d'essais	35
2.5 Résultats expérimentaux	37
2.5.1 Analyse du courant statorique par la méthode HFFT pour détecter le défaut BC	37
2.5.1.1 Enveloppe du courant statorique.....	37
2.5.1.2 Traitement de l'enveloppe par la FFT	37
2.5.2 Analyse des courants statoriques par la méthode REOD pour détecter le défaut CCES.....	38
2.5.2.1 Courants statoriques avec défaut CCES	38
2.5.2.2 Analyse des courants statoriques par l'ondelette discrète et leur énergie	39
2.5.2.3 Extraction de REOD	42
2.5.2.4 Caractéristiques des REOD au niveau 7	43
2.6 Conclusion	44
2.7 Bibliographie.....	45

Chapitre 3

Diagnostic des défauts rotoriques et statoriques du moteur à induction par les réseaux de neurones

3.1 Introduction.....	49
3.2 Réseaux de Neurones utilisés dans le diagnostic des défauts du moteur à induction.....	49
3.2.1 Réseau multicouche (MLP)	50
3.2.2 Basis Function Neural Network (RBF).....	51
3.2.3 Elman Neural Network (ENN)	51
3.2.4 Méthode d'apprentissage régularisé bayésien (BR)	52
3.3 Mise en œuvre du RN dans le diagnostic de défauts statoriques et rotoriques du MI en utilisant les méthodes HFFT et REOD.....	53
3.4 Diagnostic de défaut rotorique par hybridation de la méthode HFFT avec RNs (HFFT-RN _{bc}).....	56
3.4.1 Séquence d'apprentissage des RN _{bc}	56
3.4.2 Structure des réseaux RN _{bc}	58
3.4.3 Résultats d'apprentissage du RN _{bc}	59
3.4.4 Test de RN _{bc}	60
3.5 Diagnostic de défaut statorique par hybridation de la méthode REOD avec RN (REOD-RN _{cc}).....	62
3.5.1 Séquence d'apprentissage de RN _{cc}	63
3.5.2 Structure des réseaux RN _{cc}	65
3.5.3 Résultats d'apprentissage de RN _{cc}	66
3.5.4 Test de RN _{cc}	68
3.6 Système de surveillance par l'hybridation des méthodes "REOD et HFFT" avec RN.....	70
3.7 Conclusion	73
3.8 Bibliographie.....	74

Chapitre 4

Diagnostic des défauts rotoriques et statoriques par la technique Neuro-Flou (ANFIS) dans le moteur à induction

4.1 Introduction.....	76
4.2 Système d'inférence flou basé sur un réseau adaptatif.....	76
4.2 Types de l'ANFIS	78
4.2.1.1 Grid Partition (GP).....	78
4.2.1.2 Subtractive Clustering (SC)	79
4.3. Critères de performance	80
4.4 Méthodologie général de la détection des défauts statorique et rotorique en utilisant l'ANFIS	81
4.5 Diagnostic de défaut rotorique par la méthode hybride HFFT-ANFIS _{bc}	82
4.5.1 Structure d'ANFIS _{bc} utilisée dans le diagnostic de défaut rotorique.....	83
4.5.2 Génération de la base d'apprentissage d'ANFIS _{bc}	85
4.5.3 Résultats de test d'ANFIS _{bc}	88
4.5.4 Comparaison entre les deux modèles d'ANFIS _{bc}	89
4.6 Diagnostic de défaut statorique par la méthode hybride REOD-ANFIS _{cc}	90
4.6.1 Structure d'ANFIS _{cc} utilisée dans le diagnostic de défauts statoriques.....	90
4.6.2 Génération de la base d'apprentissage d'ANFIS _{cc}	92
4.6.3 Résultats de test d'ANFIS _{cc}	94
4.6.4 Comparaison entre les deux modèles d'ANFIS _{cc}	95
4.7 Système de surveillance par l'hybridation des méthodes "REOD et HFFT" avec l'ANFIS.....	96
4.8 Conclusion	99
4.9 Bibliographie.....	100
Conclusion générale.....	103
ANNEXE	106

Liste des figures

Fig. 1.1 Moteur à induction à cage d'écureuil	9
Fig. 1.2. Eléments de constitution d'un moteur à induction à cage d'écureuil.....	9
Fig. 1.3. Stator d'un machine à induction	10
Fig.1.4 Rotor à cage d'écureuil d'un moteur à induction	11
Fig.1.5. Exemple d'un rotor d'un MI pour :(a) rotor à l'état sain et (b) rotor avec une barre cassée.....	12
Fig.1.6. Exemple de dégâts au stator et rotor dus au défaut de roulement d'un MI.....	14
Fig. 1.7. Représentation des excentricités statique et dynamique dans le MI.....	15
Fig.1.8 Représentation des différents défauts statoriques possibles	15
Fig.1.9 Exemples de dégâts dus au défauts de court-circuits statoriques d'un MI	16
Fig.1.10 Méthodes de diagnostic du moteur à induction	17
Fig.1.11 Décomposition multi résolutions à n niveaux.....	19
Fig. 2.1 Cadre général de la méthode de détection de défaut de cassure de barre rotorique	30
Fig. 2.2 Organigramme d'extraction des indicateurs de défaut CCES	31
Fig. 2.3 Schéma général de la méthode de diagnostic du défaut de court-circuit entre spires.....	32
Fig. 2.4 Schéma descriptif du montage expérimental utilisé en diagnostic de défaut de cassure de barre rotorique	34
Fig. 2.5 Banc d'essai dédié au diagnostic de défaut cassure de barre rotorique.....	34
Fig. 2.6 Rotors utilisés dans les tests expérimentaux: (a) sain, (b) une barre cassée (1BC) et (c) deux barres cassées adjacentes (2BC).....	35
Fig. 2.7 Banc d'essai dédié au diagnostic de défaut court-circuit entre spires	36
Fig. 2.8 Schéma descriptif du montage expérimental utilisé en diagnostic de défaut CCES	36
Fig. 2.9 MI spécialement rembobiné pour faire les essais de court-circuit entre spires en trois phases	37
Fig. 2.10 Courant statorique et son enveloppe pour défaut deux barres cassées.	37
Fig. 2.11 Analyse spectrale de l'enveloppe du courant statorique sous différentes charges (faible charge, demi-charge et pleine charge) pour les états: (a) sain, (b) défaut 1BC et (c) défaut 2BC.....	39
Fig. 2.12 Courants statoriques pour: les états sain et avec défaut CCES dans les 3 phases: a_s , b_s et c_s	40
Fig. 2.13 TOD du courant statorique pour l'état sain, et défauts CCES dans les 3 phases : a_s , b_s et c_s	41

Fig. 2.14 Variation de l'énergie du courant statorique dans les bandes de fréquence pour les états sain et avec défauts CCES dans les phases : a_s , b_s et c_s	42
Fig. 2.15 Valeur de REOD calculée dans le niveau 7 pour l'état sain et avec défauts CCES dans les phases : a_s , b_s et c_s	43
Fig. 2.16 Evolution des valeurs de REOD dans le niveau 7 en fonction des spires en court-circuit sur les phases: (a) a_s , (b) b_s et (c) c_s	44
Fig. 3.1 Réseau MLP à trois couches avec 3 entrées, 3 sorties et une couche cachée	50
Fig. 3.2 Structure typique d'ENN	51
Fig. 3.3 Méthodologie générale de diagnostic de défauts rotoriques et statoriques par 3 types de RN (RBF, MLP et ENN)	55
Fig. 3.4 Entrées et sorties de la séquence d'apprentissage du RN_{bc}	57
Fig. 3.5 Organigramme de la classification du défaut BC à l'aide des RN_{bc}	58
Fig. 3.6 Sorties de la séquence d'apprentissage du RN_{bc}	59
Fig. 3.7 Erreurs d'apprentissage du réseau RN_{bc}	59
Fig. 3.8 Entrées de la séquence de test du RN_{bc}	60
Fig. 3.9 Sorties de la séquence de test du RN_{bc}	61
Fig. 3.10 Erreurs de test du réseau RN_{bc}	61
Fig. 3.11 Entrées et sorties d'apprentissage du RN_{cc}	64
Fig. 3.12 Organigramme de la classification du défaut CCES à l'aide des RN_{cc}	65
Fig. 3.13 Sorties désirées de la séquence d'apprentissage du RN_{cc}	66
Fig. 3.14 Erreurs de sortie d'apprentissage de trois RN_{cc} (RBF, MLP et ENN).....	67
Fig. 3.15. Sorties et leur erreurs de test pour les défauts CCES en: phase a_s , phase b_s et phase c_s	68
Fig. 3.16 Schéma synoptique du système de surveillance du MI par RN	70
Fig. 3.17 Sorties et leurs erreurs du système de surveillance du MI par RN	72
Fig. 4.1 Architecture de l'ANFIS	77
Fig.2.4 Organigramme pour la détection de défauts par l'ANFIS basée sur le GP et SC	81
Fig. 4.3 Fonction d'appartenance de deux entrées (f_{bc} et A_{bc}) obtenue par le modèle ANFIS _{bc} -GP	84
Fig. 4.4 Structure d'ANFIS _{bc} -GP pour la détection des défauts BC.	84
Fig. 4.5 Fonction d'appartenance de deux entrées (f_{bc} et A_{bc}) obtenue par le modèle ANFIS _{bc} -SC	85
Fig. 4.6 Structure d'ANFIS _{bc} -SC pour la détection des défauts BC.	85
Fig. 4.7 Séquence d'apprentissage de l'ANFIS _{bc}	87
Fig. 4.8 Sortie des données d'apprentissage des modèles ANFIS _{bc} (GP & SC).....	87

Fig. 4.9 Erreurs pour les données d'apprentissage des modèles ANFIS _{bc} (GP &SC).....	87
Fig. 4.10 Entrées pour tester les données des modèles ANFIS _{bc} (GP &SC).....	88
Fig. 4.11 Sortie pour tester les données des modèles ANFIS _{bc} (GP &SC).....	89
Fig. 4.12 Erreur de test d'ANFIS _{bc} (GP &SC)	89
Fig. 4.13 Fonctions d'appartenance des entrées (R_1 , R_2 et R_3) obtenues par le modèle ANFIS _{cc} -GP.....	91
Fig.4.14 Fonctions d'appartenance des entrées (R_1 , R_2 et R_3) obtenues par le modèle ANFIS _{cc} -SC.....	91
Fig. 4.15 Structure d'ANFIS _{cc} -GP pour la détection et la localisation des défauts CCES.	91
Fig. 4.16 Structure d'ANFIS _{cc} -SC pour la détection et la localisation des défauts CCES.	92
Fig. 4.17 Séquences d'apprentissage de l'ANFIS _{cc}	93
Fig.4.18 Sorties et erreurs d'apprentissage d'ANFIS _{cc} pour les modèles GP et SC.....	94
Fig. 4.19 Séquences de test de l'ANFIS _{cc}	95
Fig. 4.20 Sorties et erreurs de test d'ANFIS _{cc} pour les modèles GP et SC.....	95
Fig. 4.21 Schéma synoptique du système de surveillance du MI par ANFIS.....	97
Fig. 4.22 Sorties et erreurs du système de surveillance du MI.....	99

Liste des tableaux

Tableau 1.1 : Possibilité de défaillance dans les moteurs à induction	16
Tableau 2.1: Différentes bandes de fréquences obtenues par la décomposition en ondelettes pour 9 niveaux.	41
Tableau 3.1: Paramètres des réseaux MLP et ENN	58
Tableau 3.2 : Paramètres du réseau RBF	58
Tableau 3.3 : Comparaison entre les valeurs de MSE de trois structures de réseaux de neurones: MLP, RBF et ENN pour les phases d'apprentissage et de test pour diagnostic de défaut BC.	61
Tableau 3.4: Paramètres du réseau MLP et ENN.....	64
Tableau 3.5 : Paramètres du réseau RBF	64
Tableau 3.6 : Comparaison entre les valeurs de MSE de trois structures de réseaux de neurones MLP, RBF et ENN pour les phases d'apprentissage et de test en diagnostic de défaut CCES.	68
Tableau 3.7: Conditions de fonctionnement des séquences de test et les sorties correspondantes du système de surveillance par RN	70
Table 4.1: Paramètres de deux modèles d'ANFIS _{bc}	85
Tableau 4.2: Comparaison entre les résultats d'erreurs de deux modèles ANFIS _{bc} pour les phases d'apprentissage et de test.....	89
Table 4.3. Paramètres de deux modèles d'ANFIS _{cc}	91
Tableau 4.4: Comparaison des résultats d'erreurs des deux modèles ANFIS _{cc} pour les phases d'apprentissage et de test.....	95
Table 4.5: Paramètres de deux réseaux ANFIS-SC	97
Tableau 4.6 : Conditions de fonctionnement des séquences de test et sorties correspondantes du système de surveillance	98
Tableau 4.7 : MSE et RMSE de l'erreur de sortie du système de surveillance	98

Symboles et notations

U_s	Tensions statoriques suivant les axes a_s, b_s, c_s .
I_s	Courants statoriques suivant les axes a_s, b_s, c_s .
P	Nombre de paires de pôles
S	Glissement
f_s	Fréquence fondamentale
CCES	Défaut de Court-Circuit Entre Spires statorique
BC	Défaut de cassure de barres rotoriques
FFT	Transformée de Fourier rapide
TO	Transformée d'ondelette
TOD	Transformation d'ondelette discrète
TOC	Transformation d'ondelette continue
MI	Moteur à induction
HT	Transformée de Hilbert
HFFT	Transformée de Hilbert avec transformée de Fourier rapide
REOD	Rapport d'énergie d'ondelette discrète
RN	Réseau de neurones
MLP	Multi-Layer perceptron (Réseau de neurones multicouche)
RBF	Radial Basis Function
ENN	Elman Neural Network
ANFIS	Adaptive Neuro-Fuzzy Inference System
GP	Grid Partitioning
SC	Subtractive Clustering
MSE	Erreur quadratique moyenne
RMSE	Racine de l'erreur quadratique moyenne

Introduction générale

Introduction générale

Les machines électriques sont l'un des dispositifs les plus fabriqués et largement utilisés non seulement dans l'industrie mais aussi dans les applications domestiques. En raison de leur efficacité, elles sont des sources courantes de conversion d'énergie électromécanique. Diverses applications, notamment dans les domaines de la commande, de l'automobile et de la production d'énergie, sont servies par ces dispositifs et personne ne peut nier leur capacité à être contrôlées avec précision en termes de position, de vitesse et de couple, qui sont quelques-unes des grandeurs essentielles des dispositifs électromécaniques.

Parmi tous les types de machines électriques, le moteur à induction a été plus largement utilisé depuis le début du développement industriel. Cependant, les moteurs à aimants permanents vont probablement être de bons substituts aux moteurs à induction en raison de leurs densité de puissance et de leur rendement plus élevés. Néanmoins, les moteurs à induction restent l'une des machines les plus fiables utilisées dans les applications de démarrage en ligne et d'alimentation par onduleur [1]. Bien qu'ils soient très fiables, ils sont soumis à différents risques de défaillance / défauts. Ces défaillances peuvent être inhérentes à la machine elle-même ou aux conditions de fonctionnement. Ces défauts peuvent être dûs aux forces mécaniques ou électriques agissant sur le culasse de la machine. Si un défaut n'est pas détecté ou si on le laisse se développer, il peut conduire à une défaillance. Une variété de défauts de machine a été étudiée dans la littérature [2, 3], comme les défauts des enroulements statoriques [4, 5], les cassures de barres rotoriques [6, 7], l'excentricité [8, 9] et les défauts de roulements [10, 11].

Des stratégies de diagnostic et des schémas de contrôle ont été conçus pour assurer une commande de entraînement tolérant les pannes. Il existe de nombreuses techniques publiées et de nombreux outils disponibles pour surveiller les moteurs à induction afin d'assurer un haut degré de fiabilité et de disponibilité. Des techniques de conception ont été développées pour améliorer la fiabilité des systèmes d'entraînement à moteur à induction contre une variété de défauts qui peuvent se produire. Mais ces techniques sont parfois coûteuses à réaliser.

Au cours des dernières années, la surveillance de l'état des moteurs à induction a attiré de nombreux chercheurs en raison de son influence sur le fonctionnement sécuritaire de nombreux procédés industriels. Il est important de pouvoir détecter les défauts des moteurs alors qu'ils sont encore en cours de fonctionnement. La détection précoce et le diagnostic correct des défauts naissants pourraient permettre d'effectuer une maintenance préventive et de disposer d'un délai suffisant pour l'arrêt contrôlé du processus concerné. Ils peuvent réduire les pertes financières et éviter des conséquences catastrophiques [12]. Parmi les techniques de détection de défauts largement citées et récemment publiées, l'analyse de signature du courant statorique du moteur

(MCSA) est une méthode complètement non-invasive et peu coûteuse pour le diagnostic de défaut. Elle s'est avérée être une technique efficace pour la détection de défaut du moteur à induction. Dans la MCSA, le courant du moteur est recueilli et enregistré. À partir de ce signal, des caractéristiques sont extraites dans les domaines temporel ou fréquentiel à l'aide de différents outils de traitement de signal pour établir un diagnostic des défauts du moteur [13]. De nos jours, de nombreuses méthodes de traitement des signaux ont été utilisées pour détecter les défauts de la machine, comme la transformée de *Fourier* rapide (FFT), la transformée de *Hilbert* (TH) et la transformée d'ondelette (TD). Elles sont utilisées pour extraire des courants statoriques des informations de défaut.

Un système idéal de surveillance de l'état et de diagnostic des défauts devrait prendre les mesures minimales d'un moteur et, par l'analyse, en extraire la caractéristique. Une constatation peut être déduite pour donner éventuellement une indication claire du défaut naissant en un minimum de temps [14]. La surveillance de l'état doit établir une carte entre les signaux d'entrée et les indications de sortie de l'état du moteur. Il n'est pas facile de classer le type de défaut du moteur et d'en déterminer la gravité, car il peut être influencé par de nombreux facteurs. La surveillance de l'état et le diagnostic des défauts des moteurs à induction sont passés des techniques traditionnelles aux techniques d'intelligence artificielle (IA). Les techniques d'IA sont de bons candidats pour l'automatisation des procédures de diagnostic des défauts [15, 16]. Les techniques d'IA, telles que les systèmes experts (ES), le système logique flou (LF), le réseau neuronal artificiel (RN) et le système neuro-flou (NF) ont été appliquées dans le diagnostic de défaut de systèmes très complexes, où des modèles mathématiques précis sont difficiles à construire. Ces techniques utilisent des processus d'association, de raisonnement et de prise de décision comme le ferait le cerveau humain pour résoudre les problèmes de diagnostic [17].

Objectifs de la thèse

L'objectif principal de cette thèse est de développer un système de surveillance automatique du moteur à induction, basé sur l'hybridation entre les méthodes MCSA-HT-FFT (HFFT), MCSA-TOD et de système d'intelligence artificielle (RN et NF) pour détecter le défaut statorique du type court-circuit entre spires d'une même phase et le défaut rotorique du type cassure de barres.

Organisation de la thèse

La présente thèse est organisée en quatre chapitres résumés comme ci-dessous.

Le premier chapitre fournit un bref aperçu théorique du moteur à induction, des types de défauts et de leurs effets sur les performances, des différentes techniques de détection des défauts.

L'importance de ce chapitre est qu'il présente aux lecteurs une connaissance du domaine, permettant ainsi de comprendre où en est la recherche actuellement.

Le second chapitre sera consacré à une étude expérimentale pour analyser les défauts de cassure de barres rotoriques et court-circuits entre spires des enroulements statoriques :

- ✓ Cassure de barres au rotor par la technique de Hilbert-FFT (HFFT) qui est basé sur l'analyse spectrale de l'enveloppe du courant statorique,
- ✓ Court-circuit entre spires dans une même phase des enroulements statoriques du MI en utilisant d'une nouvelle technique basée sur le Rapport de l'Energie d'Ondelettes Discrètes (REOD) de trois courants statoriques.

Le troisième chapitre commence par une présentation des réseaux de neurones (RN) et leurs différentes architectures, ainsi que la procédure de détection et classification des deux défauts court-circuit entre spires statoriques et cassures de barres rotoriques par RN. À la fin du chapitre, Un système complet de surveillance avec des tests de performances sera présenté. L'objectif de ce chapitre est la mise en œuvre d'un RN pour effectuer la tâche de détection de défaut, la localisation de défaut de court-circuit entre spires d'une même phase au stator et la détermination du nombre de barres cassées au rotor par trois modèles de réseaux de neurones : Multi-Layer perceptron (MLP), Radial Basis Function (RBF) et Elman Neural Network (ENN), basés sur les méthodes HFFT et REOD.

Le quatrième chapitre présente un système de surveillance automatique du moteur à induction basé sur les réseaux neuro- flous (ANFIS). Il permet de détecter et classer le défaut de court-circuit entre spires statoriques d'une même phase et le défaut de cassure de barres rotoriques. Ce système effectue la tâche de la détection et la localisation de défaut de court-circuit entre spires basées sur l'hybridation des méthodes de REOD et ANFIS (REOD-ANFIScc). Il permet également la détermination du nombre de barres cassées au rotor en utilisant l'hybridation des méthodes HFFT et ANFIS (HFFT-ANFISbc). Deux modèles d'ANFIS sont utilisés: le Grid Partitioning (GP) et le Subtractive Clustering (SC), afin d'obtenir de bonnes performances et une efficacité dans la réalisation du processus de diagnostic.

Enfin une conclusion générale où l'on présente une synthèse des résultats obtenus ainsi que les perspectives futures pour l'amélioration de ce travail.

Bibliographie

1. Faiz, J., G. Joksimović, and V. Ghorbanian, *Fault diagnosis of induction motors*. 2017: Institution of Engineering & Technology.
2. Albrecht, P., et al., *Assessment of the reliability of motors in utility applications-Updated*. IEEE Transactions on Energy conversion, 1986(1): p. 39-46.
3. Bonnett, A.H. and G.C. Soukup, *Cause and analysis of stator and rotor failures in three-phase squirrel-cage induction motors*. IEEE Transactions on Industry applications, 1992. **28**(4): p. 921-937.
4. Bessam, B., et al., *Wavelet transform and neural network techniques for inter-turn short circuit diagnosis and location in induction motor*. International Journal of System Assurance Engineering and Management, 2017. **8**(1): p. 478-488.
5. Cherif, H., et al., *Early detection and localization of stator inter-turn faults based on discrete wavelet energy ratio and neural networks in induction motor*. Energy, 2020. **212**: p. 118684.
6. Talhaoui, H., et al., *Experimental diagnosis of broken rotor bars fault in induction machine based on Hilbert and discrete wavelet transforms*. The International Journal of Advanced Manufacturing Technology, 2018. **95**(1-4): p. 1399-1408.
7. Bessam, B., et al., *Detection of broken rotor bar faults in induction motor at low load using neural network*. ISA transactions, 2016. **64**: p. 241-246.
8. Oumaamar, M.E.K., et al., *Static air-gap eccentricity fault diagnosis using rotor slot harmonics in line neutral voltage of three-phase squirrel cage induction motor*. Mechanical Systems and Signal Processing, 2017. **84**: p. 584-597.
9. Yassa, N., M. Rachek, and H. Houassine, *Motor current signature analysis for the air gap eccentricity detection in the squirrel cage induction machines*. Energy Procedia, 2019. **162**: p. 251-262.
10. Bessous, N., et al., *Diagnosis of bearing defects in induction motors using discrete wavelet transform*. International Journal of System Assurance Engineering and Management, 2018. **9**(2): p. 335-343.
11. Han, Q., et al., *Stator current model for detecting rolling bearing faults in induction motors using magnetic equivalent circuits*. Mechanical Systems and Signal Processing, 2019. **131**: p. 554-575.
12. Wen, X., *A hybrid intelligent technique for induction motor condition monitoring*. 2011, University of Portsmouth.

13. Quiroz, J.C., et al., *Fault detection of broken rotor bar in LS-PMSM using random forests*. Measurement, 2018. **116**: p. 273-280.
14. Tavner, P., *Review of condition monitoring of rotating electrical machines*. IET electric power applications, 2008. **2**(4): p. 215-247.
15. Awadallah, M.A. and M.M. Morcos, *Application of AI tools in fault diagnosis of electrical machines and drives-an overview*. IEEE Transactions on energy conversion, 2003. **18**(2): p. 245-251.
16. Filippetti, F., et al., *Recent developments of induction motor drives fault diagnosis using AI techniques*. IEEE transactions on industrial electronics, 2000. **47**(5): p. 994-1004.
17. Tavner, P., et al., *Condition monitoring of rotating electrical machines*. Vol. 56. 2008: IET.

Chapitre 1

Etat de l'art sur le diagnostic de défauts du
moteur à induction

1.1 Introduction

Les moteurs électriques convertissent l'énergie électrique en énergie mécanique. En tant qu'élément fondamental de l'industrie moderne, les moteurs à induction sont largement utilisés dans des applications employant les pompes, les ventilateurs, les ascenseurs, les véhicules électriques, l'acier et les cimenteries. Les moteurs à induction et les systèmes d'entraînement sont soumis à de nombreux types de défauts. Les fabricants et les utilisateurs de moteurs à induction s'appuyaient initialement sur des méthodes de protection simples contre les surintensités et les surtensions pour garantir un fonctionnement fiable [1]. Cependant, le besoin de surveillance de l'état des moteurs à induction s'est accru récemment en raison de l'utilisation généralisée de l'automatisation et de la réduction conséquente de l'interaction directe entre l'homme et la machine pour superviser le fonctionnement du système d'entraînement du moteur. Une détection précoce des défauts naissants et un diagnostic correct permettent une maintenance rapide et non programmée ainsi qu'un temps d'arrêt court du système d'entraînement du moteur. Ils peuvent réduire les pertes financières et éviter des conséquences catastrophiques. La classification de l'état du moteur et l'estimation de la gravité des défauts à partir des signaux n'ont jamais été des tâches faciles et sont souvent influencées par de nombreux facteurs. La surveillance et le diagnostic des défauts des moteurs à induction ont suscité un grand intérêt de la part des chercheurs ces dernières années [2].

Dans ce chapitre, la structure d'un moteur à induction est d'abord présentée brièvement. Ensuite, les symptômes des défauts électriques et des défauts mécaniques du moteur à induction sont rappelés. Enfin, des méthodes de diagnostic des moteurs à induction des recherches antérieures sont brièvement rappelées.

1.2. Constitution du moteur à induction

Le moteur à induction comporte deux parties essentielles, l'une fixe appelée **stator** portant un bobinage triphasé logé dans des encoches et relié à la source d'alimentation et l'autre mobile ou **rotor** qui peut être soit bobiné soit à cage d'écureuil. Ces deux parties sont coaxiales et séparées par un entrefer (**Fig.1.1**).

Dans ce chapitre, on considère le cas d'un moteur à induction à cage d'écureuil. Toutefois, on admet que sa structure est électriquement équivalente à celle d'un rotor bobiné dont les enroulements sont en court-circuit.

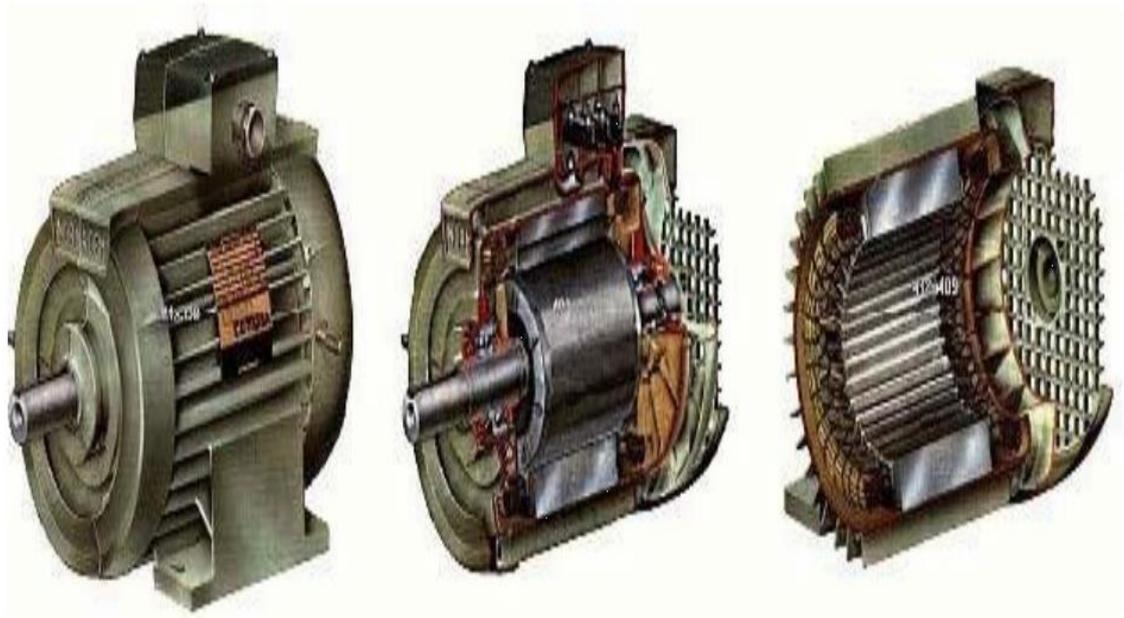


Fig. 1.1 Moteur à induction à cage d'écureuil [3].

Les éléments de constitution d'un moteur à induction à cage d'écureuil sont illustrés dans Fig. 1.2.

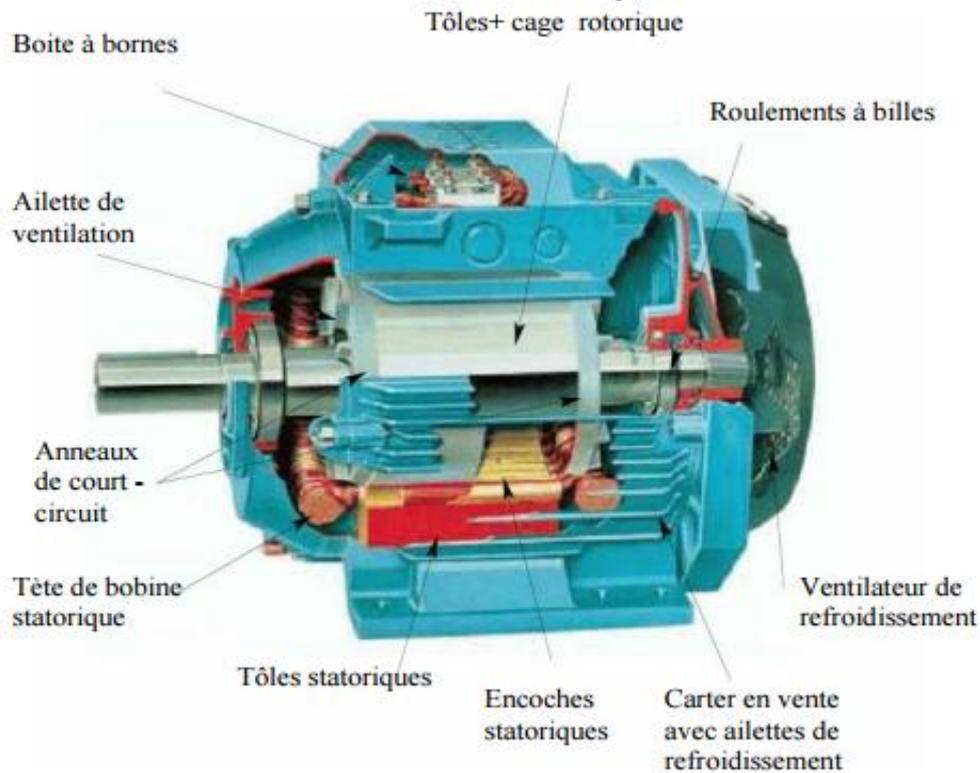


Fig. 1.2 Eléments de constitution d'un moteur à induction à cage d'écureuil

1.2.1 Stator

Il est constitué d'un enroulement bobiné réparti dans les encoches du circuit magnétique. Ce dernier est constitué d'un empilage de tôles dans lesquelles sont découpées des encoches parallèles à l'axe de la machine (Fig. 1.3). Le bobinage statorique peut se décomposer en deux parties: les

conducteurs d'encoches et les têtes de bobines. Les conducteurs d'encoches permettent de créer dans l'entrefer le champ magnétique à l'origine de la conversion électromagnétique. Les têtes de bobines permettent, quant à elles, la fermeture des courants en organisant la circulation judicieuse des courants d'un conducteur d'encoche à l'autre. L'objectif est d'obtenir à la surface de l'entrefer une distribution de courant la plus sinusoïdale possible, afin de limiter les ondulations du couple électromagnétique [4].

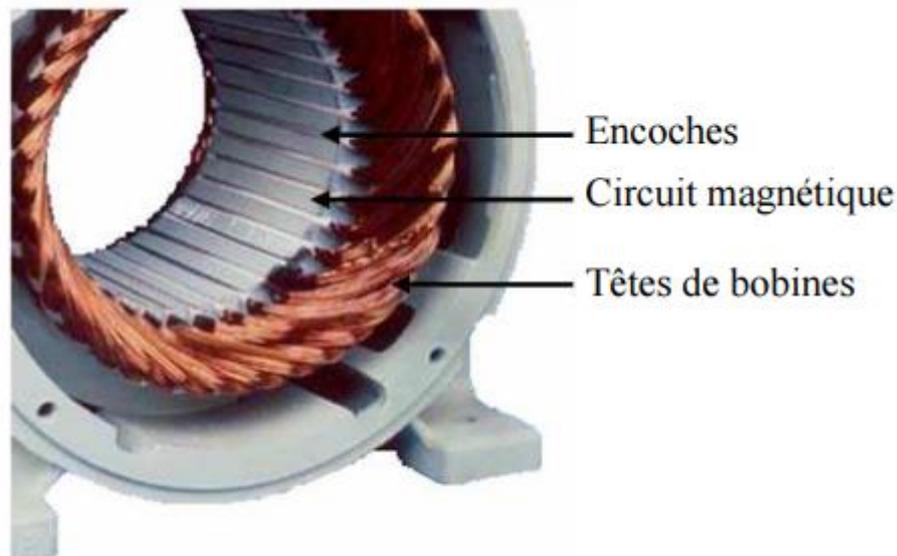


Fig. 1.3 Stator d'une machine à induction

1.2.2 Rotor

Dans le rotor à cage, les anneaux de court-circuit permettent la circulation des courants d'un conducteur d'encoche (barre rotorique) à l'autre. Ces barres conductrices sont régulièrement réparties et constituent le circuit du rotor. Cette cage est insérée à l'intérieur d'un circuit magnétique constitué de disques en tôles empilés sur l'arbre de la machine analogue à celui du moteur à rotor bobiné. Dans le cas de rotors à cage d'écureuil, les conducteurs sont réalisés par coulage d'un alliage d'aluminium, ou par des barres massives de cuivre préformées et frettées dans les tôles du rotor. **Fig.1.4** illustre un rotor à cage. Il n'y a généralement pas, ou très peu, d'isolation entre les barres rotoriques et les tôles magnétiques, mais leur résistance est suffisamment faible pour que les courants de fuite dans les tôles soient négligeables, sauf lorsqu'il y a une rupture de barre. Le moteur à cage d'écureuil est beaucoup plus simple à construire que le moteur à rotor bobiné et, de ce fait, son prix de revient est inférieur. De plus, il dispose d'une plus grande robustesse. Il constitue la plus grande partie du parc de moteurs asynchrones actuellement en service [3].

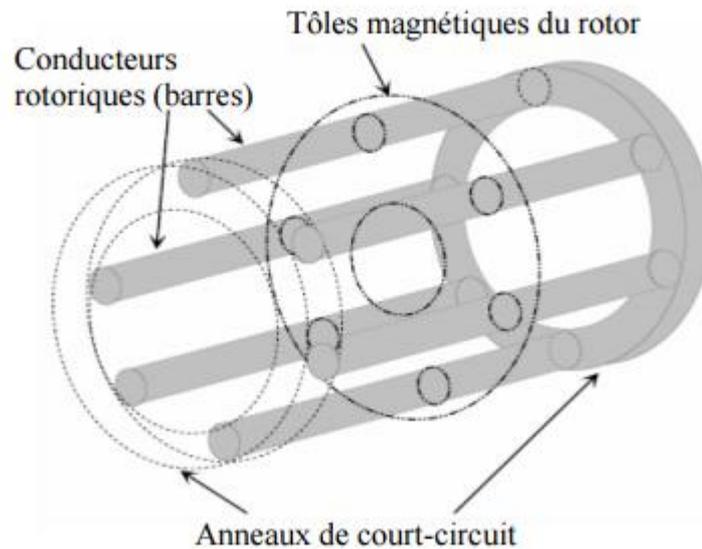


Fig. 1.4 Rotor à cage d'écureuil d'un moteur à induction

1.2.3 Organes mécaniques

La carcasse sert de support. Elle joue le rôle d'enveloppe et assure la protection contre l'environnement extérieur. L'arbre est un organe de transmission. Il comprend une partie centrale qui sert de support au corps du rotor et un bout d'arbre sur lequel est fixé un demi-accouplement. Il est généralement fabriqué en acier moulé ou forgé. Son dimensionnement est fonction des efforts de flexion (force centrifuge qui s'exerce sur lui, attraction magnétique radiale, etc...), des efforts radiaux et tangentiels dus aux forces centrifuges, des efforts de torsion (couple électromagnétique transmis en régimes permanent et transitoire). Il est supporté par un ou plusieurs paliers. Ces paliers soutiennent le rotor et assurent la libre rotation. Le second palier est libre pour assurer les dilatations thermiques de l'arbre. Une isolation électrique de l'un des paliers assure l'élimination des courants dans l'arbre dû aux dissymétries des réductances du circuit magnétique. Ils sont généralement à roulements pour les machines de petite et moyenne puissance [5].

1.3 Défaillances dans le moteur à induction

Les moteurs à induction (MI) sont les machines électriques les plus couramment utilisées dans l'industrie en raison de leur faible coût, de leur taille raisonnablement petite, de leur robustesse, de leur faible entretien et de leur fonctionnement avec une alimentation facilement disponible [6]. Cependant, ils sont sujets à différents modes de défauts conduisant à des défaillances. Ces défauts peuvent être inhérents à la machine elle-même ou peuvent être créés par les conditions de fonctionnement. Les défauts inhérents pourraient être causés par les forces mécaniques ou

électriques agissant sur l'enceinte de la machine. Si un défaut n'est pas détecté, il peut conduire à une défaillance [6, 7]. Les principaux défauts du moteur à induction à cage peuvent être classés en deux types : rotorique et statorique.

1.3.1 Défauts rotoriques

1.3.1.1 Défauts des barres cassées

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, ce qui engendre des vibrations mécaniques et donc, un fonctionnement anormal de 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 [4,8].

Le rotor d'un MI de 1950 kW, 120 A, 50 Hz, 1485 tr/mn est représenté sur **Fig. 1.5**. Il est utilisé dans une base pétrolière de la mer du nord [9]. Suite à des contraintes trop sévères de différentes natures, une barre est rompue. Le défaut n'étant pas détecté au moment opportun, une portion de la barre rompue a été totalement soulevée (comme on peut le voir sur **Fig. 1.5**) détruisant les enroulements statoriques et par conséquent engendrant l'arrêt total du moteur. Ce défaut doit être détecté rapidement afin de garantir un fonctionnement fiable du moteur et donc de l'installation globale et d'éviter sa propagation sur les autres barres rotoriques [10].

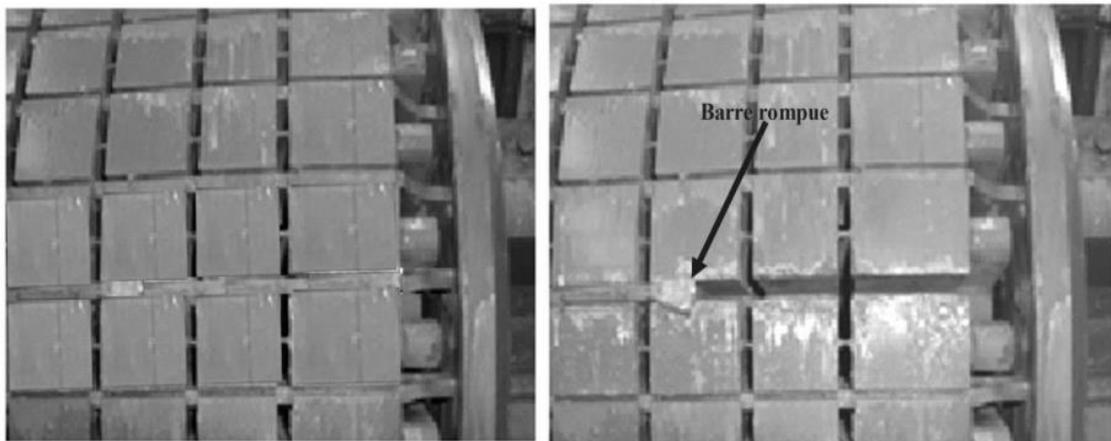


Fig. 1.5 Exemple d'un rotor d'un MI pour :(a) rotor à l'état sain et (b) rotor avec une barre cassée [9, 10]

1.3.1.2 Défauts des roulements

Les roulements à billes jouent le rôle d'interface électromécanique entre le stator et le rotor. En outre, ils représentent l'élément de maintien de l'axe de la machine permettant d'assurer une bonne rotation du rotor. Ce type de défaut est le plus fréquent sur les machines de fortes puissances. Il est, généralement, lié à l'usure du roulement et plus précisément une dégradation des billes, ou de la bande de roulement. Les causes possibles sont [3]:

- l'usure due au vieillissement,
- la température de fonctionnement élevée,
- la perte de lubrification,
- l'huile contaminée (par des paillettes métalliques issues de la dégradation des billes ou de la bande de roulement),
- le défaut de montage,
- les courants d'arbres (Shaft Current).

Les conséquences directes de cette défaillance sur les roulements sont :

- des trous dans les gorges intérieures et extérieures des roulements,
- l'ondulation de leur surface de roulement,
- l'attaque des billes,
- la corrosion due à l'eau,
- défaut de graissage (problème dû à la température),
- décollement, effritement de surface provoqué par une surcharge.

Sur le système, ce type de défaut se traduit par des oscillations du couple de charge, une apparition de pertes supplémentaires et un jeu entre la bague interne et la bague externe du roulement entraînant des vibrations par les déplacements du rotor autour de l'axe longitudinal de la machine. Dans le cas, le plus défavorable, la présence d'un roulement défectueux peut amener au blocage du moteur [3].

Un dégât grave provoqué par un défaut de roulement dans un moteur à induction est montré sur **Fig. 1.6**. On voit bien que le rotor est collé avec le stator provoquant une grande déformation des circuits magnétiques statorique et rotorique [10, 11].

