



الجمهورية الجزائرية الديمقراطية الشعبية
People's Democratic Republic Of Algeria
وزارة التعليم العالي والبحث العلمي
Ministry Of Higher Education And Scientific Research
جامعة الشهيد العربي التبسي ، تبسة
Echahid Larbi Tebessi, Tébessa
معهد المناجم
Mining Institutue



Département : Electromécanique

Filière de : Mines

Thèse présentée en vue de l'obtention du diplôme de :

Doctorat en Sciences

Spécialité : Electromécanique minière

*Contribution à la maintenance et au bon fonctionnement des équipements
industriels*

Présenté par

FARES Noureddine

Devant le jury composé de :

<i>Affiliation</i>	<i>Nom et Prénom</i>	<i>Grade</i>	<i>Université</i>
<i>Président</i>	: LOUAFI Messaoud	<i>Pr</i>	<i>Echahid Larbi Tébessi, Tébessa</i>
<i>Rapporteur</i>	: AOULMI Zoubir	<i>MCA</i>	<i>Echahid Larbi Tébessi, Tébessa</i>
<i>Co- Rapporteur</i>	: OUNNAS Djamel	<i>MCA</i>	<i>Echahid Larbi Tébessi, Tébessa</i>
<i>Examineur</i>	: HEBBIR Ncer	<i>Pr</i>	<i>Oum El Bouaghi</i>
<i>Examineur</i>	: GHOUELBOURK Sihem	<i>MCA</i>	<i>Badji Mokhtar Annaba</i>
<i>Examineur</i>	: OURICI Amel	<i>MCA</i>	<i>Badji Mokhtar Annaba</i>

Année universitaire : 2022/2023

Remerciements

Cette thèse de doctorat en sciences a été dirigée par M. **AOULMI Zoubir**, Maître de conférences -A-, Université Echahid Larbi Tebessi. Pour conclure ma recherche commencée dans la même université avec mon directeur de thèse, je tiens à le remercier pour sa confiance en moi et son attention continue à mon travail de recherche et les discussions fructueuses à travers lesquelles ces commentaires et suggestions ont été émis.

Monsieur **OUNAS Djamel**, actuellement maître de conférences -A-, à la même université, a été mon co-directeur de thèse et a assuré le suivi de ce travail. Je lui adresse mes remerciements les plus sincères.

Je tiens à exprimer mes sincères remerciements à Monsieur **LOUAFI Messaoud**, Professeur à l'Université Echahid Larbi Tebessi Tébessa, qui exprime ici ma gratitude d'avoir accepté de présider mon jury de soutenance.

Merci également aux membres du jury pour leur appréciation de ce travail :

- ✚ Monsieur **HEBBIR Ncer**, Professeur de l'université Oum El Bouaghi ;
- ✚ Madame **GHOUELBOURK Sihem**, Maîtresse de conférences -A- de l'université Badji Mokhtar Annaba ;
- ✚ Mademoiselle **OURICI Amel**, Maîtresse de conférences -A- de l'université Badji Mokhtar Annaba ;

Je tiens à remercier toutes les personnes qui ont contribué de près ou de loin à ce travail, en particulier Maître de conférences -A- **The laidjia Tawfik** et le doctorant **SOUAIDIA Chouaib**.

A mes très chers parents

A mes sœurs et frères

A ma famille

ملخص الأطروحة

تعتبر مراقبة حالة آلات الحث عن طريق كشف و تحديد الأعطال التي تحدث حتى في المراحل الأولية تقنية في طور التطور. الهدف من هذه الرسالة هو تقديم تقنية ذكاء اصطناعي (AI) لاكتشاف وتحديد أخطاء قضبان الدوار المكسورة (المجاورة والبعيدة) في المحرك اللاتزامني ، من خلال نموذج متعدد الملفات لمحاكاة هذه الحالات. في هذا العمل ، وجد أن تطبيق الشبكات العصبية الاصطناعية (ANN) على أساس متوسط الخطأ التربيعي (MSE) والغابة العشوائية (Random Forest) يلعبان دورًا مهمًا في إكتشاف وتحديد الأعطاب. تم الحصول على إشارة التيار الثابت « I_{as} » لمحرك في حالته الديناميكية يشمل خصائصه السليمة والمعيبة (قضبان دوار مكسورة). 9 خصائص إحصائية و 8 خصائص رزمة موجية من إشارة التيار الثابت. تم استخدامها كمتجه إدخال لتدريب واختبار ANN والغابة العشوائية وتحديد ما إذا كان المحرك يعمل في حالته العادية أو المعيبة. لتحسين إجراء تصنيف الأخطاء لقضبان الدوار ، تم إعتداد خوارزميات التحسين ، مثل BBAT و BPSO. ولكن فيما يتعلق بخوارزميات تقليل الأبعاد ، إستخدمنا خوارزمية تحليل المكونات الرئيسية (PCA). أظهرت النتائج المتحصل عليها أن المصنف العشوائي للغابات المعتمد على المعلومات الإحصائية ومعايير رزمة موجية المحسنة بواسطة PCA يمكنه تصنيف حالات التشغيل المختلفة للمحرك اللاتزامني بدقة عالية (98.3333%) مقارنة بالطرق الأخرى.

الكلمات المفتاحية:

مراقبة حالة المحرك الحثي ، خوارزميات تحسين (BPSO ، BBAT و PCA) ، قضيب دوار مكسور ، ميزات إحصائية ، تحويل حزمة الموجة (WPT) ، غابة عشوائية (RF) ، شبكة عصبية اصطناعية (ANN) .

Résumé de la thèse

La surveillance de l'état des machines à induction est considérée comme une technologie en développement pour la détection en ligne des défauts qui se produisent même au stade initial. L'objectif de cette thèse est de présenter une technique d'intelligence artificielle (**IA**) pour la détection et la localisation de défauts des barres rotoriques cassées (adjacentes et éloignées) dans la MAS, à travers un modèle multi-enroulements pour la simulation de ces cas. Dans ce travail, il a été constaté que l'application des réseaux de neurones artificiels (**ANN**) basés sur l'erreur quadratique moyenne (**MSE**) et la **forêt aléatoire (arbre de décision)** joue un rôle important dans la détection et la localisation des défauts. Le signal du courant statorique « I_{as} » d'un moteur à l'état dynamique a été acquis à partir d'un moteur sain et défectueux (barres rotoriques cassées). **9 caractéristiques statistiques** et **8 paramètres de paquets d'ondelettes** sont extraits de signal du courant statorique. Ces caractéristiques ont été utilisées comme vecteur d'entrée pour entraîner et tester l'**ANN** et les **forêts aléatoires** et déterminer si le moteur fonctionnait dans des conditions normales ou anormales. Pour optimiser la procédure de classification de défauts des barres rotoriques, des algorithmes d'optimisations sont adoptés, tels que **BBAT** et **BPSO**. Mais concernant les algorithmes de réduction des dimensions, nous avons utilisé l'algorithme d'analyse en composantes principales (**ACP**). Les résultats obtenus montrent que le classificateur de **forêt aléatoire** basé sur les **paramètres statistiques** et les **paramètres de paquets d'ondelettes** optimisés par **PCA** peut classer les différents états de fonctionnement de la MAS avec une grande précision (**98,3333%**) par rapport aux autres méthodes.

Mots clés :

Surveillance de l'état du moteur à induction, algorithmes d'optimisations (BPSO, BBAT et PCA), barre de rotor cassée, caractéristiques statistiques, transformation en paquets d'ondelettes (WPT), forêt aléatoire (RF), réseau de neurones artificiels (ANN).

Abstract of the thesis

Induction machine health monitoring is considered a developing technology for the online detection of faults that occur even at the initial stage. The objective of this study is to present an artificial intelligence (AI) technique for the detection and localization of adjacent and distant broken bar faults in the induction machine, through a multi-winding model for the simulation of these cases. In this work, it was found that the application of Artificial Neural Networks (ANN) based on Mean Squared Error (MSE) and **Random Forest (decision tree)** plays an important role in detecting and locating defaults. The stator current signal « I_{as} » of a motor in the dynamic state was acquired from a healthy and faulty motor with a broken rotor bar fault. **9 statistical features** and **8 wavelet packet parameters** are extracted from the stator current signal. These features were employed as an input vector to train and test the **ANN** and **random forest** and determine whether the motor was running under normal conditions or defective. For optimizing the rotor bar defect classification procedure, feature selection algorithms are adopted, such as **BBAT** and **BPSO**. For feature reduction, we used the principal component analysis (**PCA**) algorithm, to reduce the number of features. The results showed that the **random forest** classifier based on **statistical parameters** and **wavelet packet parameters** followed by **PCA** can detect the defective with high accuracy (**98.3333%**) compared to other methods.

Keywords:

induction motor health monitoring, (BPSO, BBAT and PCA) optimization algorithms, broken rotor bar, statistical features, wavelet packet transform (WPT), random forest (RF), artificial neural network (ANN)

Table des matières

Table des matières

	Page
Les titres	VI
Table des matières.....	VI
Liste des figures.....	XIII
Liste des tableaux.....	XVII
Liste des symboles et abréviations.....	XIX
Introduction générale.....	02
Chapitre I : Etat de l'art des défaillances dans les machines électriques.....	04
I.1 Introduction.....	05
I.2 Notions de sûreté de fonctionnement.....	06
I.2.1 Maintenance, surveillance et diagnostic.....	06
I.2.2 Fiabilité, disponibilité, maintenabilité et sécurité.....	07
I.2.3 Défaillance et panne.....	08
I.3 Mise en place d'un dispositif de sûreté de fonctionnement.....	08
I.3.1 Les principales étapes de conception d'un dispositif de sûreté de fonctionnement.....	08
I.3.2 La sûreté de fonctionnement des machines électriques.....	10
I.4 Problématique du diagnostic des machines électriques.....	13
I.5 Analyse des méthodes de diagnostic existantes.....	14
I.5.1 Les méthodes internes.....	15
I.5.1.1 La méthode du modèle.....	15
I.5.1.2 La redondance analytique et matérielle.....	16
I.5.2 Les méthodes externes.....	17
I.5.2.1 Les méthodes de reconnaissance des formes.....	17
I.5.2.2 Diagnostic par systèmes experts.....	18
I.5.2.3 Diagnostic par logique floue.....	19
I.5.2.4 Diagnostic par réseaux de neurones artificiels.....	20
I.5.2.5 Diagnostic par l'arbre de décisions et forêt aléatoire (Random Forest).....	21
I.6 Analyse des méthodes d'identification des défauts des machines asynchrones.....	21
I.6.1 Méthodes de diagnostic des défauts basées sur l'analyse spectrale des signaux.....	21
I.6.1.1 Diagnostic par mesure des vibrations mécaniques.....	21

I.6.1.2	Diagnostic par mesure du flux magnétique axial de fuite.....	22
I.6.1.3	Diagnostic par l'analyse des tensions statoriques induites.....	22
I.6.1.4	Diagnostic par mesure du couple électromagnétique.....	22
I.6.1.5	Diagnostic par mesure de la puissance instantanée.....	23
I.6.1.6	Diagnostic à partir du vecteur de Park.....	23
I.6.1.7	Diagnostic par mesure du courant statorique.....	24
I.7	Signatures spectrales des défauts dans le spectre du courant statorique.....	24
I.7.1	Défauts statoriques.....	24
I.7.2	Défauts rotoriques.....	24
I.7.3	Cassure de barres rotoriques.....	25
I.7.4	Excentricité d'entrefer.....	25
I.7.5	Défauts au niveau des roulements.....	27
I.8	Analyse critique des méthodes de diagnostic existantes.....	28
I.9	Position du problème à résoudre.....	30
I.10	Conclusion.....	31
Chapitre II : Modèle dédié à la simulation des défauts rotorique de la machine asynchrone.....		33
II.1	Introduction.....	34
II.2	Modèle multi-enroulements de la machine asynchrone.....	35
II.2.1	Hypothèses de départ.....	35
II.3	Calcul des inductances.....	36
II.3.1	Inductances statoriques.....	36
II.3.2	Inductances rotoriques.....	37
II.3.3	Inductance mutuelle stator/rotor.....	39
II.4	Mise en équations.....	40
II.4.1	Equations de tensions au stator.....	41
II.4.2	Equations des tensions au rotor.....	43
II.4.3	Modèle équivalent de la machine à taille réduite.....	47
II.5	Résultats de simulation.....	51
II.5.1	Interprétation des résultats.....	59
II.6	Conclusion.....	60

Chapitre III : Méthodes de traitement des signaux dédiées au diagnostic des défauts d'un système.....	62
III.1 Introduction.....	63
III.2 Définition d'un signal.....	64
III.3 Définition d'un système.....	65
III.4 Classification des signaux.....	66
III.4.1 Classification phénoménologique (statistique) des signaux.....	66
III.4.2 Classification morphologique (continu/discret).....	67
III.4.3 Classification énergétique.....	68
III.5 Signaux particuliers (utiles).....	69
III.6 Système de génération et de traitement du signal.....	71
III.7 Traitement des signaux.....	73
III.7.1 Série de Fourier (SF).....	74
III.7.2 Transformée de Fourier (TF).....	75
III.7.3 Transformée de Fourier rapide (FFT).....	76
III.7.4 Transformée de Fourier à court terme (TFCT).....	77
III.8 La transformée en ondelettes (TO).....	80
III.8.1 La transformée en ondelettes continue (TOC).....	81
III.8.2 La transformée en ondelettes discrète (TOD), ondelettes dyadiques et analyse MR.....	86
III.8.2.1 Décompositions multi-niveaux par l'ondelette discrète.....	87
III.8.3 La transformée en paquet d'ondelettes (TPO).....	88
III.9 Conclusion.....	90
Chapitre IV : Surveillance de défauts des barres cassées rotoriques de la MAS par les méthodes intelligentes.....	92
IV.1 Introduction	93
IV.2 Méthodologie d'utilisation des ANN et RF dans le domaine du diagnostic.....	94
IV.3 Réseaux de neurones (ANN).....	94
IV.3.1 Neurone biologique.....	95
IV.3.2 Neurone artificiel.....	96
IV.3.3 Présentation des réseaux de neurones artificiels.....	96
IV.3.3.1 Principe de fonctionnement.....	96

IV.3.3.2	Bref historique	96
IV.3.4	Modélisation générale d'un réseau de neurones artificiel.....	97
IV.3.5	Domaines d'application des réseaux de neurones.....	101
IV.3.6	Structure d'interconnexion	101
IV.3.6.1	Réseau multicouches.....	101
IV.3.6.2	Réseau à connexions locales.....	102
IV.3.6.3	Réseau à connexions récurrentes.....	103
IV.3.6.4	Réseau à connexions complexes.....	103
IV.3.7	Apprentissage.....	104
IV.3.7.1	Réseaux statiques et dynamiques.....	104
IV.3.7.2	Règle de <i>HEBB</i>	105
IV.3.7.3	Règle du DELTA (ou règle de <i>Widrow Hoff</i>).....	105
VI.3.8	Principaux types de réseaux de neurones.....	105
VI.3.8.1	Réseaux de neurones compétitifs.....	105
VI.3.8.2	Réseaux de neurones à fonctions de base radiales (Radial Basis Network)..	106
VI.3.8.3	Réseaux récurrents.....	107
VI.3.8.4	Réseau à architecture évolutive « ART ».....	108
VI.3.8.5	Réseau PMC (Perceptron Multi Couches).....	108
IV.4	La forêt aléatoire (Random Forest).....	112
IV.4.1	Le bagging dans les forêts de décision	114
IV.4.2	La méthode de la forêt aléatoire.....	115
IV.4.3	Les avantages de la forêt aléatoire.....	116
IV.4.4	Les défis de la forêt aléatoire.....	118
IV.5	Codage des états de fonctionnement de la MAS.....	119
IV.6	Choix des indicateurs de défauts.....	120
IV.6.1	Structure du réseau de neurones (RNA).....	120
IV.7	Les paramètres d'apprentissage de (ANN et RF).....	121
IV.7.1	Les paramètres statistiques.....	122
IV.7.2	Les paramètres temps/fréquences en paquets d'ondelettes.....	123
IV.8	Résultats de classifications des défauts de cassures des barres rotoriques.....	124
IV.8.1	Classification utilisant des paramètres hybrides sans optimisation.....	124

IV.8.1.1	Classification à l'aide de réseaux de neurones artificiels (ANN).....	124
IV.8.1.2	Classification à l'aide de la forêt aléatoire (RF).....	126
IV.8.2	Classification utilisant des paramètres hybrides avec l’algorithme BBAT.....	126
IV.8.2.1	Optimisation par BAT (OEP) et Optimisation par BAT binaire (BBAT)....	126
IV.8.2.2	Classification à l'aide de réseaux de neurones artificiels (ANN).....	127
IV.8.2.3	Classification à l'aide de la forêt aléatoire (RF).....	128
IV.8.3	Classification utilisant des paramètres hybrides avec l'algorithme BPSO.....	129
IV.8.3.1	Optimisation par essaim particulaire (OEP) et (OEPB).....	129
IV.8.3.2	Classification à l'aide de réseaux de neurones artificiels (ANN).....	132
IV.8.3.3	Classification à l'aide de la forêt aléatoire (RF).....	134
IV.8.4	Classification utilisant des paramètres hybrides avec l'algorithme PCA.....	134
IV.8.4.1	Analyse en Composantes Principales (ACP).....	134
IV.8.4.2	Classification à l'aide de réseaux de neurones artificiels (ANN).....	137
IV.8.4.3	Classification à l'aide de la forêt aléatoire (RF).....	138
IV.8.5	Interprétations des résultats	138
IV.9	Conclusion.....	139
	Conclusion générale et perspectives.....	141
	Références bibliographiques.....	144
	Annexes	153

Liste des figures

Liste des figures

Chapitre I : Etat de l'art des défaillances dans les machines électriques

I.1	Principales étapes de conception d'un dispositif de sûreté de fonctionnement	10
I.2	Classement des méthodes de diagnostic.....	15
I.3	Principe de fonctionnement de la méthode du modèle.....	16
I.4	Principe de la méthode de redondance analytique.....	16
I.5	Procédure de diagnostic basé sur la technique de la reconnaissance des formes.....	18
I.6	Architecture générale d'un système expert de diagnostic.....	19
I.7	Types d'excentricité.....	26
I.8	Vue éclatée des éléments constitutifs d'un roulement à billes.....	27

Chapitre II : Modèle dédié à la simulation des défauts rotorique de la machine asynchrone

II.1	Défaut de rupture de barres.....	34
II.2	Structure du rotor de la MAS.....	36
II.3	Induction magnétique produite par une maille rotorique.....	38
II.4	Modèle de la machine asynchrone après transformation de Park.....	42
II.5	Schéma électrique équivalent d'une maille rotorique.....	44
II.6	Projection du modèle multi enroulements sur le repère biphasé de Park « dq ».....	47
II.7	Schéma bloc de simulation de la MAS à l'état sain et défectueux.....	52
II.8	Source de tension triphasée V_{abcs}	52
II.9	Tension biphasée statorique de Park V_{dq}	53
II.10	Flux statorique Φ_{ds}	53
II.11	Flux statorique Φ_{qs}	53
II.12	Flux rotorique Φ_{dr}	54
II.13	Flux rotorique Φ_{qr}	54
II.14	Courant statorique I_{as}	54
II.15	Courants triphasés statoriques « I_{abcs} ».....	55
II.16	Vitesse mécanique « ω ».....	57
II.17	Couple électromécanique « C_{em} ».....	57
II.18	Diagramme caractéristique couple vitesse.....	58
II.19	FFT du courant statorique « I_{as} » de la MAS.....	58

Chapitre III : Méthodes de traitement des signaux dédiées au diagnostic des défauts d'un système

III.1	Signal présente une phrase du courrier en attente.....	64
III.2	Organigramme de la théorie de l'information.....	65
III.3	Schéma block d'un système.....	65
III.4	Classification des signaux déterministes et aléatoires.....	66
III.5	Les signaux déterministes.....	67
III.6	La morphologie des signaux (continus/discrets).....	67
III.7	Classification énergétique d'un signal.....	68
III.8	Signal échantillonné.....	69
III.9	Schéma d'un système de génération et de traitement du signal.....	72
III.10	Procédure de conversation (Analogique /Numérique).....	72
III.11	Périodogramme d'un signal Chirp allant de « f_1 à f_2 » et inversement.....	76
III.12	Représentation temporelle vers TFCT.....	77
III.13	Transformée de Fourier discrète de différentes fenêtres.....	78
III.14	Spectrogramme d'un signal Chirp par « TFCT » et fenêtre rectangulaire.....	79
III.15	Représentation temporelle vers ondelettes.....	80
III.16	La transformée en ondelettes.....	81
III.17	Ondelettes continue de Haar.....	82
III.18	Scalogramme du signal Chirp avec l'ondelette contenue de Haar (2D).....	85
III.19	Scalogramme du signal Chirp avec l'ondelette contenue de Haar (3D).....	85
III.20	Décomposition du signal « S » en approximations et détails.....	87
III.21	Algorithme de Mallat unidimensionnel.....	87
III.22	Décomposition en multi-niveaux.....	88
III.23	Décomposition en paquet d'ondelettes.....	89
III.24	Répartition des nœuds dans un arbre de décomposition par paquet d'ondelettes.....	90