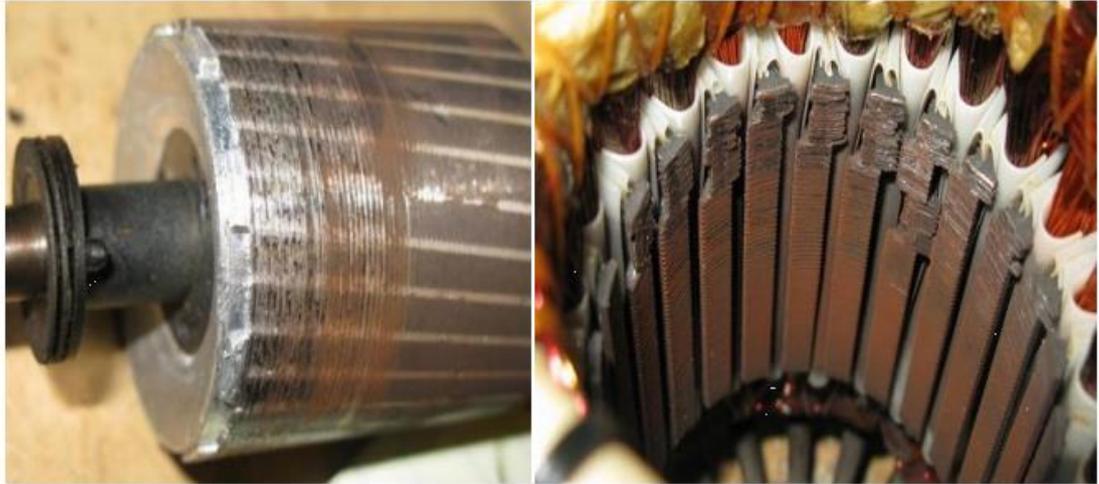


Fig. 1.6 Exemple de dégâts au stator et rotor dus au défaut de roulement d'un MI

1.3.1.3 Défauts d'excentricité

L'excentricité est un défaut du rotor, commun des machines à induction. Ce défaut produit les problèmes de vibrations et de bruit. Dans une machine à l'état sain, le rotor est aligné au centre avec l'alésage du stator et le centre de rotation du rotor est le même que le centre géométrique de l'alésage du stator. Lorsque le rotor n'est pas centré, les forces radiales déséquilibrées (Traction Magnétique Déséquilibrée (TMD) peuvent provoquer un frottement stator-rotor, ce qui peut endommager le stator et le rotor [12, 13]. Il existe trois types d'excentricité [14]:

a) Excentricité statique

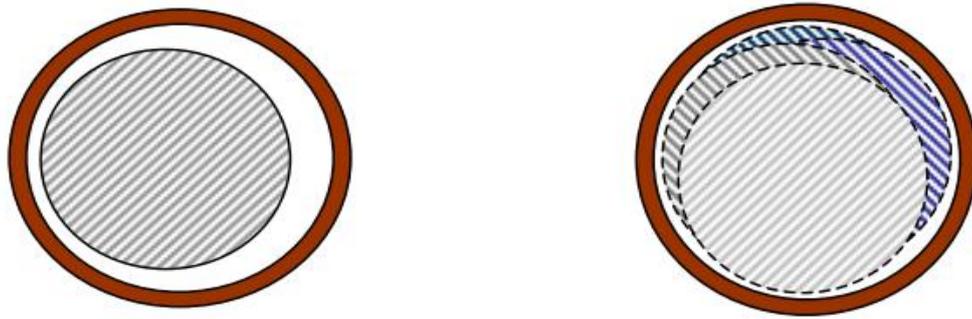
Le rotor est déplacé du centre de l'alésage stator mais tourne toujours autour de son axe qui crée le TMD. Elle est difficile à détecter à moins d'utiliser un équipement spécial [14].

b) Excentricité dynamique

Le rotor est positionné au centre de l'alésage mais ne tourne plus autour de son axe. l'excentricité dynamique produit un TMD qui tourne à la vitesse de rotation du moteur et agit directement sur le rotor. il est plus facile à le détecter par la vibration ou la surveillance de courant.

c) Excentricité mixte

En fait, les excentricités statiques et dynamiques ont tendance à coexister. Les conditions centriques idéales ne peuvent jamais être supposées. Par conséquent, un degré d'excentricité inhérent est implicite pour toute machine réelle. L'excentricité statique et dynamique combinée est appelée l'excentricité mixte [14].



Excentricité statique

Excentricité dynamique

(plusieurs positions du rotor au cours de la rotation)

Fig. 1.7 Représentation des excentricités statique et dynamique dans le MI

1.3.2 Défauts statoriques

Les défauts statoriques regroupent principalement les défauts de court-circuit d'une phase à la terre, court-circuit entre phases, ou court-circuit entre spires, comme indiqué sur **Fig. 1.8**. Ils commencent généralement par un court-circuit entre spires, avant d'évoluer vers des défauts plus graves. Une des principales causes de ces défauts est la dégradation du matériau isolant recouvrant les conducteurs. Cette dégradation est due principalement à un échauffement anormal dans le bobinage. Le courant, dans les spires court-circuitées, atteint des valeurs énormes et l'augmentation de la température qui en suit entraîne la destruction de tous les isolants et par conséquent la défaillance complète du moteur [10, 11]. Deux exemples de dégâts provoqués par le défaut de court-circuit au stator sont représentés sur **Fig. 1.9**

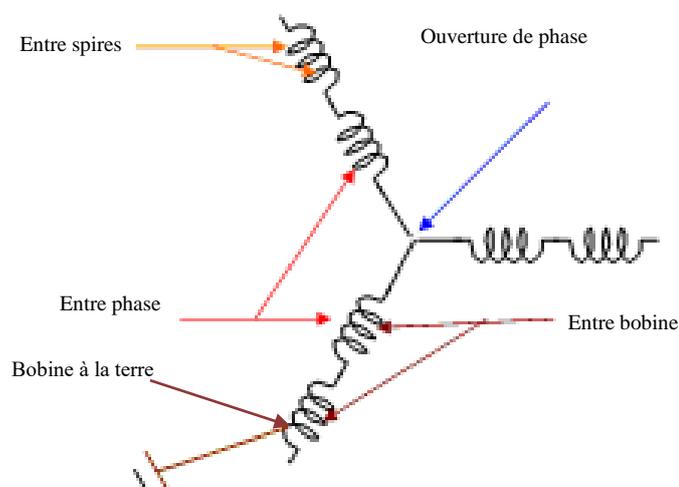


Fig. 1.8 Représentation des différents défauts statoriques possibles



Fig. 1.9 Exemples de dégâts dus au défauts de court-circuits statoriques d'un MI

1.3.3 Etude statistique des défaillances

Des études statistiques sur l'apparition de ces défauts dans les machines ont été réalisées par [15]. Elles sont basées sur les résultats obtenus par l'Institution de Electrical and Electronics Engineers (IEEE), ASEA Brown Boveri (ABB) et Electric Power Research Institute (EPRI). Les résultats de cette étude sont résumés dans **Tableau 1.1**.

La fiabilité du MI a été envisagée dans plusieurs enquêtes [16 - 18]. Selon ces études, les défaillances les plus fréquemment rencontrées dans les MIs sont les défauts des roulements et des enroulements statoriques [19].

Tableau 1.1 : Possibilité de défaillance dans les moteurs à induction [15]

Étudié par	Défaut de roulement (%)	Défaut statorique (%)	Défaut rotorique (%)	Autres (%)
IEEE	41%	28%	9%	22%
EPRI	42%	36%	8%	14%
ABB	51%	16%	5%	10%

1.4 Méthodes de diagnostic des défauts dans le moteur à induction

Les défauts peuvent se trouver à différents endroits comme dans le stator, le rotor, les pièces de roulement du moteur ou les systèmes périphériques externes associés, comme mentionné ci-dessus. **Fig. 1.10** présente différentes approches de détection des défauts pour les moteurs à

induction. Les approches sont classées en trois catégories, à savoir les approches basées sur le modèle, sur le traitement du signal et sur l'intelligence artificielle.

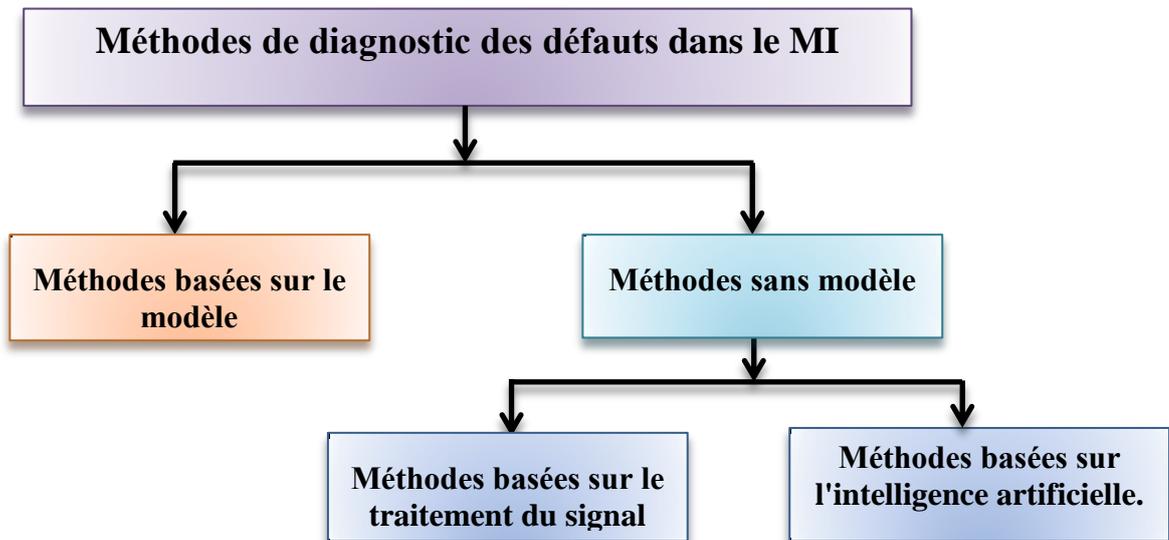


Fig. 1.10 Méthodes de diagnostic du moteur à induction

1.4.1 Méthodes basées sur le modèle

Ces méthodes de détection reposent sur des connaissances a priori du système. Elles sont basées sur des modèles mathématiques du système et des paramètres représentant le processus physique à étudier. La comparaison des signaux expérimentaux représentant le fonctionnement du système et des signaux générés par les modèles (ou des paramètres estimés) permet la détection ainsi que l'identification de la défaillance susceptible de se produire. Ces techniques supposent la connaissance de la plage de variation de ces modèles et de leurs paramètres selon les conditions de fonctionnement du système [5].

Cependant, ces méthodes ont des inconvénients car un modèle mathématique précis d'un système physique est difficile à obtenir. Habituellement, les paramètres du système peuvent varier dans le temps et les caractéristiques des défauts et des bruits ne peuvent pas être modélisés avec précision. Il y a donc toujours un manque de congruence entre le système réel (moteur) et son modèle mathématique, même dans des conditions sans faute. De telles incohérences causent des problèmes dans les applications de détection des défauts et de surveillance des conditions et peuvent être à l'origine de fausses alarmes et d'alarmes manquées [7, 20].

1.4.2 Méthodes sans modèle

Les méthodes sans modèle peuvent être classées en deux catégories: la première se basant sur le traitement de signaux issus de capteurs de grandeurs électriques ou bien mécaniques affectées par

les défauts. La deuxième utilise les systèmes experts basés sur des techniques d'intelligence artificielle [21, 22].

1.4.2.1 Méthodes basées sur le traitement de signaux

Puisque les allures temporelles ne donnent pas beaucoup d'information, on est obligé d'aller vers les techniques de traitement de signal. Les méthodes se basant sur l'analyse des signaux d'acquisition ont l'avantage d'être indépendantes des fluctuations internes du système. Ainsi, l'information contenue dans les signaux n'est pas affectée par une éventuelle erreur de modélisation. Plusieurs techniques de traitement de signal ont été utilisées depuis longtemps pour analyser le contenu spectral des différents signaux issus des machines électriques tels que: les courants, les puissances, le couple, la vitesse, le flux, les vibrations,...etc. Dans ce qui suit, on présente brièvement les transformées de *Fourier* rapide (FFT), la transformée en ondelettes (TO) et la transformée de *Hilbert* (TH).

a) Transformée de *Fourier* rapide (FFT)

La transformée de *Fourier* (FT) convertit un signal dans le domaine fréquentiel à partir du domaine temporel et la transformée de *Fourier* inverse convertit un signal dans le domaine temporel à partir du domaine fréquentiel. Pour ce faire, le nombre de calculs nécessaires est de $2N^2$ où N est le nombre de données. La FFT fait de même, c'est-à-dire qu'elle convertit un signal dans le domaine de fréquence à partir du domaine temporel et vice versa. Mais dans ce cas, le nombre de calculs nécessaires est $2N\log_2N$. Maintenant, la différence entre $2N^2$ et $2N\log_2N$ est immense. Ainsi, le nombre de calculs étant faible par rapport à la transformée de *Fourier*, cette technique peut effectuer la transformation rapidement d'où son nom FFT [23].

La FFT est plus appropriée pour l'analyse en régime permanent. Elle a été utilisée pour générer les caractéristiques liées aux défauts de différents signaux comme le courant et les vibrations [21, 24].

Dans [25, 26], la FFT est utilisée pour détecter la cassure des barres rotoriques, court circuits statoriques et excentricité rotorique respectivement via l'analyse directe du courant statorique MCSA (Motor Current Signal Analysis). [28, 28] ont proposé l'analyse MCSA-FFT comme un outil fiable pour la détection de défauts multiples du moteur à induction.

La FFT donne de bons résultats pour des fonctionnements à forte puissance ou à couple constant mais des difficultés apparaissent pour les fonctionnements à couple de charge, vitesse de rotation et tensions d'alimentation variables [29 - 31]. La nécessité de trouver d'autres techniques de traitement de signal pour les signaux non stationnaires devient donc nécessaire.

b) Transformée en ondelette (TO)

TO est un puissant outil avancé de traitement du signal qui fournit à la fois des informations sur le temps et la fréquence d'un signal en le décomposant en différentes échelles à différents niveaux de résolution grâce à l'ajustement des largeurs de temps aux fréquences d'une seule fonction prototype appelée ondelette mère. Cet ajustement, également appelé dilatation, est effectué de telle manière que les ondelettes de fréquences plus élevées seront compressées et celles de fréquences plus basses seront étirées [23].

La TO est divisée en deux catégories : la transformée en ondelettes continues (TOC) et la transformée en ondelettes discrètes (TOD). La TOC fonctionne à toutes les échelles et positions possibles (dilatation et translation continues). Cependant, la TOD utilise un sous-ensemble particulier de valeurs d'échelle et de position qui sont moins complexes à calculer et qui nécessitent moins de temps de calcul que la TOC [20]. La TOD est calculée par une série de filtres passe-bas et passe-haut qui sont connus sous le nom d'arbre de décomposition "multi résolutions". La TOD est obtenue par des filtres de différentes fréquences de coupure pour l'analyse du signal à différentes échelles. Le signal passe à travers une série de filtres passe-haut H (détails) pour analyser les hautes fréquences et il passe à travers une série de filtres passe-bas L (approximations) pour analyser les basses fréquences comme l'illustre **Fig. 1.11**. Les signaux de détails et d'approximations reflètent l'évolution temporelle des composantes de fréquence associées au signal $X(n)$ contenus dans leur bande de fréquences associées [16, 32].

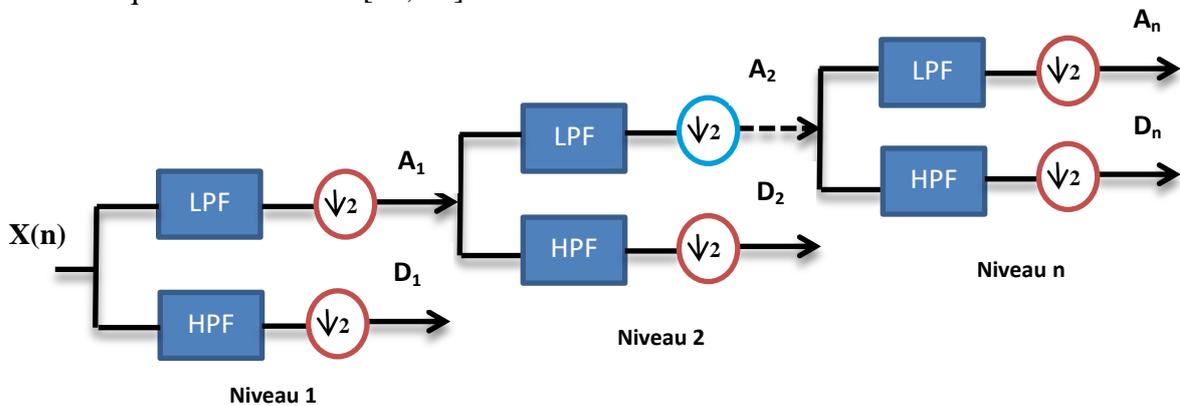


Fig. 1.11 Décomposition multi résolutions à n niveaux

Le processus de décomposition multi résolutions par l'ondelette à n niveaux est illustré sur la **Fig.11.1**, où le niveau de décomposition du premier signal, contenant deux coefficients A_1 (approximation) et D_1 (détail), sont calculés par:

$$\begin{cases} A_1 = \sum_k^n L(k - 2n)X(k) \\ D_1 = \sum_k^n H(k - 2n)X(k) \end{cases} \quad (1.1)$$

Le niveau de décomposition suivant est calculé sur la base de A_1 . Par conséquent, les nouveaux coefficients peuvent être donnés par:

$$\begin{cases} A_2 = \sum_k^n L(k - 2n)A_1(k) \\ D_2 = \sum_k^n H(k - 2n)A_1(k) \end{cases} \quad (1.2)$$

Le calcul des décompositions de niveau supérieur se fait d'une manière similaire. Le signal original peut être reconstruit comme suit [21] :

$$X(n) = A_n + D_n + D_{n-1} + \dots D_2 + D_1 \quad (1.3)$$

En calculant l'énergie associée à chaque niveau de décomposition, on peut construire un outil de diagnostic très efficace. La valeur propre d'énergie de chaque composition d'ondelette est définie par [33]:

$$E_j = \sum_{k=1}^{k=n} D_{j,k}^2(n) \quad (1.4)$$

tel que j est le niveau de décomposition.

Les valeurs propres d'énergies des niveaux des décompositions contiennent l'information des signaux dans un MI. Elles peuvent être utilisées pour diagnostiquer les défauts dans le MI et elles peuvent également indiquer la sévérité du défaut [334, 35].

Contrairement à la FFT, les ondelettes possèdent la propriété de pouvoir être bien localisées en temps ou en fréquence, ce qui les différencie principalement de l'analyse temps-fréquence classique [11] et elles présentent des avantages efficaces dans l'analyse des signaux non stationnaires [23]. De nombreux chercheurs [33 - 41] ont appliqué la TO pour détecter les défauts des MI. Dans [33 - 36] ont utilisé de méthodes basées sur la TOD pour détecter le défaut de court-circuit entre spires au stator sous différentes conditions de fonctionnement du MI. Dans [37, 38], il a été démontré le succès de la TOD dans le diagnostic des défauts cassure de barres rotoriques. Les travaux [39 - 41] ont présenté la détection de défauts de roulement et l'excentricité du MI en se basant sur la TOD.

c) Transformée de Hilbert (TH)

C'est une technique parmi les plus connues dans le domaine du traitement de signal. Elle est utilisée pour obtenir un signal analytique à partir d'un signal réel. La TH peut être utilisée pour le processus de détection des différents types de défauts par l'analyse du courant transitoire de démarrage et en régime stationnaire. Elle offre une faible sensibilité au niveau de charge du moteur par rapport au courant permanent. En outre, des conclusions fiables sont obtenues à partir de l'analyse des données, même à faible ou sans charge mécanique [41, 42].

L'hybridation de la TH avec d'autres techniques de traitement du signal est suggérée pour obtenir un bon outil de détection des défaillances. Dans ce contexte, de nombreux travaux se trouvent dans la littérature sur l'utilisation de cet outil. Dans [43], la transformée de *Hilbert* (TH) et la transformée en ondelettes (TO) sont utilisées afin de développer une méthode de diagnostic de défauts multi-classes pour les moteurs à induction utilisant des signaux de vibration radiale. Dans [44], une signature de défaut basée sur une combinaison améliorée de transformées de *Hilbert* et *Park* a été proposée. À partir de cette combinaison, peuvent être déduites deux signatures de défaut: le vecteur d'espace de courant de module de *Hilbert* et le vecteur d'espace de courant de phase de *Hilbert*. Ces deux signatures sont ensuite analysées à l'aide de la FFT. Dans [45, 46], les auteurs ont présenté une étude d'amélioration de la résolution de la méthode FFT via la TH (HT-FFT) pour diagnostiquer le défaut cassure de barre rotorique en faible glissement. Cette technique est appliquée en utilisant la TH pour extraire l'enveloppe du courant statorique puis l'analyser par la FFT pour extraire l'indicateur de défaut.

1.4.2.2 Méthodes basées sur l'intelligence artificielle.

L'intelligence artificielle (IA) est une technique efficace pour modéliser des systèmes non linéaires complexes en utilisant certaines structures et règles basées sur la connaissance a priori du système. Elle met moins l'accent sur la structure physique et les résultats intermédiaires du système, mais tente d'émuler la relation d'entrée/sortie directement [21]. Parmi ces techniques les plus courantes sont les réseaux neuronaux artificiels (RN), les systèmes de logique floue (LF) et les réseaux hybrides neuro-flous (ANFIS). Elles ont été intégrées les unes aux autres et ont aussi montré avec d'autres techniques traditionnelles [47] le succès de la technique TOD. Celle-ci présente de nombreux avantages par rapport aux approches classiques de diagnostic des défauts des machines électriques [47, 48]. En plus d'offrir de meilleures performances, la technique est facile à étendre et à modifier. Elle peut être adaptable par l'incorporation de nouvelles données ou informations. Les techniques d'IA favorisent le remplacement de l'interface humaine pour la surveillance des défauts des machines électriques, ce qui donne naissance aux concepts de diagnostic automatisé. Il existe une possibilité importante d'ajouter de l'intelligence aux machines, en fournissant un niveau de communication et une capacité de diagnostic. L'intelligence peut être intégrée dans la boîte à bornes de la machine, de sorte que l'ensemble ne nécessite pas plus d'espace. L'inconvénient majeur est que le succès de la détection des défauts dépend des données de l'apprentissage initial et que seuls les défauts représentés dans l'apprentissage peuvent être diagnostiqués. De plus, le volume de l'apprentissage est important [49].

Dans [45], les auteurs ont présenté une étude de diagnostic expérimentale sur les défauts de cassure de barres rotoriques dans le MI basée sur la logique floue et la méthode HT-FFT du courant statorique. Dans [33, 36], le RN et la TOD ont été proposés pour la détection et la localisation du défaut de court-circuit entre spires d'un MI. Dans [50], une technique de surveillance et de diagnostic des défauts des machines à induction est exposée pour tenir compte du défaut de court-circuit entre spires statoriques, du défaut de cassure de barre rotorique et du défaut mixte: court-circuit entre spires et cassure de barre simultanément. Cette technique est appliquée en se basant sur des réseaux neuro-flous de type ANFIS dont la base de connaissances utilise des indicateurs dérivés de l'analyse de la transformée en ondelettes discrètes (TOD) et de l'analyse spectrale du courant statorique de la machine (FFT). Ceci permet, en plus de la détection, l'évaluation du nombre de barres cassées et de la position des spires en court-circuit.

1.5 Conclusion

Ce chapitre est, principalement, dédié à l'état de l'art du moteur à induction et aux méthodes de surveillance et de diagnostic associées. Nous avons scindé ce chapitre en 3 parties : la première concerne la constitution du moteur à induction, la deuxième partie introduit les défauts des moteurs à induction (mécaniques et électriques) et la troisième partie traite des techniques qui permettent la mise en œuvre d'une procédure de diagnostic. Ces techniques sont classées en deux catégories: techniques basées sur le modèle et techniques sans modèle. Pour la première catégorie, on y utilise le traitement du signal (FFT, TD ,HT..) des grandeurs mesurables, à savoir le courant et la tension, et une approche système. Pour la deuxième catégorie, on y utilise des techniques de l'intelligence artificielle (RN ,LF,et NF..). Le chapitre suivant sera consacré au développement des méthodes de diagnostic des défauts type : cassure de barres rotoriques et court-circuit entre spires statoriques du moteur à induction.

1.6 Bibliographie

1. Nandi, S., H.A. Toliyat, and X. Li, *Condition monitoring and fault diagnosis of electrical motors—A review*. IEEE transactions on energy conversion, 2005. **20**(4): p. 719-729.
2. Bellini, A., et al., *Advances in diagnostic techniques for induction machines*. IEEE Transactions on industrial electronics, 2008. **55**(12): p. 4109-4126.
3. Ammar, M., *Surveillance et diagnostic des défauts des machines électriques: applications aux moteurs asynchrones*. 2012, Thèse de doctorat, Université du 20 Août 1955-Skikda.

4. Ondel, O., *Diagnostic par reconnaissance des formes: Application à un ensemble convertisseur- machine asynchrone*. 2006, Ecole Centrale de Lyon
5. Bessam, B., *Analyse et détection des défauts dans la machine asynchrone à base des techniques intelligentes*. 2016, Université Mohamed Khider-Biskra.
6. Benbouzid, M.E.H., *A review of induction motors signature analysis as a medium for faults detection*. IEEE transactions on industrial electronics, 2000. **47**(5): p. 984-993.
7. YOUSEFI, R., *FAULT DETECTION AND DIAGNOSIS METHOD FOR THREE-PHASE INDUCTION MOTOR*. 2018, Universiti Teknologi Malaysia.
8. Said, M.N., M.E.H. Benbouzid, and A. Benchaib, *Detection of broken bars in induction motors using an extended Kalman filter for rotor resistance sensorless estimation*. IEEE Transactions on energy conversion, 2000. **15**(1): p. 66-70.
9. Thomas, V.V., K. Vasudevan, and V.J. Kumar, *Online cage rotor fault detection using airgap torque spectra*. IEEE transactions on energy conversion, 2003. **18**(2): p. 265-270.
10. Mabrouk, A., *Contribution au diagnostic de la machine asynchrone en présence de variation de charge*. 2017, Thèse de doctorat, Université Mohamed Khider-Biskra.
11. YAHIA, K., *Contribution au Diagnostic de la Machine Asynchrone Triphasée par une Approche Signal*. 2012, Thèse de doctorat, Université Mohamed Khider-Biskra.
12. Dorrell, D.G., W.T. Thomson, and S. Roach, *Analysis of airgap flux, current, and vibration signals as a function of the combination of static and dynamic airgap eccentricity in 3-phase induction motors*. IEEE Transactions on Industry applications, 1997. **33**(1): p. 24-34.
13. Wu, S. and T.W. Chow, *Induction machine fault detection using SOM-based RBF neural networks*. IEEE Transactions on Industrial Electronics, 2004. **51**(1): p. 183-194.
14. Mehala, N., *Condition monitoring and fault diagnosis of induction motor using motor current signature analysis*. A Ph. D Thesis submitted to the Electrical Engineering Department, National Institute of Technology, Kurushetra, India, 2010
15. Choudhary, A., et al., *Condition monitoring and fault diagnosis of induction motors: A review*. Archives of Computational Methods in Engineering, 2019. **26**(4): p. 1221-1238.
16. Heising, C., *IEEE recommended practice for the design of reliable industrial and commercial power systems*. IEEE Inc., New York, 2007.
17. Albrecht, P., et al., *Assessment of the reliability of motors in utility applications-Updated*. IEEE Transactions on Energy conversion, 1986(1): p. 39-46.
18. Thorsen, O.V. and M. Dalva, *A survey of faults on induction motors in offshore oil industry, petrochemical industry, gas terminals, and oil refineries*. IEEE transactions on industry applications, 1995. **31**(5): p. 1186-1196

19. O'DONNELL, P., et al., *Report of large motor reliability survey of industrial and commercial installations. III*. IEEE Transactions on Industry Applications, 1987. **23**(1): p. 153-158.
20. Khechekhouché, A., et al., *Experimental diagnosis of inter-turns stator fault and unbalanced voltage supply in induction motor using MCSA and DWER*. Periodicals of Engineering and Natural Sciences, 2020. **8**(3): p. 1202-1216.
21. AMEID, T., *Contrôle et Diagnostic de la Machine à Induction*. 2018, Université Mohamed Khider–Biskra.
22. HARZELLI, I., *Contrôle non linéaire de la machine asynchrone en vue du diagnostic des défauts en utilisant des techniques avancées*. 2020, Université Mohamed Khider–Biskra.
23. Subrata, K., et al., *Induction Motor Fault Diagnosis-Approach through Current Signature Analysis*. 2016, Singapore: Springer
24. Shi, P., et al., *A new diagnosis of broken rotor bar fault extent in three phase squirrel cage induction motor*. Mechanical Systems and Signal Processing, 2014. **42**(1-2): p. 388-403.
25. Menacer, A., et al. *Effect of the position and the number of broken bars on asynchronous motor stator current spectrum*. in *2006 12th International Power Electronics and Motion Control Conference*. 2006. IEEE.
26. Kechida, R., A. Menacer, and A. Benakcha, *Fault detection of broken rotor bars using stator current spectrum for the direct torque control induction motor*. World academy of science, engineering and technology, 2010. **66**: p. 1244-1249
27. Benbouzid, M., et al., *Induction motor asymmetrical faults detection using advanced signal processing techniques*. IEEE Transactions on Energy Conversion, 1999. **14**(2): p. 147-152.
28. Panigrahy, P.S., P. Konar, and P. Chattopadhyay. *Broken bar fault detection using fused DWT-FFT in FPGA platform*. in *2014 International Conference on Power, Control and Embedded Systems (ICPCES)*. 2014. IEEE.
29. CusidóCusido, J., et al., *Fault detection in induction machines using power spectral density in wavelet decomposition*. IEEE Transactions on Industrial Electronics, 2008. **55**(2): p. 633- 643.
30. Antonino-Daviu, J.A., et al., *Validation of a new method for the diagnosis of rotor bar failures via wavelet transform in industrial induction machines*. IEEE Transactions on Industry applications, 2006. **42**(4): p. 990-996.
31. Riera-Guasp, M., et al., *A general approach for the transient detection of slip-dependent fault components based on the discrete wavelet transform*. IEEE transactions on Industrial electronics, 2008. **55**(12): p. 4167-418
32. Singh, G., *Induction machine drive condition monitoring and diagnostic research—avsurvey*. Electric Power Systems Research, 2003. **64**(2): p. 145-158.
33. Cherif, H., et al., *Early detection and localization of stator inter-turn faults based on discrete wavelet energy ratio and neural networks in induction motor*. Energy, 2020. **212**: p.118684.

34. Cherif, H., et al. *Stator inter turns fault detection using discrete wavelet transform*. in *Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED), 2015 IEEE 10th International Symposium on*. 2015. IEEE.
35. Bessam, B., et al. *A novel method for induction motors stator inter-turn short circuit fault diagnosis based on wavelet energy and neural network*. in *Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED), 2015 IEEE 10th International Symposium on*. 2015. IEEE.
36. Bessam, B., et al., *Wavelet transform and neural network techniques for inter-turn short circuit diagnosis and location in induction motor*. *International Journal of System Assurance Engineering and Management*, 2017. **8**(1): p. 478-488.
37. Talhaoui, H., et al., *Experimental diagnosis of broken rotor bars fault in induction machine based on Hilbert and discrete wavelet transforms*. *The International Journal of Advanced Manufacturing Technology*, 2018. **95**(1-4): p. 1399-1408.
38. Ameid, T., et al., *Discrete wavelet transform and energy eigen value for rotor bars fault detection in variable speed field-oriented control of induction motor drive*. *ISA transactions*, 2018. **79**: p. 217-231.
39. Bessous, N., et al., *Diagnosis of bearing defects in induction motors using discrete wavelet transform*. *International Journal of System Assurance Engineering and Management*, 2018. **9**(2): p. 335-343
40. Talhaoui, H., A. Menacer, and R. Kechida. *Mixed eccentricity fault diagnosis in the sensorless field oriented control induction motor using DWT technique*. in *2015 IEEE 10th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)*. 2015. IEEE.
41. Yahia, K., et al., *Induction motors airgap-eccentricity detection through the discrete wavelet transform of the apparent power signal under non-stationary operating conditions*. *ISA transactions*, 2014. **53**(2): p. 603-611.
42. Abd-el-Malek, M., A.K. Abdelsalam, and O.E. Hassan, *Induction motor broken rotor bar fault location detection through envelope analysis of start-up current using Hilbert transform*. *Mechanical Systems and Signal Processing*, 2017. **93**: p. 332-350
43. Konar, P. and P. Chattopadhyay, *Multi-class fault diagnosis of induction motor using Hilbert and Wavelet Transform*. *Applied Soft Computing*, 2015. **30**: p. 341-352.
44. Bacha, K., S.B. Salem, and A. Chaari, *An improved combination of Hilbert and Park transforms for fault detection and identification in three-phase induction motors*. *International Journal of Electrical Power & Energy Systems*, 2012. **43**(1): p. 1006-1016.
45. Laala, W., S.-E. Zouzou, and S. Guedidi, *Induction motor broken rotor bars detection using fuzzy logic: experimental research*. *International Journal of System Assurance Engineering and Management*, 2014. **5**(3): p. 329-336.

46. Bessam, B., et al., *Detection of broken rotor bar faults in induction motor at low load using neural network*. ISA transactions, 2016. **64**: p. 241-246.
47. Siddique, A., G. Yadava, and B. Singh. *Applications of artificial intelligence techniques for induction machine stator fault diagnostics*. in *4th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives, 2003. SDEMPED 2003*. 2003. IEEE.
48. Abdelhadi, B., A. Benoudjit, and N. Nait-Said, *Application of genetic algorithm with a novel adaptive scheme for the identification of induction machine parameters*. IEEE Transactions on Energy conversion, 2005. **20**(2): p. 284-291.
49. Toliyat, H.A., et al., *Electric machines: modeling, condition monitoring, and fault diagnosis*. 2012: CRC press.
50. Souad, L., et al. *Induction machine rotor and stator faults detection by applying the DTW and NF network*. in *2018 IEEE International Conference on Industrial Technology (ICIT)*. 2018. IEEE.

Chapitre 2

Analyse et diagnostic des défauts rotoriques et statoriques de la machine à induction: Etude expérimentale

2.1 Introduction

Les moteurs à induction (MI) souffrent de diverses défaillances mécaniques et électriques comme le court-circuit entre spires au stator [1-4], l'excentricité du rotor [5] et les cassures des barres rotoriques [6-8]. Par conséquent, il est nécessaire de développer à l'avance un système de surveillance pour la détection et le diagnostic des défauts qui peuvent survenir dans ce type de moteurs. De plus, les courts-circuits entre spires statoriques et les défauts de cassure de barres au rotor sont les causes les plus importantes de défauts dans les MI, provoquant des vibrations mécaniques qui peuvent causer des dommages dans les MI. Ces défauts deviennent plus apparents en augmentant leur gravité. Par conséquent, leur détection précoce éviterait une détérioration irréversible, réduirait les coûts de réparation et le temps d'arrêt du moteur.

Dans ce chapitre, nous présentons des approches expérimentales effectuées pour le diagnostic des défauts de type cassure de barres rotoriques et court - circuits entre spires de l'enroulement statorique dans le MI. Ces deux approches sont basées sur les deux méthodes suivantes :

- ✓ La première approche pour la détection précoce du défaut de cassure de barres dans le MI et pour différentes conditions de fonctionnement est une méthode de diagnostic améliorée basée sur une combinaison entre la transformée d'*Hilbert* (TH) et la transformée rapide de *Fourier* (FFT). Cette méthode hybride sera notée (HFFT). La méthode proposée est appliquée en utilisant la transformée TH pour extraire l'enveloppe du courant statorique, puis en l'analysant par la FFT pour extraire l'amplitude et la fréquence d'harmonique spécifique de l'enveloppe du courant statorique qui sont utilisées comme caractéristiques de défaut de cassure de barre.
- ✓ La seconde est une méthode de diagnostic pour la détection précoce et la localisation du défaut de type court-circuit entre spires dans les enroulements statoriques du MI en utilisant un nouvel indicateur basé sur le "Rapport de l'Energie d'Ondelettes Discrètes" (REOD) des trois courants statoriques.

Pour tester l'efficacité des deux approches proposées, plusieurs essais expérimentaux ont été réalisés dans différentes conditions de fonctionnement du MI.

2.2 Diagnostic du défaut rotorique du MI par la méthode Hilbert-FFT

2.2.1 Méthode Hilbert-FFT (HFFT)

La HFFT est une technique basée sur l'extraction de l'enveloppe du signal par la Transformation d'Hilbert (TH) puis son traitement par la FFT. Cette technique est utilisée pour le diagnostic des machines rotatives dans le cas des signaux stationnaires et non stationnaires [9]. La TH est définie comme une convolution d'un signal $x(t)$ avec la fonction $1/t$, comme le montre l'équation suivante [6, 7, 10, 11]:

$$\text{TH}(x(t)) = y(t) = \frac{1}{\pi.t} \times x(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (2.1)$$

La TH d'un signal $x(t)$ peut s'écrire sous la forme [6, 12]:

$$\vec{x}(t) = x(t) + jy(t) = A(t)e^{j\varphi(t)} \quad (2.2)$$

Où $y(t)$ représente la TH du signal $x(t)$. Le signal $\vec{x}(t)$ est appelé signal analytique. Le signal modulant en amplitude $A(t)$ du signal temporel est l'amplitude instantanée de $\vec{x}(t)$, calculée à l'aide de la relation suivante :

$$A(t) = \sqrt{x^2(t) + y^2(t)} \quad (2.3)$$

La phase $\varphi(t)$ du signal modulant est calculée par l'expression suivante :

$$\varphi(t) = \arctan(y(t)/x(t)) \quad (2.4)$$

Le calcul du module du signal analytique $\vec{x}(t)$ donne l'enveloppe du signal [13].

La FFT est utilisée dans le diagnostic pour extraire différentes composantes du spectre des signaux concernant les défauts. Mais à faible glissement, cette approche n'est pas en mesure de fournir de bons renseignements, surtout dans le cas du défaut de cassure de barres rotoriques, car des fréquences peuvent être masqués par le chevauchement avec la fréquence fondamentale, [8, 10, 14] . Pour cela, la HFFT est utilisée comme une solution à ce problème. Par contre, la FFT a de bonnes caractéristiques pour le diagnostic des défauts dans le MI comme [12, 13] :

- la valeur de fréquence positive du signal d'origine est maintenue tandis que les fréquences négatives sont annulées,
- l'amplitude $A(t)$ contient les basses fréquences du signal original et les hautes fréquences dans la phase $\varphi(t)$ du signal analytique.

Dans cette étude, la HFFT est appliquée au courant statorique, afin de détecter les bandes latérales des composantes fréquentielles du défaut cassure de barre, même à faible glissement, où la fréquence caractéristique de ce défaut est : $2skf_s$, où, $k = 1, 2, 3, \dots$

2.2.2 Méthodologie générale proposée pour diagnostiquer le défaut cassure de barre rotorique

Le cadre général de la méthode de diagnostic de défaut cassure de barre rotorique proposée est illustré à la Fig. 2.1. L'approche proposée a été mise en œuvre comme suit :

- **Acquisition:** le courant statorique (I_s) dans différentes conditions est acquis à l'aide du capteur de courant qui est connecté à l'interface de la carte DSpace pour enregistrer les données sur le PC.
- **Extraction des caractéristiques de défaut par la méthode HFFT :** à l'aide du logiciel Matlab, la HFFT a été appliquée au signal acquis en extrayant l'enveloppe du courant ($I_{s_enveloppe}$) par HT puis en le traitant par FFT.
- **Sélection des caractéristiques et décision :** l'amplitude (A_{bb}) et la fréquence (f_{bb}) correspondant à l'harmonique $2sf_s$ extraite de $I_{s_enveloppe}$ ont été choisies comme indicateurs de défaut cassure de barre rotorique pour le diagnostic dans différentes conditions de fonctionnement du MI.

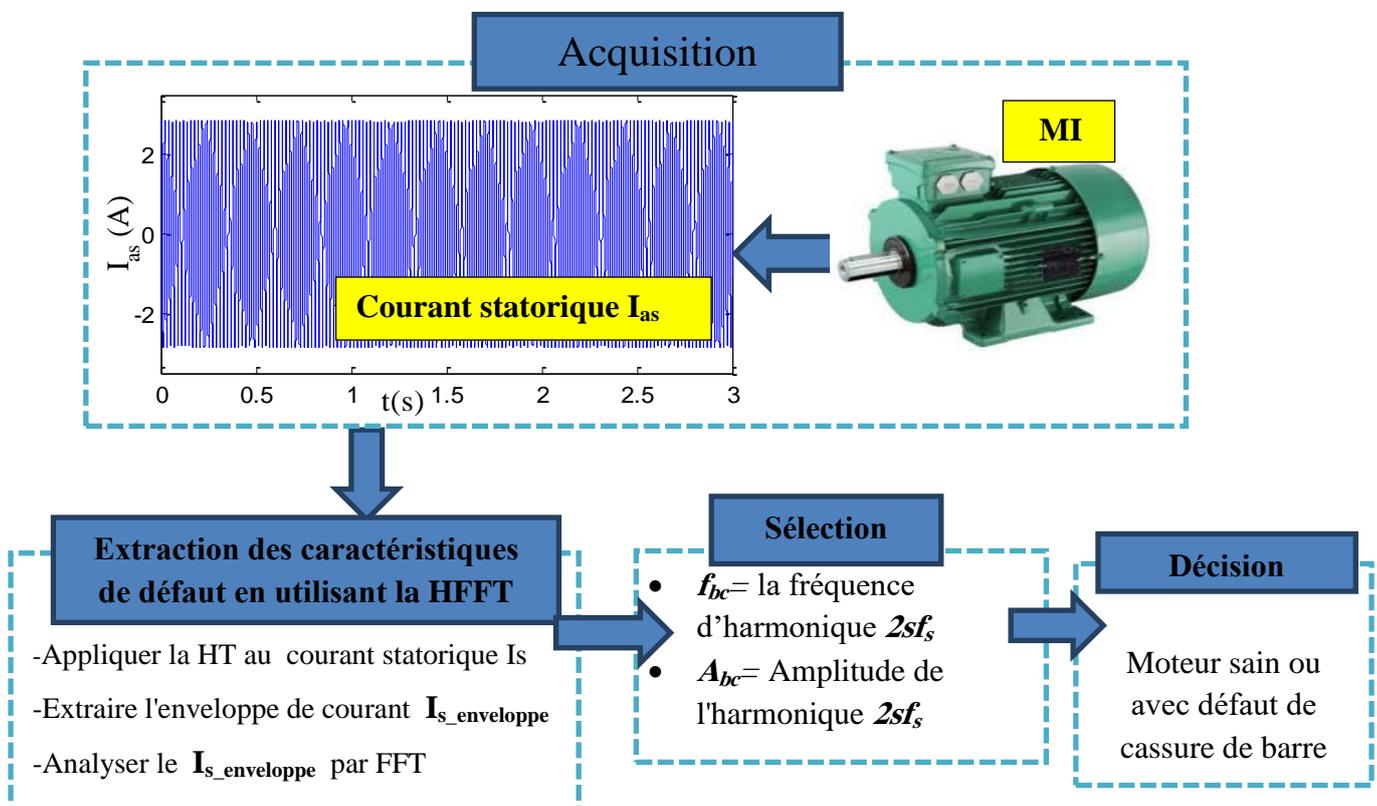


Fig. 2.1 Cadre général de la méthode de détection de défaut de cassure de barre rotorique

2.3 Diagnostic du défaut de court-circuit entre spires statoriques par la méthode du rapport d'énergie d'ondelette discrète (REOD) au MI

2.3.1 Méthode de Rapport d'Énergie d'Ondelette Discrète (REOD)

Cette méthode est basée sur la transformation d'ondelette discrète qui est appliquée aux trois courants statoriques du MI pour extraire l'indicateur de défaut court - circuit entre spires (CCES) afin de détecter et localiser de façon précoce ce défaut.

La **Fig. 2.2** montre le cadre général des étapes d'extraction des indicateurs de défaut qui sont proposées dans cette étude.