Chapitre IV : Surveillance de défauts des barres cassées rotoriques de la MAS par les méthodes intelligentes

IV.1	Le neurone biologique.....	95
IV.2	Neurone artificiel.....	98
IV.3	Fonctions d'activations des neurones.....	99
IV.4	Les couches d'un réseau multicouche.....	102
IV.5	Réseau à connexions locales.....	102

IV.6	Réseau à connexions récurrentes.....	103
IV.7	Réseau à connexions complexes.....	103
IV.8	Recherche de la zone minimale dans l'espace de configuration des poids du réseau.....	110
IV.9	Un réseau multicouche.....	111
IV.10	Organigramme global d'une forêt aléatoire.....	114
IV.11	Organigramme détaillé d'une forêt aléatoire.....	116
IV.12	Courant statorique « I_{as} » du cas de trois barres rotorique adjacentes cassées.....	123
IV.13	Arbre de décomposition du signal « I_{as} » par la méthode paquets d'ondelettes.....	123
IV.14	Analyse du signal « I_{as} » de défaut de trois barres rotorique adjacentes cassées par PO.....	124
IV.15	Réseau de neurones Feedforward sans optimisation.....	124
IV.16	Histogramme d'erreur entre les valeurs cibles et les valeurs prédites D'ANN SO.....	125
IV.17	État d'entraînement d'ANN sans optimisation.....	125
IV.18	Courbe de performance d'apprentissage du classificateur de réseau neuronal SO.....	125
IV.19	Le taux d'erreur équilibré de RF sans optimisation.....	126
IV.20	Réseau de neurones Feedforward avec BBAT.....	127
IV.21	Histogramme d'erreur entre les valeurs cibles et les valeurs prédites D'ANN avec BBAT.....	127
IV.22	État d'entraînement d'ANN avec BBAT.....	128
IV.23	Courbe de performance d'apprentissage du classificateur de réseau neuronal avec BBAT.....	128
IV.24	Le taux d'erreur équilibré de RF avec BBAT.....	128
IV.25	Résultats de fitness pour l'algorithme BBAT avec RF.....	129
IV.26	Réseau de neurones Feedforward avec BPSO.....	132
IV.27	Histogramme d'erreur entre les valeurs cibles et les valeurs prédites D'ANN avec BPSO.....	132
IV.28	État d'entraînement d'ANN avec BPSO.....	133
IV.29	Courbe de performance d'apprentissage du classificateur de réseau neuronal avec BPSO.....	133
IV.30	Résultats de fitness pour l'algorithme BPSO avec ANN.....	133
IV.31	Le taux d'erreur équilibré de RF avec BPSO.....	134
IV.32	Résultats de fitness pour l'algorithme BPSO avec RF.....	134
IV.33	Réseau de neurones Feedforward avec PCA.....	137
IV.34	Histogramme d'erreur entre les valeurs cibles et les valeurs prédites D'ANN avec PCA.....	137
IV.35	État d'entraînement d'ANN avec PCA.....	137
IV.36	Courbe de performance d'apprentissage du classificateur de réseau neuronal avec PCA.....	138
IV.37	Le taux d'erreur équilibré de RF avec PCA.....	138

Liste des tableaux

Liste des tableaux

Chapitre I : Etat de l'art des défaillances dans les machines électriques

I.1	Synthèse des défaillances du stator sur la machine asynchrone.....	12
I.2	Synthèse des défaillances du rotor sur la machine asynchrone.....	13

Chapitre II : Modèle dédié à la simulation des défauts rotorique de la machine asynchrone

II.1	Inductances de la machine asynchrone à cage d'écureuil.....	40
II.2	Couple , vitesse et courant statorique de la machine asynchrone à l'état sain.....	59
II.3	Couple , vitesse et courant statorique de la machine asynchrone à l'état défectueux.....	59

Chapitre III : Méthodes de traitement des signaux dédiées au diagnostic des défauts d'un système

III.1	Les signaux particuliers (utiles) échantillonnés.....	70
III.2	Les fenêtres de la transformée de Fourier à court terme (TFCT).....	78
III.3	Famille des ondelettes.....	83

Chapitre IV : Surveillance de défauts des barres cassées rotoriques de la MAS par les méthodes intelligentes

IV.1	Différentes fonctions d'activations utilisées dans les RNA (ANN).....	100
IV.2	Correspondance RNA-Domains d'applications.....	101
IV.3	Codage des états de fonctionnement de la machine asynchrone.....	119
IV.4	les paramètres statistiques.....	122
IV.5	Résultats des classificateurs ANN et RF sans et avec algorithmes d'optimisation.....	139

Liste des symboles et abréviations

Liste des symboles et abréviations

f_{cs}	: Fréquence de défaut de court-circuit des bobines statoriques
f_{brc}	: Fréquence de défaut des barres rotoriques cassées
f_{exc}	: Fréquence de défaut d'excentricité du rotor
f_b	: Fréquence de défaut d'une bille du roulement
$f_{b.int}$: Fréquence de défaut de la bague intérieure du roulement
$f_{b.ext}$: Fréquence de défaut de la bague extérieure du roulement
f_c	: Fréquence de défaut de la cage du roulement
n_b	: Le nombre d'éléments roulants
BD	: Le diamètre d'un élément roulant
PD	: La distance entre les centres des billes diamétralement opposées
β	: L'angle du contact des billes avec les bagues du roulement
f_{rot}	: La fréquence de rotation du rotor
B_s	: L'induction magnétique
Φ_s	: Le flux magnétique dans l'entrefer
Ψ_{saT}	: Le flux magnétique total traversant l'enroulement de la phase « a » dû au courant « i_{sa} »
L_{sp}	: L'inductance principale « magnétisante » d'une phase statorique
L_{as}	: L'inductance totale « propre » de la phase « a »
L_{sf}	: L'inductance de fuite statorique
M_s	: L'inductance mutuelle entre les phases statoriques
α	: l'angle entre les barres rotoriques
Φ_{rk}	: Flux principal produit par une maille rotorique « k »
L_{rp}	: L'inductance principale d'une maille rotorique
L_{rr}	: L'inductance totale de la « $k^{\text{ème}}$ » maille rotorique
L_b	: L'inductances de fuite d'une barre rotorique
L_e	: L'inductances de fuite de portion d'anneaux de court-circuit
Φ_{rjrk}	: Le flux traversant la « $j^{\text{ème}}$ » maille, produit par le courant « i_{rk} » circulant dans la maille « k »
M_{rr}	: L'inductance mutuelle entre mailles rotoriques non adjacentes
$M_{rk(k-1)}$: L'inductance mutuelle entre la « $k^{\text{ème}}$ » maille et adjacentes
L_{abcs}	: Inductance totale des phases statoriques

M_{rksa}	: L'inductance mutuelle entre une maille rotorique et une phase statorique « a »
I_{abcs}	: Les courants statoriques
I_{rk}	: Le courant dans les maille rotorique « k »
I_{bk}	: Le courant de la barre rotorique « k »
V_{abcs}	: Les tensions statoriques
V_{rk}	: Les tensions dans les barres rotoriques
Φ_{abcs}	: Les flux statoriques
R_s	: La résistance statorique
R_r	: La résistance rotorique
L_s	: L'inductance statorique
M_s	: L'inductance mutuelle entre deux phases statoriques
M_{sr}	: L'inductance mutuelle entre phase statorique et une maille rotorique
N_s	: Nombre de spires par phase statorique
N_r	: Nombre de barres rotoriques
$P(\theta_s)$: Matrice de rotation de Park
L_{sc}	: L'inductance cyclique statorique
L_{rc}	: L'inductance cyclique rotorique
Φ_{dqs}	: Les flux statoriques dans le repère de Park « d, q »
V_{dqs}	: Les tensions statoriques dans le repère de Park « d, q »
I_{dqs}	: Les courants statoriques dans le repère de Park « d, q »
R_e	: La résistance d'une portion d'anneau de court-circuit
L_e	: L'inductance de fuite d'anneau de court-circuit
R	: Le rayon moyen de l'entrefer
l	: La longueur active du circuit magnétique
e	: L'épaisseur de l'entrefer
C_{em}	: Le couple électromagnétique
Ω	: La vitesse mécanique
ω	: La pulsation mécanique
p	: Nombre de pair de pôles
θ	: L'angle de déphasage entre le stator et le rotor
V_{0dqr}	: Les tensions rotoriques dans le repère de Park « d, q »

R_{rf}	: La résistance de barre rotorique cassée « $R_{rdd}, R_{rdq}, R_{rqd}, R_{rqq}$ »
R_b	: La résistance d'une barre rotorique
J	: Le moment d'inertie
f	: Coefficient de frottement visqueux
SF	: Série de Fourier
TF	: Transformée de Fourier
FFT	: Fast Fourier Transform
TFCT	: Transformée de Fourier à Court Terme
TO	: Transformée en Ondelettes
TOC	: Transformée en Ondelettes Continue
TOD	: Transformée en Ondelettes Discrète
TPO	: Transformée en Paquets d'Ondelettes
ANN	: Artificial Neural Network
RF	: Random Forest
BBAT	: Binary Bat Algorithm
BPSO	: Binary Particles Swarm Optimization
PCA	: Principal Component Analysis

Introduction générale

Introduction générale

La surveillance et le diagnostic des processus industriels sont devenus de plus en plus importants ces dernières années. Ils sont devenus un instrument efficace pour réduire les temps d'arrêt du système de production et minimiser les pertes économiques. Dans le cadre du diagnostic des systèmes industriels, les machines tournantes sont fréquemment considérées comme le cœur de divers procédés industriels. On peut citer par exemple, les machines asynchrones comme celles existantes dans les stations de production d'électricité, les cimenteries et les complexes pétrochimiques, etc. Les machines asynchrones ne peuvent être exemptes des pannes et de défaillances de plusieurs types, telles que : les défauts électriques, de balourd, d'accouplement, des roulements, et cassures des barres rotoriques. Plusieurs enquêtes statistiques ont révélé que les pannes dues à des barres de rotor endommagées sont la cause la plus fréquente de problèmes de machines asynchrones. D'un point de vue industriel et scientifique, il est donc indispensable de concentrer les efforts de recherche sur le diagnostic de ce type de défauts. Plusieurs stratégies de surveillance de l'état des barres de rotor ont récemment été conçues et utilisées. On peut citer l'approche éléments finis, l'étude des vibrations mécaniques, et l'analyse des signes de défauts dans les courants statoriques.

La taxonomie des approches diagnostiques les divise en deux catégories : les méthodes internes qui utilisent des modèles mathématiques et les procédures externes.

L'étude de cette thèse porte sur le diagnostic de problèmes dans les barres rotoriques à l'aide des signaux du courant statorique. Nous employons une approche « sans modèle », utilisant des méthodes de reconnaissance des formes intelligentes telles que les réseaux de neurones (ANN) et la forêt aléatoire (RF), à l'aide de certains algorithmes d'optimisations tels que BPSO, BBAT et l'algorithme de réduction de dimension PCA. A la suite de ce qui précède, la thèse est organisée en quatre chapitres.

Le premier chapitre est consacré à la présentation des concepts fondamentaux de la fiabilité et de ses enjeux. Un cours de vocabulaire lié à cette technique a été offert. Nous avons vu les principaux processus nécessaires à l'établissement d'un système de fiabilité, et chacun nécessite des informations et des objectifs hautement spécialisés.

Nous nous sommes également concentrés sur certains objets du Génie Electrique, notamment les machines électriques et, cas particulier, les machines asynchrones. En raison de leur utilisation répandue dans les systèmes industriels, la mise en œuvre de dispositifs de surveillance des problèmes pouvant survenir lors de

leur fonctionnement revêt une importance particulière. Nous avons ensuite effectué une revue rapide des approches utilisées pour détecter et diagnostiquer leurs défauts, en nous concentrant sur deux grandes familles de méthodes : les "méthodes internes" et les "méthodes externes".

Le deuxième chapitre a utilisé des circuits électriques à plusieurs enroulements connectés magnétiquement avec une alimentation directe au réseau électrique. Pour se concentrer sur l'étude de la simulation des défauts de rupture de barre, un modèle de rotor sous forme de mailles reliées électriquement entre elles et couplées magnétiquement a été établi, où une maille est constituée de deux barres et des deux portions d'anneaux qui relient eux. La résistance et l'inductance caractérisent chaque segment de barre et d'anneau.

Le troisième chapitre a présenté une compréhension générale des signaux et de leur catégorisation. Viennent ensuite les différents ensembles de traitement du signal, qui se concentrent sur la série de Fourier pour les signaux périodiques et la transformée de Fourier selon ses variations, notamment les ondelettes pour les signaux non stationnaires.

Le quatrième chapitre a été présenté pour l'utilisation des méthodes intelligentes telles que les réseaux de neurones (ANN) et les forêt aléatoires (RF), qui ont été aidés par des algorithmes d'optimisation tels que BPSO, BBAT et l'algorithme de réduction de dimension PCA.

Les résultats acquis démontrent l'utilité de ces méthodes pour détecter et localiser les défauts des barres rotoriques cassées au sein de la machine asynchrone triphasée.

Enfin, la thèse se termine par une conclusion générale qui met en évidence la valeur de cette thèse en révélant les nombreuses perspectives.

Chapitre I

Etat de l'art des défaillances dans les machines électriques

I.1 Introduction

L'étude des défaillances des équipements électriques est devenue de plus en plus pertinente à mesure que les normes de fiabilité, de sécurité et de disponibilité des systèmes industriels sont devenues plus strictes. En effet, la continuité de service est un attribut crucial et nécessaire que tout système doit avoir aujourd'hui afin de répondre aux besoins de l'utilisateur. Étant donné que les éléments d'un système sont interdépendants, une défaillance d'un élément peut entraîner l'arrêt complet du système, et ce type de circonstance peut être coûteux dans certaines applications.

Les enjeux économiques en constante évolution conduisent à une production toujours plus importante. Dans un environnement hautement performant, même le plus petit défaut d'un processus peut être désastreux. Par conséquent, il est essentiel de vérifier régulièrement que le processus se déroule bien. Les mesures des variables dans cette procédure fournissent les informations nécessaires pour traduire le comportement d'un système. Par conséquent, un système de surveillance doit être mis en place afin de détecter, localiser et identifier tout défaut. Un système de surveillance doit permettre de caractériser le mode de fonctionnement d'un système à partir d'informations préalablement acquises.

En raison de la variété des systèmes et des problèmes à diagnostiquer, ainsi que de l'hétérogénéité des informations disponibles, de nombreuses méthodologies de détection et de localisation des défauts ont été développées. Ces approches sont classées selon qu'un modèle du processus à surveiller est disponible ou non.

Dans le cas des techniques basées sur des modèles, le principe de diagnostic repose souvent sur un test de cohérence entre un comportement de processus observé fourni par des capteurs et un comportement de processus prédit offert par une description mathématique du processus. Les méthodes de redondance analytique nécessitent un modèle du système à surveiller. Ce modèle comprend un certain nombre de paramètres dont les valeurs sont supposées connues en fonctionnement normal. La comparaison du comportement réel du système et du comportement attendu fourni par le modèle donne une quantité dite résiduelle, qui sera utilisée pour décider si le système est défectueux ou non.

Si le modèle n'est pas disponible, les données du système doivent être analysées pour déterminer son état.

Dans ce chapitre, nous aborderons d'abord les concepts fondamentaux de la sûreté de fonctionnement et ses enjeux. Cette méthode sera accompagnée d'un cours de vocabulaire. Les principaux processus nécessaires à l'établissement d'un système de fiabilité seront ensuite examinés, car chacun nécessite des informations et des objectifs hautement spécialisés.

Nous nous concentrerons ensuite sur des objets spécifiques du Génie Electrique, en particulier les machines électriques et, cas particulier, les machines asynchrones. En raison de leur présence prédominante dans les systèmes industriels, l'adoption de dispositifs de surveillance des défauts pouvant survenir lors de leur utilisation est d'une grande importance. Nous ferons ensuite un bref état de l'art des approches utilisées pour détecter et diagnostiquer leurs défauts, en nous concentrant sur deux grands groupes de méthodes : les "méthodes internes" et les "méthodes externes".

I.2 Notions de sûreté de fonctionnement

La fiabilité est définie comme la capacité d'une entité à exécuter une ou plusieurs fonctions requises dans des conditions spécifiées. Elle se définit scientifiquement comme l'étude statique et dynamique des systèmes d'un point de vue prédictif, opérationnel et expérimental, en tenant compte des facteurs de probabilité et de répercussions associés aux défaillances. La méthode « fiabilité » est fondée sur quelques notions fondamentales qui ont été expliquées et enrichies au cours de l'évolution de ce métier. La fiabilité, comme toute science, a son propre ensemble d'idées terminologiques [1]. Reprendre ce langage de base est donc une introduction indispensable à cette discipline.

I.2.1 Maintenance, surveillance et diagnostic

La notion de maintenance est particulièrement importante dans le contexte de la fiabilité. Elle comprend les notions de surveillance et de diagnostic qui nous intéressent particulièrement. Voici différentes définitions de cette expression [2].

- ✚ **Maintenance** : ensemble des activités destinées à maintenir ou à rétablir un bien dans un état ou dans des conditions données de sûreté de fonctionnement pour accomplir une fonction requise.
- ✚ **Maintenance préventive** : maintenance ayant pour objet de réduire la probabilité de défaillance ou de dégradation d'un bien ou d'un service rendu. Les activités correspondantes sont déclenchées selon un échancier établi à partir d'un nombre prédéterminé d'unités d'usages, et/ou des critères prédéterminés significatifs de l'état de dégradation du bien ou du service [3].
- ✚ **Maintenance corrective** : ensemble des activités réalisées après la défaillance d'un bien, ou la dégradation de sa fonction, pour lui permettre d'accomplir une fonction requise, au moins provisoirement. La maintenance corrective comprend en particulier : la localisation de la défaillance et son diagnostic, la remise en état avec ou sans modification, le contrôle du bon fonctionnement.
- ✚ **Maintenance curative** : activités de maintenance corrective ayant pour objet de rétablir un bien dans

un état spécifié ou de lui permettre d'accomplir une fonction requise. Les résultats de l'activité doivent être permanents. Ces opérations peuvent inclure : des réparations, des réglages ou des améliorations visant à éliminer le(s) défaut(s). [2].

Par conséquent, il apparaît que si un composant d'une entité est jugé défectueux, sa réparation ou son remplacement doit être considéré comme une maintenance corrective. S'il est déterminé qu'il ne présente pas de dysfonctionnement mais qu'il s'est dégradé, sa réparation ou son remplacement doit être considéré comme un entretien préventif. Le mode de maintenance approprié doit être choisi en fonction des problèmes identifiés sur une entité. Cette décision est fortement influencée par les informations fournies par les étapes de surveillance/détection et de diagnostic décrites ci-dessous.

- ✚ **Surveillance / détection de comportement** : actes manuels ou mécaniques destinés à inspecter l'état d'un bien ou d'un service et à détecter la présence d'une panne éventuelle. Les informations requises pour ces activités peuvent provenir directement du système ou de mesures indirectes [2].
- ✚ **Diagnostic** : Action de déterminer la ou les causes probables de la ou des pannes ou l'évolution d'une ou plusieurs paramètres de dégradation significatives à l'aide d'une logique de raisonnement basée sur un ensemble d'informations. Le diagnostic vous permet de confirmer, de compléter ou de modifier vos théories sur l'origine et la cause des problèmes, ainsi que d'identifier les procédures de maintenance corrective nécessaires [4].

La surveillance/détection est l'application de procédures basées sur l'étude des fluctuations des paramètres ou grandeurs d'exploitation de l'entité, dans le but de déterminer la nécessité d'une inspection ou d'une réparation. Entretien préventif pour assurer son bon fonctionnement. Si la surveillance permet de détecter une défaillance, le diagnostic consiste à examiner les effets de la défaillance et, si possible, à identifier les raisons et l'importance de la défaillance. Un examen attentif des définitions de la surveillance et du diagnostic révèle qu'il s'agit d'outils de maintenance qui tentent d'améliorer la sûreté de fonctionnement de l'entité à laquelle ils s'appliquent.

I.2.2 Fiabilité, disponibilité, maintenabilité et sécurité

La surveillance et les diagnostics sont des outils importants pour accroître la fiabilité, la maintenabilité, la disponibilité et la sécurité d'une entité. Définissons plus précisément ces diverses idées.

- ✚ **Fiabilité** : Capacité d'un élément à exécuter des fonctions essentielles dans des conditions spécifiées pendant une période spécifiée. Il est défini par la chance que l'entité exécutant ces activités à l'instant « 0 » puisse aussi les faire à l'instant « t » [5].