Les trois courants statoriques (I_{as} , I_{bs} , et I_{cs}) dans différentes conditions de tests sont d'abord acquis. Ainsi, les trois courants statoriques sont analysés par l'ondelette discrète qui en extrait les signaux de décompositions de détail et d'approximation. Ensuite, l'énergie d'ondelette discrète est calculée pour chaque décomposition en choisissant la valeur la plus élevée. Enfin, les rapports d'énergie d'ondelettes discrètes (REOD) sont calculés pour le niveau choisi précédemment et qui est calculé en divisant ces valeurs d'énergie dans l'ordre direct comme suit [1, 15]:

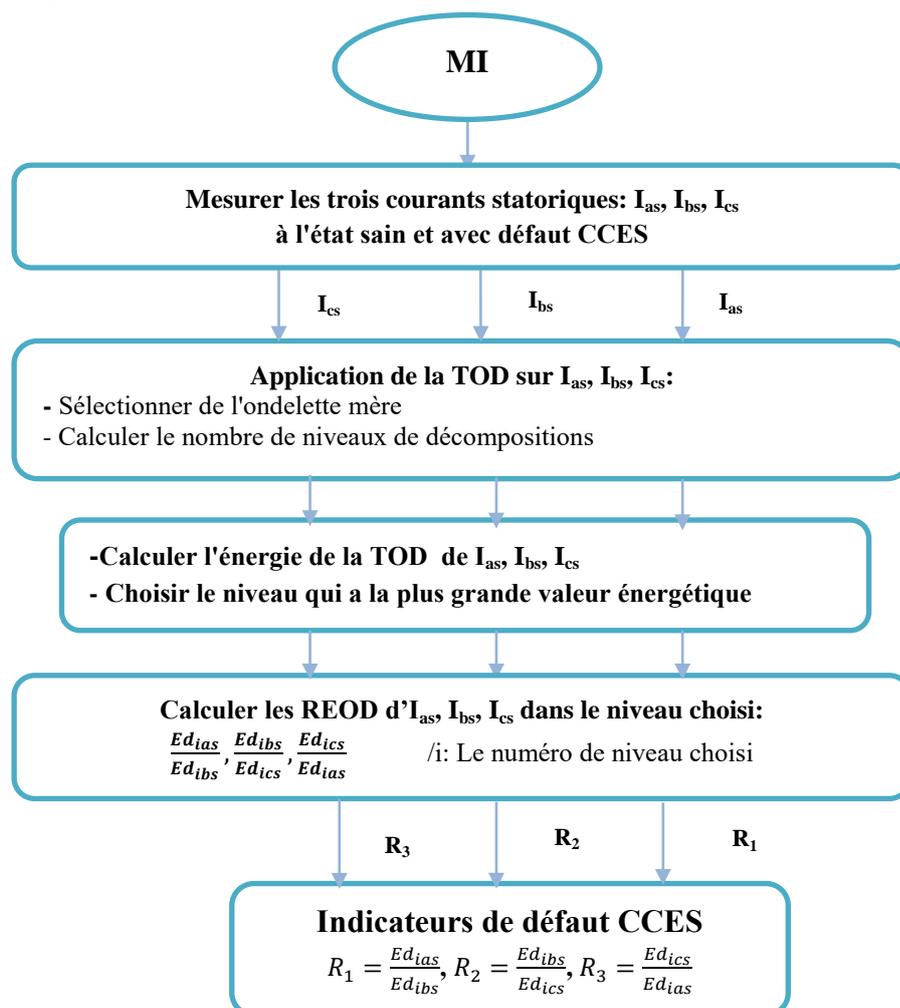


Fig. 2.2 Organigramme d'extraction des indicateurs de défaut CCES

2.3.2 Méthodologie générale proposée pour diagnostiquer le défaut CCES

Les étapes générales de la méthodologie de diagnostic proposée sont représentées sur la **Fig. 2.3** qui est effectuée comme suit :

- **Acquisition:** Les trois courants statoriques (I_{as} , I_{bs} , et I_{cs}) sont acquis dans des conditions de tests différentes.
- **Extraction d'indicateur de défaut CCES par la méthode de REOD:** La TOD est appliquée aux trois courants de lignes afin de décomposer les courants en signaux de détails et d'approximations. Ensuite, l'énergie emmagasinée dans chaque décomposition est calculée pour les trois courants. On choisit ensuite le niveau de décomposition qui a la plus grande valeur énergétique. Enfin, les valeurs de REOD sont calculées dans le niveau choisi pour les trois courants en divisant les valeurs d'énergie dans l'ordre direct comme suit [1, 15] :

($R_1 = \frac{Ed_{ias}}{Ed_{ibs}}$), ($R_2 = \frac{Ed_{ibs}}{Ed_{ics}}$), et ($R_3 = \frac{Ed_{ics}}{Ed_{ias}}$), où, i représente le numéro de niveau choisi. Les trois REOD sont sélectionnés comme indicateurs de défaut CCES dans l'approche de diagnostic proposée.

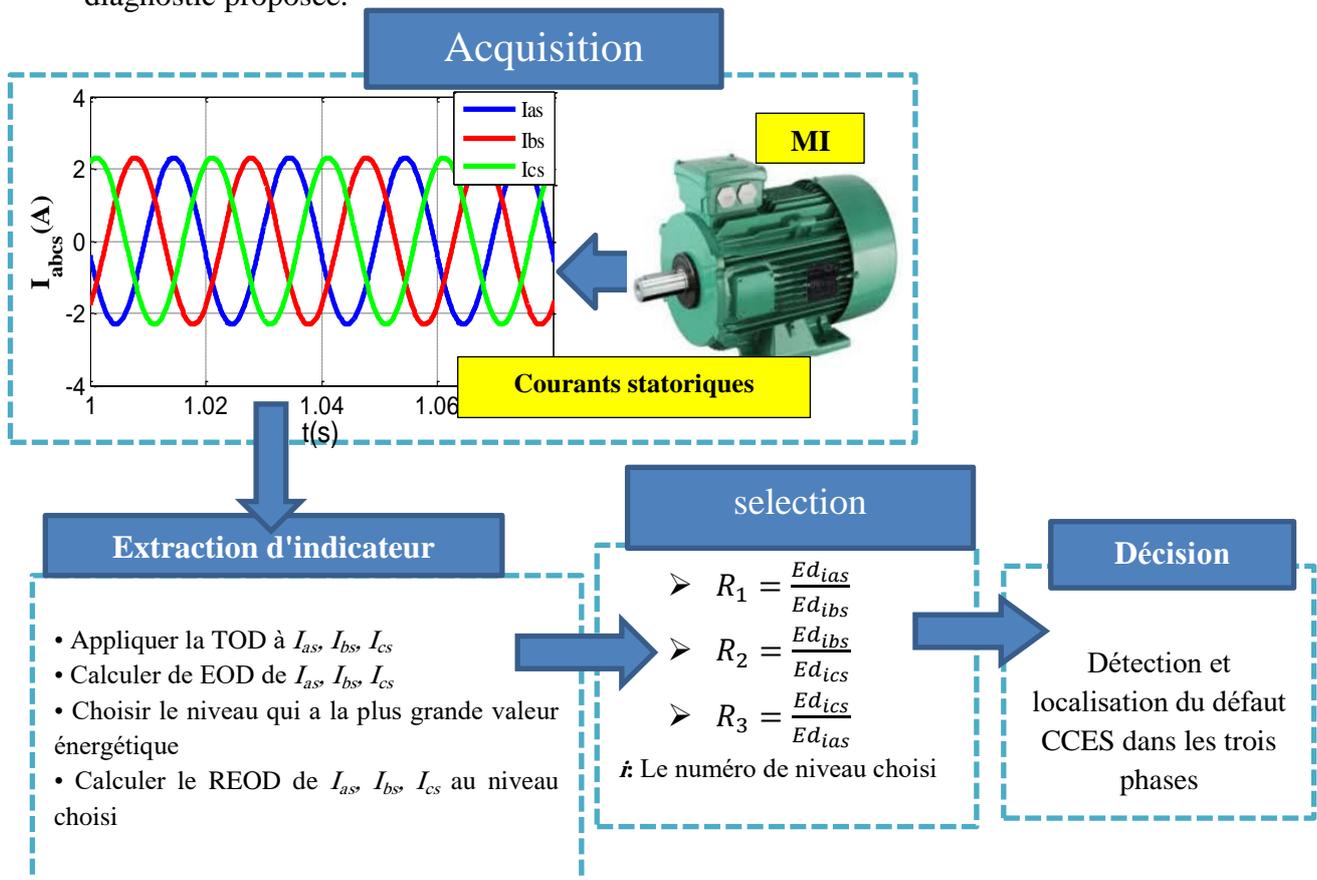


Fig. 2.3 Schéma général de la méthode de diagnostic du défaut de court-circuit entre spires

2.4 Description des bancs d'essais utilisés pour diagnostiquer les défauts rotoriques et statoriques

Les essais expérimentaux ont été réalisés au niveau du Laboratoire de Génie Electrique de Biskra (LGEB).

Afin de valider expérimentalement les méthodes **HFFT** et **REOD** décrites précédemment pour détecter les défauts de barres cassées (BC) rotoriques et court - circuit dans l'enroulement statorique (CCES), respectivement, on présentera dans cette partie la conception de deux bancs d'essais de moteurs triphasés à induction à cage, où les paramètres sont donnés dans l'annexe « A ».

2.4.1 Premier banc d'essai

Ce banc d'essai est destiné à la détection de défaut de barre cassée rotorique, comme montré sur la **Fig. 2.5**. Le descriptif de la configuration expérimentale est donné sur la **Fig. 2.4**. Une série de tests a été effectuée sur trois moteurs à induction à cage d'écureuil de même type. Un moteur est considéré comme sain et les deux autres avec défauts: une barre cassée et deux barres cassées adjacentes. L'alimentation utilisée est un autotransformateur triphasé (0-450) V pour alimenter directement le MI en (Y,400V,50 Hz). La charge mécanique a été appliquée au moteur en raccordant l'arbre à une génératrice à courant continu (DC) d'une puissance nominale de 1 kW. La sortie de la génératrice (DC) est connectée à une charge résistive variable, afin de permettre des tests à différents niveaux de charge. Les mesures des grandeurs du MI sont effectuées à l'aide du capteur de vitesse incrémental et des capteurs de courants connectés au stator. L'acquisition de données est effectuée en utilisant la carte dSpace 1104 avec un DSP TMS32F240 via le logiciel Control Desk. La fréquence d'échantillonnage de l'acquisition de données est de 10 kHz dans tous les résultats expérimentaux. Pour les essais en laboratoire, une rupture de barre rotorique est introduite en perçant un petit trou de 3,1 mm de diamètre dans la barre rotorique, comme le montre la **Fig. 2.6**.

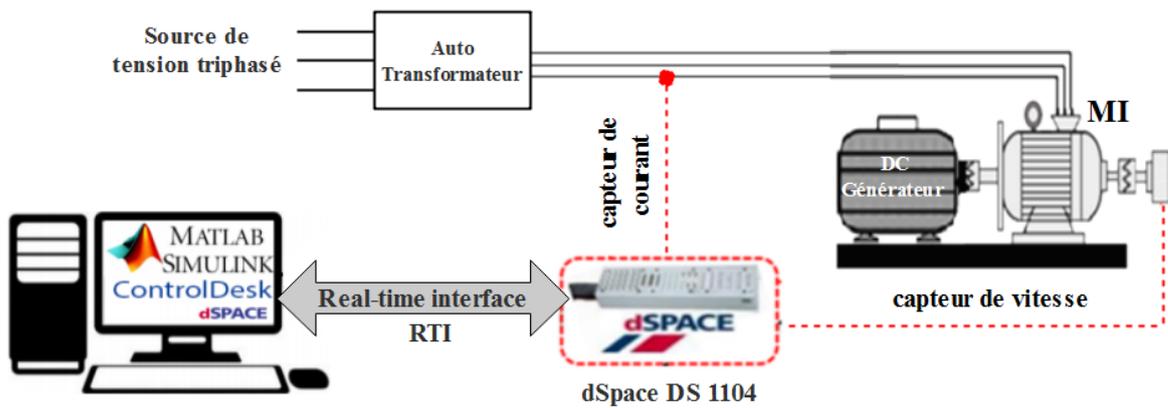


Fig. 2.4 Schéma descriptif du montage expérimental utilisé en diagnostic de défaut de cassure de barre rotorique

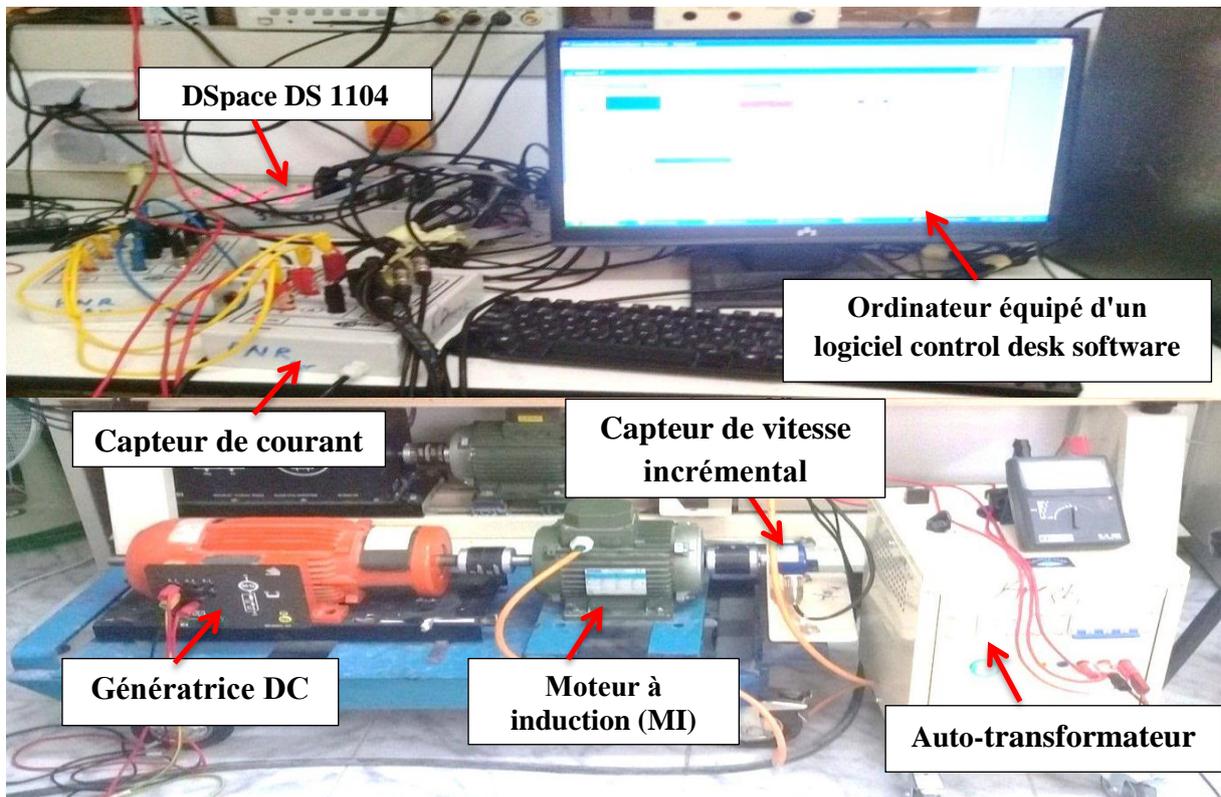


Fig. 2.5 Banc d'essai dédié au diagnostic de défaut cassure de barre rotorique

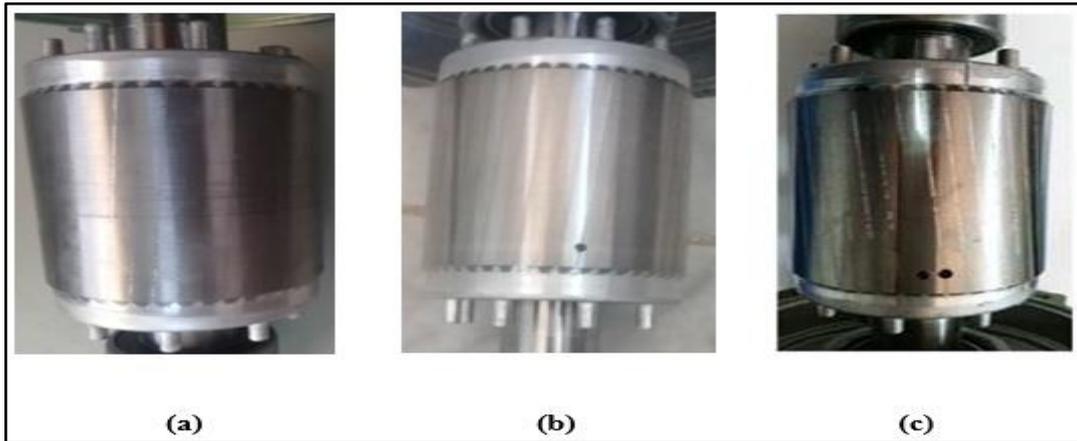


Fig. 2.6 Rotors utilisés dans les tests expérimentaux: (a) sain, (b) une barre cassée (1BC) et (c) deux barres cassées adjacentes (2BC)

2.4.2 Deuxième banc d'essais

Le deuxième banc d'essai (**Fig. 2.7**) est conçu pour la détection de défaut statorique CCES.

La **Fig. 2.8** représente le schéma descriptif du montage expérimental. Les trois indicateurs expérimentaux (REOD) de défaut sont extraits des courants statoriques du MI à l'aide de trois capteurs de courants qui sont reliés à l'interface de la carte dSpace pour enregistrer les données sur le PC. Le logiciel Matlab permet de traiter les trois courants par DWT puis de calculer les trois REOD par un algorithme spécifique.

Afin de créer le défaut CCES dans les tests, l'enroulement statorique est spécialement rembobiné en ajoutant 12 prises connectées aux bobines des trois phases statoriques. Les extrémités de ces fils externes se connectent à une boîte à bornes de moteur qui permet de réaliser le défaut de court-circuit entre spires avec un nombre de tours différents dans les trois phases, comme indiqué sur la **Fig. 2.9**. Le défaut CCES est appliqué pendant 2 secondes à travers un circuit de contrôle du temps par carte dSpace. Ce temps doit être court pour pouvoir utiliser le moteur plus d'une fois dans les tests. Notre moteur est conçu pour effectuer des défauts avec un nombre faible et élevé de spires court-circuitées.

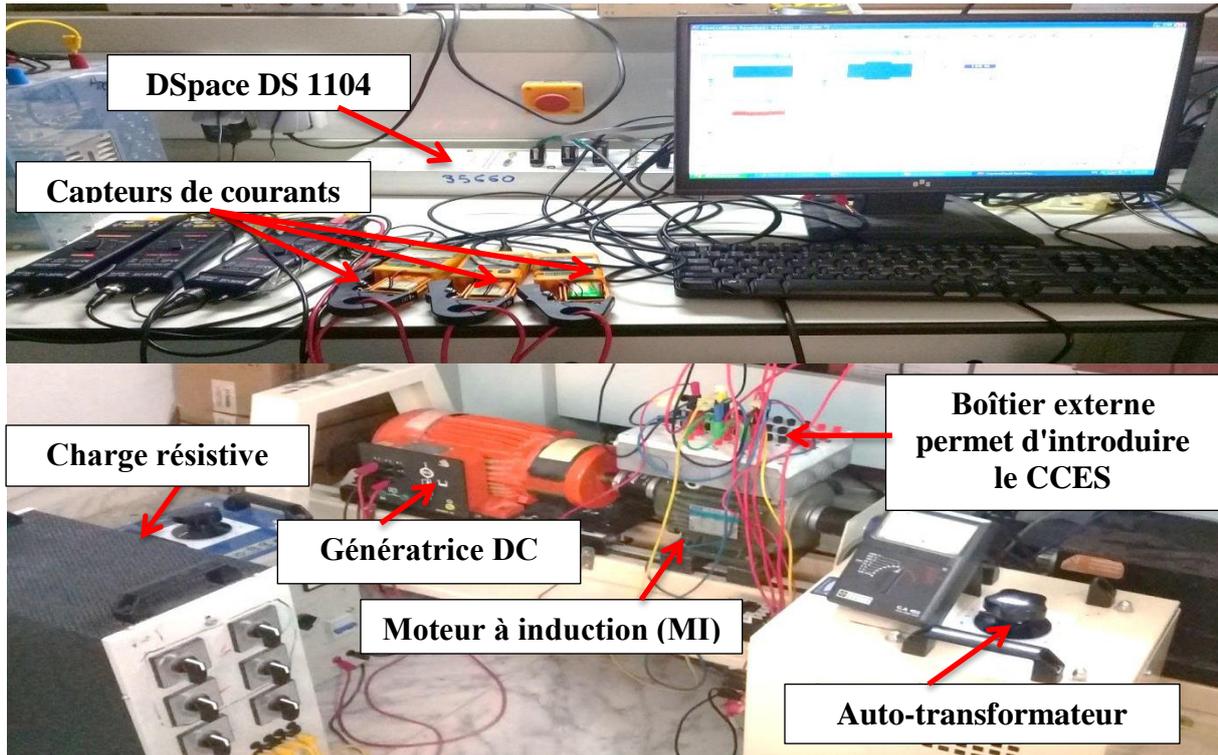


Fig. 2.7 Banc d'essai dédié au diagnostic de défaut court-circuit entre spires

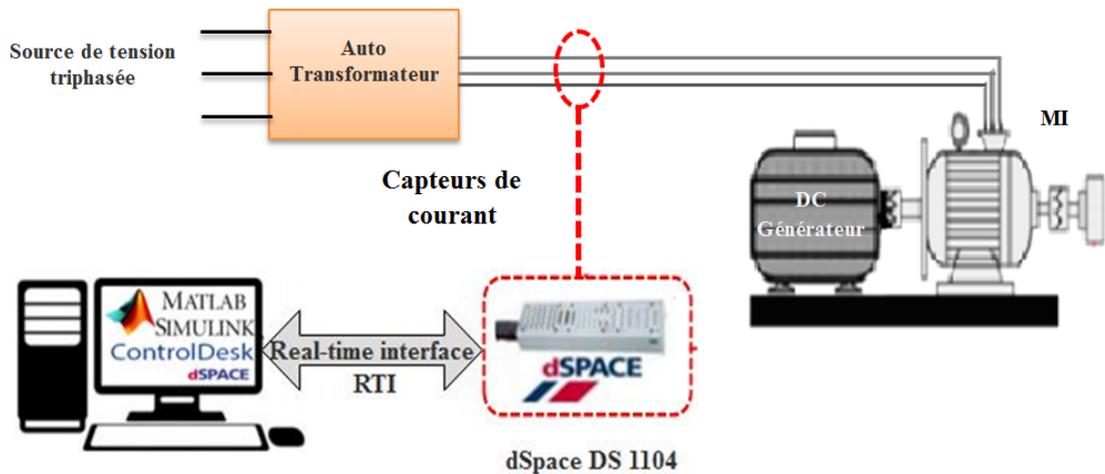


Fig. 2.8 Schéma descriptif du montage expérimental utilisé en diagnostic de défaut CCES

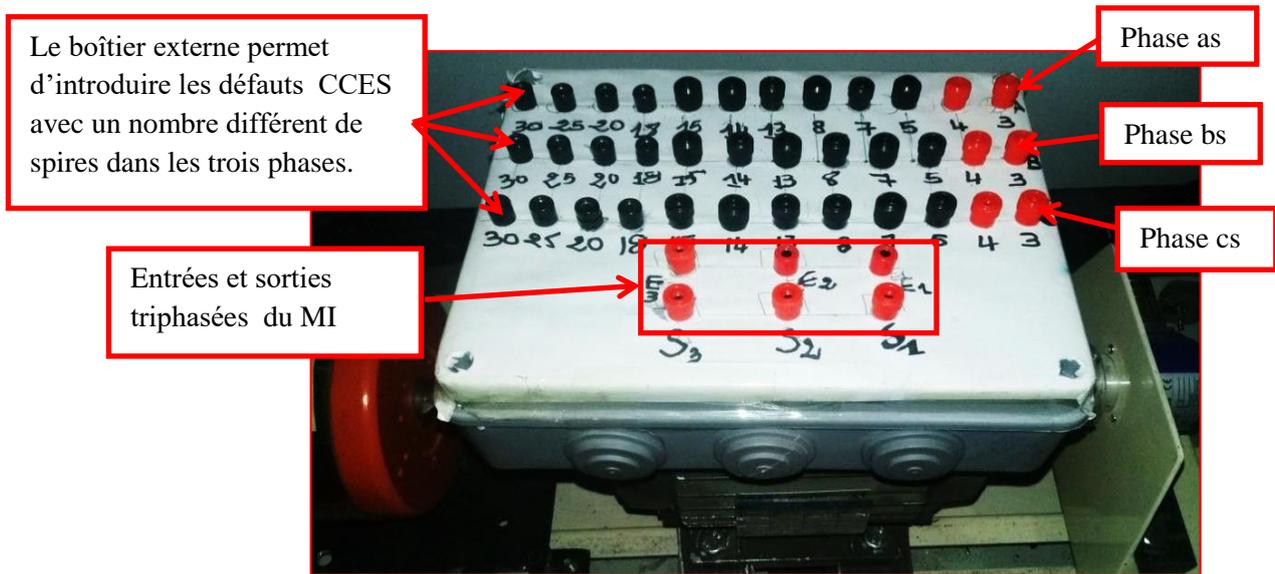


Fig. 2.9 MI spécialement rembobiné pour faire les essais de court-circuit entre spires en trois phases

2.5 Résultats expérimentaux

2.5.1 Analyse du courant statorique par la méthode HFFT pour détecter le défaut BC

2.5.1.1 Enveloppe du courant statorique

La Fig. 2.10 représente le résultat expérimental du courant statorique avec son enveloppe pour défaut de deux barres cassées (2BC) au rotor du MI. Le défaut cassure de barre rotorique provoque la déformation du champ magnétique dans l'entrefer du moteur, entraînant une modulation séquentielle des courants statoriques. Cette modulation des courants statoriques est ce que l'on appelle « l'enveloppe » qui se répète cycliquement à une vitesse égale au double de la fréquence de glissement ($2sf_s$). Typiquement, la transformation HT est utilisée pour extraire l'enveloppe du courant pour détecter ce défaut.

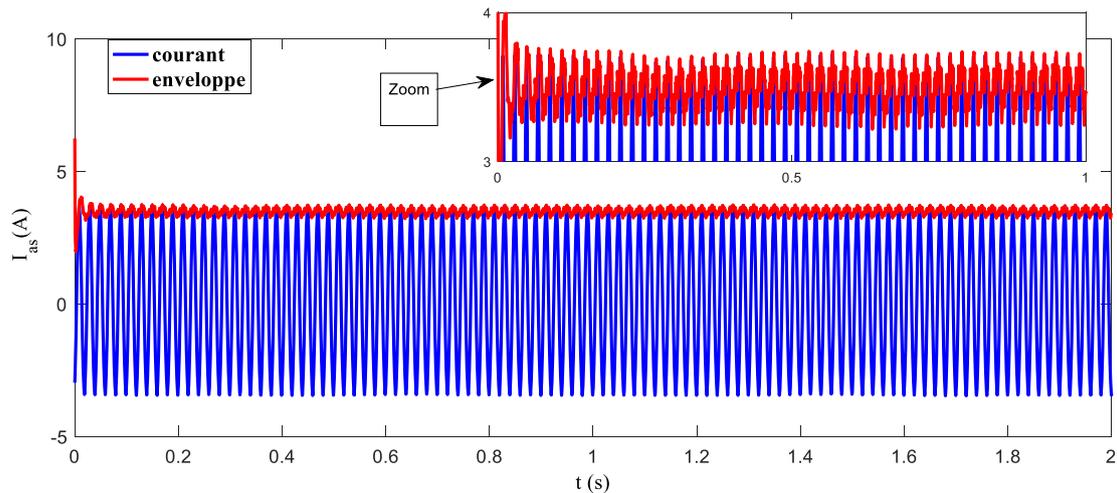


Fig. 2.10 Courant statorique et son enveloppe pour défaut deux barres cassées.

2.5.1.2 Traitement de l'enveloppe par la FFT

La **Fig. 2.11 (a, b et c)** représente les résultats expérimentaux de l'analyse spectrale de l'enveloppe du courant statorique de la phase a_s pour les états sain et défectueux (une barre cassée (1BC) et deux barres cassées (2BC)) sous trois charges différentes: faible charge, demi-charge et pleine charge.

A l'état sain, (**Fig. 2.11 -a**), on observe la présence de l'harmonique $2sf_s$ de faible amplitude, qui correspond à celui créé par le défaut BC. L'apparition de cet harmonique est le résultat de l'asymétrie naturelle du rotor, par exemple des bulles dans les barres du rotor lors de l'étape de moulage, ce qui génère une légère perturbation dans la répartition du flux magnétique dans l'entrefer. Parfois, d'autres phénomènes, comme l'oscillation de la charge, qui contribuent également à fait d'apparaître cet harmonique.

Dans les états défectueux (**Fig. 2.11 -b,c**), on observe que la fréquence et l'amplitude de l'harmonique $2sf_s$ sont très affectées par le défaut de cassure de barre rotorique, où il existe une relation directe entre les deux valeurs (la fréquence et l'amplitude) et le nombre de barres cassées. De plus, ils sont très sensibles aux charges.

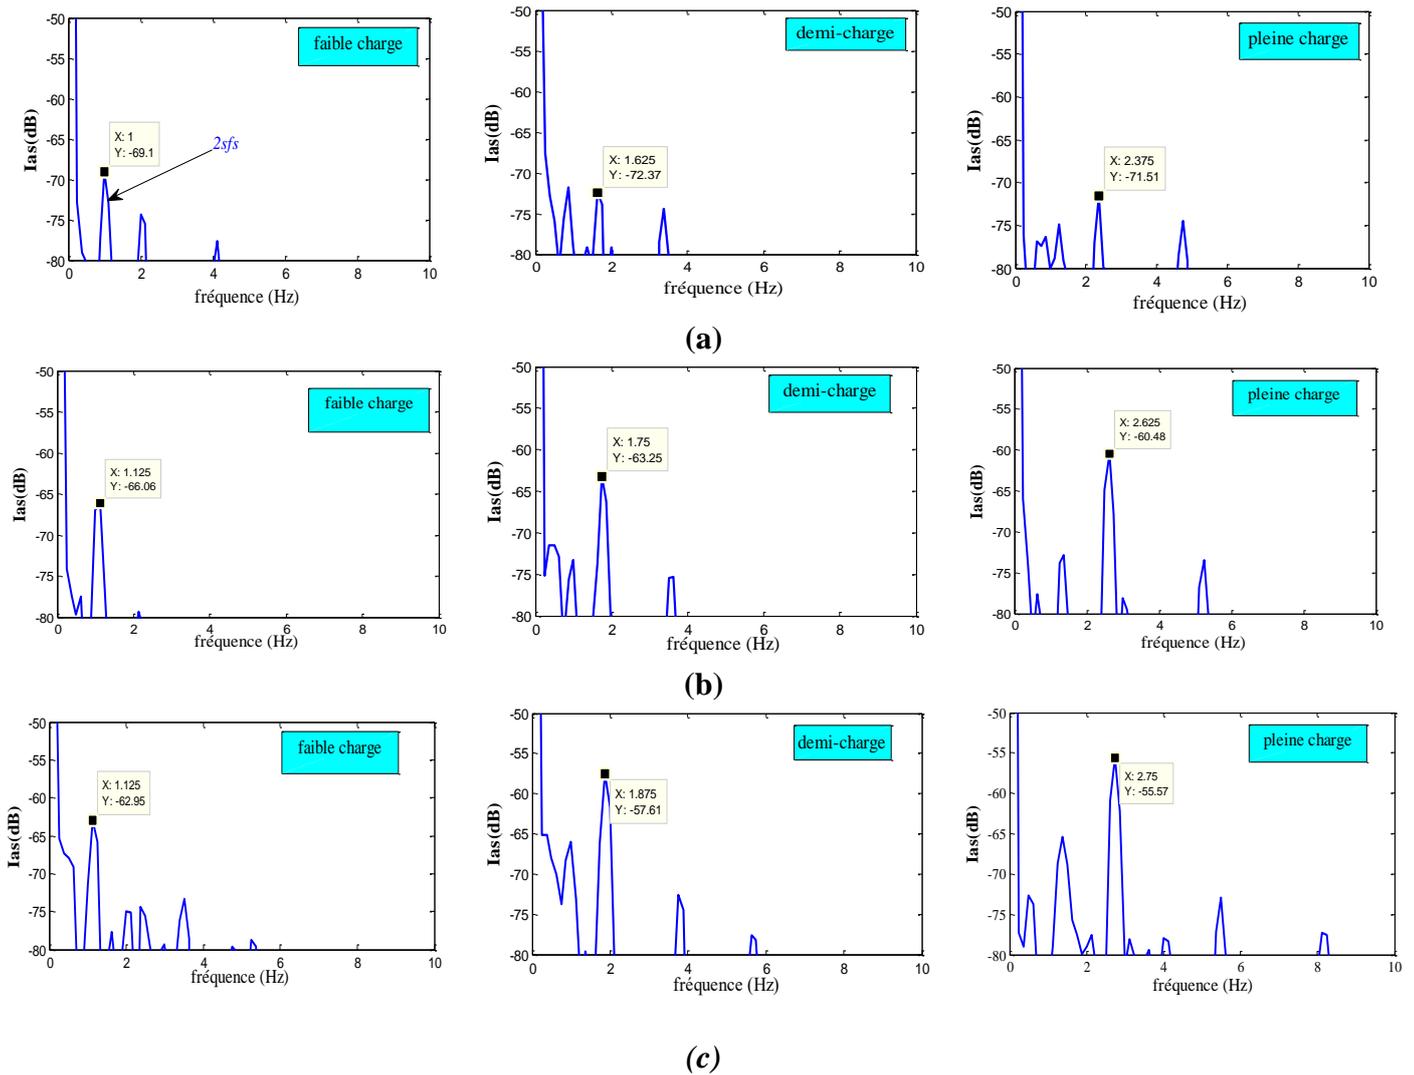


Fig. 2.11 Analyse spectrale de l'enveloppe du courant statorique sous différentes charges (faible charge, demi-charge et pleine charge) pour les états: (a) sain, (b) défaut 1BC et (c) défaut 2BC

2.5.2 Analyse des courants statoriques par la méthode REOD pour détecter le défaut CCES

2.5.2.1 Courants statoriques avec défaut CCES

La **Fig. 2.12** représente les résultats expérimentaux du courant statorique triphasé (I_{as} , I_{bs} , et I_{cs}) pour les cas : sain et en défaut de court-circuit de 18 spires dans les phases : as, bs et cs de l'enroulement statorique du MI, sous une charge moyenne. Par rapport aux quatre états des courants statoriques, on constate que, dans les états de défauts, une augmentation de l'amplitude du courant de la phase où le défaut s'est produit et une hauteur relativement faible pour les autres phases.

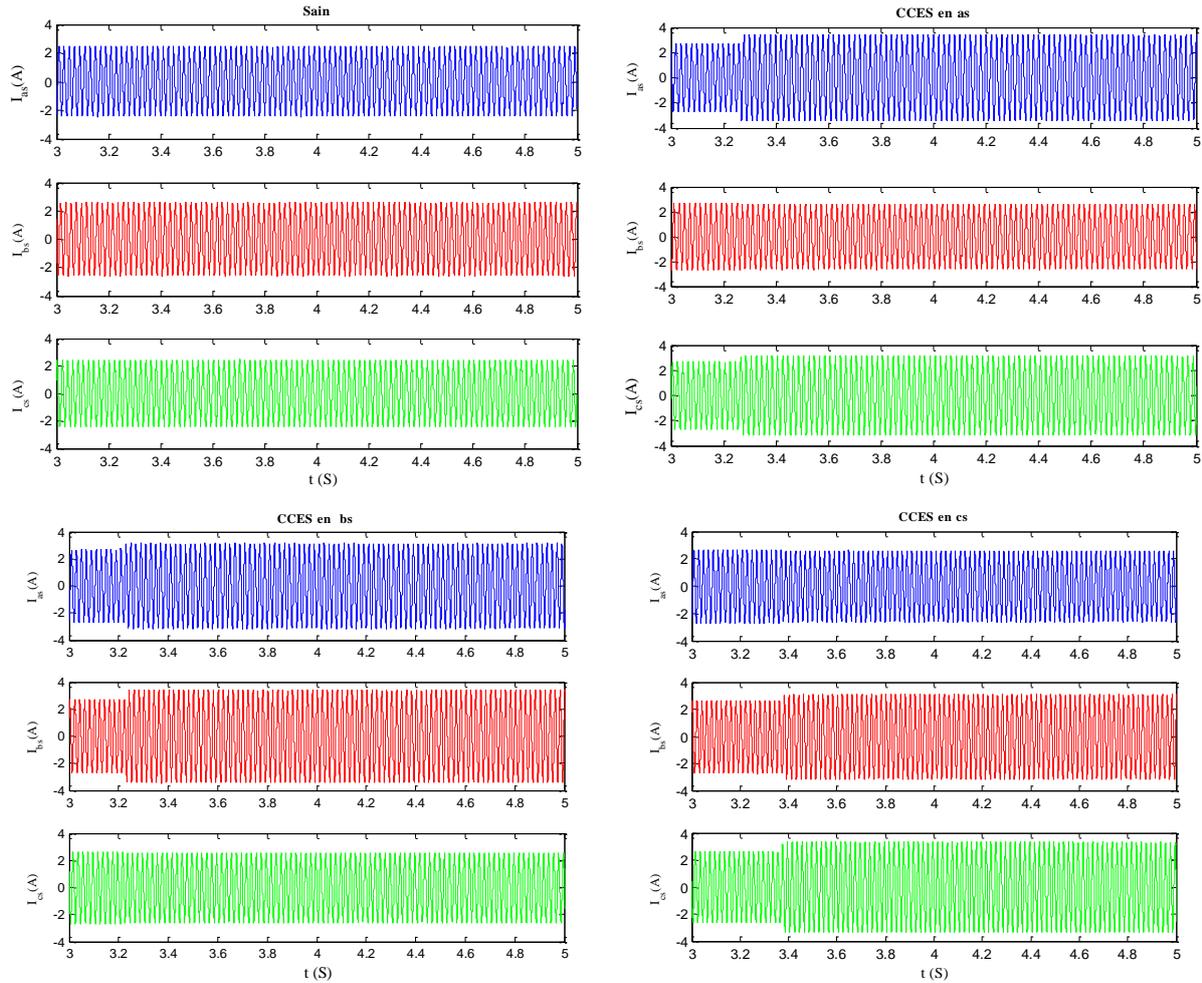


Fig. 2.12 Courants statoriques pour: les états sain et avec défaut CCES dans les 3 phases: *as*, *bs* et *cs*

2.5.2.2 Analyse des courants statoriques par l'ondelette discrète et leur énergie

Dans ce travail, la décomposition multi résolution de la TOD est basée sur l'ondelette mère « Daubechies 44 » (db44) qui donne de bonnes performances dans la décomposition et la reconstruction des signaux. Le nombre de niveaux de décomposition est basé sur l'expression (2.5):

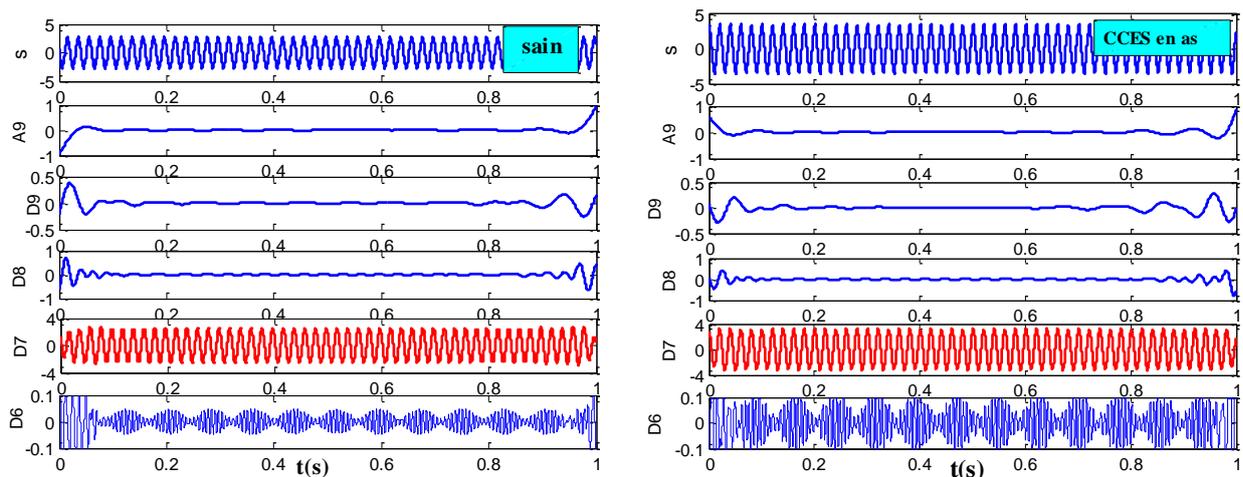
$$n_{ls} > \text{int}\left(\frac{\log(\frac{f_e}{f_s})}{\log(2)}\right) + 1 \quad (2.5)$$

Où, n_{ls} est le nombre de niveaux de décomposition, $f_e = 10$ kHz: la fréquence d'échantillonnage du courant analysé et $f_s = 50$ Hz: la fréquence fondamentale du courant, Le nombre de décompositions est donc égal à 9.

Tableau 2.1 Différentes bandes de fréquences obtenues par la décomposition en ondelettes pour 9 niveaux.

Coefficient	bande de fréquence (Hz)
D1	2500-5000
D2	1250-2500
D3	625-1250
D4	312.5-625
D5	156.25-312.5
D6	78.125-156.25
D7	39.0625-78.125
D8	19.531-39.0625
D9	9.765-19.531
A9	0-9.765

La **Fig. 2.13** représente les résultats expérimentaux des décompositions de TOD du courant statorique en phase as. Les décompositions de détails et d'approximations sont obtenues par l'ondelette mère "db44", pour les cas: sain et avec défauts CCES pour les trois phases (as, bs, et cs) avec 18 spires court-circuitées sous une charge moyenne (3,5 Nm). On note différentes perturbations dans les coefficients d'ondelettes dans les signaux de décompositions (D6, D7, D8, D9 et A9) pour les quatre cas. La décomposition au niveau 7 (D7) représente la plus grande où elle est analogue au signal d'origine du courant car elle contient la fréquence fondamentale 50Hz comme indiqué dans le **Tableau 2.1**.



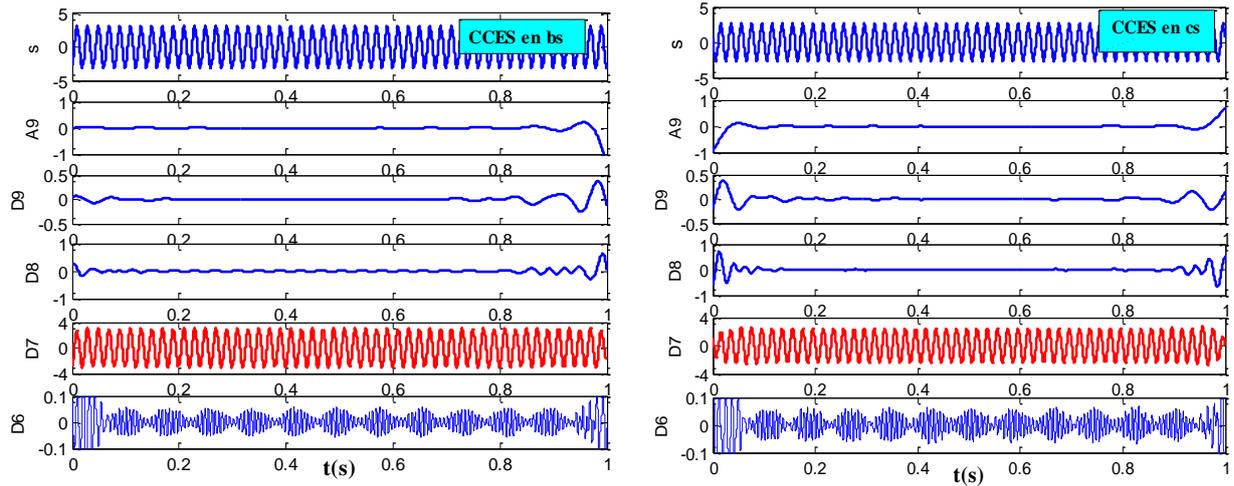
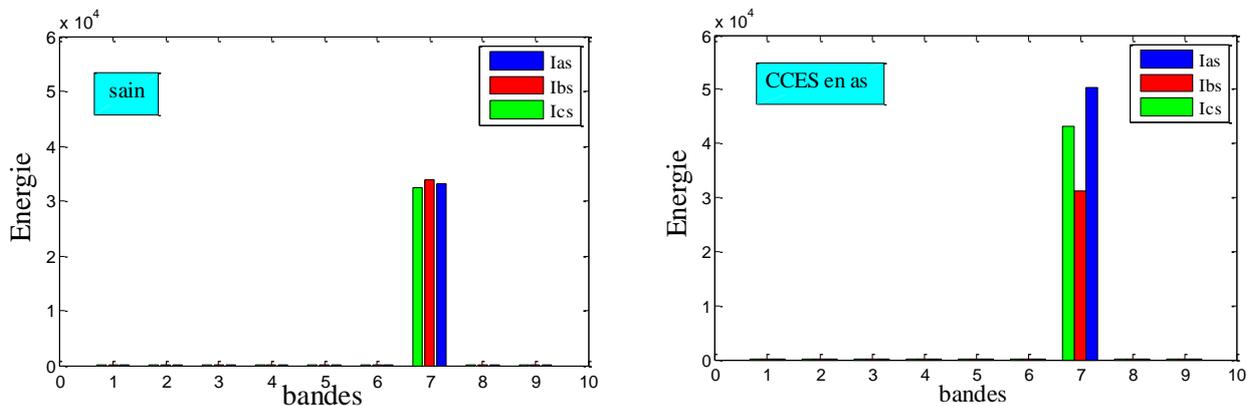


Fig. 2.13 TOD du courant statorique pour l'état sain, et défauts CCES dans les 3 phases : as, bs et cs.