- ✚ **Maintenabilité** : La capacité d'un élément à être restauré par un entretien adéquat afin d'exécuter les fonctions requises dans certaines conditions. Il est défini par la probabilité d'être dans un état à l'instant « t » pour effectuer ces opérations tout en sachant qu'il était en panne à l'instant « 0 ». Ce n'est que sur ce dernier point que la maintenabilité diffère de la fiabilité : elle désigne la rapidité avec laquelle le service attendu est repris après une interruption. La brièveté des pannes est ce qui définit la maintenabilité [5].
- ✚ **Disponibilité** : Aptitude d'un élément à remplir les fonctions requises dans des conditions spécifiées. Il est défini par la probabilité d'être dans un état à l'instant « t » pour remplir les fonctions requises [2].
- ✚ **Sécurité** : La capacité d'un élément à ne pas produire de dommages ou d'événements critiques ou catastrophiques dans certaines conditions [2].

I.2.3 Défaillance et panne

Enfin, pour compléter cette liste non exhaustive de termes liés à la sûreté de fonctionnement, nous conseillons de définir précisément les termes de défaillance et panne.

- ✚ **Défaillance** : La perte de la capacité d'une entité à exécuter une fonction requise. Après qu'une entité échoue, elle est dans un état d'échec. Une défaillance est un passage d'un état à un autre, par opposition à une panne qui est un état.
- ✚ **Défaillance partielle** : Échec à la suite duquel l'objet ne peut exécuter que certaines des fonctions nécessaires ou ne les exécute qu'avec des performances limitées.
- ✚ **Défaillance complète** : Défaillance entraînant l'incapacité totale de l'objet à exécuter toutes les fonctions nécessaires.
- ✚ **Panne** : L'état d'un élément qui est incapable de remplir une fonction requise dans les conditions d'utilisation données.
- ✚ **Panne complète** : panne résultant d'une défaillance totale.

Il est évident que dès qu'une défaillance survient, signalée par l'incapacité d'une entité à remplir son rôle, elle est étiquetée hors service. En conséquence, la panne est toujours le résultat d'une défaillance.

I.3 Mise en place d'un dispositif de sûreté de fonctionnement

I.3.1 Les principales étapes de conception d'un dispositif de sûreté de fonctionnement

Le déploiement d'une stratégie de sûreté comporte plusieurs étapes, que nous allons résumer ci-dessous [2].

✚ Etape 1 – Recherche de signatures des défaillances

L'une des premières étapes de l'établissement d'un système de sûreté de fonctionnement consiste à s'intéresser aux phénomènes et aux scénarios cruciaux susceptibles de mettre en péril la fonction, l'environnement et la mission d'un système. Cela pose des problèmes concernant les événements pouvant conduire à une situation critique et les implications de défauts à forte probabilité d'occurrence. Cette réflexion est une composante essentielle de la stratégie sûreté de fonctionnement. Il est par conséquent essentiel de bien comprendre l'élément à surveiller, à la fois en l'absence et en présence de problèmes. Dans ce contexte, la fiabilité est toujours entièrement dépendante de la connaissance du système considéré et de l'état des sciences impliquées. L'enjeu pour le concepteur est alors de déterminer quels sont les éléments les plus sensibles d'une installation, dont les quantités permettront de constater les impacts des erreurs, et comment les défauts vont se présenter sur ces grandeurs. Cette dernière phase, dite de recherche de signes de défaillance, est une étape importante dans la réalisation d'un dispositif de sûreté. Cette étude peut être menée de différentes manières. Elle peut être alimentée par des retours d'expérience sur des produits défaillants ou simplement par une compréhension "théorique" du processus. Il est également possible d'utiliser des outils de modélisation et de simulation, ainsi que des expériences expérimentales.

Etape 2 – Mise au point de méthodes de Surveillance / détection

Les connaissances acquises à l'étape "1" permettent de renseigner sur le comportement du système en cas de panne, sur ses défaillances les plus probables et les plus critiques, et sur les signes de leur manifestation. La phase de mise en place des méthodes de surveillance/détection se nourrit de ces fonctionnalités, les démultiplie, pour produire des approches qui permettent au système de mettre l'accent sur les débuts ou l'apparition d'un défaut lors du fonctionnement du système. Comme indiqué précédemment, les méthodes de surveillance/détection sont souvent basées sur des mesures directes ou indirectes de grandeurs liées au système en fonctionnement. Le but est de rechercher l'apparition de signatures des pannes surveillées et de générer automatiquement, c'est-à-dire sans recours à l'expérience humaine, des indicateurs informant de cette présence.

✚ Etape 3 - Diagnostic des défaillances :

L'étape de diagnostic consiste à examiner les données de surveillance dans le but d'identifier et de découvrir la ou les causes probables de la panne. Les méthodes de diagnostic peuvent tirer parti de toutes les informations disponibles concernant leur relation de cause à effet. Cette étape donne des informations pour identifier le degré de criticité du défaut et pour focaliser les mesures d'action disponibles pour le contenir.

Etape 4 - Décision d'actions :

Enfin, l'étape décisionnelle intervient pour mettre en œuvre les actions les plus appropriées pour répondre aux normes de sûreté de fonctionnement « maintien en fonction, sécurisation, maintenance, ... ».

La figure (I.1) résume ces différentes étapes. Pour résumer, la fiabilité est la capacité à reconnaître, identifier, analyser et contrôler les problèmes du système.



Figure I.1 : Principales étapes de conception d'un dispositif de sûreté de fonctionnement [2]

I.3.2 La sûreté de fonctionnement des machines électriques

Les concepts généraux de fiabilité décrits précédemment peuvent être appliqués à n'importe quel appareil. Les systèmes modernes dans le domaine du génie électrique intègrent progressivement le concept de sécurité de fonctionnement. La surveillance de l'état de santé des systèmes, la détection de défauts, les dispositifs de sécurité, par exemple, sont recherchés pour minimiser les coûts de maintenance et augmenter la disponibilité et la fiabilité des installations dans les secteurs du ferroviaire, de l'aéronautique ou du spatial, mais aussi dans

les disciplines des machines électriques, pour limiter les coûts de maintenance et augmenter la disponibilité et la fiabilité des installations.

En raison de leur prévalence dans un large éventail de processus, les machines asynchrones sont parmi les composants les plus fréquemment rencontrés dans ces systèmes. Les enjeux concernant leur sécurité de fonctionnement sont donc d'une importance majeure pour les opérateurs et les producteurs.

Les défauts fondamentaux des machines électriques "asynchrones" peuvent être divisés en deux catégories. [6] :

- ✚ **Les défauts mécaniques** : excentricité du rotor, usure de roulements, désalignement de l'arbre de transmission, défauts de la charge « déséquilibre, défaut de réducteur mécaniques ou tout autre défaut pouvant survenir dans la charge entraînée » ;
- ✚ **Les défauts électriques** : défauts d'isolement des bobinages statoriques, défauts de cage dans les machines asynchrones, défauts d'alimentation, ...etc.

Les tableaux ci-joints (I.1 et I.2) résument les nombreux défauts qui affectent la machine asynchrone. [6].

Tableau I.1 : Synthèse des défaillances du stator sur la MAS

Composants		Défaillances	Causes possibles	Effets sur le système	observable
Machine asynchrone à cage d'écureuil	Stator	Isolant dans un enroulement	<ul style="list-style-type: none"> Dégradations de l'isolant à la fabrication Tension élevée Courant élevé Vibrations mécaniques Température élevée Vieillessement naturel 	Court-circuit dans l'enroulement	<ul style="list-style-type: none"> Température Vibrations Courants
		Court-circuit entre spires	Défaut d'isolants	<ul style="list-style-type: none"> Augmentation des courants statoriques et rotoriques Variation d'amplitude sur les autres phases Modification de facteur de puissance 	<ul style="list-style-type: none"> Température Vibration Courant Puissance instantanée
		Court-circuit entre phases	Décharge partielle	Dépend fortement de la localisation <ol style="list-style-type: none"> Proche de l'alimentation : <ul style="list-style-type: none"> Fusion des conducteurs Disjonction par les protections Proche du neutre : <ul style="list-style-type: none"> Augmentation des courants dans les barres et les anneaux Déséquilibre des courants statoriques 	<ul style="list-style-type: none"> Courants (déséquilibré) Température Tension Puissance instantanée
		Court-circuit phase/bâti	Dégradation des isolants	<ol style="list-style-type: none"> Augmentation du courant dans la phase entraîne : <ul style="list-style-type: none"> Une augmentation de la température et défauts d'isolants L'apparition d'une composante homopolaire entraîne : <ul style="list-style-type: none"> Une pulsation du couple 	<ul style="list-style-type: none"> Courant de fuite
		Circuit magnétique		Dissymétrie du fonctionnement de la machine entraîne : <ul style="list-style-type: none"> Surchauffe Surtension Elévation du courant 	<ul style="list-style-type: none"> Température Courants Tensions
		Déséquilibre d'alimentation	<ul style="list-style-type: none"> Problème sur le réseau d'alimentation Défaillance du convertisseur 	Augmentation de : <ul style="list-style-type: none"> Courants dans les autres phases Vibrations Echauffement 	<ul style="list-style-type: none"> Vibrations Courants Tensions Puissance

Tableau I.2 : Synthèse des défaillances du rotor sur la MAS

Composants		Défaillances	Causes possibles	Effets sur le système	observable
Machine asynchrone à cage d'écureuil	Rotor	Ruptures de barres	Surcharge	<ul style="list-style-type: none"> • Réduction de la valeur moyenne du couple électromagnétique • Oscillations de la vitesse • Vibrations mécaniques 	<ul style="list-style-type: none"> • Vibrations • Couple électromagnétique • Courant
		Ruptures d'anneaux	<ul style="list-style-type: none"> • Bulles coulées • Dilatations différentielles • Surcharge du couple • Détérioration des conditions de fonctionnement 	Déséquilibre la répartition des courants entraînent : <ul style="list-style-type: none"> • Modulation d'amplitude des courants statoriques 	<ul style="list-style-type: none"> • Courant • Vibration
		Excentricité	<ul style="list-style-type: none"> • Positionnement incorrect des paliers lors de l'assemblage • Usure des roulements • Défaut de charge • Défaut de fabrication 	Balourd (mécanique et magnétique) entraîne : <ul style="list-style-type: none"> • Oscillations du couple 	<ul style="list-style-type: none"> • Vibrations • Courants • Couple
	Axe	Roulements	<ul style="list-style-type: none"> • Usure • Température élevée • Perte de lubrification • Défaut de montage • Huile contaminée 	1. Oscillations du couple de charge entraîne : <ul style="list-style-type: none"> • Augmentation des pertes • Augmentation des vibrations 2. Altération de l'équilibre magnétique	<ul style="list-style-type: none"> • Vibrations • Courants • Puissance instantanée • Variables mécaniques

I.4 Problématique du diagnostic des machines électriques

Pour éviter de résoudre un problème de diagnostic inverse mal posé, il est essentiel de s'appuyer sur les liens de cause à effet.

En général, le problème du diagnostic se résume à une méconnaissance du modèle déterministe de cause à effet ; plus précisément, il faut identifier les variables déterministes des défauts, puis sélectionner les signatures qui indiquent mieux "caractériser" ces défauts grâce au traitement du signal de ces variables. De plus, qu'il soit

médical ou industriel, le diagnostic repose toujours sur une comparaison entre le comportement du processus en panne et le comportement du processus sain « ou son modèle ».

La comparaison nécessite des indications indiquant des symptômes qui, une fois analysés, permettent de découvrir un comportement anormal, d'en déduire la fonction ou l'élément défaillant de « localiser », d'en déterminer la cause et, si possible, d'y remédier. [7, 8].

De plus, l'idée hautement stratégique de la maintenance prédictive nécessite de connaître les grandeurs importantes à évaluer afin d'obtenir une image au plus près de l'état de la machine.

Le système de suivi de la machine doit être capable de [9, 10] :

- ✚ Interférer le moins possible avec le système (les grandeurs peuvent-elles être mesurées en temps réel « on line », problème de sécurité, etc.) ;
- ✚ Être capable de suivre plusieurs grandeurs ;
- ✚ Être évolutif ;
- ✚ Être pilotable à distance ;
- ✚ Stocker les données pour permettre une analyse tendancielle.

La stratégie générale de diagnostic est la suivante : [11, 12, 13, 14, 15] :

- ✚ Identifier les défauts et les pannes potentiels ;
- ✚ Déterminer les grandeurs mesurables associées à ces défauts (quantités indicatrices) ;
- ✚ Choisir la méthode la plus proche des critères définis ci-dessus ;
- ✚ Définissez les seuils d'alerte qui nécessiteront une intervention.

D'après ce qui précède, le problème à résoudre en termes de diagnostic consiste à connaître le comportement caractéristique du système en cas de panne, sélectionner les méthodes de diagnostic adaptées à leur application au cas étudié, identifier les valeurs indicatrices, et concevoir l'architecture du système de diagnostic et sa mise en œuvre.

I.5 Analyse des méthodes de diagnostic existantes

L'organigramme ci-dessous décrit les différentes approches de diagnostic. [8].

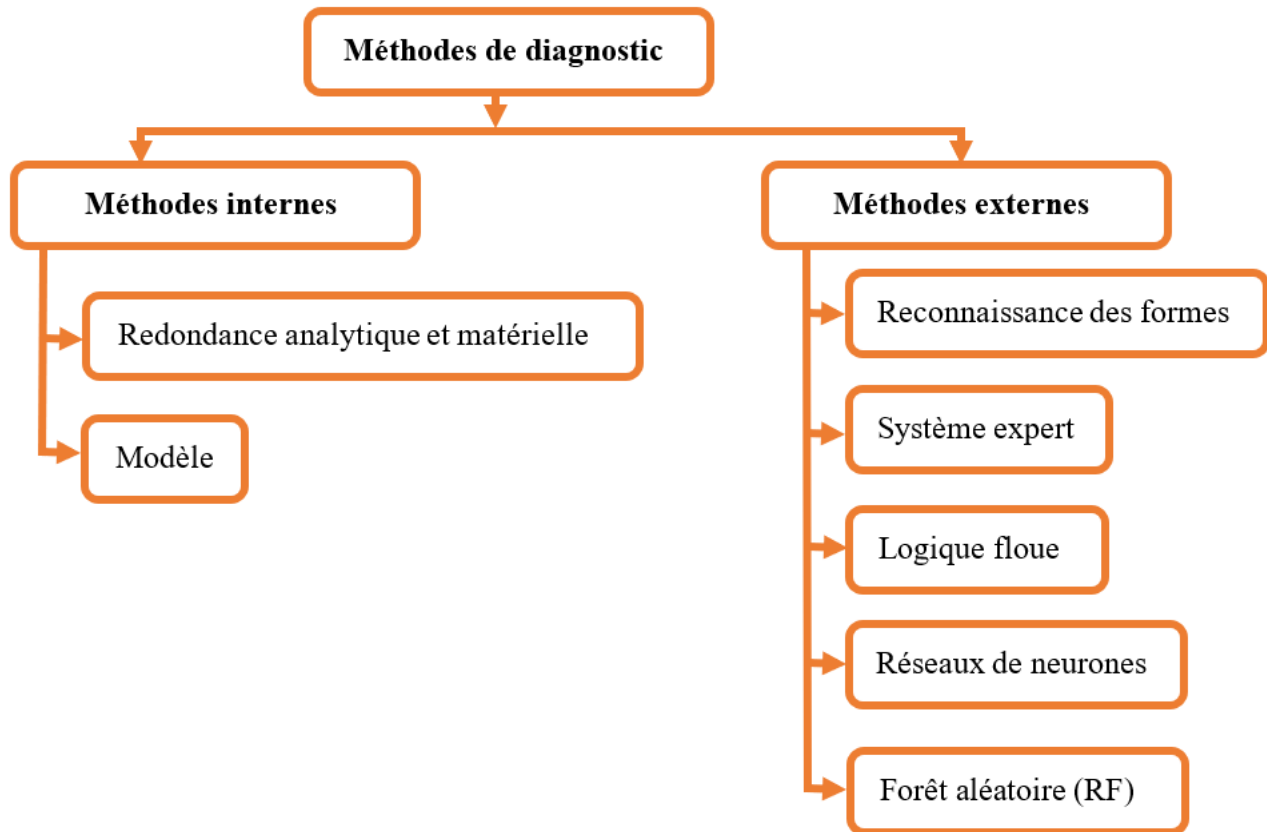


Figure I.2 : Classement des méthodes de diagnostic

I.5.1 Les méthodes internes

Cette famille de méthodes est principalement développée à partir d'approches utilisées par les ingénieurs de contrôle. En validant des modèles physiques ou comportementaux à l'aide de techniques d'identification de paramètres, il est possible d'exécuter la méthode du problème inverse.

Le diagnostic de panne est réalisé en suivant l'évolution des paramètres physiques en temps réel, ou en inversant des modèles de type "boîte noire" ; les techniques internes de diagnostic sont divisées en deux grands groupes.

- ✚ La méthode du modèle ;
- ✚ La méthode de redondance analytique et matérielle.

I.5.1.1 La méthode du modèle

La méthode de diagnostic par modélisation compare les grandeurs déterminées à partir d'un modèle représentatif du fonctionnement des différentes entités du procédé avec des mesures directement observées sur

le procédé industriel. La Figure (I.3) décrit le fonctionnement d'un système de détection de défaillance basé sur un modèle. [7].




Figure I.3 : Principe de fonctionnement de la méthode du modèle

En général, il est préférable d'utiliser un modèle qui prend en compte les chaînes de contrôle, les actionneurs et les sous-ensembles du processus industriel indépendamment pour des opérations continues avec un système de contrôle. Le modèle a la même structure que le processus, comme mentionné dans [7] pour un système d'entraînement électrique. La technique de comparaison de comportement est utilisée pour trouver des différences entre les signaux d'état normaux et aberrants. L'observation simultanée des signaux de sortie comparatifs permet d'isoler rapidement le module problématique.

I.5.1.2 La redondance analytique et matérielle

La redondance analytique est basée sur la connaissance d'un modèle mathématique du système à surveiller (Figure I.4). Ce modèle, placé dans les mêmes conditions que le système, est calculé en temps réel. Par conséquent, il peut donner les relations de redondance nécessaires pour comparer le processus au modèle. [16, 17].




Figure I.4 : Principe de la méthode de redondance analytique

D'autre part, il existe un moyen de redondance matérielle qui consiste à dupliquer ou à tripler l'équipement en de nombreux actionneurs, capteurs et systèmes de contrôle [7]. Cette approche est principalement utilisée dans des circonstances où la continuité de service est requise (avionique). En effet, une fois le problème reconnu, il est avantageux d'utiliser la partie de l'équipement qui est encore en bon état de fonctionnement. Cependant, il s'agit d'un processus coûteux et compliqué.

I.5.2 Les méthodes externes

Dans cette catégorie, on découvre les méthodes basées sur l'intelligence artificielle [8, 15], qui peuvent être classées en cinq grandes familles :

- ✚ Méthodes de reconnaissance des formes ;
- ✚ Diagnostic par systèmes experts ;
- ✚ Diagnostic par logique floue ;
- ✚ Diagnostic par réseaux de neurones ;
- ✚ Diagnostic par forêt aléatoire (RF).

I.5.2.1 Les méthodes de reconnaissance des formes

La reconnaissance de formes est une technique de conception d'algorithmes permettant de classer des éléments dont l'apparence diffère de celle d'un objet typique. Il s'agit de déterminer à quel type de forme une forme observée ressemble le plus. [18, 19, 20].

Dans ce scénario, la forme est déterminée par une collection de paramètres « d » appelés caractères, qui sont les composants du vecteur de forme « x » ; les prototypes sont les points représentatifs du vecteur de forme dans l'espace dimensionnel « d ». Dans un problème de reconnaissance de formes, il est communément admis que les formes « x » à identifier correspondent à des « M » catégories bien définies appelées classes et désignées « w_1, w_2, \dots, w_m ». De plus, compte tenu du bruit de mesure, les vecteurs d'une certaine classe « w_i » forment une zone spécifique dans l'espace de dimension « d ».

Le problème de reconnaissance de formes consiste à découvrir les formes qui séparent les classes « M » pour catégoriser ultérieurement une nouvelle forme « x » lors de l'opération de classification ou de discrimination [21].

L'approche de diagnostic basée sur la reconnaissance des formes se compose de quatre étapes principales, qui sont résumées dans la figure (I.5).