La **Fig. 2.14** représente les valeurs d'énergie d'ondelette discrète (EOD) issues de la décomposition de détail de trois courants statoriques (I_{as} , I_{bs} et I_{cs}) sous une charge moyenne et pour les cas: sain et avec défauts CCES dans les phases (as, bs et cs) avec 18 spires court-circuitées. On remarque que l'énergie emmagasinée dans Ed7 a la plus grande valeur car elle se trouve à la marge de la bande de fréquences [39.0625-78.125], qui contient la fréquence fondamentale, comme indiqué dans le **Tableau 2.1**. Le comportement des valeurs Ed7 peut être suivi dans le diagnostic sans avoir à suivre toutes les quantités de niveaux d'énergie.



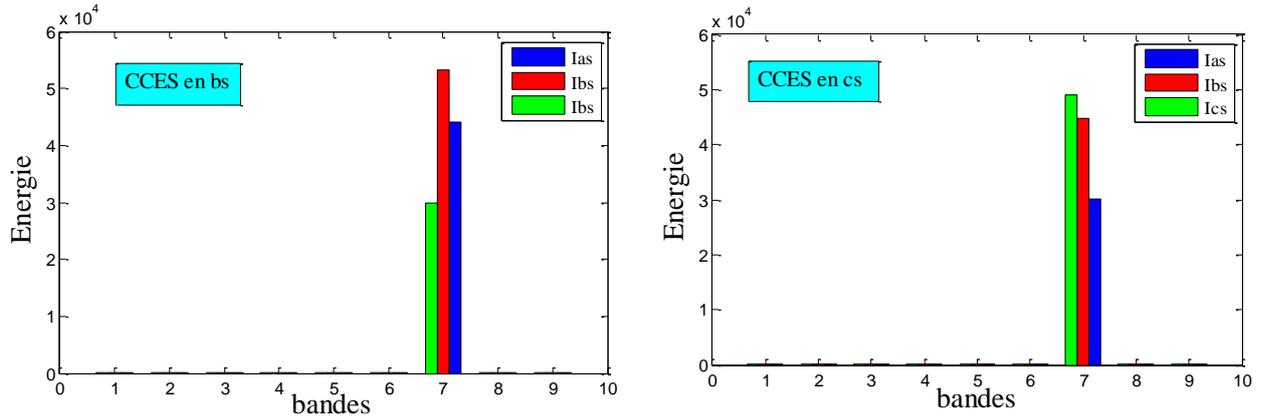


Fig. 2.14 Variation de l'énergie du courant statorique dans les bandes de fréquence pour les états sain et avec défauts CCES dans les phases : as, bs et cs.

2.5.2.3 Extraction de REOD

En se basant sur les résultats obtenus à la **Fig. 2.14**, le niveau 7 qui contient la valeur d'énergie la plus élevée (E_{d7}) est choisi dans tous les cas pour calculer les valeurs de REOD, comme expliquées précédemment dans le paragraphe (2.3.1).

La **Fig. 2.15** montre les résultats expérimentaux de REOD pour les trois courants statoriques, à savoir E_{d7as} / E_{d7bs} , E_{d7bs} / E_{d7cs} et E_{d7cs} / E_{d7as} , relativement au niveau 7 dans les états sains et avec défauts CCES dans les trois phases (18 spires court-circuitées) sous une charge moyenne. On constate que à l'état sain, les valeurs des trois rapports sont approximativement égales à « 1 ». Contrairement aux états défectueux, les valeurs des trois rapports varient en fonction du lieu du défaut. Cette variation se produit selon une permutation circulaire directe ($E_{d7as} / E_{d7bs} \rightarrow E_{d7bs} / E_{d7cs} \rightarrow E_{d7cs} / E_{d7as}$). Ainsi, on remarque qu'avec ces indicateurs, la phase défectueuse peut être facilement détectée et localisée.

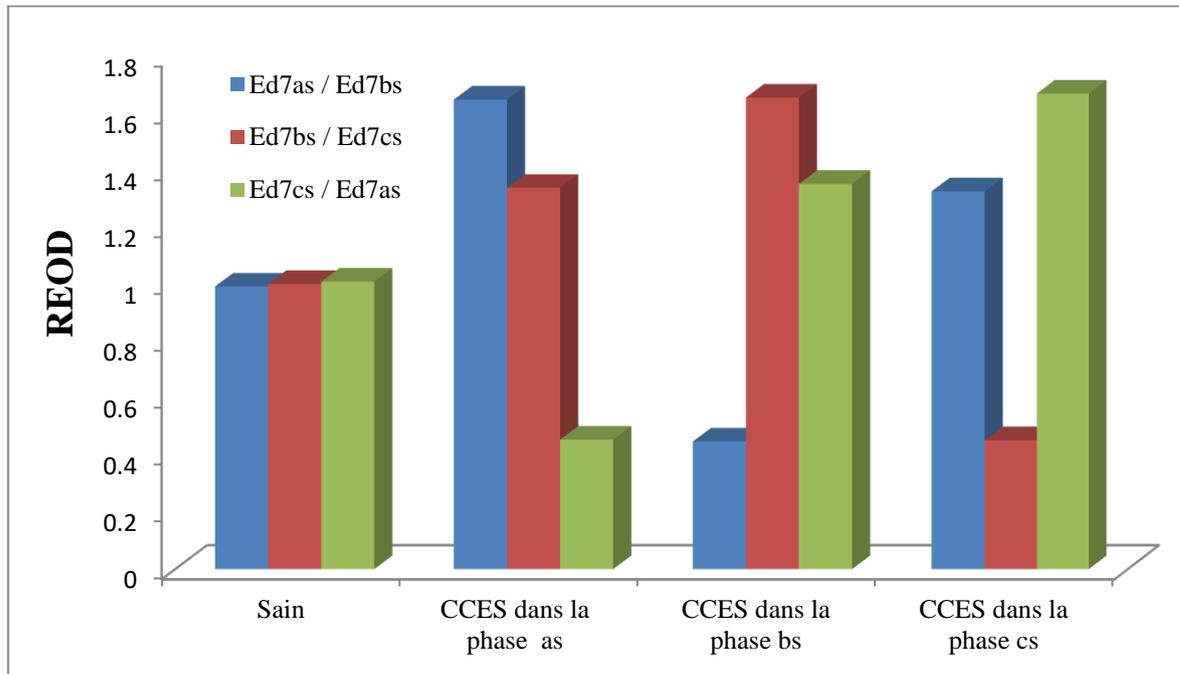


Fig. 2.15 Valeur de REOD calculée dans le niveau 7 pour l'état sain et avec défauts CCES dans les phases : as, bs et cs.

2.5.2.4 Caractéristiques des REOD au niveau 7

La **Fig. 2.16** montre les trois REOD de Ed7 dans plusieurs cas de défauts CCES dans les phases: as (**Fig. 2.16-a**), bs (**Fig. 2.16-b**) et cs (**Fig. 2.16-c**) sous une charge moyenne en MI. Les résultats obtenus indiquent que le REOD ne montre aucune interférence entre les valeurs, même avec diverses conditions défectueuses. Pour cela, on peut affirmer que les trois REOD de l'Ed7 sont des caractéristiques distinctives et peuvent être utilisées comme un indicateur efficace pour détecter la défaillance CCES et localiser la phase où cette défaillance s'est produite. De plus, ils fournissent des informations sur la gravité du défaut (le nombre de spires défectueuses). Ainsi, les trois REOD peuvent fournir des données suffisantes pour le système de diagnostic intelligent pour assurer une surveillance efficace.

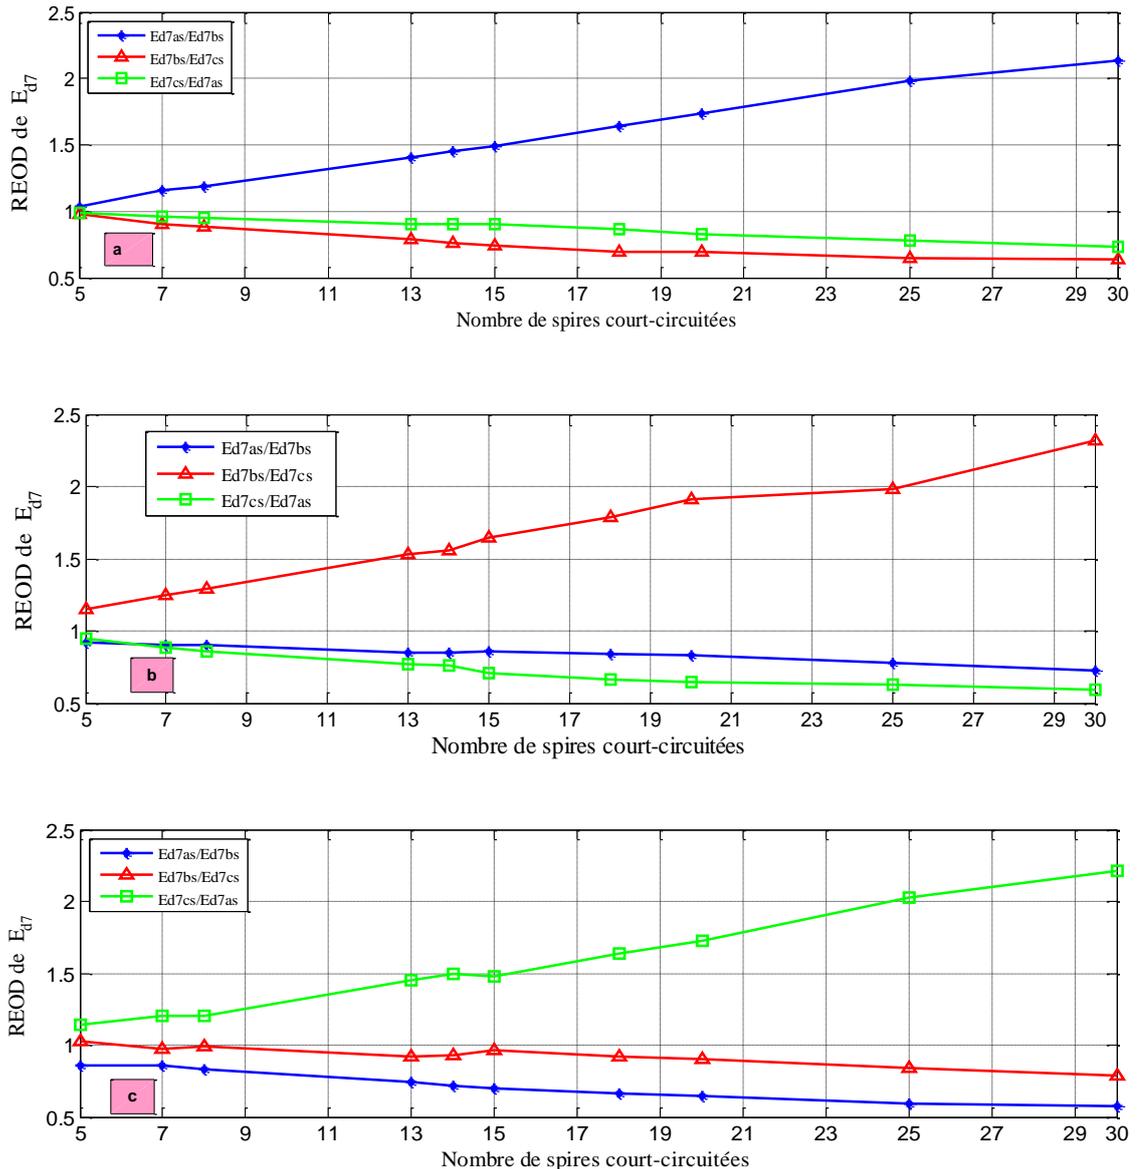


Fig. 2.16 Evolution des valeurs de REOD dans le niveau 7 en fonction des spires en court-circuit sur les phases: (a) a_s , (b) b_s et (c) c_s

2.6 Conclusion

Ce chapitre a proposé deux approches de diagnostic efficaces pour détecter d'une façon précoce les défauts de cassure de barre rotorique et court-circuit entre spires statoriques dans différentes conditions du MI.

La première approche est basée sur la méthode HFFT qui est appliquée à l'aide de HT pour extraire l'enveloppe du courant statorique puis la traiter par la FFT. La fréquence et l'amplitude du spectre $2sf_s$ de l'enveloppe ont été choisies comme indicateurs de défaut de barre cassés. L'approche proposée a été mise en œuvre par des tests expérimentaux qui ont été utilisés sur

trois moteurs à induction. Le premier avait une barre cassée, le second deux barres adjacentes cassées, le troisième était un moteur sain. Les tests expérimentaux sont menés pour différentes charges. Les résultats expérimentaux ont montré que l'amplitude et la fréquence de l'harmonique $2sf_s$ avaient une sensibilité élevée au défaut de cassure de barre. Pour cela, ils ont été choisis comme indicateurs de défaut qui ont permis des résultats efficaces et précis pour détecter le défaut même à faibles charges.

La deuxième approche est utilisée pour la détection et la localisation précoce du défaut de court-circuit entre spires statoriques dans le MI à l'aide d'un nouvel indicateur basé sur le rapport d'énergie de l'ondelette discrète (REOD) des trois courants statoriques, qui sont utilisés comme indicateurs pour obtenir des informations simultanées sur le défaut et son emplacement. Cette approche a été vérifiée par les résultats expérimentaux. Les résultats obtenus garantissent la précision et la fiabilité de la technique proposée pour le diagnostic des défauts CCES dans le MI. Cela peut permettre de détecter des nombres élevés et faibles de spires court-circuitées et localiser la phase défectueuse même dans diverses conditions.

Les résultats obtenus dans ce chapitre ont démontré l'efficacité des deux approches de diagnostics proposés : le HFFT pour diagnostiquer les défauts de cassure de barre rotorique et le REOD pour la détection et la localisation de défaut de court-circuit entre spires au stator du MI. L'automatisation de la détection et la classification de défauts étudiés en MI, à travers les techniques d'intelligence artificielle comme les réseaux de neurones (ANN) et le Neuro-Flou (ANFIS) basée sur l'approche précédente (HFFT et REOD) seront l'objectif des troisième et quatrième chapitres.

2.7 Bibliographie

1. Cherif, H., et al., *Early detection and localization of stator inter-turn faults based on discrete wavelet energy ratio and neural networks in induction motor*. Energy, 2020. **212**: p. 118684.
2. Cherif, H., et al. *Stator inter turns fault detection using discrete wavelet transform*. in *Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED), 2015 IEEE 10th International Symposium on*. 2015. IEEE.
3. Bessam, B., et al., *Wavelet transform and neural network techniques for inter-turn short circuit diagnosis and location in induction motor*. International Journal of System Assurance Engineering and Management, 2017. **8**(1): p. 478-488.

4. Sahraoui, M., et al., *Detection of inter-turn short-circuit in induction motors using Park–Hilbert method*. International Journal of System Assurance Engineering and Management, 2014. **5**(3): p. 337-351.
5. Li, D.Z., W. Wang, and F. Ismail, *An intelligent harmonic synthesis technique for air-gap eccentricity fault diagnosis in induction motors*. Chinese Journal of Mechanical Engineering, 2017. **30**(6): p. 1296-1304.
6. Bessam, B., et al., *Detection of broken rotor bar faults in induction motor at low load using neural network*. ISA transactions, 2016. **64**: p. 241-246.
7. Talhaoui, H., et al., *Experimental diagnosis of broken rotor bars fault in induction machine based on Hilbert and discrete wavelet transforms*. The International Journal of Advanced Manufacturing Technology, 2018. **95**(1-4): p. 1399-1408.
8. Laala, W., S.-E. Zouzou, and S. Guedidi, *Induction motor broken rotor bars detection using fuzzy logic: experimental research*. International Journal of System Assurance Engineering and Management, 2014. **5**(3): p. 329-336.
9. Vedreño Santos, F.J., *Diagnosis of electric induction machines in non-stationary regimes working in randomly changing conditions*. 2013.
10. Harzelli, I., A. Menacer, and T. Ameid, *A fault monitoring approach using model-based and neural network techniques applied to input–output feedback linearization control induction motor*. Journal of Ambient Intelligence and Humanized Computing, 2019: p. 1-20.
11. Rangel-Magdaleno, J., et al., *Hilbert spectrum analysis of induction motors for the detection of incipient broken rotor bars*. Measurement, 2017. **109**: p. 247-255.
12. Puche-Panadero, R., et al., *Improved resolution of the MCSA method via Hilbert transform, enabling the diagnosis of rotor asymmetries at very low slip*. IEEE Transactions on Energy Conversion, 2009. **24**(1): p. 52-59.
13. Karmakar, S., et al., *Induction motor fault diagnosis*. Vol. 25. 2016: Springer.
14. Ameid, T., et al., *Discrete wavelet transform and energy eigen value for rotor bars fault detection in variable speed field-oriented control of induction motor drive*. ISA transactions, 2018. **79**: p. 217-231.
15. Khechekhouche, A., et al., *Experimental diagnosis of inter-turns stator fault and unbalanced voltage supply in induction motor using MCSA and DWER*. Periodicals of Engineering and Natural Sciences, 2020. **8**(3): p. 1202-1216.

Chapitre 3

Diagnostic des défauts rotoriques et statoriques
du moteur à induction par les réseaux de neurones

3.1 Introduction

Les réseaux de neurones (RN) ont gagné en popularité par rapport aux autres techniques en raison de leur capacité de généralisation [1], ce qui signifie qu'ils sont capables de fonctionner de manière satisfaisante même pour des défauts invisibles. Les réseaux neuronaux [2] peuvent effectuer des détections de défauts basées sur des mesures et un entraînement sans avoir besoin de modèles mathématiques complexes et rigoureux. De plus, l'interprétation heuristique des conditions motrices que seuls les humains sont parfois capables de faire peut être facilement mise en œuvre dans les réseaux de neurones grâce à un apprentissage supervisé. Pour de nombreux schémas de détection de défaut, des informations redondantes sont disponibles et peuvent être utilisées pour obtenir des résultats plus précis. Ce concept peut être facilement implémenté dans un réseau neuronal exploitant ses fonctionnalités de traitement parallèle à entrées multiples pour améliorer la robustesse des performances du réseau.

L'objectif de ce chapitre est de donner la méthodologie pour la mise en œuvre d'un RN afin d'effectuer la tâche de détection de défaut, de localiser le défaut de court-circuit entre spires d'une même phase au stator et de déterminer le nombre de barres cassées au rotor par trois paradigmes de réseaux de neurones (RN), à savoir, Multi-Layer perceptron (MLP), Radial Basis Function (RBF), et Elman Neural Network (ENN) basée sur les méthodes HFFT et REOD. Dans ce chapitre, on commencera par une présentation des RN et leurs différentes architectures, ainsi que la procédure de détection et classification des deux défauts court-circuit entre spires statoriques et cassures de barres rotoriques par RN. À la fin du chapitre, un système complet de surveillance avec des tests de performances sera présenté.

3.2 Réseaux de Neurones utilisés dans le diagnostic des défauts du moteur à induction

En raison de leur capacité à apprendre et à généraliser les relations fonctionnelles non linéaires entre les variables d'entrée et de sortie, les réseaux neuronaux artificiels (RNA), fournissent un mécanisme flexible pour l'apprentissage et la reconnaissance des défauts du système [3].

Le RN est un réseau parallèle constitué principalement d'éléments interconnectés appelés neurones, liés par des connexions appelées biais qui sont assimilées aux synapses du cerveau humain et pondérés par des poids adaptatifs comparables au potentiel synaptique [4]. La fonction d'activation est un élément clé pour le RN. Puisque chaque neurone calcule sa sortie en appliquant sa fonction aux entrées reçues. La réponse du RN dépend de la fonction d'activation. Il peut s'agir

d'une simple fonction de seuil ou d'une fonction tangente, sigmoïdale, hyperbolique ou radiale.... [5] (voir l'annexe B). Le modèle mathématique d'un neurone dans la i ième couche est donné par l'expression (3.1) [6]:

$$y_j^l = f(\sum_i^{n_l} w_{ji}^l x_i + b_j^l) \quad (3.1)$$

Où: x_i les vecteurs d'entrée, w_{ji}^l désigne le poids du neurone j dans la couche l , b_j^l est l'entrée de biais et f est la fonction d'activation.

Dans ce travail, trois réseaux de neurones sont applicables à la détection et la classification des défauts rotoriques et statoriques du MI : réseau multicouche (MLP), réseau Elman Neural Network (ENN) à fonction d'activation softmax et réseau radial basis fonction (RBF).

3.2.1 Réseau multicouche (MLP)

Les réseaux multicouches (Multi-Layer perceptron) (MLP), également appelé "multi-layer feedforward", est la structure la plus utile dans le domaine de la classification. Il se compose de trois couches ou plus : couche d'entrée, couche de sortie et couches intermédiaires (cachées). Chaque neurone d'une couche est connecté à tous les neurones de la couche suivante [7] comme indiqué sur la Fig.3.1. Le nombre de neurones d'entrée et de sortie dépend respectivement des représentations des objets d'entrée et de sortie. Le softmax est choisi comme fonction d'activation car il est principalement utilisé pour les problèmes de multi-classification. La fonction **Softmax** est représentée dans l'équation (3.5) [8]:

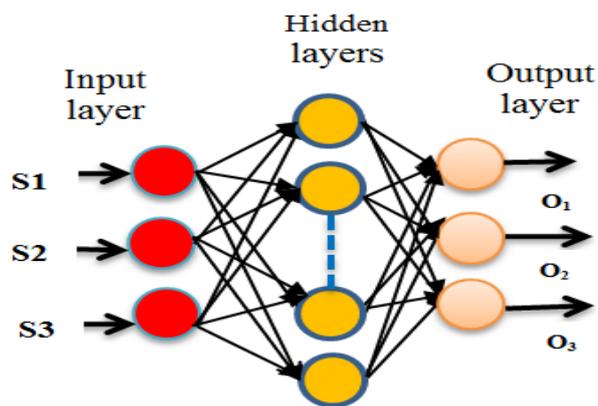


Fig. 3.1 Réseau MLP à trois couches avec 3 entrées, 3 sorties et une couche cachée

3.2.2 Basis Function Neural Network (RBF)

Le réseau de neurones RBF est un réseau feedforward qui se distingue du MLP par sa fonction d'activation de base radiale exprimée comme suit:

$$g(x) = \exp\left(-\frac{\|x - c_i\|^2}{\sigma_i^2}\right) \quad (3.2)$$

Où c désigne le centre de la fonction de base et σ est le rayon de la fonction.

3.2.3 Elman Neural Network (ENN)

Elman Neural Network est un réseau neuronal récurrent, initialement proposé par Elman (Elman 1990). L'une des caractéristiques les plus importantes d'ENN est l'utilisation d'une couche de contexte agissant comme une fonction de mémoire transitoire. La structure de l'ENN est la suivante [8]:

$$y(t) = h(w_3 x(t)) \quad (3.3)$$

Où :

$$x(t) = k(w_1 x_c(t) + w_2 u(t-1)) \text{ , and } x_c(t) = x(t-1) \quad (3.4)$$

Où $y(t)$ est la t^{th} sortie de la couche de sortie, $x(t)$ représente la t^{th} sortie de la couche cachée, et $x_c(t)$ est la t^{th} sortie de la couche de contexte qui fonctionne comme une mémoire à court terme fournissant l'état précédent de la couche cachée. w_1 , w_2 et w_3 sont le poids de la couche de contexte au calque caché. u sont les données d'entrée de la couche d'entrée. $k(x)$ est la fonction d'activation softmax exprimée comme suit [8]:

$$k(x) = \frac{e^{z^l}}{\sum_{m=0}^n e^{z^m}} \quad (3.5)$$

La couche de sortie est choisie linéaire.

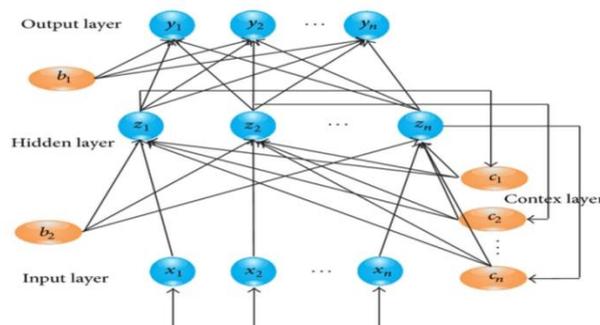


Fig. 3.2 Structure typique d'ENN [9]

3.2.4 Méthode d'apprentissage régularisé bayésien (BR)

La méthode bayésienne peut être considérée comme la meilleure méthode pour l'apprentissage du réseau neuronal [10, 11]. Dans la méthode bayésienne, une nature probabiliste est attribuée au processus d'apprentissage du réseau de neurone avec un calcul rigoureux de l'incertitude [12]. La fonction objectif régularisée est donnée par:

$$R_{of} = \beta_B MSE_D + \alpha_B MSE_{\hat{W}} \quad (3.6)$$

Où:

$$MSE_{\hat{W}} = \frac{1}{m} \sum_{i=1}^m w_i^2 \quad (3.7)$$

Et m est le nombre total de paramètres dans le réseau. β_B et α_B sont appelés hyper-paramètres (paramètre de régularisation). L'objectif principal est de déduire a posteriori la répartition appropriée des paramètres. Le mécanisme de l'inférence bayésienne est basé sur la distribution antérieure, construite sans aucune connaissance sur les poids ajustables, puis une probabilité de probabilité est construite afin de fournir la probabilité de générer le paramètre adéquat, donc évaluer le modèle.

Pour une particule RN A avec m paramètres, une base de données $D = x_i, y_i \quad_{i=1}^S$, en minimisant une fonction d'objective R_{of} . La méthode bayésienne peut être utilisée pour estimer la distribution de probabilité postérieure $P(w|D, \alpha_B, \beta_B, A)$ pour les poids comme suit:

$$P(w|D, \alpha_B, \beta_B, A) = \frac{P(D|w, \beta_B, A) P(w|\alpha_B, A)}{P(D|\alpha_B, \beta_B, A)} \quad (3.8)$$

Où : $P(w|\alpha_B, A) = \left(\frac{\alpha_B}{2\pi}\right)^{m/2} \exp\left(-\frac{\alpha_B}{2} \omega' \omega\right)$, et $P(D|w, \beta_B, A)$ est la fonction de vraisemblance,

$P(D|\alpha_B, \beta_B, A)$ est connue comme la preuve agissant comme facteur de normalisation défini comme suit:

$$P(D|\alpha_B, \beta_B, A) = \frac{P(D|w, \beta_B, A) P(w|\alpha_B, A)}{P(w|D, \alpha_B, \beta_B, A)} = \frac{Z_F(\alpha_B, \beta_B)}{\pi/\beta \quad S/2 \quad \pi/\alpha_B \quad m/2} \quad (3.9)$$

Sur la base de l'approximation de Laplace, on peut estimer $Z_F(\alpha_B, \beta_B)$ comme suit :

$$Z_F(\alpha_B, \beta_B) \propto |\mathbf{H}^{MAP}|^{-1/2} \exp -R_{of} \quad \omega^{MAP} \quad (3.10)$$

Où MAP représente au maximum a posteriori et $\mathbf{H} = \beta_B \nabla^2 E_D + \alpha_B \nabla^2 E_{\tilde{W}}$ désigne la matrice de la fonction objective $R_{of}(w)$ qui peut être approché à un produit de la matrice jacobienne comme suit:

$$\mathbf{H} = \mathbf{J}\mathbf{J}' \quad (3.11)$$

$$\mathbf{J} = \begin{bmatrix} \frac{\partial e_1(w)}{\partial w_1} & \frac{\partial e_1(w)}{\partial w_2} & \dots & \frac{\partial e_1(w)}{\partial w_m} \\ \frac{\partial e_2(w)}{\partial w_1} & \frac{\partial e_2(w)}{\partial w_2} & \dots & \frac{\partial e_2(w)}{\partial w_m} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_o(w)}{\partial w_1} & \frac{\partial e_o(w)}{\partial w_2} & \dots & \frac{\partial e_o(w)}{\partial w_m} \end{bmatrix}$$

Dans cette étude, les réseaux MLP et ENN avec des fonctions d'activation softmax et des réseaux de neurones RBF sont sélectionnés pour classer les défauts statoriques et rotoriques, basée sur l'algorithme bayésien régularisé (BR).

3.3 Mise en œuvre du RN dans le diagnostic de défauts statoriques et rotoriques du MI en utilisant les méthodes HFFT et REOD

Fig.3.3 représente le schéma général pour la mise en œuvre d'un RN capable de diagnostiquer les défauts de court-circuit entre spires statoriques et cassure de barres rotoriques du MI en se basant sur les méthodes HFFT et REOD qui sont exposées au chapitre 2. Les différentes étapes de cette méthodologie sont :

- **Acquisition**

Les courants statoriques (I_s) du MI sont acquis à l'aide des capteurs de courant sous différentes conditions (moteur sain et moteur défectueux). Ces courants seront analysés par les méthodes : HFFT et REOD.

- **Hybridation des méthodes HFFT et REOD avec RN**

Les courants statoriques sont analysés par les méthodes HFFT et REOD pour extraire les indicateurs de défauts (CCES et BC) comme on l'a expliqué précédemment au chapitre 2. Pour rappel, on utilise les trois rapports ($R_1 = \frac{Ed_{7as}}{Ed_{7bs}}$, $R_2 = \frac{Ed_{7bs}}{Ed_{7cs}}$ et $R_3 = \frac{Ed_{7cs}}{Ed_{7as}}$) qui sont calculés par la méthode REOD, comme indicateurs de défaut CCES statorique et la fréquence f_{bc} et l'amplitude A_{bc} de l'harmonique $2sf_s$, qui sont calculées par la méthode HFFT, comme indicateur de défaut BC rotorique. Toutes ces grandeurs sont, à leur tour, utilisées comme entrées aux trois types de réseaux de neurones : RBF, MLP et ENN pour la détection et la classification automatique des défauts

(court-circuit entre spires statoriques pour localiser les phases en défaut et quantifier le nombre de barres cassées au rotor du MI).

- **Détection et classification de défauts par RN**

La conception du diagnostic de défaut, basée sur les réseaux de neurones, comprend cinq étapes.

1. Préparation de données d'apprentissage appropriées pour les RNs, obtenues par les essais expérimentaux pour extraire les indicateurs de défauts et qui sont considérées comme entrées du RNs.
2. Sélection d'une structure appropriée de RNs.
3. Apprentissage des RNs.
4. Test des RNs.
5. Evaluation des modèles de RNs

Les différents types de RNs sont réalisés à travers deux phases d'apprentissage et de test. Au cours de la phase d'apprentissage, les RNs sont formés pour saisir les relations sous-jacentes entre les entrées et les sorties choisies. Après l'apprentissage, les RNs sont testés avec un ensemble de données qui ne sont pas utilisées auparavant.

Afin d'évaluer l'efficacité et les performances des trois types de RNs proposés (RBF, MLP et ENN) et sélectionner la meilleure structure pour détecter et classifier les deux défauts (BC et CCES), l'erreur quadratique moyenne (MSE) est utilisée, où le type de RNs le plus efficace est celui qui a l'erreur minimale. Le MSE est calculé à l'aide de l'expression suivante.

$$MSE = \frac{1}{n} \sum_{i=0}^n X_i - Y_i^2 \quad (3.12)$$

Où n est le nombre d'échantillons ; X_i et Y_i sont les valeurs mesurées et prédites, respectivement [13, 14].

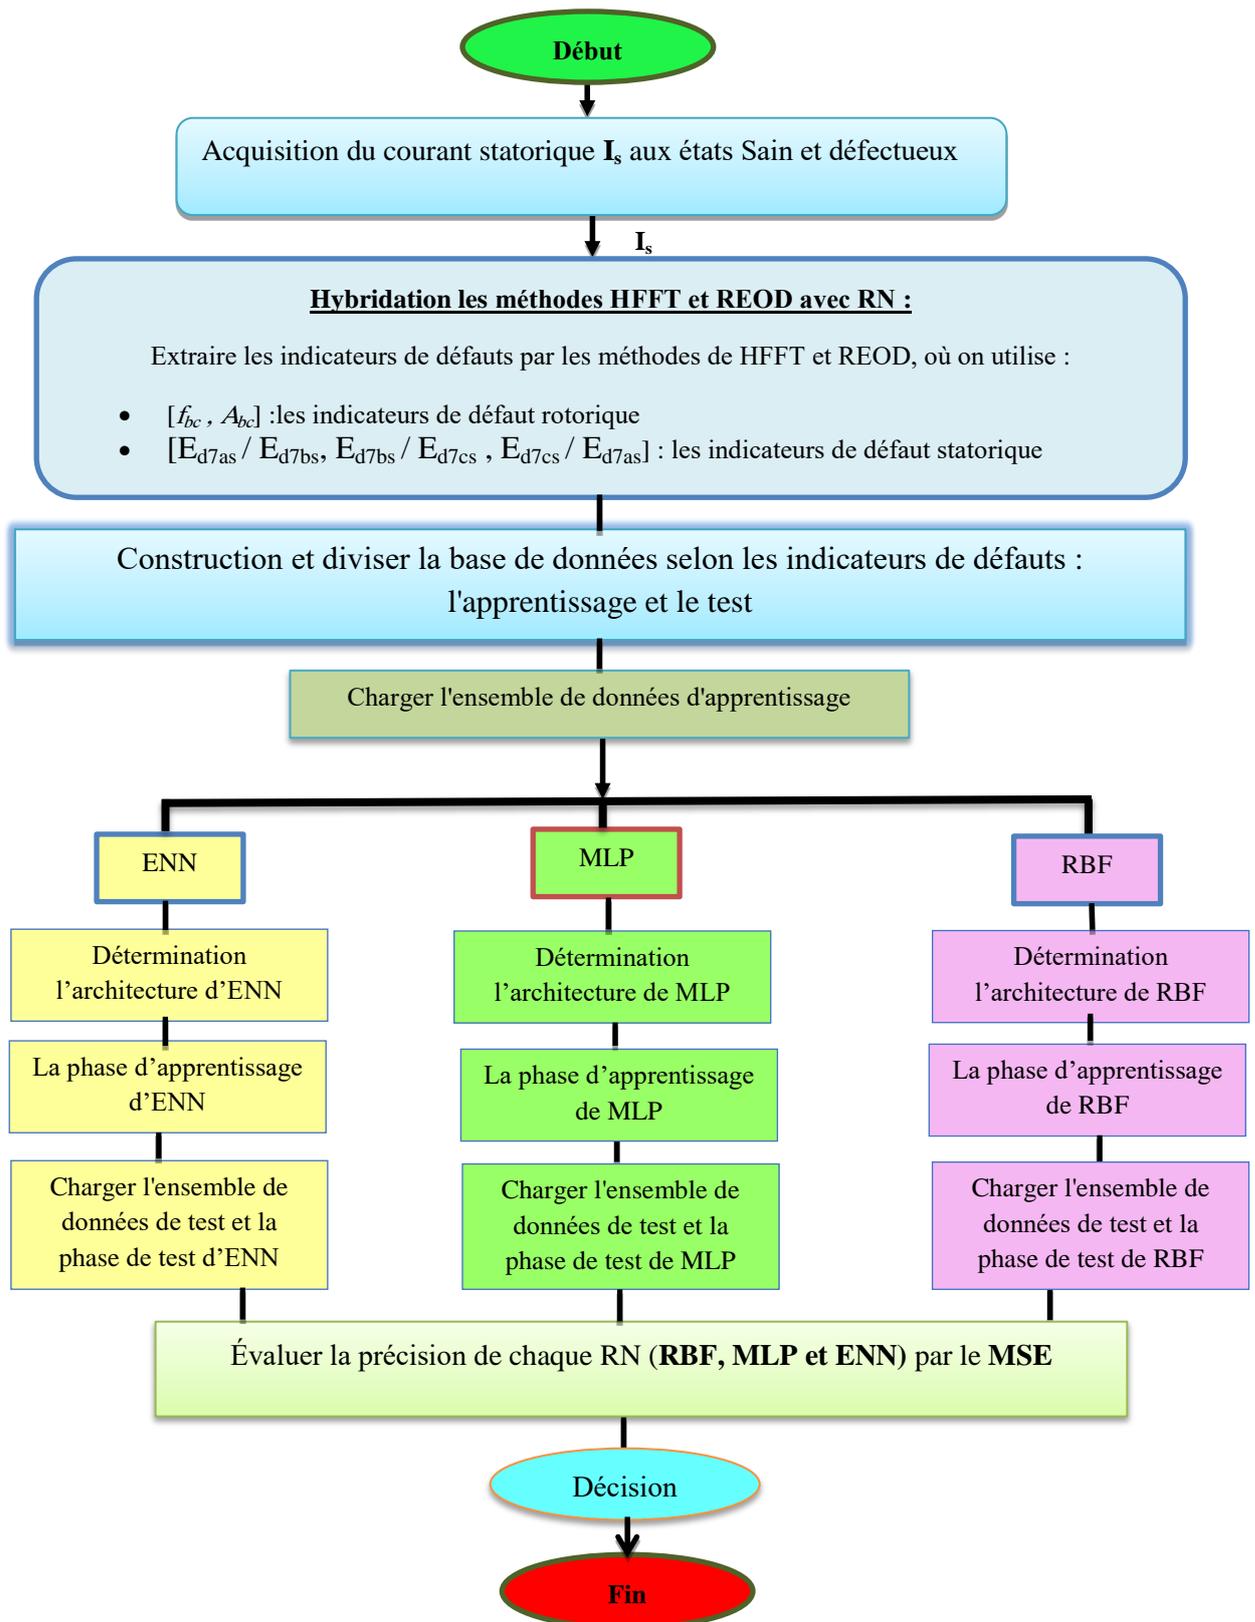


Fig. 3.3 Méthodologie générale de diagnostic de défauts rotoriques et statoriques par 3 types de RN (RBF, MLP et ENN)

3.4 Diagnostic de défaut rotorique par hybridation de la méthode HFFT avec RNs (HFFT-RN_{bc})

Les défauts de barres cassées rotoriques sont prédominants dans le MI. Ils provoquent rarement des pannes immédiates, en particulier dans les grands moteurs multipolaires. Cependant, s'il y a suffisamment de barres cassées au rotor, le moteur peut ne pas démarrer car il peut ne pas être en mesure de développer un couple d'accélération suffisant [15]. Par conséquent, La détermination précoce du nombre de barres cassées au rotor est d'une grande importance et aide à la prise de décision sur le fonctionnement ou l'arrêt de la machine.

D'après l'étude expérimentale réalisée au chapitre 2, on montre que la méthode HFFT, qui est basée sur l'analyse spectrale de l'enveloppe du courant statorique, possède des informations riches représentant d'une manière significative le défaut de barres cassées rotoriques. L'apparition de l'harmonique $2.s.f_s$ de l'analyse spectrale de l'enveloppe du courant statorique a donné un bon révélateur de défaut rotorique. Par conséquent, l'amplitude et la fréquence (A_{bc} et f_{bc}) de l'harmonique $2.s.f_s$ peuvent être utilisées comme des indicateurs efficaces pour le diagnostic du défaut rotorique du MI [16]. Ainsi, peut-on les considérer comme entrées du réseau de neurones (RN_{bc}) pour déterminer automatiquement le nombre de barres cassées au rotor.

Trois différentes structures de RN_{bc}: MLP, RBF et ENN, basées sur la méthode d'apprentissage régularisée bayésienne, sont utilisées pour quantifier d'une façon précoce le nombre de barres cassées rotoriques du MI.

3.4.1 Séquence d'apprentissage des RN_{bc}

La séquence d'apprentissage des RN_{bc} (MLP, RBF et ENN) est composée du vecteur des entrées $I=[f_{bc}, A_{bc}]$ et du vecteur des sorties désirées $S=[S_1, S_2]$. Les entrées du RN_{bc} sont composées de 90 échantillons. Elles sont extraites suite à des essais expérimentaux sous différentes conditions, comme le montre la **Fig. 3.4**. Les RN_{bc} sont présentés de la manière suivante:

- 30 échantillons pour l'état sain du moteur sous 6 charges (10%, 30%, 50%, 70%, 90%, 100% de la charge nominale),
- 30 échantillons avec un défaut d'une barre cassée au rotor sous 6 charges (10%, 30%, 50%, 70%, 90%, 100% de la charge nominale),
- 30 échantillons avec un défaut de deux barres cassées au rotor sous 6 charges (10%, 30%, 50%, 70%, 90%, 100% de la charge nominale).

Les sorties désirées (S_i) des RN_{bc} sont formées comme suit :

- $S_1= 1$ pour un défaut 1BC ; autrement, $S_1= 0$;
- $S_2= 1$ pour un défaut 2BC ; autrement, $S_2= 0$;

Ainsi, les états de sortie de RN_{bc} sont définis comme ci-dessous:

- [0; 0] : pas de défaut (mode sain);
- [1; 0] Défaut de 1BC;
- [0; 1] Défaut de 2BC.