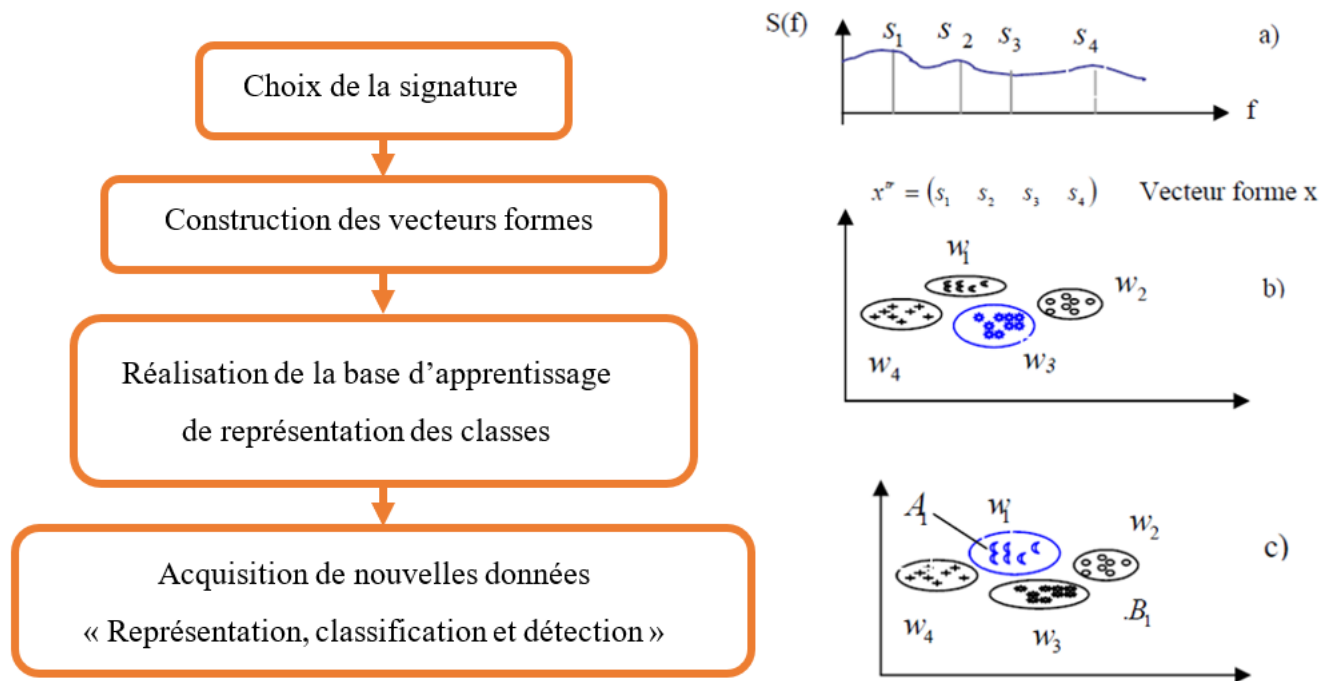


Figure I.5 : Procédure de diagnostic basée sur la technique de la reconnaissance des formes

Dans ce cas, la phase finale est définitivement corrélée au fonctionnement du système de diagnostic. En revanche, après avoir acquis une nouvelle signature, on calcule la forme associée dans l'espace de présentation et on procède à son classement, qui est simple (il faudra par exemple décider s'il faut rejeter « B » ou ajoutez-le à une nouvelle classe).

1.5.2.2 Diagnostic par systèmes experts

Un système expert doit fournir des réponses associées à une situation donnée, sachant que la complexité du domaine étudié ne permet pas d'établir a priori toutes les configurations possibles des situations ; tel un spécialiste du dépannage, il réalise son diagnostic à partir d'une description partielle de la situation. En effet, il peut déduire des implications possibles, établir de nouvelles hypothèses et approfondir son diagnostic à partir de l'ensemble des symptômes qui lui sont accessibles en utilisant les informations supplémentaires recueillies sur le système à examiner [11].

Un système expert est composé de plusieurs composants majeurs [8] (Figure I.6), qui comprennent :

- ✚ **La base de connaissances** : Il contient toutes les informations nécessaires pour relever les défis sur le terrain ;
- ✚ **La base de faits** : La base de faits, qui contient initialement les informations de base du domaine, est

progressivement complétée par des conclusions ou de nouveaux faits déterminés par le moteur d'inférence.

✚ **Le moteur d'inférence :** Pour proposer une solution au problème donné, le moteur d'inférence exploite indépendamment les informations incluses dans les bases de faits et de connaissances. De plus, le moteur d'inférence génère de nouveaux faits dans son mécanisme de raisonnement, qui sont enregistrés dans la base de faits.

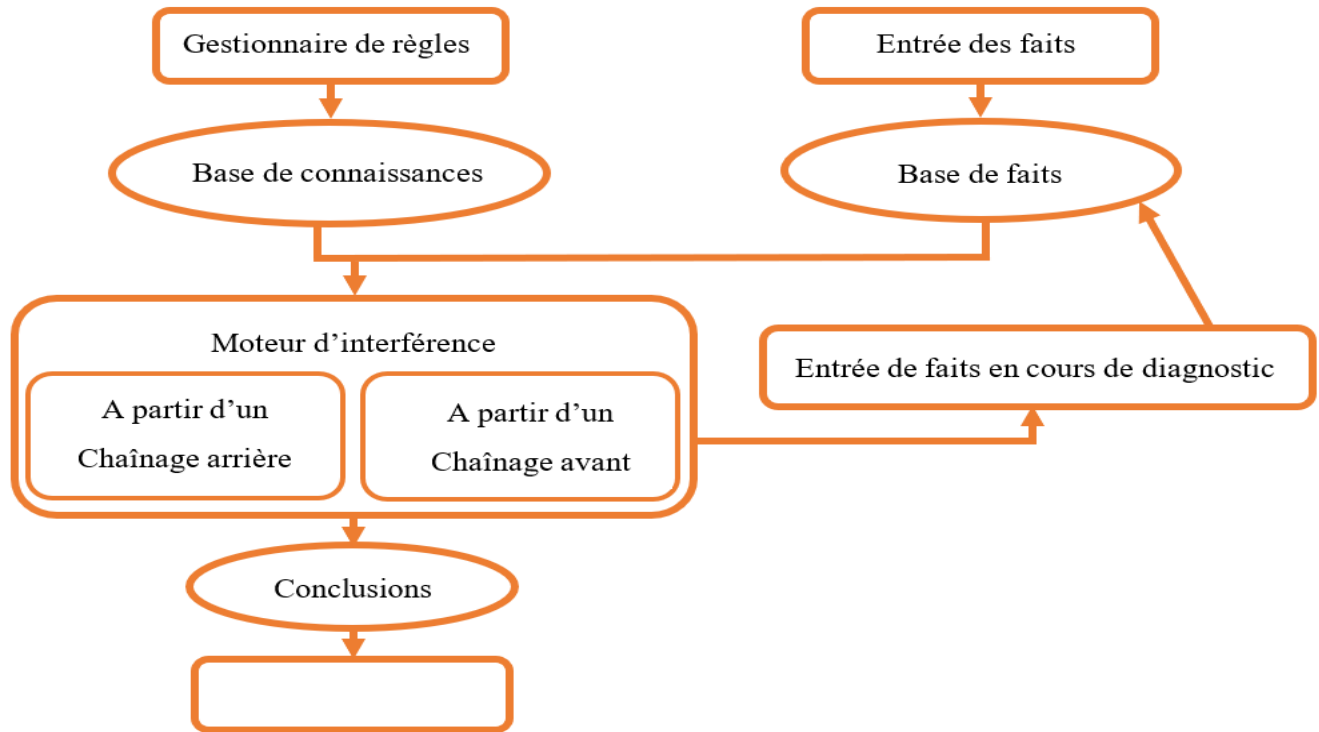


Figure I.6 : Architecture générale d'un système expert de diagnostic

I.5.2.3 Diagnostic par logique floue

Pour tenir compte de l'imprécision, l'idée de sous-ensemble flou a été proposée. La fonction d'appartenance d'un ensemble flou accepte des valeurs comprises entre « 0 et 1 ». Celles-ci représentent le degré d'appartenance d'un élément à cet ensemble : « 0 » dénote une non-appartenance stricte et « 1 » dénote une appartenance stricte. [22].

Le principe de fonctionnement du diagnostic basé sur la logique floue est d'extraire et de calculer des signaux d'entrée à l'aide de règles linguistiques représentées sous la forme de fonctions d'appartenance ; ces règles peuvent décrire tous les modèles de comportement possibles correspondant aux différentes manifestations du défaut considéré. [23, 21].

De manière générale, le fonctionnement d'un système flou se décompose en trois étapes :

- ✚ La fuzzification ;
- ✚ L'inférence ;
- ✚ La défuzzification.

L'étape de fuzzification implique généralement un traitement de base des données ; ces données sont ensuite manipulées par des règles linguistiques, qui imposent leur description par des fonctions d'appartenance. La fuzzification donne un ensemble de variables floues reliées par un vecteur, qui sera présenté au niveau du bloc d'inférence.

Les valeurs des variables linguistiques du bloc d'inférence sont régies par de nombreuses règles qui doivent tenir compte du comportement statique et dynamique du système.

Dans l'étape finale, la valeur floue "linguistique" doit être changée en une valeur définie pour en déduire l'état du système ; cela se fait dans le bloc de défuzzification ; on trouve des implémentations de cette méthode pour le diagnostic des machines asynchrones dans [23, 21].

I.5.2.4 Diagnostic par réseaux de neurones artificiels

C'est l'une des méthodes de diagnostic externe ; elle utilise la catégorisation automatique des signaux et des formes [8, 24].

Les principes de fonctionnement des réseaux de neurones sont inspirés des processus du cerveau humain. De l'extérieur, le réseau neuronal apparaît comme une « boîte noire » qui reçoit les signaux d'entrée et fournit les réponses appropriées.

Les signatures sont fréquemment utilisées dans le diagnostic pour faire la distinction entre les conditions opérationnelles normales et pathologiques. Après avoir mémorisé et appris les différentes formes de signatures associées à un état spécifique, l'opérateur humain peut lire une nouvelle signature et identifier l'état de la machine. S'il connaît déjà la nouvelle signature, il devra l'interpréter et la mémoriser.

En général, l'ANN permet la reconstruction du processus de pensée humaine décrit ci-dessus.

Un réseau de neurones, quant à lui, se caractérise par [8, 25, 26] :

- ✚ La nature des cellules élémentaires qui le constituent (binaires ou continues) ;
 - ✚ L'architecture et le nombre des couches du réseau ;
 - ✚ La nature des connexions ;
 - ✚ Les méthodes d'apprentissage ;
-

- ✚ Les performances de classification ;
- ✚ Les mécanismes de mémorisation.

I.5.2.5 Diagnostic par l'arbre de décisions et forêt aléatoire (Random Forest)

✚ Arbre de décisions

Les arbres de décision sont une méthode qui s'est révélée particulièrement efficace dans de nombreuses applications, notamment les problèmes de régression et la classification supervisée, pour la prédiction d'une variable qualitative à l'aide de n'importe quel type de variable (qualitatif et/ou quantitatif). Cette polyvalence lui donne un avantage sur les autres techniques de classification.