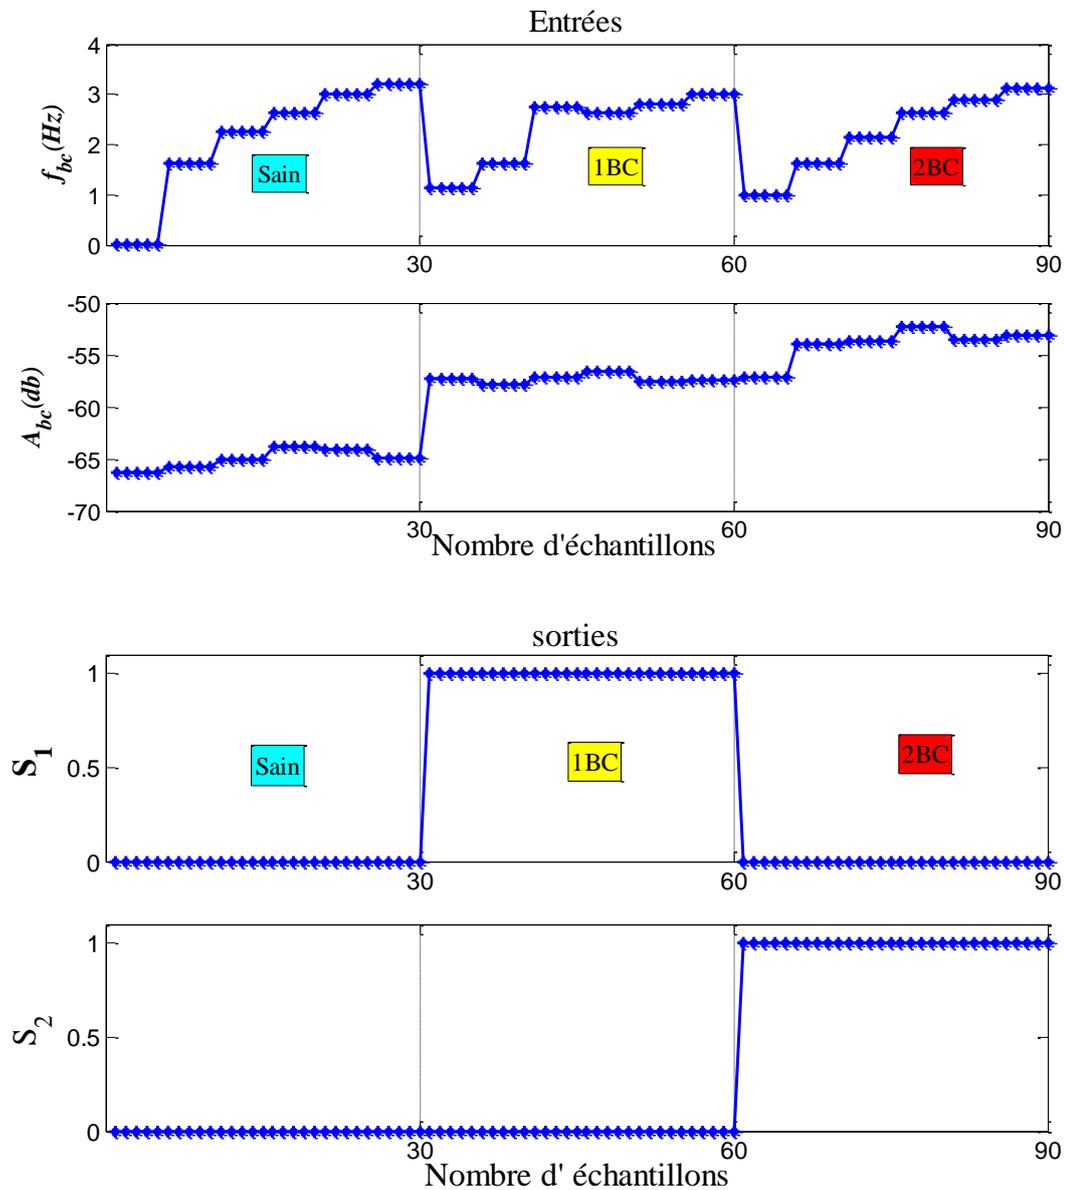


Fig. 3.4 Entrées et sorties de la séquence d'apprentissage du RN_{bc}

3.4.2 Structure des réseaux RN_{bc}

Les réseaux neuronaux (MLP, RBF et ENN), utilisés pour le diagnostic de défaut cassure de barres, se composent de deux entrées, qui sont l'amplitude A_{bc} et la fréquence f_{bc} du spectre $2sf_s$ et deux sorties correspondant au nombre de barres cassées au rotor du MI, comme illustré sur **Fig. 3.5**.

3.4.3 Résultats d'apprentissage du RN_{bc}

Fig. 3.6 et 3.7 représentent les sorties et les erreurs d'apprentissage des trois structures de RN_{bc} : MLP, RBF et ENN à l'état sain et avec défauts : 1BC et 2BC du MI afin de détecter et estimer le nombre de barres cassées. L'évolution des erreurs met en évidence les bonnes performances d'apprentissage des trois réseaux. Ceci prouve que les réseaux ont bien appris les séquences de défauts représentées et ont pu reproduire correctement les sorties désirées. Toutefois, on constate bien que le réseau ENN est plus performant et plus précis que les réseaux "MLP et RBF", où l'erreur quadratique moyenne (MSE) atteint 10^{-11} , tandis qu'elle atteint 10^{-10} et 10^{-6} avec les deux réseaux MLP et RBF, respectivement, comme indiqué dans **Tableau 3**.

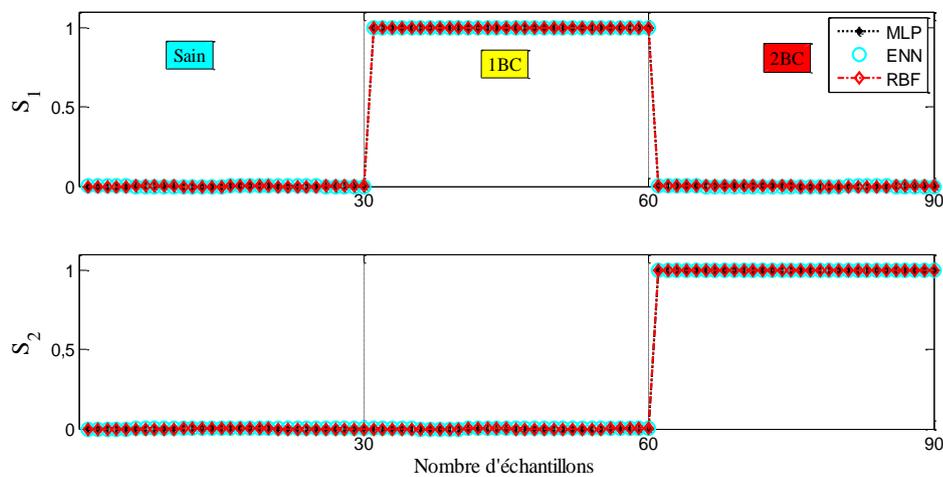


Fig. 3.6 Sorties de la séquence d'apprentissage du RN_{bc}

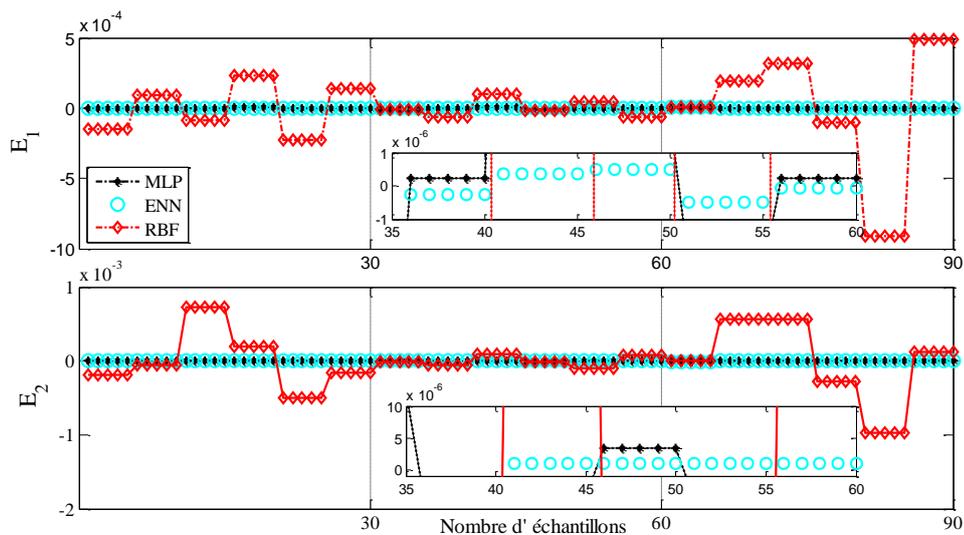


Fig. 3.7 Erreurs d'apprentissage du réseau RN_{bc}

3.4.4 Test de RN_{bc}

Afin d'évaluer la capacité de généralisation des RN_{bc} , on utilise des exemples non appris dans la base d'apprentissage qui sont composés de 15 échantillons présentés comme il est montré sur **Fig. 3.8**:

- 5 échantillons pour le fonctionnement sain pour les charges (vide, 20%, 40%, 60%, 80% de la charge nominale),
- 5 échantillons pour le fonctionnement avec défaut d'une barre cassée pour les charges (vide, 20%, 40%, 60%, 80% de la charge nominale),
- 5 échantillons pour le fonctionnement avec défaut de deux barres cassées pour les charges (vide, 20%, 40%, 60%, 80% de la charge nominale).

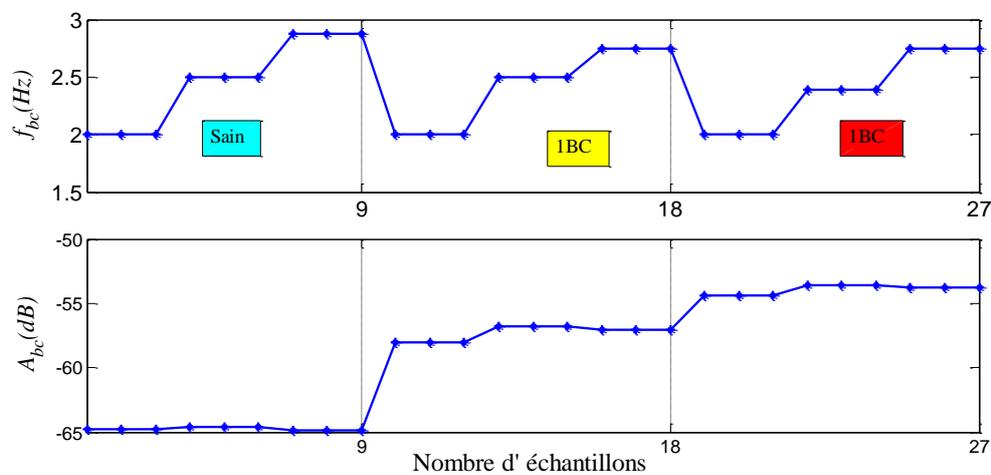


Fig. 3.8 Entrées de la séquence de test du RN_{bc}

Fig. 3.9 et **Fig. 3.10** représentent l'état des deux sorties (S_1 , S_2) et les erreurs de test des trois réseaux (MLP, RBF et ENN). Les sorties indiquent (0,0) pour le fonctionnement sain, (1,0) pour un défaut d'une barre cassée (1BC) et (0,1) pour un défaut de deux barres cassées (2BC). On remarque que les trois réseaux RN_{bc} détectent correctement le fonctionnement sain et le fonctionnement en défaut (1BC et 2BC) et identifient (avec faibles erreurs) le nombre de barres cassées sous différents couples de charge du moteur. Ainsi qu'il est déjà noté, le réseau ENN est plus performant avec une erreur quadratique moyenne (MSE) atteignant 10^{-10} et capable de détecter ce défaut et de déterminer avec plus de précision le nombre de barres cassées au rotor par rapport aux deux autres réseaux (MLP et RBF).

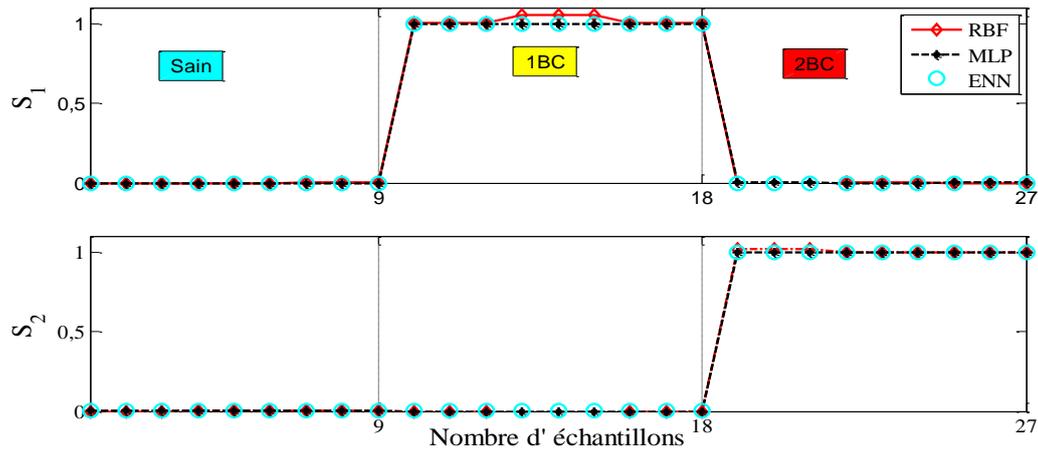


Fig. 3.9 Sorties de la séquence de test du RN_{bc}

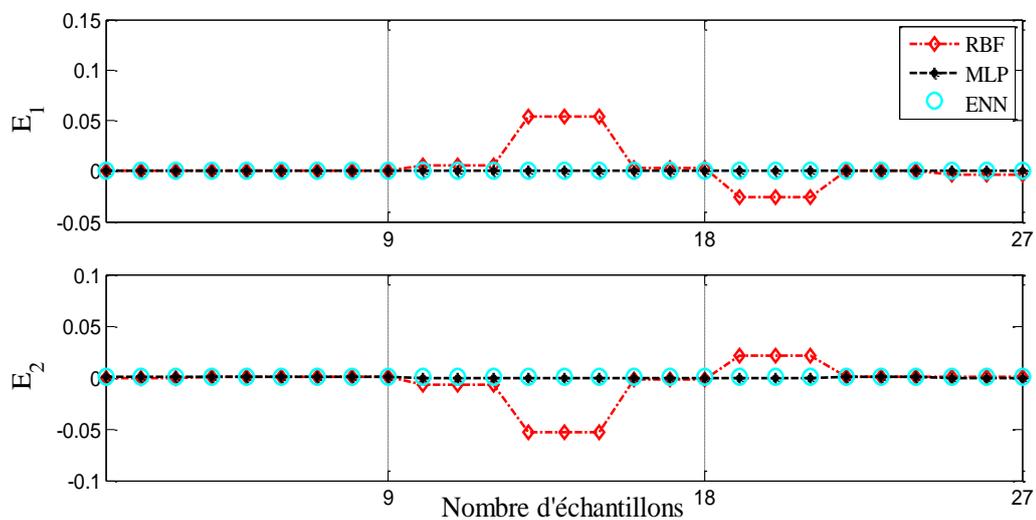


Fig. 3.10 Erreurs de test du réseau RN_{bc}

Les valeurs MSE de deux sorties (S_1 , S_2) pour la détection et l'identification du nombre de barres cassées au rotor du MI sont représentées sur **Tableau 3.3** dans les phases d'apprentissage et de test de trois réseaux de neurones proposés (MLP, RBF et ENN). Par comparaison entre les valeur MSE de deux sorties et pour les trois réseaux, on remarque que le réseau ENN est plus efficace que les deux réseaux (MLP et RBF) car il présente les plus faibles erreurs MSE : 10^{-11} pour la phase d'apprentissage et 10^{-10} pour la phase de test.

Tableau 3.3 : Comparaison entre les valeurs de MSE de trois structures de réseaux de neurones: MLP, RBF et ENN pour les phases d'apprentissage et de test pour diagnostic de défaut BC.

Phase	Sorties	MSE		
		RBF	MLP	ENN
<i>Apprentissage</i>	S_1	0.0775×10^{-6}	0.0849×10^{-10}	0.3514×10^{-11}
	S_2	0.1422×10^{-6}	0.1366×10^{-10}	0.4149×10^{-11}
<i>Test</i>	S_1	0.4007×10^{-3}	0.5709×10^{-7}	0.1642×10^{-10}
	S_2	0.3773×10^{-3}	0.5701×10^{-7}	0.0105×10^{-10}

3.5 Diagnostic de défaut statorique par hybridation de la méthode REOD avec RN (REOD-RN_{cc})

Les défauts d'enroulements statoriques commencent comme des défauts de court-circuit entre spires non détectés qui peuvent se développer et aboutir à une défaillance du moteur. Pour cette raison, la détection précoce du défaut de court-circuit entre spires et la détermination de la phase dans laquelle il se produit, pendant le fonctionnement du MI, peuvent supprimer certains dommages dans les bobines adjacentes et le noyau du stator, réduisant ainsi le coût de maintenance et le temps d'arrêt du moteur.

Les résultats obtenus, dans le chapitre 2 ont montré de bonnes performances en diagnostic de défaut CCES. Ils sont obtenus en utilisant la méthode de REOD qui est basée sur la transformation d'ondelette discrète des courants statoriques. Dans cette méthode, on utilise les trois rapports d'énergies d'ondelette des courants statoriques ($R_1 = E_{d7as} / E_{d7bs}$, $R_2 = E_{d7bs} / E_{d7cs}$, et $R_3 = E_{d7cs} / E_{d7as}$) comme indicateurs de défaut [13, 17].

Selon les études menées, les rapports d'énergies d'ondelette des courants (R_1 , R_2 et R_3) sont choisis comme indicateurs effectifs de défaut CCES en MI. Ces rapports conviendront très bien comme entrées de trois structures des RN_{cc} (MLP, RBF et ENN) pour l'auto-détection et la localisation de défaut.

3.5.1 Séquence d'apprentissage de RN_{cc}

Fig. 3.11 représente la séquence d'apprentissage des RN_{cc} qui est constituée d'une séquence successive d'exemples extraits des essais expérimentaux du MI dans différentes conditions. Les données d'apprentissage composées des vecteurs d'entrée:

$R = [R_1 = E_{d7as} / E_{d7bs}, R_2 = E_{d7bs} / E_{d7cs}, R_3 = E_{d7cs} / E_{d7as}]$ et le vecteur des sorties désirées (O).

Les entrées des RN_{cc} sont constituées d'une série successive d'exemples (96 échantillons) divisée en quatre parties correspondant à différentes conditions du moteur comme suit :

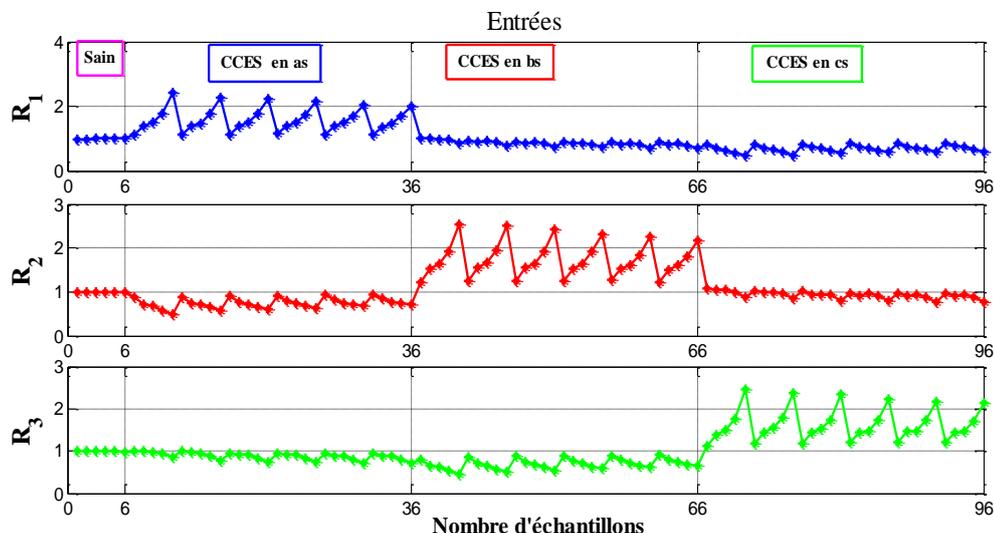
- **Partie 1:** 6 échantillons pour l'état sain du moteur sous 6 charges (à vide, 10%, 30%, 50%, 70 et 90% de la charge nominale),
- **Partie 2:** 30 échantillons (5x6) représentent les états de défaut CCES des (7-13-15-20-30) spires court-circuitées de la phase **as** sous 6 charges (à vide, 10%, 30%, 50% , 70 et 90% de la charge nominale).
- **Partie 3:** 30 échantillons (5x6) représentent les états de défaut CCES des (7-13-15-20-30) spires court-circuitées de la phase **bs** sous 6 charges (à vide, 10%, 30%, 50% , 70 et 90% de la charge nominale).
- **Partie 4:** 30 échantillons (5x6) représentent les états de défaut CCES des (7-13-15-20-30) spires court-circuitées de la phase **cs** sous 6 charges (à vide, 10%, 30%, 50% , 70 et 90% de la charge nominale).

Les sorties désires (O_i) des RN_{cc} sont formées comme suit :

- $O_1 = 1$ pour un défaut CCES dans la phase a_s ; autrement, $O_1 = 0$;
- $O_2 = 1$ pour un défaut CCES dans la phase b_s ; autrement, $O_2 = 0$;
- $O_3 = 1$ pour un défaut CCES dans la phase c_s ; autrement, $O_3 = 0$.

Ainsi, les états de sortie de RN_{cc} sont définis comme ci-dessous:

- [0; 0; 0] pas de défaut (mode sain);
- [1; 0; 0] Défaut de CCES dans la phase a_s ;
- [0; 1; 0] Défaut de CCES dans la phase b_s ;
- [0; 0; 1] Défaut de CCES dans la phase c_s .



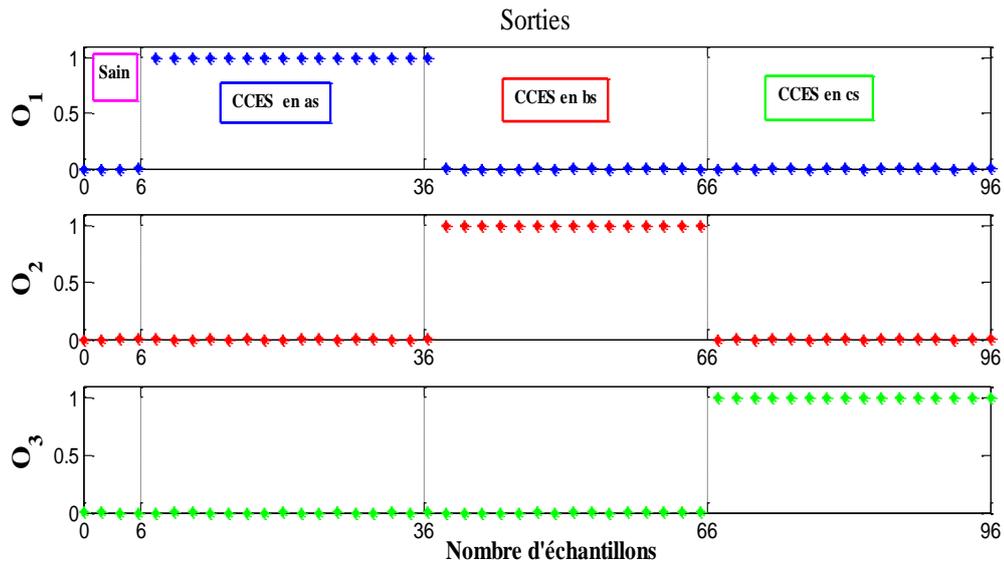


Fig. 3.11 Entrées et sorties d'apprentissage du RN_{cc}

3.5.2 Structure des réseaux RN_{cc}

Trois structures de RN_{cc} les plus courantes ont été choisies et améliorées en fonction de l'approche bayésienne d'apprentissage pour la détection et la classification des défauts CCES, à savoir : MLP, RBF et ENN.

Dans cette étude, les trois types de RNs consistent en une couche d'entrée avec trois neurones qui sont respectivement : $R_1 = E_{d7as} / E_{d7bs}$, $R_2 = E_{d7bs} / E_{d7cs}$ et $R_3 = E_{d7cs} / E_{d7as}$, une couche cachée contient 10 neurones avec une fonction d'activation « **softmax** » pour les types MLP et ENN, « **base radiale** » pour les réseaux RBF et, enfin, une couche de sortie qui contient trois neurones, avec une fonction d'activation du type « **purelin** ». On a utilisé Matlab pour effectuer l'apprentissage (hors ligne) et le test basé sur l'algorithme bayésien régularisé (BR) avec 1000 itérations comme illustré dans **Tableaux 4 et 5**.

Après avoir déterminé les entrées, les sorties et la structure du RN, l'étape suivante consiste à acquérir des données à partir de tests expérimentaux du MI. Ces données sont traitées et classées dans un enregistrement appelé base de données. La base de données d'apprentissage doit être représentée en termes de qualité et de quantité des différents modes de fonctionnement du moteur. La tâche de RN_{cc} cherche à coupler chacune des données d'entrée au mode de fonctionnement (sain ou défectueux) et à localiser la phase défectueuse comme indiqué sur **Fig. 3.12**.

Tableau 3.4: Paramètres du réseau MLP et ENN

Paramètres du réseau MLP et ENN		
Couche	Nb. de Neurones	Fonction d'activation
Couches d'entrée	3	
Couches cachées	10	Softmax
Couches de sortie	3	Purelin
Algorithme d'apprentissage	BR	
Nombre d'itérations	1000	

Tableau 3.5 : Paramètres du réseau RBF

Paramètres du réseau RBF		
Couche	Nb. de Neurones	Fonction d'activation
Couches d'entrée	3	
Couches cachées	10	radial basis
Couches de sortie	3	Purelin
Algorithme d'apprentissage	BR	
Nombre d'itérations	1000	

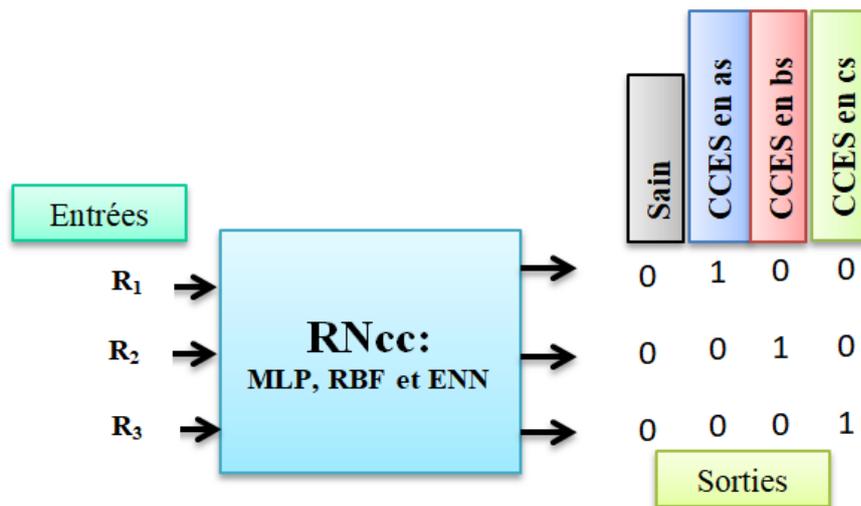


Fig. 3.12 Organigramme de la classification du défaut CCES à l'aide des RN_{cc}

3.5.3 Résultats d'apprentissage de RN_{cc}

Fig. 3.13 et **Fig. 3.14** montrent les sorties d'apprentissage et leurs erreurs dans trois RN_{cc} (MLP, RBF et ENN) sous plusieurs conditions (modes sain et défectueux) du MI, pour la détection et la localisation des défauts CCES. Il est clair que les RN_{cc} ont parfaitement appris l'ensemble de données d'entrée, où ils ont donné la sortie désirée correctement avec de faibles erreurs dans les trois modèles RN_{cc}. Mais par comparaison entre les réponses des trois structures de RN_{cc} proposés,

on constate que le réseau ENN est le meilleur avec une erreur minimale par rapport au MLP et au RBF.

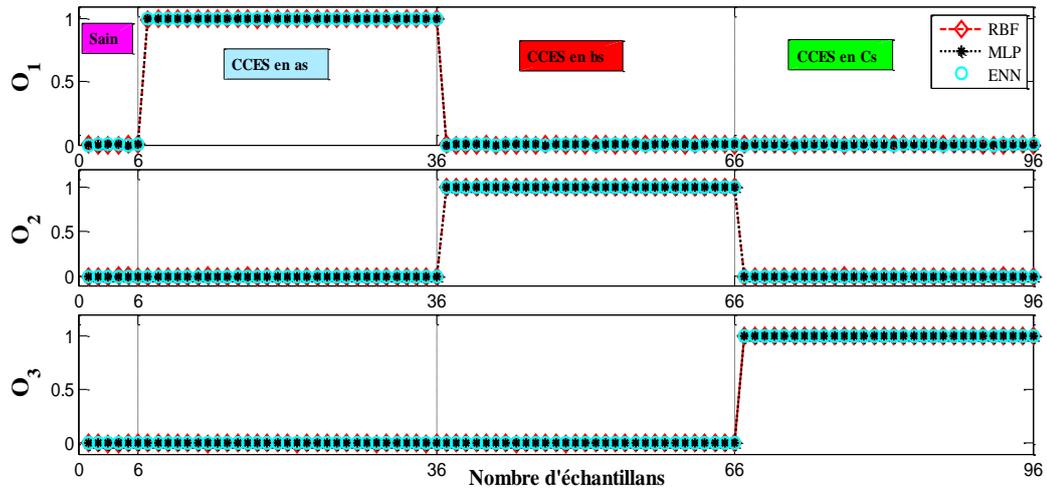


Fig. 3.13 Sorties désirées de la séquence d'apprentissage du RN_{cc}

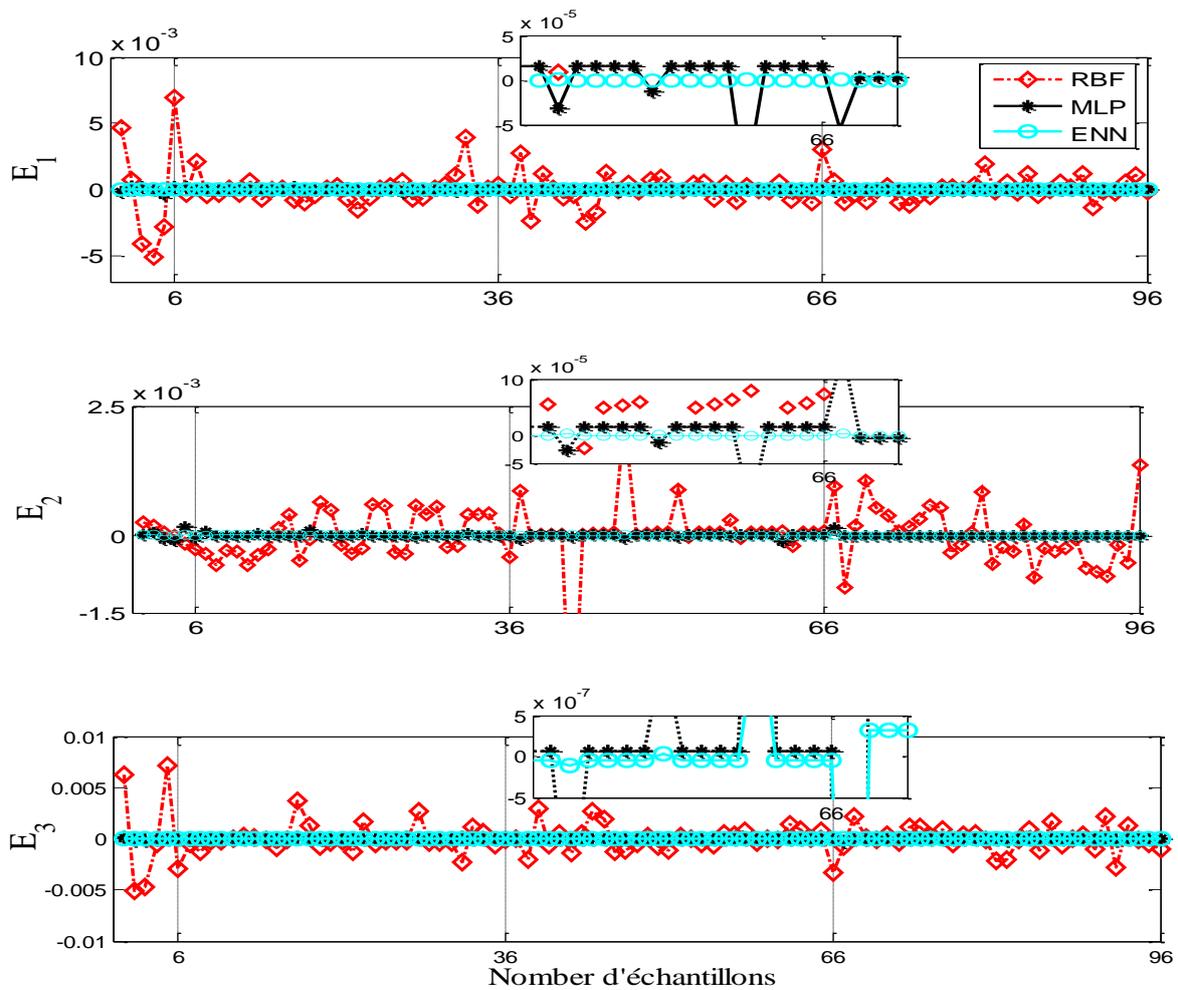


Fig. 3.14 Erreurs de sortie d'apprentissage de trois RN_{cc} (RBF, MLP et ENN)

3.5.4 Test de RN_{cc}

Pour évaluer les performances de trois RN_{cc} (MLP, RBF et ENN), on teste les réseaux par des exemples différents de ceux utilisés dans la phase d'apprentissage. Ils sont composés de 25 échantillons comme suit:

- 5 échantillons pour l'état sain du moteur,
- 20 échantillons pour un fonctionnement avec défaut de (16,18 et 20) spires court-circuitées sous des charges de (20%, 40%, 60%, 80% et 100% de la charge nominale) sur chaque phase.

Les sorties de test et leurs erreurs sont indiquées à la **Fig. 3.15**. Selon l'erreur la plus faible du test, il est évident que le modèle ENN peut identifier correctement les défauts CCES et déterminer la phase dans laquelle il s'est produit avec un grand et même un petit nombre de spires court-circuités, comparé au MLP et au RBF.

Tableau 3.6 résume les erreurs MSE pour les phases d'apprentissage et de test. À travers les résultats du tableau, on montre que le modèle ENN offre plus de précision lorsqu'il a obtenu une erreur (RMS) minimale avec 10^{-9} en apprentissage et environ 10^{-8} en test par rapport au MLP avec 10^{-8} en apprentissage et 10^{-7} en test et RBF qui ont obtenu l'erreur maximale 10^{-5} en entraînement et 10^{-3} en test.

À partir de ces résultats, on conclut que le modèle de réseau ENN a les performances les plus élevées pour classer les défauts CCES par rapport au MLP et au RBF. De plus, le MLP avec fonction d'activation softmax a également donné de bons résultats qui ne sont pas trop éloignés de ce que l'on obtient avec le modèle ENN, mais les résultats RBF sont les moins bons, pas stables (oscillation) et avec une grosse erreur par rapport à ENN et MLP.

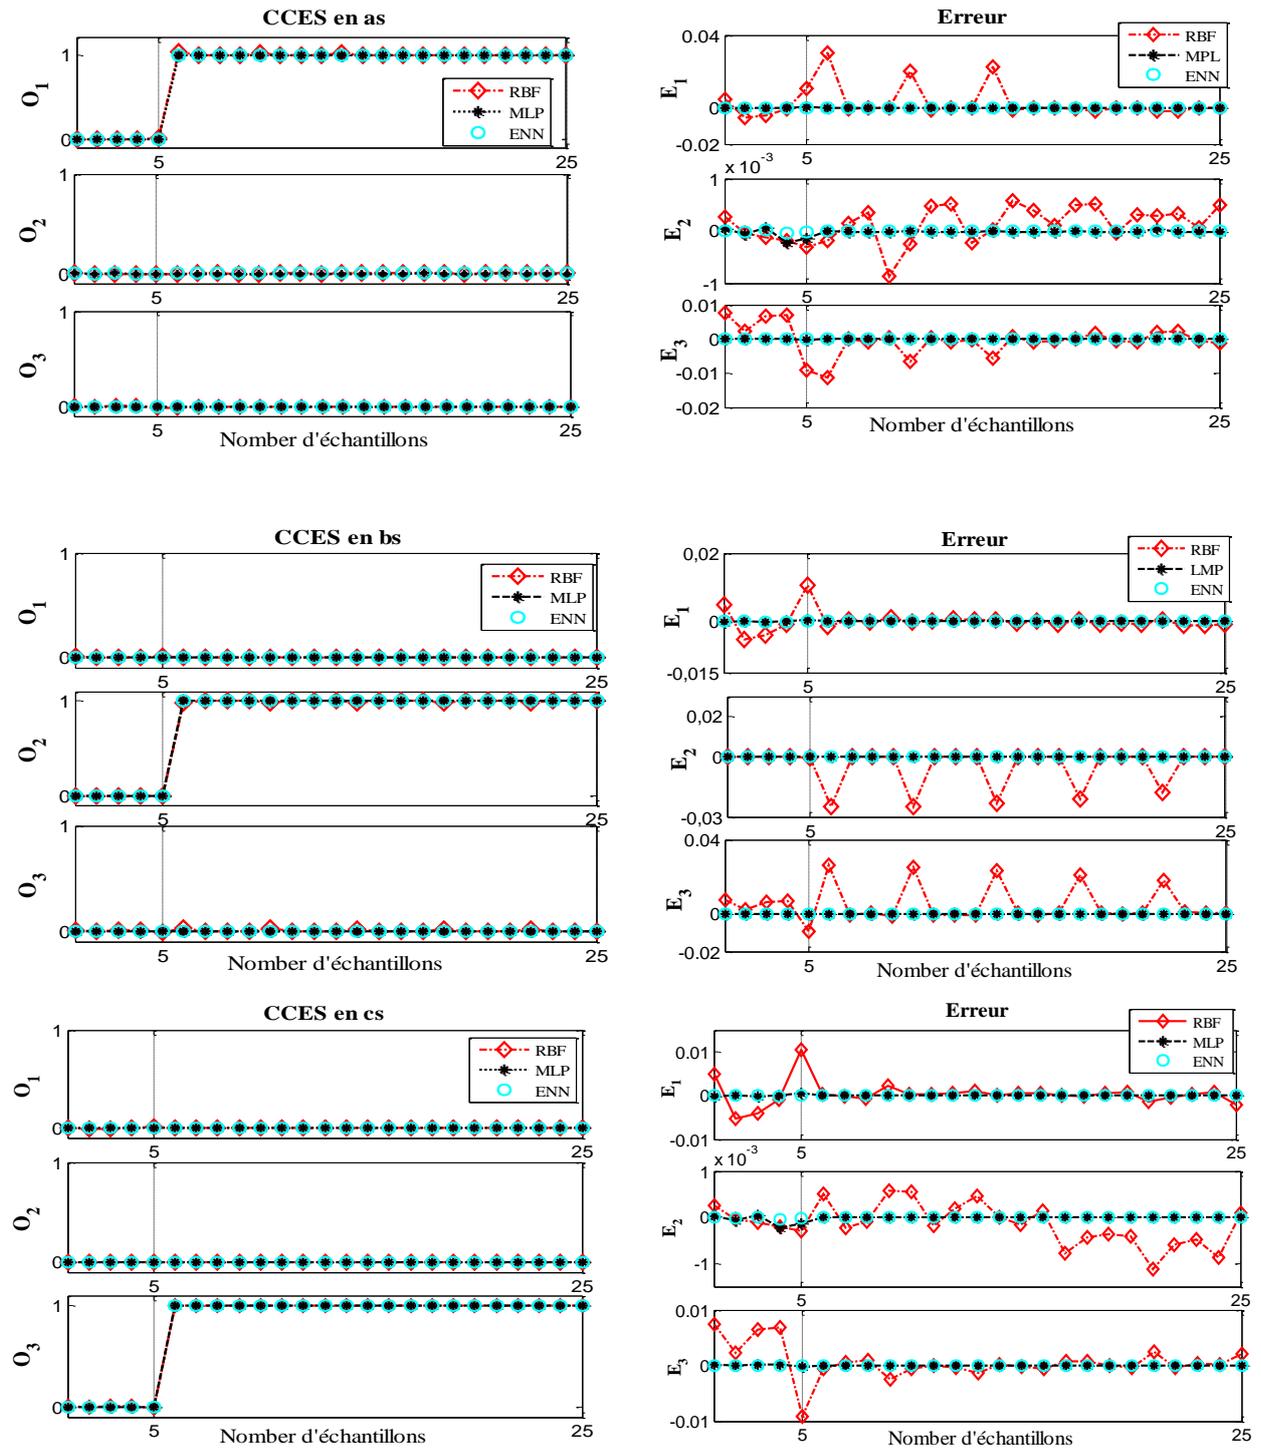


Fig. 3.15. Sorties et leur erreurs de test pour les défauts CCES en: phase a_s , phase b_s et phase c_s

Tableau 3.6 Comparaison entre les valeurs de MSE de trois structures de réseaux de neurones MLP, RBF et ENN pour les phases d'apprentissage et de test en diagnostic de défaut CCES.

Phase	Sorties	MSE		
		RBF	MLP	ENN
<i>Apprentissage</i>	O1	0.2199×10^{-5}	0.4690×10^{-8}	0.1244×10^{-9}
	O2	0.0483×10^{-5}	0.2050×10^{-8}	0.0204×10^{-9}
	O3	0.2863×10^{-5}	0.2406×10^{-8}	0.0594×10^{-9}
<i>Test pour CCES en as</i>	O1	0.8032×10^{-4}	0.1609×10^{-7}	0.1013×10^{-8}
	O2	0.0013×10^{-4}	0.0344×10^{-7}	0.0108×10^{-8}
	O3	0.1805×10^{-4}	0.0472×10^{-7}	0.0066×10^{-8}
<i>Test pour CCES en bs</i>	O1	0.0076×10^{-3}	0.1539×10^{-7}	0.1018×10^{-8}
	O2	0.1013×10^{-3}	0.0348×10^{-7}	0.0110×10^{-8}
	O3	0.1158×10^{-3}	0.0464×10^{-7}	0.0059×10^{-8}
<i>Test pour CCES en cs</i>	O1	0.0787×10^{-4}	0.1523×10^{-7}	0.1014×10^{-8}
	O2	0.0021×10^{-4}	0.0322×10^{-7}	0.0108×10^{-8}
	O3	0.1033×10^{-4}	0.0511×10^{-7}	0.0067×10^{-8}

3.6 Système de surveillance par l'hybridation des méthodes "REOD et HFFT" avec RN

Globalement, la surveillance regroupe la fonction de détection et de diagnostic de défaut en même temps [18]. Pour cette raison, nous avons regroupé dans ce travail les deux réseaux RN_{cc} et RN_{bc} où nous choisissons la structure du réseau ENN basée sur les deux méthodes "REOD" et "HFFT", car il est le plus performant comparé au MLP et au RBF. **Fig. 3.16** représente le schéma synoptique de ce système.

Le réseau ENN_{cc} a pour fonction essentielle de détecter et localiser automatique le défaut de court-circuit entre spires au stator de façon précoce en se basant sur la méthode REOD. Ce réseau se compose de 3 entrées qui sont les rapports d'énergie d'ondelette des courants statoriques [R_1 R_2 R_3] et trois sorties $O=[O_1$ O_2 $O_3]$, avec :

- $O=[0$ 0 $0]$: le moteur à l'état sain ou avec défaut de barre cassée.
- $O=[1$ 0 $0]$: le moteur avec défaut de court-circuit entre spires dans la phase **as**.
- $O=[0$ 1 $0]$: le moteur avec défaut de court-circuit entre spires dans la phase **bs**.
- $O=[0$ 0 $1]$: le moteur avec défaut de court-circuit entre spires dans la phase **cs**.

Premièrement, le réseau ENN_{bc} est utilisé pour séparer l'état sain de l'état de défaut de cassure de barre rotorique et deuxièmement pour déterminer le nombre de barres cassées au rotor du MI. Il est composé de 2 entrées $[f_{bc} A_{bc}]$ et deux sorties $S = [S_1 S_2]$. Le réseau ENN_{bc} est actif si les sorties $O = [0 0 0]$. Ce réseau fonctionne comme suit :

- $O = [0 0 0]$ et $S = [0 0]$: le moteur à l'état sain
- $O = [0 0 0]$ et $S = [1 0]$: le moteur avec défaut d'une barre cassée (1BC)
- $O = [0 0 0]$ et $S = [0 1]$: le moteur avec défaut de 2 barres cassées (2BC)

Les paramètres des deux réseaux (ENN_{cc} et ENN_{bc}) sont les mêmes que ceux utilisés dans les parties (3.3) et (3.4) de ce chapitre.

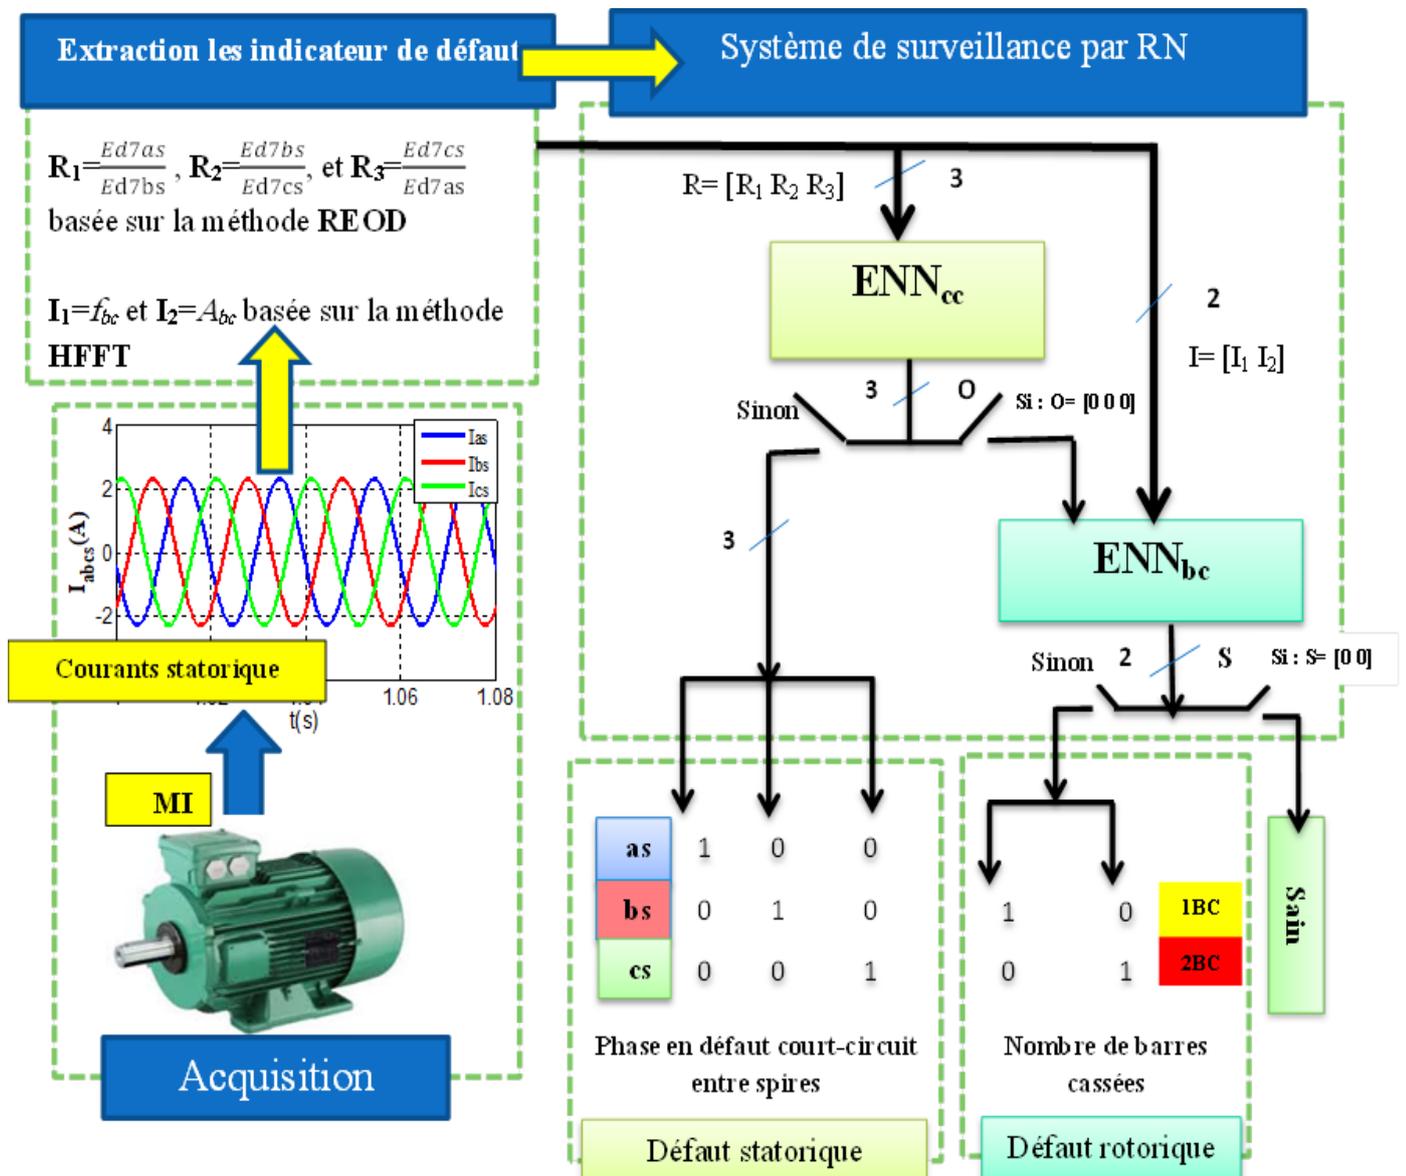


Fig. 3.16 Schéma synoptique du système de surveillance du MI par RN

Le système a été testé avec différents cas de défauts (CCES et BC) à différentes charges. **Fig. 3.17** illustre les résultats du test d'une séquence présentée aux entrées du système. Cette séquence de tests est composée de 75 exemples de fonctionnement du moteur décrits dans **Tableau 3.7** avec l'état des sorties correspondant à chaque groupe d'échantillons.

On constate que les erreurs des sorties des deux réseaux sont plus faibles (**Fig. 3.17**), ce qui montre l'efficacité du système de surveillance proposé par la structure du réseau ENN qui a donné les meilleurs performances comparativement aux réseaux MLP et RB. Par les résultats obtenus, on conclut que le système est capable de diagnostiquer de façon précoce et fiable les défauts statorique (CCES) et rotorique (BC). Aussi, ce système offre l'avantage de distinguer correctement l'état sain de l'état en défaut sous différentes charges du MI.

Tableau 3.7: Conditions de fonctionnement des séquences de test et les sorties correspondantes du système de surveillance par RN

Nombre d'échantillons	Défaut rotorique	Défaut statorique	Charge appliquée (%)	O ₁	O ₂	O ₃	S ₁	S ₂
1 à 5	Sain	Sain	20%, 40%, 60%, 80%, et 100%	0	0	0	0	0
6 à 10	1BC	Sain	20%, 40%, 60%, 80%, et 100%	0	0	0	1	0
11 à 15	2BC	Sain	20%, 40%, 60%, 80%, et 100%	0	0	0	0	1
16 à 35	Sain	Phase as (8-14-18- 25 spires)	20%, 40%, 60%, 80%, et 100%	1	0	0	0	0
36 à 55	Sain	Phase bs (8-14-18- 25 spires)	20%, 40%, 60%, 80%, et 100%	0	1	0	0	0
56 à 75	Sain	Phase cs (8-14-18- 25 spires)	20%, 40%, 60%, 80%, et 100%	0	0	1	0	0

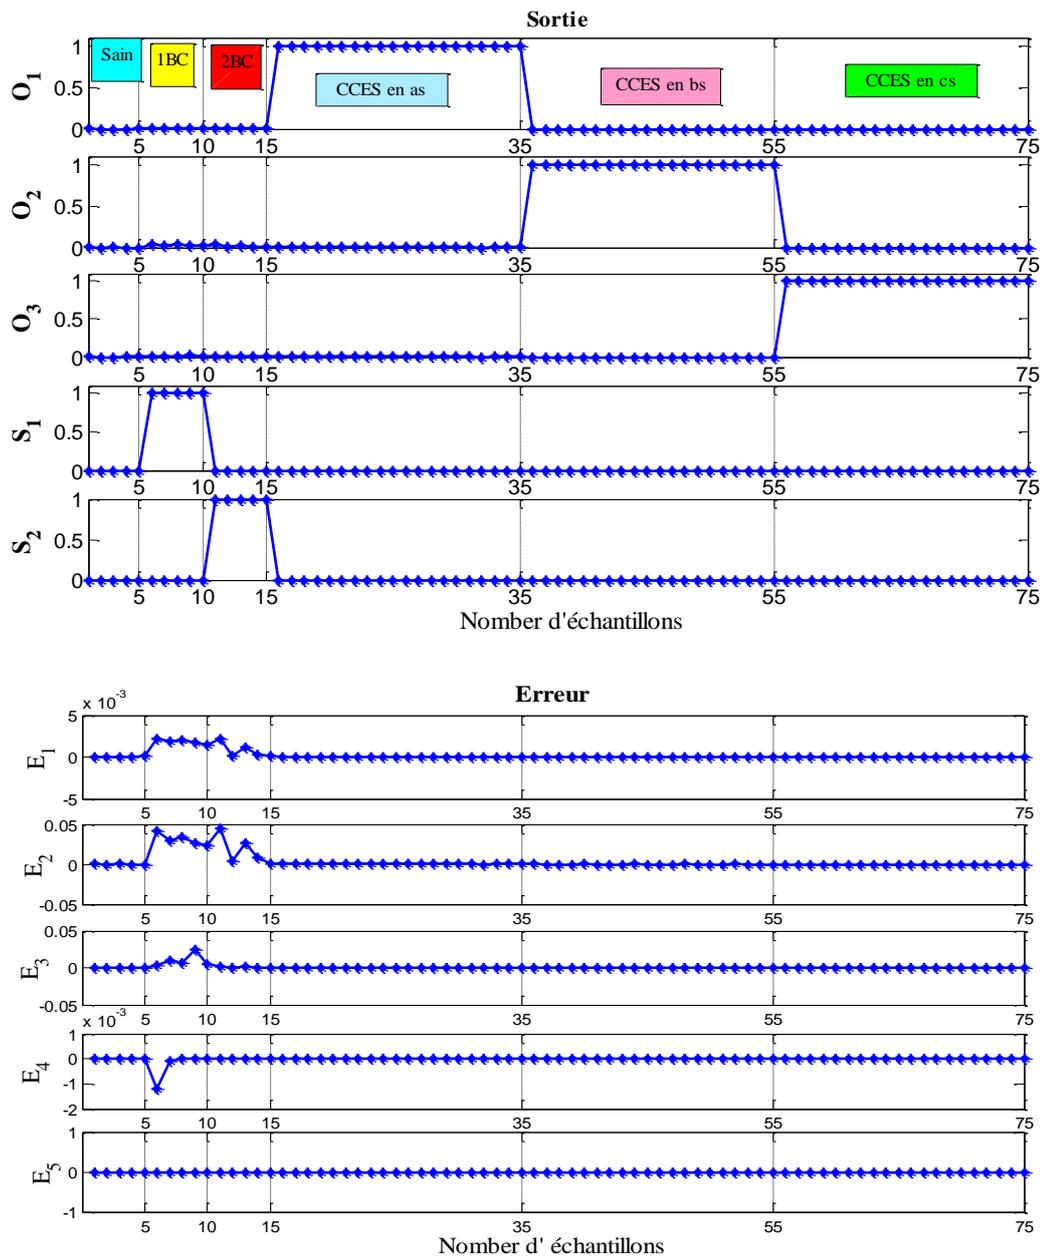


Fig. 3.17 Sorties et leurs erreurs du système de surveillance du MI par RN

3.7 Conclusion

Dans ce chapitre, on a proposé une étude expérimentale d'un système de surveillance automatique pour diagnostiquer les défauts statoriques et rotoriques dans un MI. Cette étude est basée sur trois structures différentes de RN à savoir : MLP, RBF et ENN. Le défaut statorique étudié est de type court-circuit entre spires afin de réaliser une détection précoce et déterminer automatiquement la phase en défaut par l'hybridation entre la méthode de REOD et les RN_{cc} . Dans ce cas, les rapports d'énergie d'ondelette discrète des courants statoriques sont utilisés comme indicateur de défaut et entrées pour les RN_{cc} . On a aussi structuré les RN_{bc} pour déterminer le

nombre de barres cassées au rotor en se basant sur la méthode HFFT. Cette dernière utilise l'analyse spectrale de l'enveloppe du courant statorique pour l'extraction de l'amplitude et de la fréquence de l'harmonique $2sf_s$. Ces deux paramètres sont utilisés comme indicateurs de défaut et comme entrées des réseaux RN_{bc} . Les détections de deux défauts sont réalisées en tenant compte de la variation de la charge du MI. Dans ce travail, les résultats obtenus montrent l'efficacité des méthodes de diagnostic proposées. En comparant les réponses des trois structures de réseaux de neurones proposées, le réseau ENN offre de meilleures performances de détection en termes de vitesse de convergence et de capacité d'identification des défauts « rotorique et statorique ».

Pour l'amélioration supplémentaire des performances de détection des défauts, on suggère d'autres techniques intelligentes avancées basées sur l'ANFIS. Ceci fera l'objet du chapitre suivant.

3.8 Bibliographie

1. Rajakarunakaran, S., et al., *Artificial neural network approach for fault detection in rotary system*. Applied Soft Computing, 2008. **8**(1): p. 740-748.
2. Cho, H.C., et al., *Fault detection and isolation of induction motors using recurrent neural networks and dynamic Bayesian modeling*. IEEE Transactions on Control Systems Technology, 2009. **18**(2): p. 430-437.
3. Patan, K., *Artificial neural networks for the modelling and fault diagnosis of technical processes*. 2008: Springer.
4. Chehaidia Seif Eddine, A.A., Kherfane Hamid, Boukhezzer Boubekeur, Cherif Hakima, *An Improved Machine Learning Techniques Fusion Algorithm for Controls Advanced Research Turbine (CART) Power Coefficient Estimation*. U.P.B. Sci. Bull. Series C, 2020. **82**(2): p. 279-292.
5. Celik, E., et al., *Application of artificial neural network to estimate power generation and efficiency of a new axial flux permanent magnet synchronous generator*. International Journal of Hydrogen Energy, 2017. **42**(28): p. 17692-17699.
6. Dahbi, A., N. Nait-Said, and M.-S. Nait-Said, *A novel combined MPPT-pitch angle control for wide range variable speed wind turbine based on neural network*. International Journal of Hydrogen Energy, 2016. **41**(22): p. 9427-9442.
7. BOUKRA, T., *Diagnostic et pronostic des défauts des Moteurs Asynchrones*. Thèse Doctorat, 2016. **Université 20 Août 1955 - Skikda**.
8. Yu, Y., X. Wang, and R. Bründlinger, *Improved Elman Neural Network Short-Term Residents Load Forecasting Considering Human Comfort Index*. Journal of Electrical Engineering & Technology, 2019. **14**(6): p. 2315-2322.

9. Jiang, P., et al., *Time series analysis and forecasting for wind speeds using support vector regression coupled with artificial intelligent algorithms*. Mathematical Problems in Engineering, 2015. **2015**.
10. Sun, Z., et al., *A Bayesian regularized artificial neural network for adaptive optics forecasting*. Optics Communications, 2017. **382**: p. 519-527.
11. Heydecker, B. and J. Wu, *Identification of sites for road accident remedial work by Bayesian statistical methods: an example of uncertain inference*. Advances in Engineering Software, 2001. **32**(10-11): p. 859-869.
12. Chandra, R. and A. Kapoor, *Bayesian neural multi-source transfer learning*. Neurocomputing, 2020. **378**: p. 54-64.
13. Cherif, H., et al., *Early detection and localization of stator inter-turn faults based on discrete wavelet energy ratio and neural networks in induction motor*. Energy, 2020. **212**: p. 118684.
14. Subbaraj, P. and B. Kannapiran, *Fault detection and diagnosis of pneumatic valve using Adaptive Neuro-Fuzzy Inference System approach*. Applied Soft Computing, 2014. **19**: p. 362-371.
15. Benchabane, F., et al., *Experimental investigation on induction motors inter-turns short-circuit and broken rotor bars faults diagnosis through the discrete wavelet transform*. e & i Elektrotechnik und Informationstechnik, 2018. **135**(2): p. 187-194.
16. Bessam, B., et al., *Detection of broken rotor bar faults in induction motor at low load using neural network*. ISA transactions, 2016. **64**: p. 241-246.
17. Khechekhouche, A., et al., *Experimental diagnosis of inter-turns stator fault and unbalanced voltage supply in induction motor using MCSA and DWER*. Periodicals of Engineering and Natural Sciences, 2020. **8**(3): p. 1202-1216.
18. Bouzid, M., *Diagnostic de défaut de la machine asynchrone par réseaux de neurones*. These de doctorat, l'Ecole Nationale d'Ingénieurs de Tunis, 2009.

Chapitre 4

Diagnostic des défauts rotoriques et statoriques
par la technique Neuro-Flou (ANFIS) dans le
moteur à induction

4.1 Introduction

Dans ce chapitre, on propose l'utilisation de la technique Neuro-Flou (ANFIS) pour automatiser la détection et la classification de défauts statoriques et rotoriques d'un moteur à induction. On effectue les tâches de détection et de localisation de défauts de court-circuit entre spires d'une même phase au stator par hybridation des méthodes REOD et ANFIS. On appelle cette méthode (REOD-ANFIS_{cc}). On détermine aussi le nombre de barres cassées au rotor par hybridation des méthodes HFFT et ANFIS. Cette méthode hybride sera notée (HFFT-ANFIS_{bc}). A cet effet, deux modèles d'ANFIS sont utilisés : le "Grid Partitioning" et le "Subtractive Clustering", afin d'obtenir de bonnes performances et l'efficacité dans la réalisation du processus de diagnostic. Cela permet de créer un système de surveillance automatique qui combine la détection et la classification des deux types de défauts. Pour tester l'efficacité de la méthode proposée, plusieurs essais expérimentaux ont été réalisés dans différentes conditions de fonctionnement du MI (moteur sain et moteur avec défauts) et sous différentes charges.

4.2 Système d'inférence flou basé sur un réseau adaptatif

Ce système est appelé en anglais "Adaptive Network Based Fuzzy Inference System (ANFIS)". L'ANFIS est une combinaison de logique floue et d'algorithme de réseau neuronal (RN). Elle fût proposée au début des années 90 par J. S. Jang. Il s'agit d'une technique neuro-floue hybride qui apporte les capacités d'apprentissage des réseaux de neurones au système d'inférence flou de type Takagi-Sugeno. Le rôle de l'apprentissage est l'ajustement des paramètres de ce système d'inférence flou. La force du système ANFIS est la possibilité de génération automatique des règles floues en utilisant le **Grid Partitioning** ou le **Subtractive Clustering** [1]. La règle d'apprentissage hybride est appliquée par l'ANFIS pour optimiser le système d'inférence final grâce à l'apprentissage du RN. C'est l'équivalent du système de premier ordre Takagi-Sugeno [1]. Il est représenté par les deux règles **Si-Alors** suivantes :

1^{ère} règle: si x est A_1 et y est B_1 , alors $f_1 = p_1x + q_1y + r_1$

2^{ème} règle: si x est A_2 et y est B_2 , alors $f_2 = p_2x + q_2y + r_2$

Où :

- x_1 et x_2 sont les variables d'entrée,
- A_1, A_2, B_1 et B_2 les ensembles flous,
- y_i les sorties de chaque règle p_i, q_i et r_i sont des paramètres du conséquent de la règle i déterminés pendant le processus d'apprentissage.

Le système ANFIS se compose de cinq couches, dans lesquelles trois couches sont des nœuds fixes schématisés par des cercles et deux couches adaptatives schématisées par des carrés (**Fig. 4.1**).

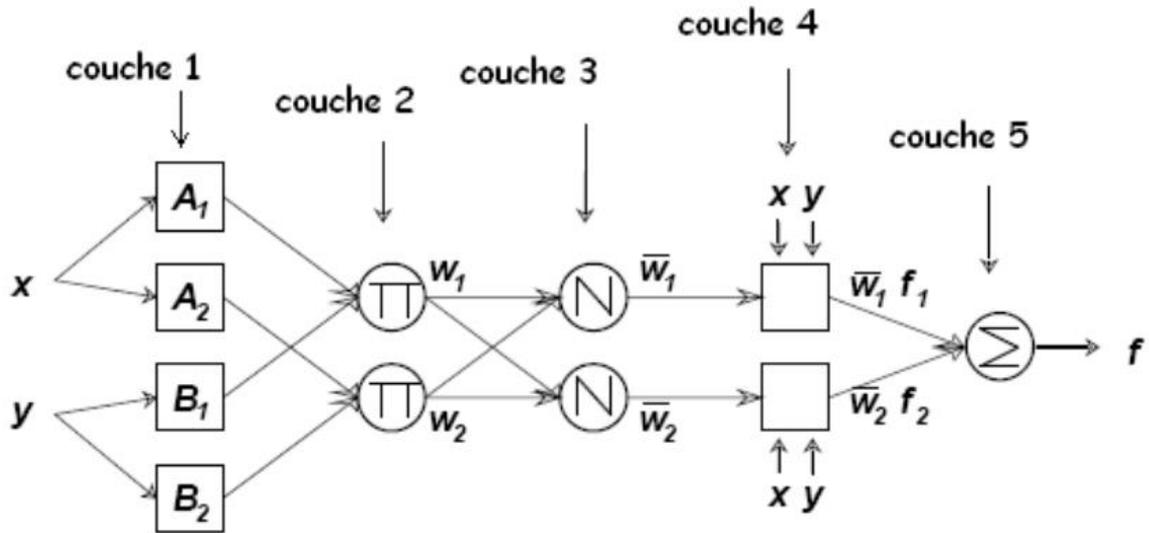


Fig. 4.1 Architecture de l'ANFIS

- **Première couche pour la fuzzification**

C'est un sous-ensemble flou dans le système d'inférence avec des nœuds adaptatifs, où chaque nœud fait le calcul des degrés d'appartenance des variables d'entrée, qui sont données par :

$$O_i^1 = \mu_{A_i}(x) \tag{4.1}$$

Où :

x : désigne l'entrée du nœud i .

A_i : termes linguistiques associés aux fonctions d'appartenance au nœud i .

μ_{A_i} : est une fonction d'appartenance qui peut être triangulaire, trapézoïdale, gaussienne ou en forme de cloche.

Les sorties O_i^1 de la première couche représente donc les degrés d'appartenance des variables d'entrée aux ensembles flous [2].

Dans cette étude, la fonction d'appartenance gaussienne donnée par l'expression (4.2) est :

$$\mu_{A_i}(x) = e^{-\frac{1}{2}\left(\frac{x-c}{\sigma}\right)^2} \tag{4.2}$$

La fonction d'appartenance (MF) type gaussien est entièrement définie par deux paramètres non linéaires c et σ , où c est le centre de MF et σ détermine la largeur de MF de type gaussien. Ces paramètres non linéaires sont appelés paramètres de prémisse qui sont ajustés lors de la phase

d'apprentissage sur la base d'un algorithme d'optimisation inspiré du RN artificiel, afin de trouver la fonction d'appartenance optimale conduisant aux meilleures performances en terme d'erreur [1, 3].

- **Deuxième couche pour le produit**

C'est un sous-ensemble de nœuds fixe portant l'étiquette Π . Il est formé d'un nœud pour chaque règle floue et génère les poids synaptiques w_i [2, 4].

$$\text{Où : } W_i = \mu_{A_i}(x) \cdot \mu_{B_i}(y) \quad \text{pour } i=1,2 \quad (4.3)$$

La sortie de chaque nœud de cette couche représente le poids d'une règle.

- **Troisième couche pour la normalisation**

C'est un sous-ensemble de nœuds fixes qui normalisent chaque poids, en le divisant selon le total de tous les poids associés à chaque règle. Sa fonction d'activation est donnée par l'expression (4.4)

$$\bar{W} = \frac{W_i}{W_1 + W_2}, \quad i = 1, 2. \quad (4.4)$$

- **Quatrième couche pour la défuzzification**

Chaque nœud de cette couche est un nœud adaptatif à une sortie, avec une fonction de nœud définie comme [5] :

$$O_i^4 = \bar{W}f_i = \overline{W_i(p_i x + q_i y + r_i)} \quad (4.5)$$

Où $\{p_i, q_i, r_i\}$ sont les paramètres conséquents à définir lors de la phase d'apprentissage.

- **Cinquième couche de la sortie**

Il s'agit d'un nœud fixe unique qui additionne toutes les informations reçues de la couche précédente et délivre la sortie de réseau, telle que [1, 3]:

$$O_i^5 = \sum \bar{W}f_i \quad (4.6)$$

Dans la présente étude, un algorithme d'apprentissage hybride est utilisé afin d'adapter les paramètres du réseau. L'algorithme hybride est un algorithme à deux passes. Il combine la méthode des moindres carrés et la méthode de descente de gradient de rétro-propagation pour optimiser la prémisse et les paramètres conséquents. Dans la première passe, les paramètres de prémisse sont adaptés par la méthode de descente de gradient de rétro-propagation. Alors que les paramètres sont déterminés par la méthode des moindres carrés dans la deuxième passe [6, 7].

4.2.1 Types de l'ANFIS

4.2.1.1 Grid Partition (GP)

Dans cette méthode, l'espace de données d'entrée est divisé en sous-espace rectangulaire à l'aide d'une partition parallèle à l'axe ; chaque entrée est partitionnée en fonctions d'appartenance de

forme identique. Le nombre de règles floues si-alors est égal à M^n , où n est la dimension d'entrée et M est le nombre de sous-ensembles flous partitionnés pour chaque variable d'entrée.

La grille est construite sans prendre aucune signification physique ou répartition de la densité des données, et chaque partie de la grille est utilisée pour générer des règles floues basées sur les données d'entraînement d'entrée-sortie du système, ce qui permet des processus d'apprentissage rapides et une optimisation du temps de calcul. Cependant, les performances de cette méthode dépendent fortement de la taille des entrées et du réseau ; généralement, une grille plus fine conduit à des performances élevées. Une répartition adaptative de la grille peut être utilisée pour optimiser la taille et l'emplacement des régions floues de grille [5, 8, 9].

4.2.1.2 Subtractive Clustering (SC)

La méthode de Subtractive Clustering (SC) est proposée par Chiu en [10], en étendant la méthode de clustering de montagne[11]. Dans cet algorithme, chaque point de données est considéré comme un candidat de centre de cluster, puis il calcule le potentiel de chaque point de données en mesurant la densité des données de points qui l'entourent. L'algorithme est un processus itératif, qui supposait que chaque point est un centre de cluster potentiel en fonction de son emplacement par rapport aux autres points de données. Il consiste à choisir un point qui a la probabilité d'être le centre de cluster potentiel le plus élevé, puis à supprimer tous les points qui se trouvent à l'intérieur du rayon du premier centre de cluster (le rayon est défini par les voisinages du centre). Et, recalculez le potentiel des autres points pour déterminer le prochain centre de cluster. Enfin, répétez cette étape jusqu'à ce que toutes les données soient dans le rayon d'un centre de cluster [5, 8]: l'algorithme peut être résumé comme suit:

- **Etape.1:** Considérons une collection de n points de données $\{X_1, X_2, \dots, X_n\}$ dans un espace à m dimensions; Sélectionnez le point de données avec le potentiel le plus élevé pour être le centre du premier groupe.
- **Etape.2 :** Mesurer la densité (D_i) correspondant aux données x_i :

$$D_i = \sum_{j=1}^n \exp\left(-\frac{\|X_i - X_j\|^2}{(r_a/2)^2}\right) \quad (4.6)$$

Où r_a est un nombre positif qui représente le rayon où toutes les données à l'intérieur de lui sont considérées comme voisines ; le point de données avec la mesure de densité la plus élevée est sélectionné comme premier cluster central dénoté X_{c1} et sa densité est D_{c1} .

- **Etape 3 :** Recalculez les mesures de densité pour chaque point de données x_i à l'aide de l'expression (4.7) :

$$D_i = D_i - D_{c1} \exp\left(-\frac{\|X_i - X_j\|^2}{(r_b/2)^2}\right) \quad (4.7)$$

$r_b = \mathbf{K} \cdot r_a$ (\mathbf{K} est un nombre positif, généralement $\mathbf{K} = 1,5$ [10, 11]), en conséquence; tous les points proches du premier centre de cluster \mathbf{X}_{c1} auront une mesure de faible densité et ne seront donc pas considérés comme les prochains centres de cluster. Le centre de cluster suivant \mathbf{X}_{c2} est sélectionné après que la mesure de densité pour chaque point de données a été recalculée [8].

- **Etape 4:** Recalculer toutes les mesures de densité pour les points de données encore. Et répétez les processus jusqu'à ce qu'un nombre suffisant des centres de cluster sont générés [8, 9, 12].

4.3. Critères de performance

Dans ce travail, la tâche d'apprentissage et de test des modèles ANFIS peut être évaluée par l'erreur quadratique moyenne (MSE) et la racine de l'erreur quadratique moyenne (RMSE), pour la validation et déterminer les performances des modèles prédits qui correspondent avec les valeurs de base de données mesurées. MSE et RMSE peuvent être définis, respectivement, comme suit :

$$MSE = \frac{1}{n} \sum_{i=0}^n (X_i - Y_i)^2 \quad (4.8)$$

$$RMSE = \sqrt{\left(\frac{1}{n} \sum_{i=0}^n (X_i - Y_i)^2\right)} \quad (4.9)$$

Où n est le nombre d'échantillons ; \mathbf{X}_i et \mathbf{Y}_i sont les valeurs mesurées et prédites, respectivement [13].

4.4 Méthodologie général de la détection des défauts statorique et rotorique en utilisant l'ANFIS

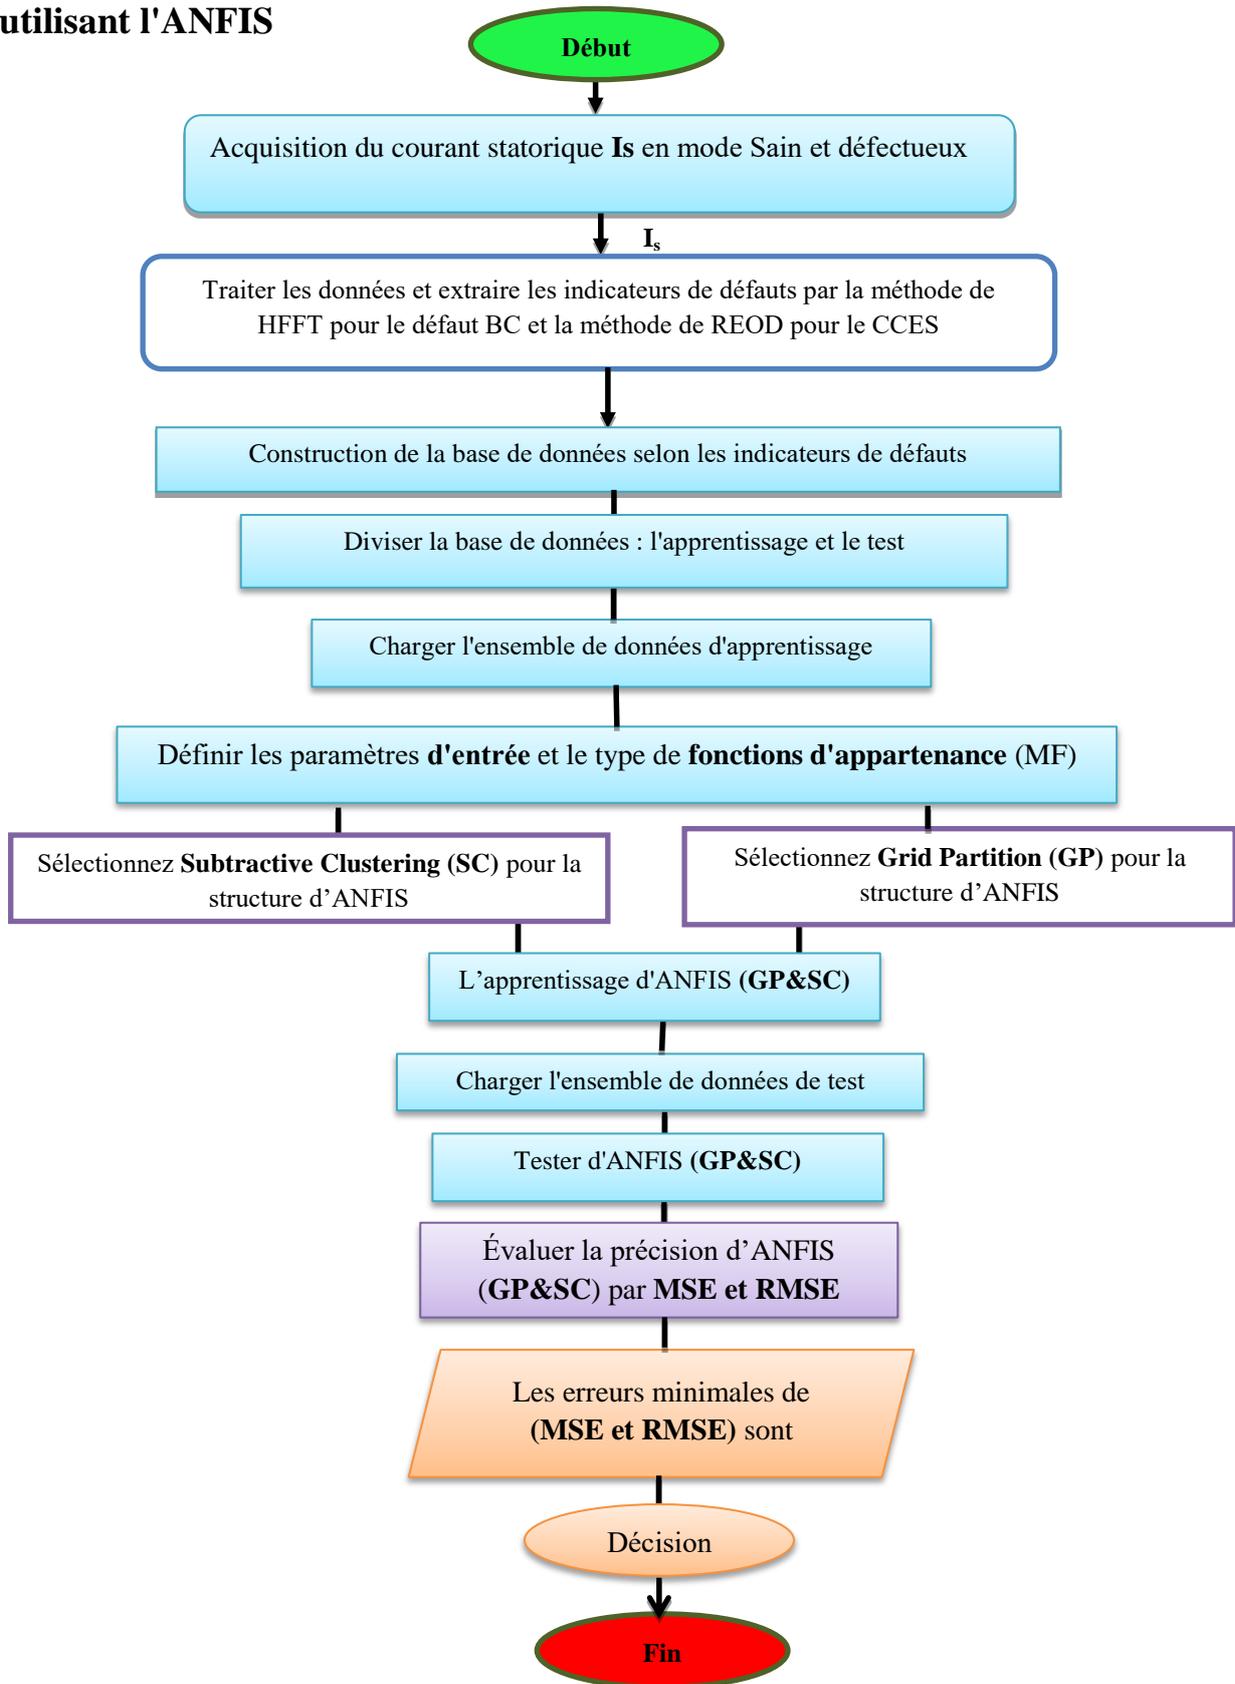


Fig.2.4 Organigramme pour la détection de défauts par l'ANFIS basée sur le GP et SC

Dans ce travail, la méthodologie proposée, pour diagnostiquer les défauts statoriques et rotoriques de la MI par l'ANFIS, est représentée sur la **Fig. 4.2**. Elle est élaborée comme suit:

- **Acquisition des courants statoriques (Is)**

Elle se fait dans différentes conditions (sain, avec défaut et sous différentes charges) à l'aide des capteurs de courant qui sont connectés à l'interface de la carte DSpace pour enregistrer les données sur le PC.

- **Extraction des indicateurs de défauts**

Elle se fait à l'aide du logiciel Matlab. Nous avons traité les données acquises par les méthodes HFFT et REOD pour extraire les indicateurs des défauts: barres cassés rotoriques et court-circuit entre spires statoriques, comme nous l'avons expliqué dans le deuxième chapitre.

- **Classification de défauts**

Elle est réalisée en utilisant l'hybridation des méthodes (HFFT et REOD) et l'ANFIS. Cette hybridation est basée sur les deux structures "GP et SC". La classification des défauts est effectuée pour : quantifier les nombres de barres cassées dans le rotor et localiser les phases de défaut de court-circuit entre spires au stator du MI. On construit les bases de données selon les indicateurs de défauts qui sont formés à partir des couple (entrée/sortie). Les entrées représentent les indicateurs de défauts sélectionnés et la sortie est le nombre de BC ou la phase qui contient des défauts CCES. Nous avons soigneusement divisé la base de données : une partie pour l'apprentissage et l'autre pour le test. L'opération d'apprentissage consiste à chercher une configuration optimale des paramètres du système correspondant à un taux de succès élevé. On procède à un test avec la base de données test pour vérifier que notre système réagit correctement. On pourra ainsi déterminer le taux de succès ou de bonne classification. Après ces deux opérations, le système ANFIS est prêt à l'exploitation [4].

- **Évaluation de la précision d'ANFIS**

Afin d'évaluer l'efficacité et les performances des modèles ANFIS (GP et SC), l'erreur quadratique moyenne (MSE) et la racine de l'erreur quadratique moyenne (RMSE) sont choisies pour être les critères de précision, où le modèle avec les erreurs minimales est le plus efficace.

4.5 Diagnostic de défaut rotorique par la méthode hybride HFFT-ANFIS_{bc}

Les propriétés de la méthode de diagnostic "HFFT" la rendent appropriée pour concevoir des systèmes d'inférence neuro-flou adaptatifs. Pour générer les règles du système d'inférence floue, les deux algorithmes GP et SC sont utilisés.

Comme nous avons fait au chapitre précédent, les indicateurs de défauts sont choisis pour la détection de défauts cassure de barres rotoriques à base de la méthode de HFFT, où l'on a regroupé dans un vecteur \mathbf{I} les entrées du réseau ANFIS_{bc} et la sortie représente le nombre de barres cassées au rotor. L'expression de \mathbf{I} est la suivante:

$$\mathbf{I} = [I_1 \ I_2]^T$$

Où:

- $I_1 = f_{bc}$: la fréquence de spectre (2.s/fs);
- $I_2 = A_{bc}$: l'amplitude de spectre (2.s/fs).

4.5.1 Structure d'ANFIS_{bc} utilisée dans le diagnostic de défaut rotorique

Les deux modèles ANFIS_{bc} proposés (ANFIS_{bc}-GP et ANFIS_{bc}-SC) ont été développés à partir des données collectées par les mesures expérimentales. L'ensemble de données a été soigneusement divisé en sous-ensembles de l'apprentissage qui a été utilisé pour former les modèles d'ANFIS_{bc} et de test pour vérifier l'exactitude et l'efficacité du modèle ANFIS_{bc} formé, comme indiqué ci-dessous. Bien que, le nombre de données d'apprentissage utilisé pour construire l'ANFIS_{bc} soit faible, les données collectées sont de bonne qualité et décrivent la dynamique du système. De plus, les scénarios expérimentaux envisagés peuvent nous aider à prendre une bonne décision sur l'état des barres au rotor du MI.

Le premier modèle ANFIS_{bc} proposé est ANFIS_{bc}-GP qui est basé sur la division de l'espace de données en plusieurs composantes carrées, comme nous l'avons mentionné précédemment. Les paramètres ANFIS_{bc}-GP sont composés de deux entrées variables qui sont la fréquence f_{bc} (I_1) et l'amplitude $A_{bc}(I_2)$ de l'harmonique 2sfs et une sortie variable représentant le nombre de barres cassées au rotor du MI. Une sortie floue linéaire avec six fonctions d'appartenance de type gaussien (MFs) est utilisée, comme indiqué sur **Fig. 4.3**. Ainsi, les deux entrées floues sont représentés par 6 ensembles flous type gaussiens et dirigés par 36 règles "IF-THEN" significatives, comme illustré sur **Fig. 4.4**. Les paramètres modifiés d'ANFIS_{bc}-GP ont été optimisés à l'aide de l'algorithme d'entraînement hybride. Le nombre d'itérations d'apprentissage utilisées est 100, car on déduit que le fait d'augmenter le nombre d'itérations n'entraîne pas une plus faible erreur.

Le deuxième modèle ANFIS_{bc} est ANFIS_{bc}-SC. Ses paramètres sont composés des mêmes entrées et sorties du premier modèle à 25 fonctions d'appartenance (MFs) de type gaussien, comme le montre **Fig. 4.5**. Le nombre de règles floues utilisées est 25 règles (voir **Fig. 4.6**). Pour générer ces règles, en utilisant la technique de regroupement soustractif, il est essentiel de déterminer les valeurs appropriées des paramètres "accept ratio", "reject ratio", "squash factor" et "cluster radius".

Les performances du modèle ANFIS_{bc}-SC sont très sensibles au paramètre «rayon de cluster» tandis que le reste des paramètres n'a pas une grande influence. Dans ce travail, le «facteur de squash», le «taux d'acceptation» et le «taux de rejet» ont été choisis respectivement 1,25, 0,5 et 0,15, tandis que le rayon de cluster est égal à 0,1.

Le MSE et le RMSE sont finalement calculés pour sélectionner les meilleurs paramètres adaptatifs. Les paramètres des deux modèles ANFIS_{bc} utilisés sont résumés dans **Tableau 4.1**.

Dans cette étude, les deux modèles ANFIS_{bc} sont développés à l'aide de MATLAB R2013b, Fuzzy Control Toolbox (voir l'annexe « C ») dans ordinateur avec processeur CORE i3 à 2,10 GHz et 4 Go de RAM.

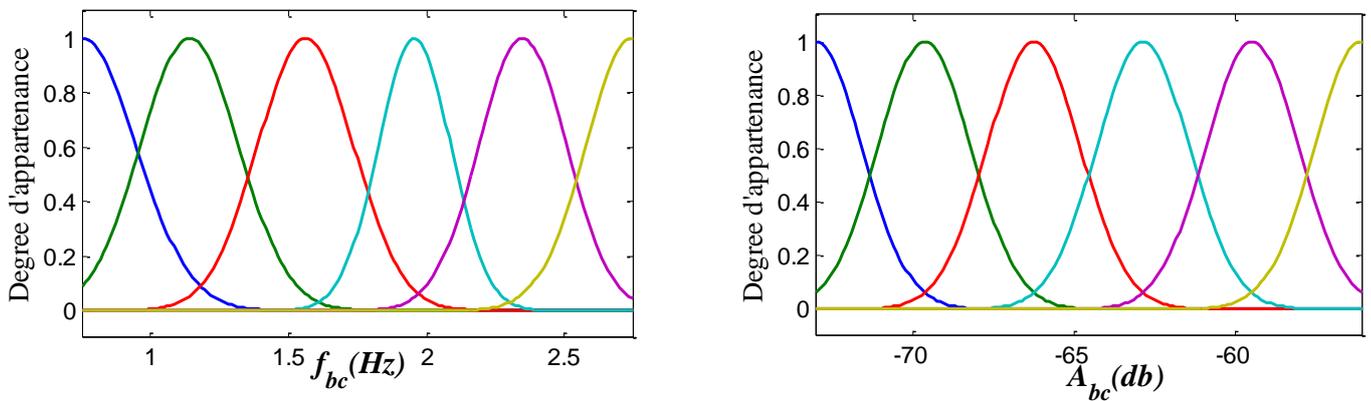


Fig. 4.3 Fonction d'appartenance de deux entrées (f_{bc} et A_{bc}) obtenue par le modèle ANFIS_{bc}-GP

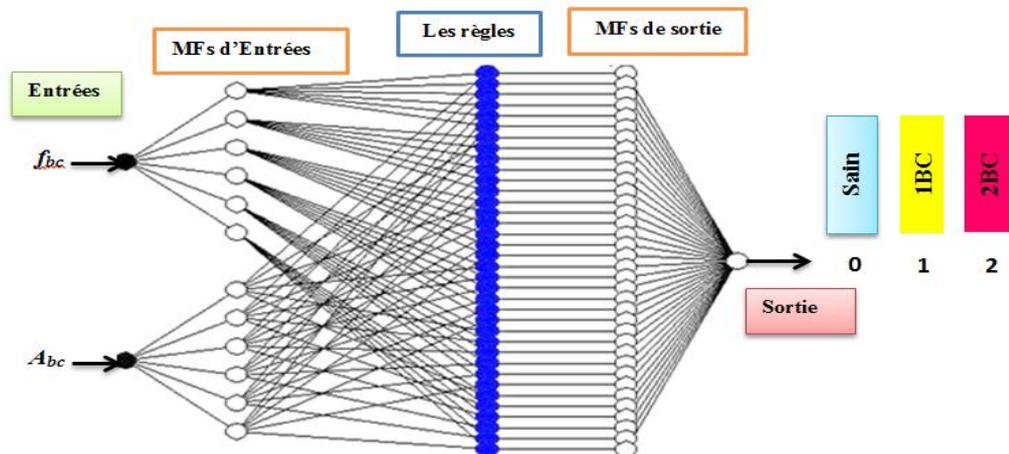


Fig. 4.4 Structure d'ANFIS_{bc}-GP pour la détection des défauts BC.

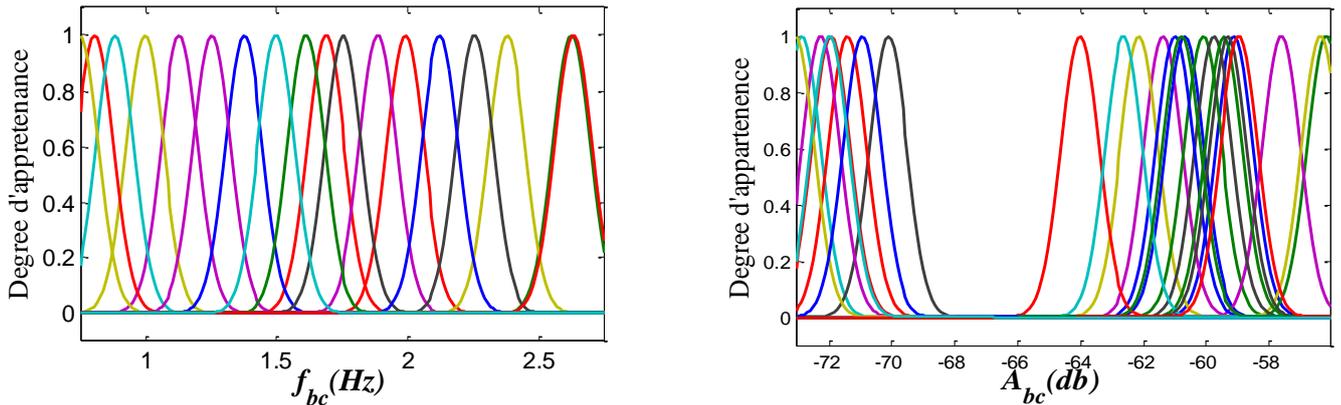


Fig. 4.5 Fonction d'appartenance de deux entrées (f_{bc} et A_{bc}) obtenue par le modèle ANFIS_{bc}-SC

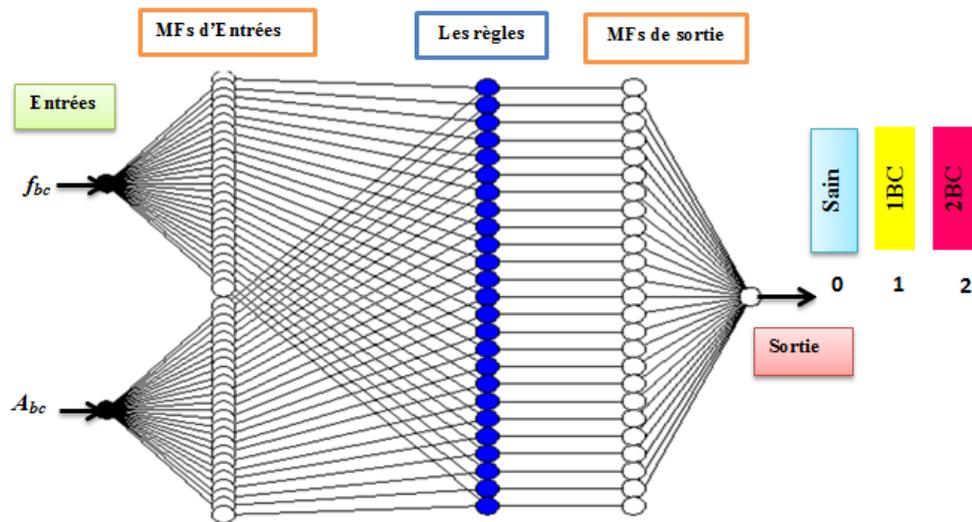


Fig. 4.6 Structure d'ANFIS_{bc}-SC pour la détection des défauts BC.

Table 4.1 Paramètres de deux modèles d'ANFIS_{bc}

paramètres d'ANFIS _{bc}	ANFIS _{bc} -GP	ANFIS _{bc} -SC
Nombre d'entrées	2	2
Nombre de sortie	1	1
Type de fonctions d'appartenances (MFs)	Gaussien	Gaussien
Sortie de MFs	Linéaire	Linéaire
Nombre de règles floues	36	25
Nombre d'itérations d'apprentissage	100	100

4.5.2 Génération de la base d'apprentissage d'ANFIS_{bc}

La création d'un ensemble de données d'apprentissage est d'une importance capitale pour le développement du modèle ANFIS_{bc}. Afin d'atteindre les objectifs souhaités, les données

d'apprentissage doivent contenir suffisamment d'informations, y compris plusieurs scénarios de fonctionnement du moteur à l'état sain et en défaut de cassure de barres sous différentes charges.

Pour conduire la phase d'apprentissage des modèles ANFIS_{bc} proposés (GP et SC), 105 échantillons sont utilisés en prenant $I = [f_{bc}, A_{bc}]$ comme entrée et le nombre de barres cassées au rotor comme sortie. L'ensemble des données d'entrée, représenté sur **Fig. 4.3**, est constitué par une série d'échantillons (105) composés de 5 parties, chaque partie représentant trois états des conditions de fonctionnement du MI sous 7 charges comme suit:

- 7x5 échantillons pour un moteur sain sous charges (10%, 20%, 40%, 50%, 70%, 80% et 100%) de la charge nominale,
- 7x5 échantillons pour un moteur avec une barre cassée sous les charges (10%, 20%, 40%, 50%, 70%, 80% et 100% de la charge nominale),
- 7x5 échantillons pour un moteur avec deux barres cassées sous les charges (10%, 20%, 40%, 50%, 70%, 80% et 100% de la charge nominale).

L'ensemble de données de sortie est nécessaire pour réaliser l'apprentissage supervisé. Cet ensemble de données est construit en faisant correspondre chaque échantillon de l'ensemble de données d'entrée avec sa sortie désirée qui indique le nombre de barres cassées au rotor du MI pour les deux modèles ANFIS_{bc}-GP et ANFIS_{bc}-SC, comme le montre **Fig. 4.7**. Il est clair que les modèles ANFIS_{bc} ont parfaitement appris car ils ont donné correctement la sortie désirée :

- sortie = 0 pour un moteur sain,
- sortie = 1 pour un moteur avec défaut d'une barre cassée,
- sortie = 2 pour un moteur avec défaut de deux barres cassées.

Fig. 4.8 montre les erreurs des sorties d'apprentissage des modèles ANFIS_{bc}-GP et ANFIS_{bc}-SC dans plusieurs conditions (modes sain et défectueux) du MI. Il est à noter que les valeurs d'erreur sont très faibles dans les deux modèles ANFIS_{bc}, mais par la comparaison entre les deux modèles, on constate que l'ANFIS_{bc}-SC est plus stable avec une erreur minimale par rapport au modèle ANFIS_{bc}-GP.

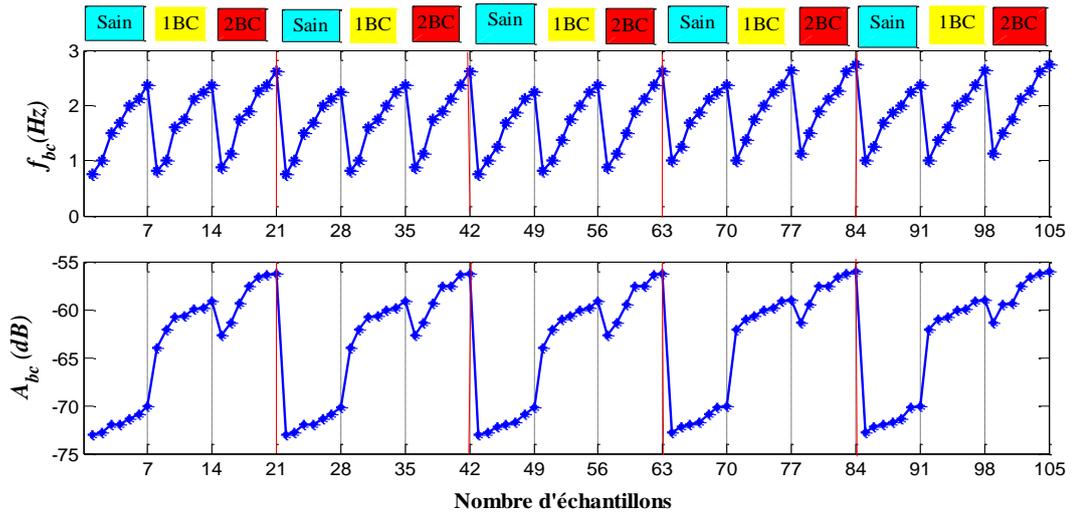


Fig. 4.7 Séquence d'apprentissage de l'ANFIS_{bc}

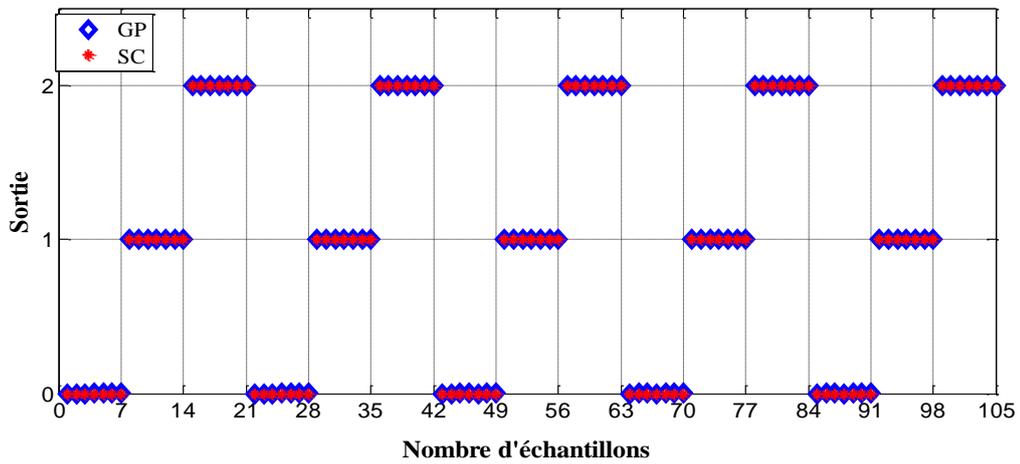


Fig. 4.8 Sortie des données d'apprentissage des modèles ANFIS_{bc} (GP & SC)

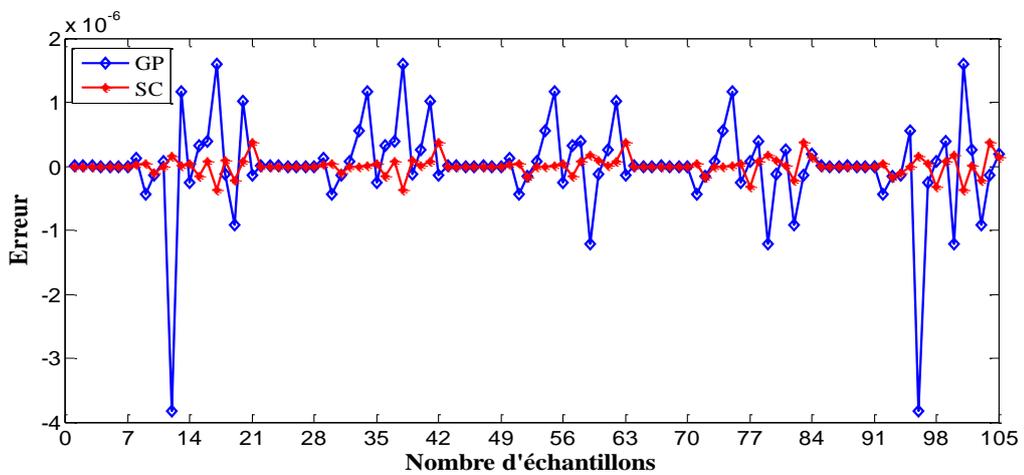


Fig. 4.9 Erreurs pour les données d'apprentissage des modèles ANFIS_{bc} (GP & SC)

4.5.3 Résultats de test d'ANFIS_{bc}

Afin d'évaluer la capacité de généralisation de deux modèles ANFIS_{bc} (GP & SC), le réseau doit être présenté avec un ensemble de données de test composé d'une séquence différente de celle lors de l'apprentissage. Ce dernier se répartit comme suit (voir **Fig. 4.10**) :

- 9 échantillons pour un fonctionnement sain du moteur sous les charges (30%, 60% et 90% de la charge nominale),
- 9 échantillons pour fonctionnement avec défaut d'une barre cassée du moteur sous les charges (30%, 60% et 90% de la charge nominale),
- 9 échantillons pour fonctionnement avec défaut de deux barres cassées sous les charges (30%, 60% et 90% de la charge nominale).

Le test de sortie et leurs erreurs des deux modèles ANFIS_{bc} sont représentés respectivement sur **Fig. 4.11** et **Fig. 4.12**, où il est noté que le réseau a indiqué des sorties variables qui représentent le nombre de barres cassées au rotor. Il est clair que le modèle ANFIS_{bc}-SC peut quantifier avec précision le nombre de barres cassées avec une erreur et un temps plus petits que le modèle ANFIS_{bc}-GP.

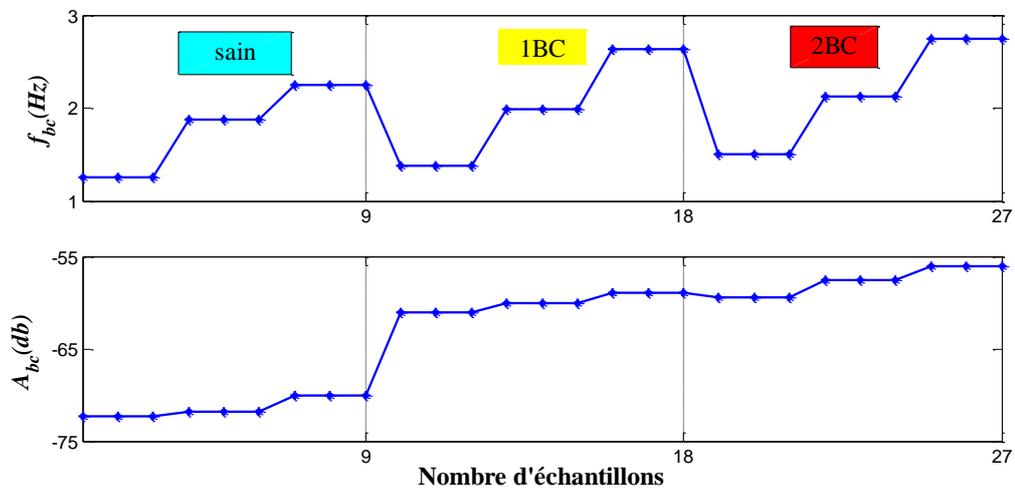


Fig. 4.10 Entrées pour tester les données des modèles ANFIS_{bc} (GP & SC)

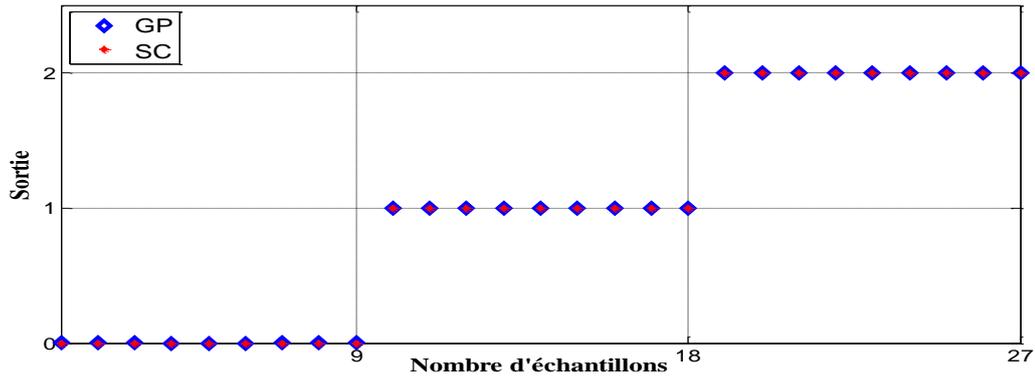


Fig. 4.11 Sortie pour tester les données des modèles ANFIS_{bc} (GP &SC)

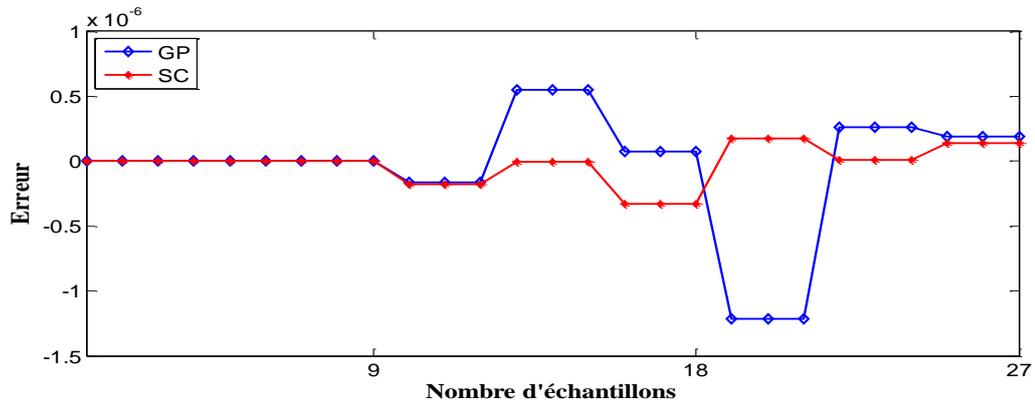


Fig. 4.12 Erreur de test d'ANFIS_{bc} (GP &SC)

4.5.4 Comparaison entre les deux modèles d'ANFIS_{bc}

Tableau 4.2 représente les erreurs (MSE et RMSE) qui sont utilisées pour l'évaluation des deux modèles ANFIS_{bc} des phases d'apprentissage et de test. D'après ce tableau, on observe que le modèle ANFIS_{bc}-SC donne les erreurs (MSE=1,9152x10⁻¹⁴ et RMSE=1,3839x10⁻⁷) pour la phase d'apprentissage et (MSE= 2,1088x10⁻¹⁴ et RMSE=1,4522x10⁻⁷) pour la phase de test. Ce modèle donne de meilleurs résultats que le modèle ANFIS_{bc}-GP pour quantifier le nombre de barres cassées au rotor du MI. Cela indique la performance et l'efficacité élevées du modèle ANFIS_{bc}-SC qui peuvent être utilisées avec succès pour la détection et la classification des défauts de BC.

Tableau 4.2: Comparaison entre les résultats d'erreurs de deux modèles ANFIS_{bc} pour les phases d'apprentissage et de test.

Phase	Modèles d'ANFIS _{bc}	RMSE	MSE
Apprentissage	GP	7.3541 x10 ⁻⁷	5.4083 x10 ⁻¹³
	SC	1.3839 x10 ⁻⁷	1.9152 x10 ⁻¹⁴
Test	GP	4.6240x10 ⁻⁷	2.1381x10 ⁻¹³
	SC	1.4522x10 ⁻⁷	2.1088x10 ⁻¹⁴

4.6 Diagnostic de défaut statorique par la méthode hybride REOD-ANFIS_{cc}

Sur la base de la méthode de REOD, les trois rapports d'énergies d'ondelette des courants statoriques ($\mathbf{R}_1 = E_{d7as} / E_{d7bs}$, $\mathbf{R}_2 = E_{d7bs} / E_{d7cs}$ et $\mathbf{R}_3 = E_{d7cs} / E_{d7as}$) sont choisis comme indicateurs pour la détection et la localisation des phases en défaut de court-circuit entre spires au stator du MI. Ces indicateurs sont regroupés dans un vecteur R comme suit.

$$\mathbf{R} = [\mathbf{R}_1 \ \mathbf{R}_2 \ \mathbf{R}_3]^T$$

Où:

- \mathbf{R}_1 : 1^{er} rapport d'énergie d'ondelette discrète E_{d7as} / E_{d7bs} ;
- \mathbf{R}_2 : 2^{ème} rapport d'énergie d'ondelette discrète E_{d7bs} / E_{d7cs} ;
- \mathbf{R}_3 : 3^{ème} rapport d'énergie d'ondelette discrète E_{d7cs} / E_{d7as} .

Le vecteur R est utilisé comme entrée du réseau ANFIS_{cc}. Tandis que la sortie représente la phase en défaut de court-circuit entre spires. Comme nous l'avons mentionné précédemment, afin de générer des règles floues, on utilise les deux techniques : GP et SC.

4.6.1 Structure d'ANFIS_{cc} utilisée dans le diagnostic de défauts statoriques

Les deux modèles d'ANFIS_{cc} (GP et SC) établis se composent de trois entrées variables qui sont les rapports d'énergies d'ondelette des courants statoriques (\mathbf{R}_1 , \mathbf{R}_2 , et \mathbf{R}_3) et d'une sortie variable représentant la phase de défauts de court-circuits entre spires. L'ensemble de données est généré à l'aide des essais expérimentaux dans différentes conditions. Une partie des données générées est utilisée comme échantillons d'apprentissage, tandis que l'autre partie est utilisée pour tester le modèle ANFIS_{cc}. Par la suite, pour évaluer les performances du modèle proposé, la différence entre les valeurs de sortie prévues et réelles a été évaluées en fonction de MSE et RMSE.

Pour le modèle ANFIS_{cc}-GP, on a utilisé 4 fonctions d'appartenance type gaussien et 64 règles floues, comme le montrent **Fig. 4.13** et **Fig. 4.15**. Cependant, le modèle ANFIS_{cc}-SC utilise 18 fonctions d'appartenance type gaussien, avec 18 règles floues utilisées, comme l'indiquent **Fig. 4.14** et **Fig. 4.16**. Le «facteur de squash», le «taux d'acceptation», le «taux de rejet» et le «rayon de cluster» ont été choisis 1.25, 0.5, 0.15 et 0.1, respectivement. Les paramètres des deux modèles ANFIS_{cc} utilisés sont résumés dans **Tableau 4.3**.

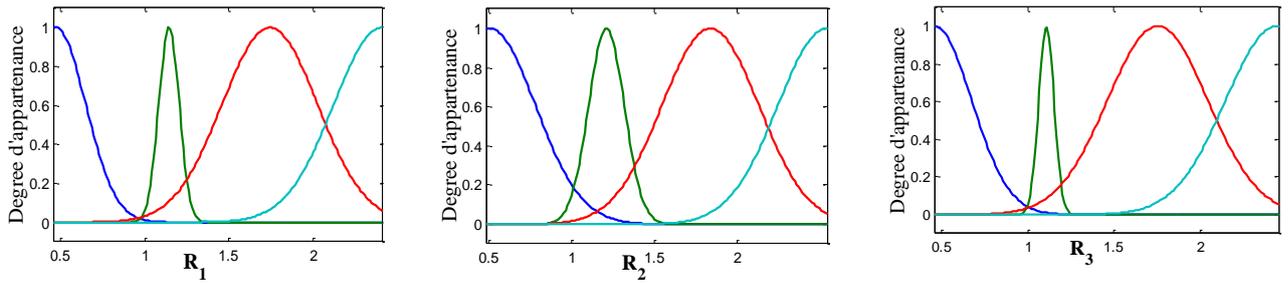


Fig. 4.13 Fonctions d'appartenance des entrées (R_1 , R_2 et R_3) obtenues par le modèle ANFIS_{cc}-GP

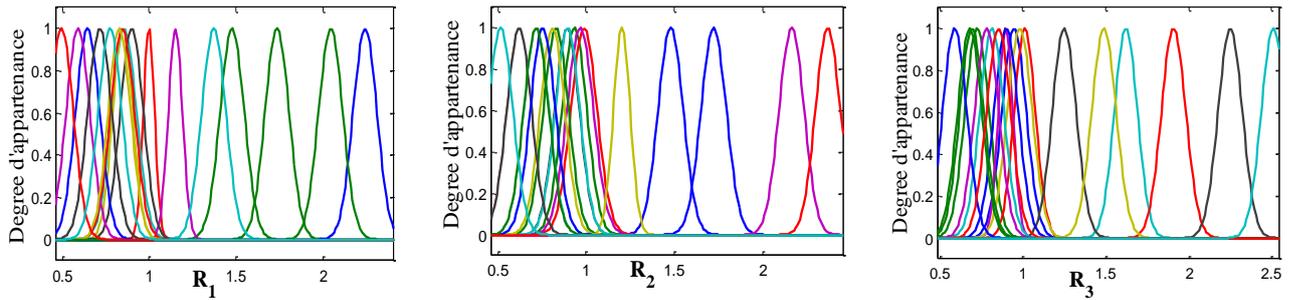


Fig.4.14 Fonctions d'appartenance des entrées (R_1 , R_2 et R_3) obtenues par le modèle ANFIS_{cc}-SC

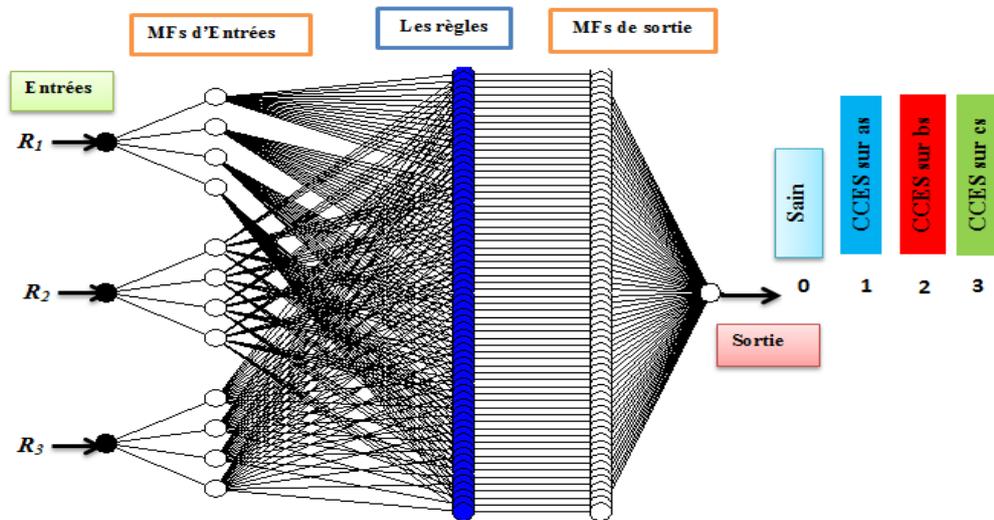


Fig. 4.15 Structure d'ANFIS_{cc}-GP pour la détection et la localisation des défauts CCES.

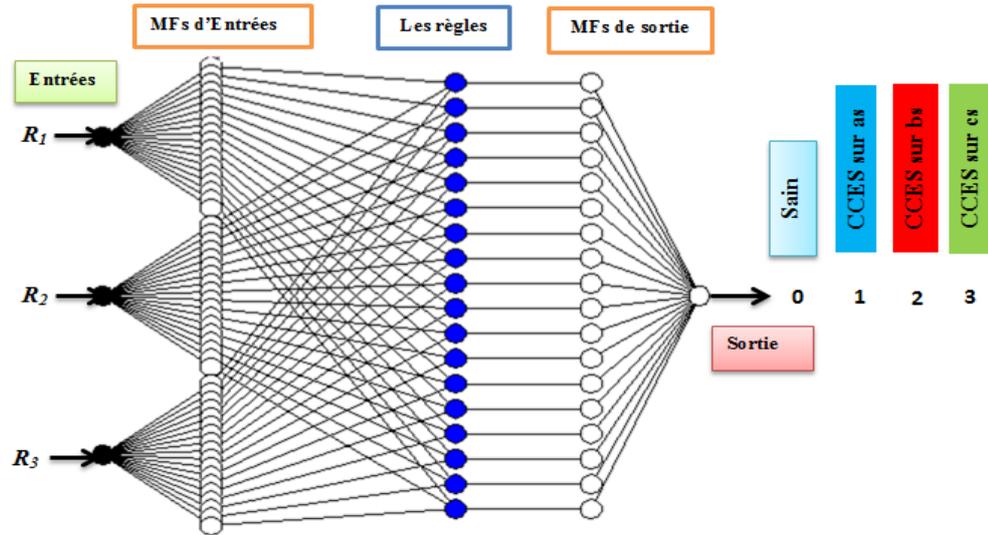


Fig. 4.16 Structure d'ANFIS_{cc}-SC pour la détection et la localisation des défauts CCES.

Table 4.3. Paramètres de deux modèles d'ANFIS_{cc}

Paramètres d'ANFIS _{cc}	ANFIS _{cc} -GP	ANFIS _{cc} -SC
Nombre d'entrées	3	3
Nombre de sortie	1	1
Type de fonctions d'appartenance (MFs)	Gaussien	Gaussien
Sortie de MFs	Linéaire	Linéaire
Nombre de règles floues	64	18
Nombre d'itérations d'apprentissage	100	100

4.6.2 Génération de la base d'apprentissage d'ANFIS_{cc}

Pour faire la phase d'apprentissage de réseau d'ANFIS_{cc} (GP et SC), 96 échantillons sont utilisés en prenant $R = [R_1 \ R_2 \ R_3]^T$ comme vecteur d'entrée et la détection et la localisation de la phase en défaut court-circuit entre spires comme sortie. L'ensemble de données d'entrée, représenté sur Fig. 4.17, est constitué par une série d'échantillons (96) composés de 4 parties. Chaque partie est simulée sous 6 charges comme suit :

- **Partie 1:** 6 échantillons pour l'état sain du moteur sous 6 charges (à vide, 10%, 30%, 50%, 70 et 90% de la charge nominale),
- **Partie 2:** 30 échantillons (5x6) représentant les états de défaut CCES des (7-13-15-20-30) spires court-circuitées en phase **as** sous 6 charges (à vide, 10%, 30%, 50% , 70% et 90% de la charge nominale),

- **Partie 3:** 30 échantillons (5x6) représentant les états de défaut CCES des (7-13-15-20-30) spires court-circuitées en phase **bs** sous 6 charges (à vide, 10%, 30%, 50% , 70% et 90% de la charge nominale),
- **Partie 4:** 30 échantillons (5x6) représentant les états de défaut CCES des (7-13-15-20-30) spires court-circuitées en phase **cs** sous 6 charges (à vide, 10%, 30%, 50% , 70% et 90% de la charge nominale).

La sortie variable désirée (O) d'ANFIS_{cc} est formée comme suit

- O= 0 pour un état sain du MI,
- O= 1 pour un défaut CCES dans la phase a_s,
- O= 2 pour un défaut CCES dans la phase b_s,
- O =3 pour un défaut CCES dans la phase c_s.

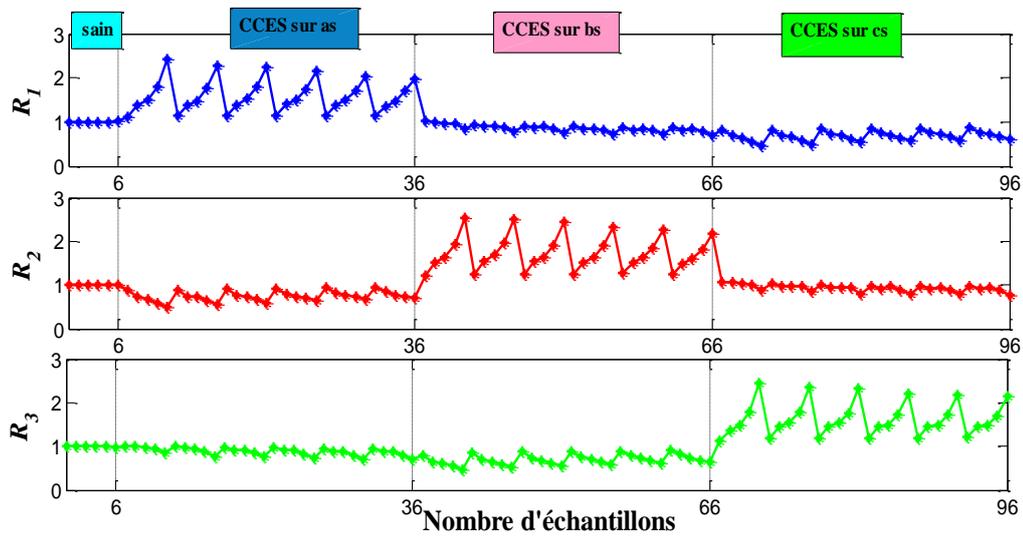
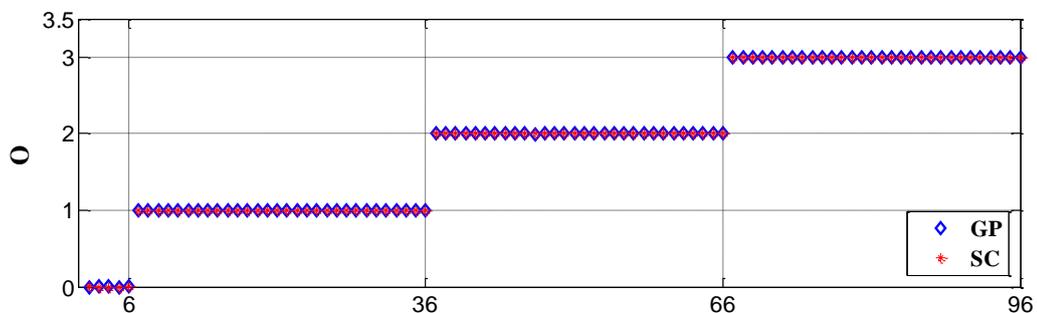


Fig. 4.17 Séquences d'apprentissage de l'ANFIS_{cc}



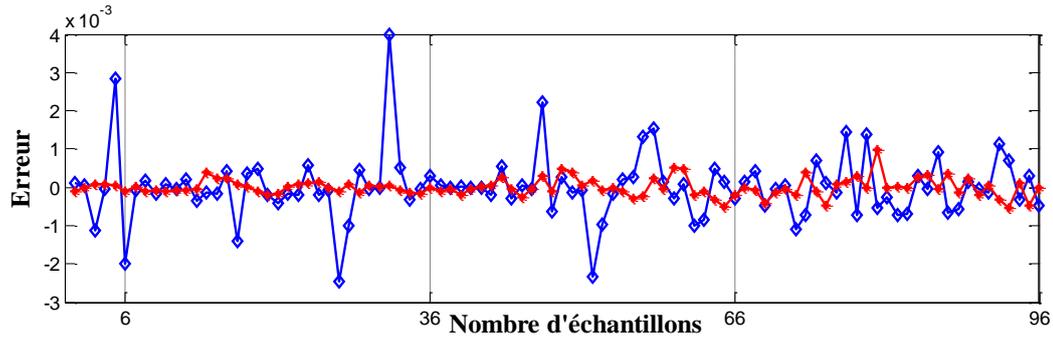


Fig.4.18 Sorties et erreurs d'apprentissage d'ANFIScc pour les modèles **GP** et **SC**.

Fig. 4.18 représente les sorties et les erreurs d'apprentissage d'ANFIScc pour les deux modèles GP et SC. On remarque que les erreurs d'apprentissage sont presque nulles, ce qui prouve que le réseau a bien appris les séquences de défauts. Cependant, par comparaison entre les deux modèles, on déduit que le modèle ANFIS_{cc}-SC a une plus faible valeur d'erreur et est plus stable que le modèle ANFIScc-GP.

4.6.3 Résultats de test d'ANFIScc

Afin d'évaluer les performances du réseau ANFIS_{cc}, on le teste par des exemples différents de celui utilisé pour l'apprentissage. On considère un réseau composé de 65 échantillons comme indiqué ci-dessous (voir **Fig. 4.19**):

- 5 échantillons pour l'état sain du moteur,
- 20 échantillons pour un fonctionnement avec des défauts de (8, 14,18, et 25) spires court-circuitées dans la phase **as** sous des charges de (20%, 40%, 60%, 80% et 100% de la charge nominale),
- 20 échantillons pour un fonctionnement avec des défauts de (8, 14,18, et 25) spires court-circuitées dans la phase **bs** sous des charges de (20%, 40%, 60%, 80% et 100% de la charge nominale),
- 20 échantillons pour un fonctionnement avec des défauts de (8, 14,18 et 25) spires court-circuitées dans la phase **cs** sous des charges de (20%, 40%, 60%, 80% et 100% de la charge nominale).

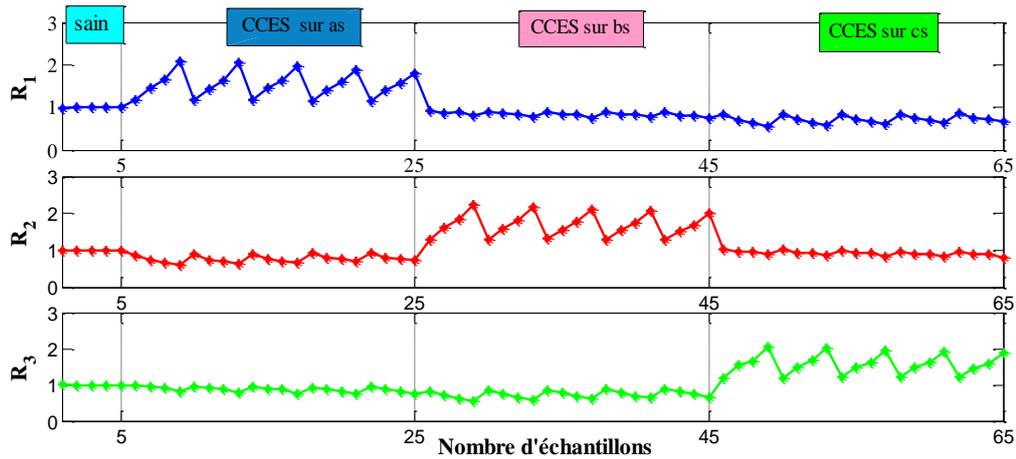


Fig. 4.19 Séquences de test de l'ANFIS_{cc}

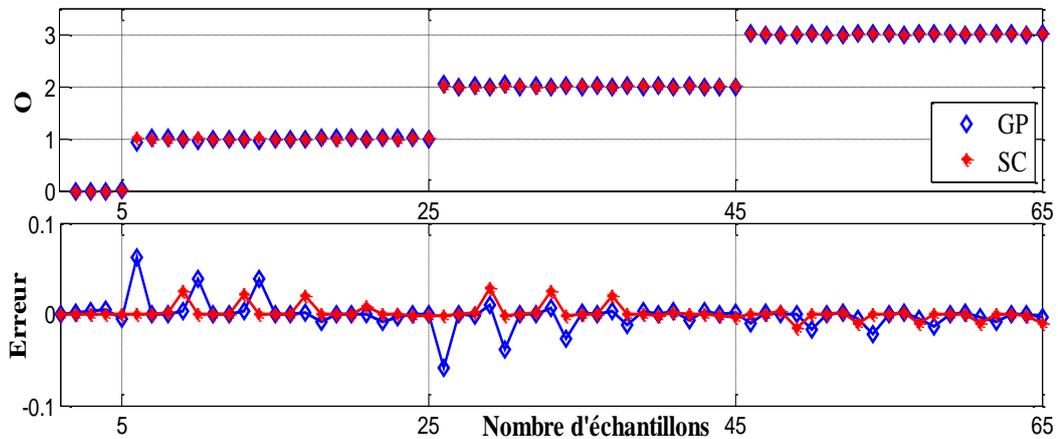


Fig. 4.20 Sorties et erreurs de test d'ANFIS_{cc} pour les modèles GP et SC.

Les sorties et les erreurs de test d'ANFIS_{cc} sont représentés sur **Fig.4.18**, pour les deux structures GP et SC, où l'on remarque que les deux réseaux (ANFIS_{cc}-GP et ANFIS_{cc}-SC) ont indiqué à la sortie : la valeur (0) pour le régime sain, (1) pour un CCES dans la phase as, (2) pour un défaut CCES dans la phase bs et (3) pour un défaut CCES dans la phase cs. La classification de ces exemples est effectuée avec une bonne précision, ce qui prouve que le ANFIS_{cc} est capable de localiser la phase de défaut court-circuit entre spires. Selon les erreurs de sortie des deux modèles ANFIS_{cc} (GP et SC), on remarque que le modèle ANFIS_{cc}-SC est plus efficace et plus précis que le modèle ANFIS_{cc}-GP.

4.6.4 Comparaison entre les deux modèles d'ANFIS_{cc}

Les erreurs (MSE et RMSE) pour les phases d'apprentissage et de test des deux modèles d'ANFIS_{cc} (GP et SC) sont représentées dans **Tableau 4.4**. Selon les résultats qui sont montrés sur ce tableau, on observe que, le modèle ANFIS_{cc}-SC donne des résultats plus précis. En effet, il

donne une petite erreur par rapport au modèle d'ANFIS_{cc}-GP pour localisation de la phase de défaut de court-circuit entre spires.

Tableau 4.4: Comparaison des résultats d'erreurs des deux modèles ANFIS_{cc} pour les phases d'apprentissage et de test.

Phase	Modèles d'ANFIS _{cc}	RMSE	MSE
Apprentissage	GP	8.6319×10^{-4}	7.4510×10^{-7}
	SC	2.3191×10^{-4}	5.3780×10^{-8}
Test	GP	0.0147	2.1716×10^{-4}
	SC	0.0080	6.4800×10^{-5}

4.7 Système de surveillance par l'hybridation des méthodes "REOD et HFFT" avec l'ANFIS

Après avoir étudié les performances de chaque ANFIS séparément comme, le système de diagnostic hybride est présenté dans **Fig. 4.21**. Dans ce système, nous avons regroupé les deux réseaux ANFIS avec structure SC : ANFIS_{cc}-SC et ANFIS_{bc}-SC, basés sur les méthodes REOD et HFFT. Dans ce système chaque ANFIS est sensé réaliser une tâche bien déterminée.

1^{er} réseau « ANFIS_{cc}-SC » est composé de 3 entrées qui sont les rapports d'énergies d'ondelette des courants statoriques [R_1 R_2 R_2] et une seule sortie variable « O » telle que :

- O=0 : moteur à l'état sain ou avec défaut de barre cassée,
- O=1 : moteur avec défaut de court –circuit entre spires dans la phase **as**,
- O=2 : moteur avec défaut court –circuit entre spires dans la phase **bs**,
- O=3 : moteur avec défaut court –circuit entre spires dans la phase **cs**.

2^{ème} réseau « ANFIS_{bc}-SC » est composé de 2 entrées [f_{bc} A_{bc}] et une sortie « S ». Le réseau ANFIS_{bc}-SC n'est actif que si le sortie O=0. Ce réseau fonctionne comme suit :

- O=0 et S=0 : moteur à l'état sain,
- O=0 et S=1 : moteur avec défaut d'une barre cassée,
- O=0 et S=2 : moteur avec défaut de 2 barres cassées.

Généralement, on peut résumer le fonctionnement de ce système comme suit : le réseau ANFIS_{cc} est celui qui nous informe sur le lieu du défaut de court-circuit entre spires, dans le cas où $O \neq 0$, si non, le moteur à l'état sain ou avec défaut de barre cassée. Le réseau ANFIS_{bc} est celui

qui détermine le nombre de barres cassées au rotor lorsque la sortie $S \neq 0$, si non, l'état du moteur est sain.

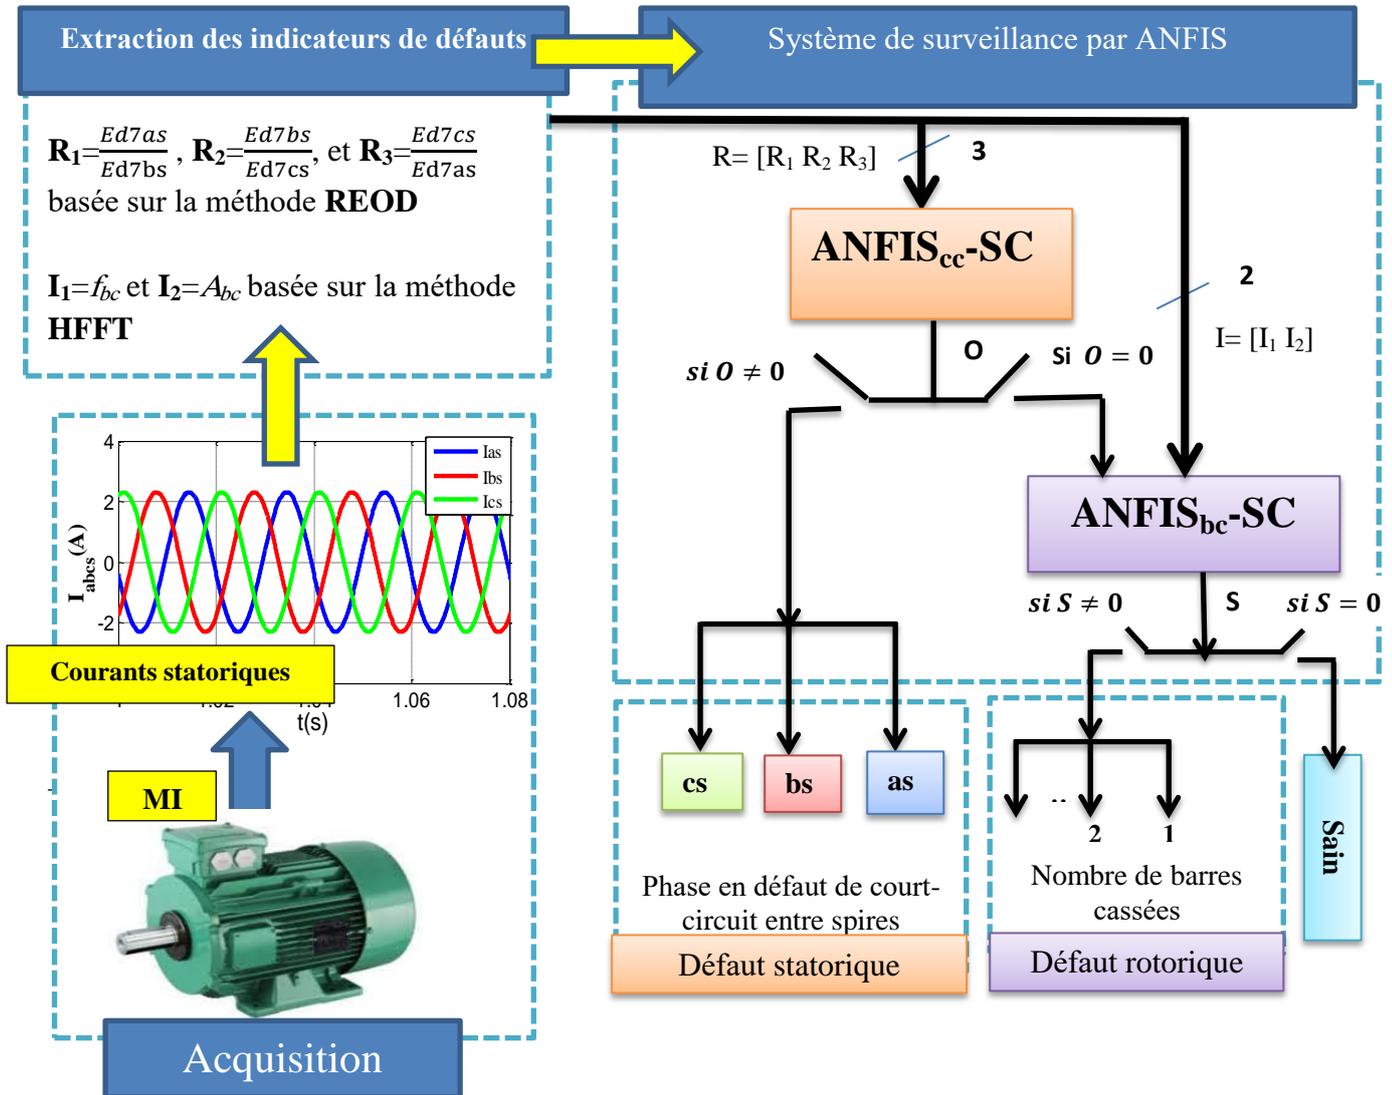


Fig. 4.21 Schéma synoptique du système de surveillance du MI par ANFIS

Les deux réseaux ANFIS utilisés dans le système de surveillance sont composés :

- pour le réseau d'ANFIS_{cc} de 3 entrées regroupées dans un vecteur R et une sortie «O»,
- pour le réseau d'ANFIS_{bc} de 2 entrées regroupées dans un vecteur I et une sortie « S ».

Parce qu'il a donné de bons résultats que la structure GP, on choisit le modèle d'ANFIS avec structure SC pour les deux réseaux, comme nous l'avons mentionné précédemment.

Pour chaque variable d'entrée, on a utilisé des fonctions d'appartenance type gaussien. Les paramètres de chacun des deux ANFIS dans le système proposé sont donnés dans **Tableau 4.5**.

Table 4.5. Paramètres de deux réseaux ANFIS-SC

Paramètres ANFIS	ANFIS _{cc} -SC	ANFIS _{bc} -SC
Nombre d'entrées	3	2
Nombre de sortie	1	1
Type de fonctions d'appartenance (MFs)	Gaussien	Gaussien
Sortie de MFs	Linéaire	Linéaire
Nombre de règles floues	12	19
Nombre d'itérations d'apprentissage	100	100

Selon cette structure, on obtient un système de surveillance qui présente 5 entrées et 2 sorties variables comme l'illustré sur **Fig. 4.21**. La sortie (O) est destinée à la surveillance du défaut statorique (court-circuit entre spires). Par contre, la sortie (S) est réservée à la surveillance du défaut rotorique (cassure de barres).

Pour tester le système de surveillance, nous avons choisi une base de données composée de 75 séquences de fonctionnement du moteur. Nous avons introduit ces dernières successivement à l'entrée de notre système, comme illustré dans **Tableau 4.6**.

Tableau 4.6 : Conditions de fonctionnement des séquences de test et sorties correspondantes du système de surveillance

Nombre d'échantillons	Défaut rotorique	Défaut statorique	Charge appliquée (%)	Sortie « O »	Sortie « S »
1 à 5	Sain	Sain	20%, 40%, 60%, 80% et 100%	0	0
6 à 10	1BC	Sain	20%, 40%, 60%, 80% et 100%	0	1
11 à 15	2BC	Sain	20%, 40%, 60%, 80% et 100%	0	2
16 à 35	Sain	Phase as (8-14-18-25 spires)	20%, 40%, 60%, 80% et 100%	1	0
36 à 55	Sain	Phase bs (8-14-18-25 spires)	20%, 40%, 60%, 80% et 100%	2	0
56 à 75	Sain	Phase cs (8-14-18-25 spires)	20%, 40%, 60%, 80% et 100%	3	0

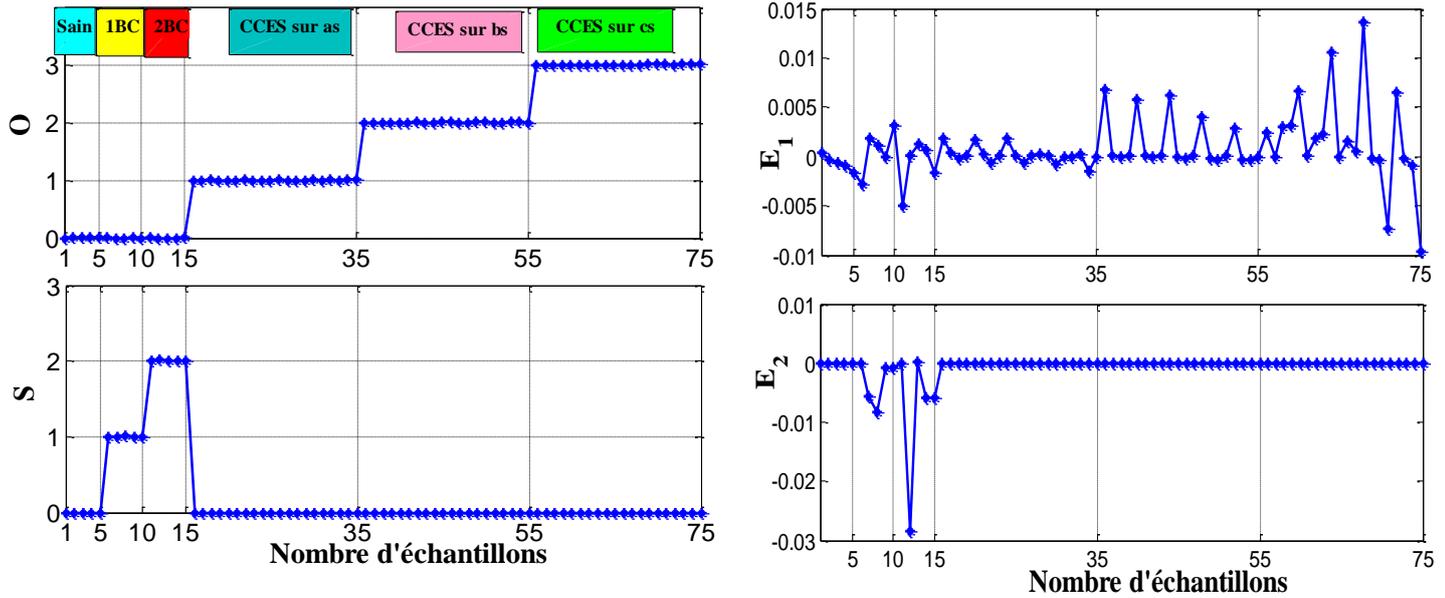


Fig. 4.22 Sorties et erreurs du système de surveillance du MI

Tableau 4.7: MSE et RMSE de l'erreur de sortie du système de surveillance

	MSE	RMSE
E_1	1.0355×10^{-5}	0.0032
E_2	1.3010×10^{-5}	0.0036

Les sorties ainsi que les erreurs du système de surveillance sont représentées sur Fig. 4.22. Suivant l'erreur de sortie des deux réseaux ANFIS de Fig. 4.18 et Tableau 4.7, on peut dire que le système de surveillance proposé avec la structure SC est capable de signaler automatiquement les défauts statoriques et rotoriques de manière efficace et fidèle dès qu'ils apparaissent. L'avantage de ce système est aussi de bien différencier le fonctionnement sain et le fonctionnement défectueux sous différentes charges du moteur.

4.8 Conclusion

Dans ce chapitre, nous avons proposé une étude expérimentale d'un système de surveillance automatique pour diagnostiquer les défauts statoriques et rotoriques dans un moteur à induction. Ce système de surveillance est basé sur l'ANFIS. Le système est constitué de deux réseaux ANFIS. Le premier réseau ANFIS_{cc} est responsable de la détection et la localisation précoces des défauts de court-circuit entre spires au stator en se basant sur les rapports d'énergie d'ondelette discrète des

courants statoriques. Le deuxième réseau ANFIS_{bc} est utilisé afin de détecter d'une façon précoce le défaut et déterminer le nombre de barres cassées au rotor en se basant sur la méthode HFFT.

Deux modèles d'ANFIS (ANFIS-GP et ANFIS-SC) ont été utilisés pour détecter et classer les deux défauts « barres cassées » et « court-circuit entre spires ». Les critères de performance, représentés par MSE et RMSE, montrent que le modèle ANFIS-SC fournit un bon et précis diagnostic pour les deux défauts puisqu'il a permis d'obtenir une erreur minimale par rapport au modèle ANFIS-GP, raison pour laquelle, on l'a choisi comme structure d'ANFIS dans le système de surveillance proposé.

4.9 Bibliographie

1. Jang, J.-S., *ANFIS: adaptive-network-based fuzzy inference system*. IEEE transactions on systems, man, and cybernetics, 1993. **23**(3): p. 665-685.
2. Bessam, B., *Analyse et détection des défauts dans la machine asynchrone à base des techniques intelligentes*. 2016, Université Mohamed Khider-Biskra.
3. Parey, A. and A. Singh, *Gearbox fault diagnosis using acoustic signals, continuous wavelet transform and adaptive neuro-fuzzy inference system*. Applied Acoustics, 2019. **147**: p. 133-140.
4. Harrouche, F., *Etude comparative de deux méthodes d'optimisation d'un système de classification des défauts mécaniques par la logique floue*. 2019.
5. Bourzami, A., *Contribution à l'étude de la stabilité des grands réseaux électriques dans un marché de l'électricité dérégulé en présence des sources d'énergie renouvelable par la logique floue*. 2019.
6. Cheng, F., L. Qu, and W. Qiao, *Fault Prognosis and Remaining Useful Life Prediction of Wind Turbine Gearboxes Using Current Signal Analysis*. IEEE Transactions on Sustainable Energy, 2018. **9**(1): p. 157-167.
7. Chehaidia Seif Eddine, A.A., Kherfane Hamid, Boukhezzar Boubekour, Cherif Hakima, *An Improved Machine Learning Techniques Fusion Algorithm for Controls Advanced Research Turbine (CART) Power Coefficient Estimation*. U.P.B. Sci. Bull. Series C, 2020. **82**(2): p. 279-292.
8. Benmouiza, K. and A. Cheknane, *Clustered ANFIS network using fuzzy c-means, subtractive clustering, and grid partitioning for hourly solar radiation forecasting*. Theoretical and Applied Climatology, 2019. **137**(1-2): p. 31-43.

9. Fattahi, H., *Indirect estimation of deformation modulus of an in situ rock mass: an ANFIS model based on grid partitioning, fuzzy c-means clustering and subtractive clustering*. Geosciences Journal, 2016. **20**(5): p. 681-690.
10. Chiu, S.L., *Fuzzy model identification based on cluster estimation*. Journal of Intelligent & fuzzy systems, 1994. **2**(3): p. 267-278.
11. Yager, R.R. and D.P. Filev, *Generation of fuzzy rules by mountain clustering*. Journal of Intelligent & Fuzzy Systems, 1994. **2**(3): p. 209-219.
12. Fattahi, H. and Z. Bayatzadehfard, *A comparison of performance of several artificial intelligence methods for estimation of required rotational torque to operate horizontal directional drilling*. Iran University of Science & Technology, 2017. **7**(1): p. 45-70.
13. Subbaraj, P. and B. Kannapiran, *Fault detection and diagnosis of pneumatic valve using Adaptive Neuro-Fuzzy Inference System approach*. Applied Soft Computing, 2014. **19**: p. 362-371.

Conclusion générale

Conclusion générale

L'objectif de cette thèse est de contribuer au développement du domaine de la surveillance et du diagnostic des défauts des moteurs à induction. Les applications étendues du moteur à induction dans les applications industrielles ont augmenté le besoin d'une surveillance continue de leur l'état. Le diagnostic des défauts, basé sur l'intelligence artificielle, est au centre de cette recherche. Une étude détaillée de la littérature est présentée pour résumer les techniques de pointe liées aux méthodes proposées dans cette recherche. La surveillance de l'état et le diagnostic des défauts des moteurs à induction sont passés ces dernières années des techniques traditionnelles à des techniques artificielles intelligentes, telles que la logique floue (LF), les réseaux de neurones (RN), les systèmes d'inférence flous basés sur un réseau adaptatif (ANFIS en anglais) et SVM..... Ils ont été appliqués au diagnostic des défauts de systèmes non linéaires, très complexes et variant dans le temps, où des modèles mathématiques précis sont difficiles à construire.

Nous avons commencé par présenter les différentes techniques de diagnostic de la machine asynchrone à cage d'écureuil (appelée ici machine à induction (MI)) et nous avons vu que la détection d'un défaut, qu'il soit mécanique ou électrique, est basée sur le contenu spectral de signaux (le plus souvent du courant statorique absorbé par le MI).

Dans cette thèse, il y a deux études expérimentales : la première pour le diagnostic de défaut rotorique type rupture de barre et la deuxième diagnostic de défaut statorique type court-circuit entre spires. La machine utilisée en expérimentation sous différentes conditions est un moteur de 1,1 kW. Les signaux analysés sont les courants statoriques. Ici nous avons proposé deux approches de diagnostic efficaces pour détecter précocement les défauts de cassure de barres rotoriques et de court-circuits entre spires statoriques.

La première approche est basée sur la méthode HFFT qui est appliquée à l'aide de HT pour extraire l'enveloppe du courant statorique puis la traiter par la FFT. La fréquence et l'amplitude du spectre $2sf_s$ de l'enveloppe ont été choisies comme indicateurs de défaut de barre cassée. L'approche proposée a été mise en œuvre par des tests expérimentaux qui ont été utilisés sur trois moteurs à induction: le premier avait une barre cassée, le second avec deux barres cassées adjacentes, le troisième était un moteur sain. Ces tests sont menés sous des charges différentes. Les résultats expérimentaux ont montré que l'amplitude et la fréquence de l'harmonique $2sf_s$ avaient une sensibilité élevée au défaut de cassure de barre. Pour cela, ils ont été choisis comme indicateurs de défaut qui ont permis d'obtenir des résultats précis pour détecter le défaut même sous de faibles charges.

La deuxième approche est utilisée pour la détection et la localisation précoce du défaut de court-circuit entre spires statoriques dans le MI à l'aide d'un nouvel indicateur basé sur le rapport

Conclusion générale

d'énergie des ondelettes discrètes (REOD) de trois courants statoriques qui sont utilisés comme indicateurs pour obtenir des informations simultanées sur le défaut et son emplacement. Cette approche a été vérifiée par des résultats expérimentaux. Les résultats obtenus garantissent la précision et la fiabilité de la technique proposée pour le diagnostic des défauts CCES dans le MI. Cette technique peut permettre de détecter des nombres élevés ou faibles de spires court-circuitées et localiser la phase défectueuse même dans diverses conditions.

Les résultats obtenus de deux méthodes ont montré l'efficacité des deux approches de diagnostic proposées : la HFFT pour diagnostiquer les défauts de cassure de barres rotoriques et la REOD pour la détection et la localisation de défaut de court-circuits entre spires au stator du MI.

Afin d'automatiser les méthodes de diagnostic, on a utilisé les techniques d'intelligence artificielle : les réseaux de neurone (RN) et les réseaux Neuro-Flous (ANFIS) basés sur l'approche précédente (HFFT et REOD).

Les RN ont été utilisés pour la détection précoce et la localisation automatique de la phase de défaut court-circuit entre spires. Cette technique est basée sur les rapports d'énergie d'ondelette discrète des courants statoriques qui sont utilisés comme indicateurs de défaut et entrées pour les RN. Aussi, on a structuré les RN pour déterminer le nombre de barres cassées au rotor en utilisant la méthode de HFFT qui emploie l'analyse spectrale de l'enveloppe du courant statorique de raie 2sfs (amplitude et fréquence) comme indicateurs de défaut et les utilise comme entrées du RN. Dans cette étude, trois structures différentes de RN sont utilisées à savoir les : MLP, RBF et ENN. Par comparaison entre les résultats de trois structures de réseaux de neurones proposées, on remarque que le réseau ENN offre de meilleures performances de détection en termes de vitesse de convergence et de capacité d'identification des deux défauts étudiés. Les résultats expérimentaux obtenus montrent que l'hybridation entre "HFFT-ENN" et "REOD-ENN" est capable de diagnostiquer les deux défauts précisément et est fiable sous différentes conditions de fonctionnement du moteur. Ceci a permis d'élaborer un système de surveillance automatique et robuste pour détecter, localiser et identifier les défauts CCES et BC du MI à cage d'écureuil en se basant sur les RN type ENN.

D'autre part, on a proposé un système de surveillance automatique basé sur ANFIS pour diagnostiquer les défauts statoriques et rotoriques dans le moteur à induction. Le système est constitué de deux réseaux ANFIS. Le premier réseau ANFIS_{cc} sert à détecter et localiser d'une façon précoce les défauts de court-circuits entre spires au stator en se basant sur les rapports d'énergie d'ondelette discrète (REOD) des courants statoriques. Le deuxième réseau ANFIS_{bc} sert à la détection précoce et à la détermination du nombre de barres cassées au rotor en utilisant la méthode HFFT. Deux modèles d'ANFIS: ANFIS-GP et ANFIS-SC ont été élaborés pour détecter et classer

Conclusion générale

les deux défauts. Par comparaison des résultats obtenus par les deux modèles de réseau, on remarque que le réseau d'ANFIS-SC ont été plus performants et précis que l'ANFIS-GP.

Comme perspectives pour améliorer notre étude du diagnostic des défauts du MI, l'étude pourrait être élargie en considérant d'autres types de défauts (excentricité, roulements....) et utiliser d'autres outils de diagnostic et de détection avancées (SVM, Deep learning,....) ou par estimation paramétrique surtout en régime variable.

ANNEXE

ANNEXE

A

Tableau 1.A: Paramètres du moteur d'induction utilisés dans les essais expérimentaux

P_n: puissance nominale	1.1 kW
V_s: Tension nominale	400/230V
I_s: Courant nominale	2.5/4.3A
N_n: Vitesse nominale	1450 rpm
f_s: Fréquence nominale statorique	50Hz
P: Nombre de paires de pôles	2
R_s: résistance du stator	6.75 Ω
R_r: résistance du rotor	6.21 Ω
L_m: inductance mutuelle	495.7 mH
L_f: Inductance de fuite statorique	23.5 mH
n_b: Nombre de barres au rotor	46
n_s: Nombre de spires par phase	396

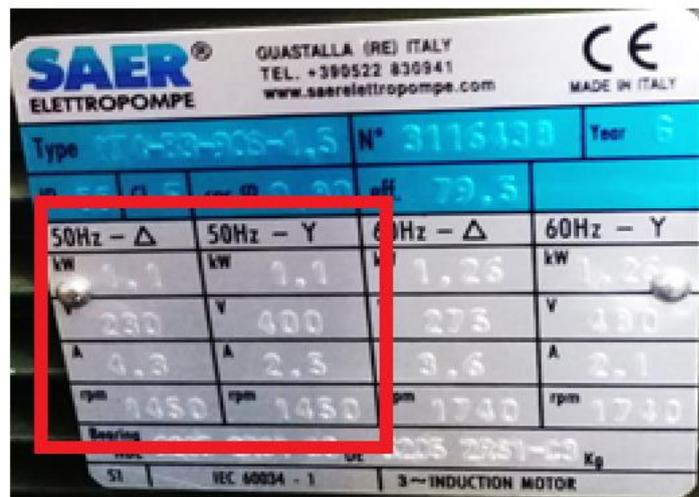


Fig. 1.A plaque signalétique du moteur utilisé

Réseaux de neurones artificiels

Neurone artificiel

L'élément de base d'un réseau de neurones est, bien entendu, le neurone artificiel [1] présenté par **Fig. 1.B**. Un neurone artificiel contient deux éléments principaux:

- un ensemble de poids associés aux connexions du neurone,
- une fonction d'activation (Tableau 1.B).

Les valeurs d'entrée sont multipliées par leurs poids correspondant et sont additionnées pour obtenir la somme. Cette somme devient l'argument de la fonction d'activation, qui est le plus souvent d'une des formes présentées ci-dessous. Une fonction d'activation importante est la simple multiplication par la valeur 1, c'est à dire que la sortie est simplement une somme pondérée.

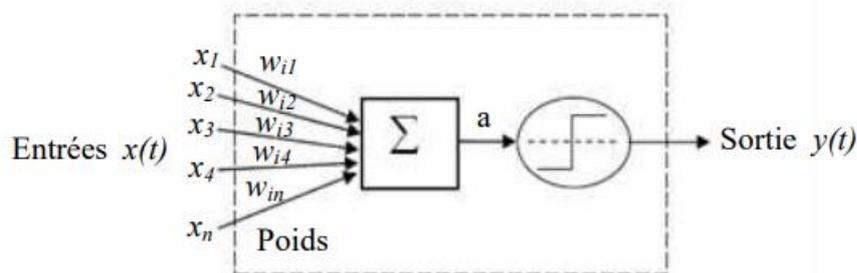
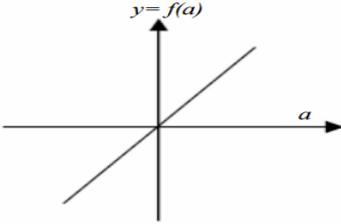
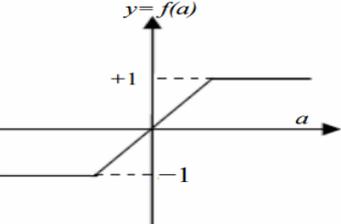
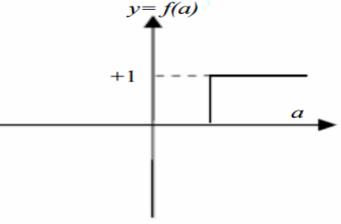
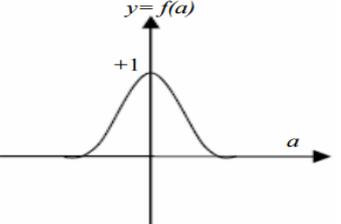
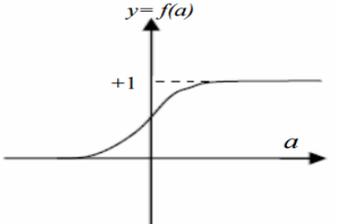
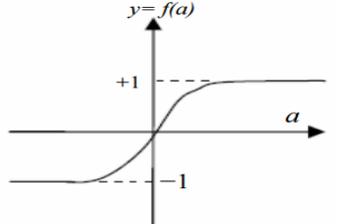
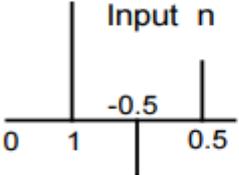
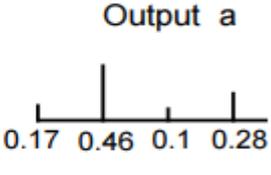


Fig. 1.B Modèle d'un neurone artificiel

Fonction d'activation

La fonction d'activation est en général une fonction non linéaire monotone croissante [2]. Par ailleurs, les fonctions de transfert sont de qualités diverses: elles peuvent être déterministes, continues, discontinues ou aléatoires. Ces fonctions sont présentées dans le tableau 1.B :

Tableau 1.B Fonctions d'activation.

Fonction identité	
Fonction linéaire bornée	
Fonction seuil	
Fonction gaussienne	
Fonction sigmoïde	
Fonction tangente hyperbolique	
Fonction softmax	<div style="display: flex; justify-content: space-around; align-items: flex-end;"> <div style="text-align: center;"> <p>Input n</p>  </div> <div style="text-align: center;"> <p>Output a</p>  </div> </div>

Implémentation d'un système ANFIS par l'interface graphique (ANFIS editor GUI) sous Matlab

On peut résumer les étapes d'implémentation d'un système (ANFIS) pour le diagnostic des défauts dans un MI sous Matlab comme suit :

1. Ouverture de l'interface (ANFIS editor GUI) :

L'interface graphique de l'éditeur ANFIS est ouverte par la commande « **anfisedit** » dans la fenêtre de "MATLAB commande". Une interface graphique (ANFIS editor GUI) s'affichera comme le montre **Fig. 1.C**. L'interface inclut quatre secteurs distincts pour soutenir un déroulement des opérations typiques. Le GUI vous laisse accomplir les tâches suivantes:

- ✓ charger, tracer et effacer les données,
- ✓ générer ou charger la structure initiale du système FIS,
- ✓ apprentissage du système ANFIS,
- ✓ valider le système ANFIS qualifié.

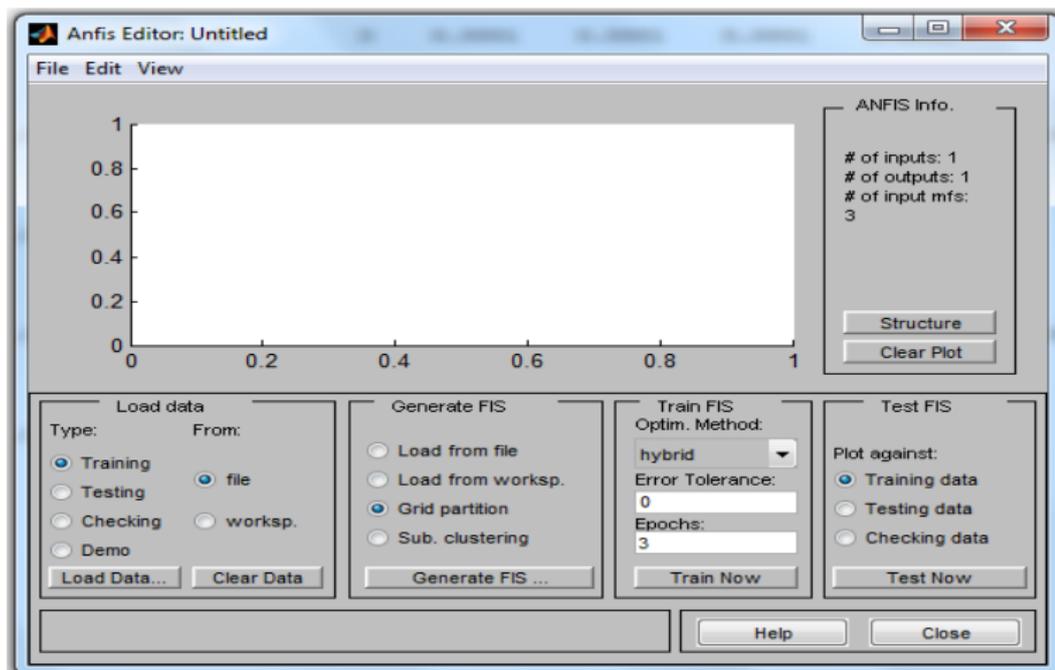


Fig. 1.C interface graphique pour l'implémentation d'un système ANFIS

2. Importation des bases de données

Pour charger un ensemble de données, on utilise la zone de chargement de données sur l'interface graphique comme suit (voir la Fig. 2.C):

1. Spécifiez le type de données.
2. Sélectionnez les données à partir d'un fichier ou de l'espace de travail de MATLAB.
3. Cliquez sur "**Load Data**".

Pour effacer un ensemble de données spécifiques définies à partir de l'interface graphique:

1. Dans la zone de données de charge, sélectionnez le type de données.
2. Cliquez sur effacer les données.



Fig. 2.C boîte de dialogue pour importer la base de données

3. Initialisation et génération du système FIS (Loading the Initial FIS Structure)

Avant de commencer l'apprentissage de l'ANFIS, on doit spécifier une structure FIS (modèle initial). Pour spécifier la structure du modèle, on effectue l'une des tâches suivantes.

Dans la rubrique «**Generate FIS**» de l'interface graphique ANFIS, on sélectionne une des deux méthodes : «**grid partition**» ou «**subclustering**».

Remarque:

- ✓ Pour importer un système FIS déjà généré et sauvegardé, on clique sur «**load from file**» ou «**load from workspace**» de la rubrique «**generate FIS**» de l'interface graphique ANFIS editor pour importer le système FIS initial.
- ✓ Pour afficher une représentation graphique de la structure du modèle initial de la FIS, on clique sur **Structure**.

4. Apprentissage du système ANFIS (training the FIS)

Il y'a deux méthodes d'apprentissage (optimisation des paramètres) disponibles :

- La méthode hybride (hybrid) qui est la méthode par défaut. cette méthode est mixte. Elle utilise la méthode des moindres carrés et la méthode de rétro-propagation.
- La méthode de rétro-propagation.

La tolérance d'erreur est utilisée pour créer un critère d'arrêt d'apprentissage qui est lié à la taille d'erreur. L'apprentissage s'arrête après que l'erreur de données d'apprentissage reste dans les limites de cette tolérance. Il est préférable de laisser l'erreur tendre vers zéro si nous ne savons pas comment l'erreur d'apprentissage peut se comporter [3].

L'apprentissage du FIS qui permet l'adaptation du réseau est fait selon les étapes suivantes :

- ✓ Sélectionner la méthode d'optimisation dans la rubrique «**Train Fis**».
- ✓ Régler le nombre d'itérations et la tolérance d'erreur pour l'apprentissage dans la rubrique «train fis» de l'interface graphique.
- ✓ Lancer l'opération d'apprentissage avec «**Train now**» de la rubrique «**Train Fis**», une fenêtre s'affiche

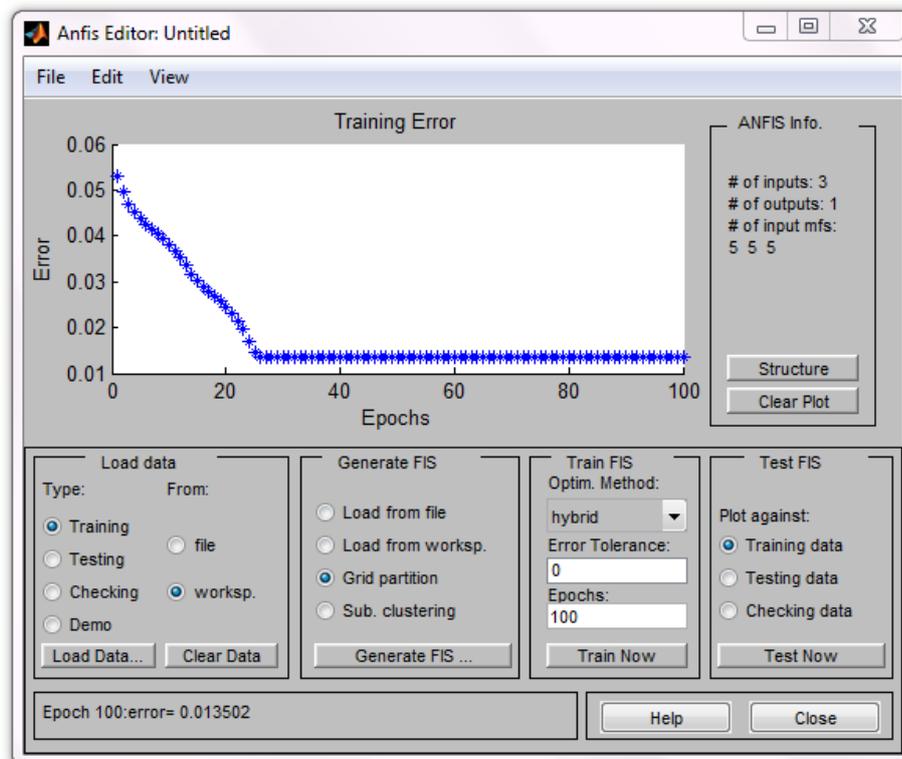


Fig. 3.C apprentissage du système ANFIS

5. Test du système ANFIS entraîné (Testing the trained FIS) :

Une fois que le FIS est formé, l'étape de validation du modèle FIS est faite par un test (Testing) ou le contrôle (Checking) des données qui diffère de celle utilisée pour former les FIS. Pour valider les FIS formés:

- Dans la partie "**Load Data**" de l'éditeur ANFIS, sélectionnez le jeu de données de validation ("**Testing Data**" or "**Checking Data**") et cliquez sur "**Load Data**".
- Dans la partie "**Test FIS**", sélectionner le jeu de validation, puis cliquez sur "**Test now**".

Cette fenêtre représente la sortie du système entraîné (FIS output :*) en couleur rouge par rapport à l'entrée (données de validation (checking data :+)) en couleur bleu, comme montrer sur la **Fig. 4.C**.

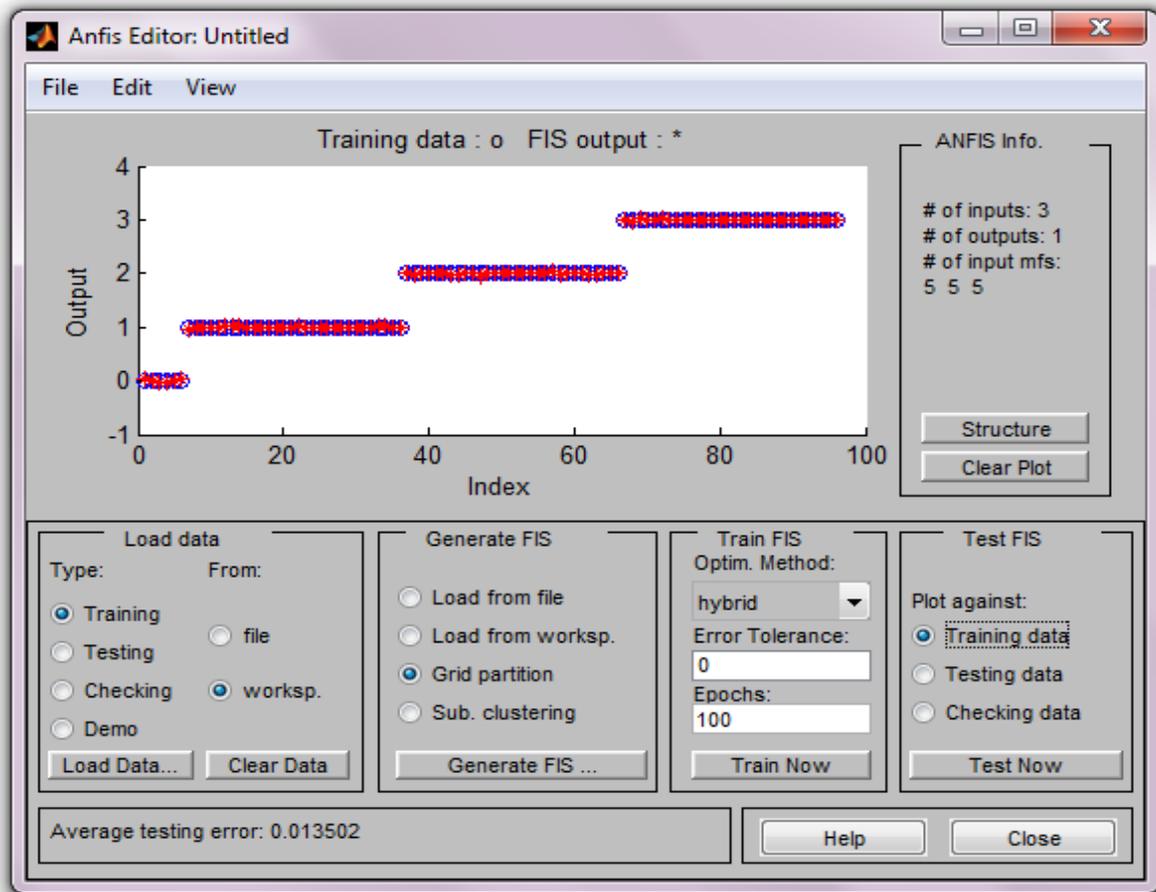


Fig.4.C test du système ANFIS entraîné

Bibliographie

1. Personnaz, L. and I. Rivals, *Réseaux de neurones formels pour la modélisation, la commande et la classification*. 2003: CNRS.
2. Gondran, M. and C. Muller, *Réseaux de neurones et apprentissage*. REE. Revue de l'électricité et de l'électronique, 1997(3): p. 6-9.
3. Harrouche, F., *Etude comparative de deux méthodes d'optimisation d'un système de classification des défauts mécaniques par la logique floue*. 2019.

Contributions Scientifiques

Publications Internationals:

1. **Cherif, H.**, Benakcha, A., Laib, I., Chehaidia, S. E., Menacer, A., Soudan, B., et al. (2020). Early detection and localization of stator inter-turn faults based on discrete wavelet energy ratio and neural networks in induction motor. *Energy*, 212, 118684.
2. **Cherif,H** , Benakcha, A., Khechekhouche, A., Menacer, A.,Chehaidia, S. E., & Panchal, H. (2020). « Experimental diagnosis of inter-turns stator fault and unbalanced voltage supply in induction motor using MCSA and DWER». *Periodicals of Engineering and Natural Sciences (PEN)*, 8(3), 1202-1216
3. Bessam, B., Menacer, A., Boumehraz, M., & **Cherif, H.** (2017). Wavelet transform and neural network techniques for inter-turn short circuit diagnosis and location in induction motor. *International Journal of System Assurance Engineering and Management*, 8(1), 478-488.
4. Bessam, B., Menacer, A., Boumehraz, M., & **Cherif, H.** (2016). Detection of broken rotor bar faults in induction motor at low load using neural network. *ISA transactions*, 64, 241-246.
5. B. Bessam, A. Menacer, M. Boumehraz, **H. Cherif** «DWT and Hilbert Transform for Broken Rotor Bar Fault Diagnosis in Induction Machine at Low Load» *Journal Energy Procedia* 74 (2015) 1248– 1257.
6. Chehaidia Seif Eddine, Kherfane Hamid, Boukhezzar Boubekeur,**Cherif Hakima** (2020). «An Improved Machine Learning Techniques Fusion Algorithm for Controls Advanced Research Turbine (CART) Power Coefficient Estimation».U.P.B. Sci. Bull. Series C, 82(2), 279-292.

Conférences Internationals

1. **H. Cherif**, A. Menacer , R. Romary, R. Pusca « Dispersion field analysis using Discrete Wavelet Transform for inter-turn stator fault detection in Induction Motors » Proceedings of the 11th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives, Tinos, Greece/29 Aug.-1 Sept. 2017
2. **H. Cherif**, A. Menacer, Zied DRISS« Influence of the load on the inter turn stator fault detection using discrete wavelet transform» Proceedings of the 2nd international conference on Mechanics and Energy (ICME'2016) which is held Hammamet-Tunisia from 22 to 24 December 2016.
3. **H. Cherif**, A. Menacer, B. Bessam, R.Kechida « Stator Inter Turns Fault Detection Using Discrete Wavelet Transform » Proceedings of the 10th IEEE International Symposium on

Diagnostics for Electric Machines, Power Electronics and Drives, Guarda-Portugal /September 1-4,2015 .

4. **H.CHerif** , A. Menacer , B. Bessam «Diagnosis of Stator Inter turns short circuit and Stator Voltage Unbalance Fault Using Fast Fourier and discrete wavelet transforms» Proceedings of the First International Conference on Applied Automation and Industrial Diagnostics (ICAAID 2015) Djelfa on 29-30 March 2015, Algeria.
5. **H.CHerif** , A. Menacer , B. Bessam , R.Kachida« Stator inter turn fault and voltage unbalance detection Using Fast Fourier and discrete wavelet transforms» Proceedings of the Conference on Electrical Engineering (CGE'09) EMP, Bordj El -Bahri, 14- 15 April 2015 , Algeria.
6. **H.CHerif** , A. Menacer , B. Bessam «Diagnosis of Stator Turn-to-Turn Fault and Stator Voltage Unbalance Fault Using Fast Fourier and discrete wavelet transforms» Proceedings of the First International Conference on Electrical Engineering ICEEB'14 Biskra, December 07-08, 2014, Algeria.
7. Y. Azzoug, A. Menacer, T.Ameid et **H. Cherif** « Etude Expérimentale du Diagnostic des Défauts Statoriques et Rotoriques de la Machine à Induction en Boucle Ouverte en utilisant la Transformé de Fourier » Proceedings de 4^{ème} Conférence Internationale sur la Maintenance et la Sécurité Industrielle CIMSI'2017, Skikda 20-21 Novembre 2017.
8. R. Kechida, A. Menacer , H. Talhaoui, **H. Cherif** « Discrete Wavelet Transform for Stator Fault Detection in induction Motor» Proceedings of the 10th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives, Guarda-Portugal /September 1-4,2015
9. B. Bessam, A. Menacer, M. Boumehraz, **H. Cherif** «A Novel Method for Induction Motors Stator Inter-Turn Short Circuit Fault Diagnosis based on Wavelet Energy and Neural Network» Proceedings of the 10th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives, Guarda-Portugal /September 1-4,2015.