Il s'agit d'une représentation graphique d'une technique de catégorisation qui permet une modélisation directe d'un phénomène mesuré. En effet, la procédure consiste à découper l'espace des facteurs explicatifs en groupes homogènes en posant une série de questions binaires (type oui/non) sur les caractéristiques de chaque échantillon.

Contrairement à de nombreux outils de classification, les arbres de décision sont extrêmement intuitifs et fournissent une représentation graphique pertinente et facile à lire d'un processus de classification particulier. Cette représentation graphique se présente sous la forme d'un arbre composé de feuilles terminales (classes individuelles) obtenues en suivant un chemin le long des nœuds, chaque nœud correspondant à une question binaire utilisant une variable du jeu de données. Pour obtenir une forêt aléatoire avec un pouvoir discriminant plus élevé, exécutez en parallèle un grand nombre d'arbres de décision créés au hasard avant de les calculer en moyenne [27].

I.6 Analyse des méthodes d'identification des défauts des machines asynchrones

I.6.1 Méthodes de diagnostic des défauts basées sur l'analyse spectrale des signaux

Le personnel de maintenance évalue une variété de signaux de machine pour dépanner une installation industrielle. En effet, l'évolution temporelle et le contenu spectral de ces signaux permettent de détecter et de trouver des anomalies perturbant le bon fonctionnement de la machine. Selon la littérature, voici les principales approches de diagnostic utilisées pour obtenir des informations sur l'état de santé de la machine : [28].

I.6.1.1 Diagnostic par mesure des vibrations mécaniques

La méthode la plus couramment utilisée dans la pratique est le diagnostic des pannes à l'aide de vibrations mécaniques. Les vibrations dans la machine asynchrone sont provoquées par les efforts radiaux induits par le

champ d'entrefer. Ces forces sont proportionnelles au carré de l'induction magnétique.

$$\sigma(\theta, t) = \frac{B_s^2(\theta, t)}{2\mu_0} \quad (\text{I.1})$$

Le produit de FMM « F_m » et de la perméance « P » donne la distribution de l'induction magnétique dans l'entrefer.

$$B = F_m \cdot P \quad (\text{I.2})$$

La force magnétomotrice intègre les effets des asymétries du stator ou du rotor, et la perméance est affectée par les variations de l'entrefer « dues aux ouvertures des encoches du stator et du rotor et à l'excentricité ». En conséquence, l'analyse spectrale des signaux de vibration mécanique permet la détection de défauts électriques et mécaniques. Les spectres des signaux vibratoires du moteur défectueux sont comparés à ceux obtenus lorsque le moteur est en bon état de fonctionnement. Les accéléromètres détectent les vibrations de la machine. [28].

I.6.1.2 Diagnostic par mesure du flux magnétique axial de fuite

Dans une machine idéale et sans défaut, les courants et tensions statoriques sont équilibrés, annulant le flux de fuite axial. Toute défaillance génère un déséquilibre électrique et magnétique au niveau du stator, entraînant des flux de fuites axiaux dont les valeurs dépendent de la gravité du défaut. Une bobine enroulée autour de l'arbre de la machine servira de siège à une force électromotrice induite. L'analyse spectrale de la tension créée dans cette bobine peut être utilisée pour détecter divers défauts [28].

I.6.1.3 Diagnostic par l'analyse des tensions statoriques induites

Une nouvelle technique de détection des pannes de rotor dans les machines asynchrones a été développée. Cette technique est basée sur l'exploitation du contenu fréquentiel de la tension induite dans les enroulements statoriques par le flux rotorique lors de la déconnexion du moteur de réseau. La tension créée dans les enroulements du stator est directement affectée par la rupture d'une barre. Cette méthode évite les impacts de la non-idéalité de la source « déséquilibres et présence d'harmoniques » ainsi que la non-linéarité des propriétés magnétiques de la machine. [28].

I.6.1.4 Diagnostic par mesure du couple électromagnétique

Cette approche détecte à la fois les défaillances du rotor et les problèmes de court-circuit entre les spires des bobines du stator. Le couple électromagnétique produit par les machines électriques résulte de l'interaction des

champs du stator et du rotor. Par conséquent, tout défaut du stator ou du rotor a un effet direct sur le couple électromagnétique. L'analyse spectrale du signal de couple « mesuré ou estimé » renseigne sur l'état du moteur. [28].

I.6.1.5 Diagnostic par mesure de la puissance instantanée

De nombreuses études ont été menées sur l'utilisation de la puissance instantanée pour la détection de défauts dans les dispositifs asynchrones. La puissance instantanée est le produit des courants et des tensions dans chacune des trois phases du stator. Par conséquent, le niveau d'information fourni par cette grandeur est supérieur à celui fourni par le contenu d'une seule phase. Cette stratégie offre un avantage sur les autres [28].

I.6.1.6 Diagnostic à partir du vecteur de Park

Il convient de noter que le modèle bidimensionnel peut être utilisé pour décrire le phénomène des harmoniques dans le spectre. L'un des plus reconnus et des plus appropriés et employés par le vecteur Park « $I_d(t), I_q(t)$ » en fonction des courants de phase « $I_{as}, I_{bs}, et I_{cs}$ » est le suivant :

$$\begin{cases} I_d(t) = \sqrt{\frac{2}{3}} \cdot i_{as}(t) - \frac{1}{\sqrt{6}} \cdot i_{bs}(t) - \frac{1}{\sqrt{6}} \cdot i_{cs}(t) \\ I_q(t) = \frac{1}{\sqrt{2}} \cdot i_{bs}(t) - \frac{1}{\sqrt{2}} \cdot i_{cs}(t) \end{cases} \quad (I.3)$$

Il sera simple de construire les graphes « $I_d(t)$ » en fonction de « $I_q(t)$ » pour un fonctionnement sain, où le vecteur courant dessine un cercle, et pour un fonctionnement défectueux, lorsque le vecteur dessine une éclipse.

Lorsque les courants d'alimentation sont tous d'ordre positif, le vecteur Park aura les composantes suivantes :

$$\begin{cases} I_d(t) = \frac{\sqrt{6}}{2} \cdot I \sin(\omega t) \\ I_q(t) = \frac{\sqrt{6}}{2} \cdot I \sin(\omega t - \frac{\pi}{2}) \end{cases} \quad (I.4)$$

Avec :

I : la valeur maximale du courant direct ;

ω : la pulsation angulaire de l'alimentation.

Étant donné que le courant d'alimentation incorpore d'autres composants, tels que le composant inverse, les équations (I.3) et (I.4) ne sont plus valables dans des conditions déséquilibrées. Le module du vecteur courant

de Park change suite à un défaut de la machine [28]. Il est cependant crucial de noter que l'intérêt du vecteur de Park n'est plus dans l'étude du défaut de court-circuit à partir du changement des formes, mais plutôt dans son application pour arriver au spectre où les composantes directes et inverse apparaissent indépendamment les unes aux autres. Le courant de stator peut également être utilisé pour représenter visuellement les différentes signatures dans le spectre de courant.

I.6.1.7 Diagnostic par mesure du courant statorique

Parmi tous les signaux utilisables, le courant statorique s'est avéré être l'un des plus intéressants car il est très facile d'accès et permet de détecter aussi bien des défauts électromagnétiques que purement mécaniques. Dans la littérature, cette technique est connue sous le nom de « **Motor Current Signature Analysis** » (MCSA). Les défauts de la machine asynchrone se reflètent dans le spectre du courant statorique [28, 29].

- ✚ L'apparition des raies spectrales dont les fréquences sont directement liées à la fréquence de rotation de la machine, aux fréquences des champs tournants et aux paramètres physiques de la machine « nombre d'encoche rotorique et nombre de paires de pôles » ;
- ✚ La modification de l'amplitude des raies spectrales, déjà présentes dans le spectre du courant.

La surveillance par courant statorique nécessite une connaissance approfondie des problèmes et de leurs signatures.

I.7 Signatures spectrales des défauts dans le spectre du courant statorique

I.7.1 Défauts statoriques

Le défaut le plus courant du stator est la mise en court-circuit d'une ou plusieurs spires de son bobinage ; la fréquence caractéristique de ce défaut est :

$$f_{cs} = f_s \cdot \left[\frac{n}{p} (1 - g) \pm k \right] \quad (I.5)$$

Avec : $n = 1, 2, 3, \dots$ et $k = 1, 3, 5, \dots$

I.7.2 Défauts rotoriques

L'analyse du spectre de courant de stator en régime permanent révèle des problèmes de rotor tels que des barres cassées, des anneaux de court-circuit ou l'excentricité de l'entrefer.

I.7.3 Cassure des barres rotoriques

L'existence de barres de rotor cassées provoque une asymétrie du rotor, ce qui se traduit par des raies spectrales autour de la fréquence fondamentale « f_s » telles que :

$$f_{brc} = f_s \cdot (1 \pm 2kg) \quad (I.6)$$

L'amplitude de ces composantes spectrales est proportionnelle à la sévérité du défaut.

I.7.4 Excentricité d'entrefer

Les défauts mécaniques se manifestent typiquement au niveau de l'entrefer par des défauts d'excentricité. L'excentricité d'une machine électrique est un phénomène qui évolue dans le temps et se produit dès sa construction. Dans les machines électriques, un certain degré d'excentricité est normal.

Les fabricants et les utilisateurs définissent un niveau maximum autorisé de "5 %", alors que dans d'autres circonstances, un niveau maximum de "10 %" de la largeur de d'entrefer est tolérée. Il existe trois types d'excentricité :

✚ L'excentricité statique

Dans la plupart des cas, cela est dû à un désalignement de l'axe de rotation par rapport à l'axe du stator. Elle est causée par une erreur de centrage des flasques « figure I.7.b » et apparaît même sur des machines de fabrication récente en raison des processus de fabrication et d'assemblage [30].

✚ L'excentricité dynamique

L'excentricité de ce type est induite par la distorsion du cylindre du rotor, la déformation du cylindre du stator ou la dégénérescence du roulement à billes. Il correspond au décalage du centre de rotation du rotor par rapport au centre géométrique du stator, ainsi qu'à une rotation du centre du rotor autour du centre géométrique de ce stator (figure I.7.c).

✚ L'excentricité mixte

En pratique, excentricité statique et dynamique coexistent. Même dans les machines de fabrication modernes, un niveau inhérent d'excentricité statique se produit. Cela se traduit par des forces d'attraction magnétique régulières non compensées dans une direction, ce qui peut entraîner une flexion de l'arbre et une dégradation des roulements au fil du temps, initiant ainsi une excentricité dynamique. Sans diagnostic précoce,

l'excentricité devient suffisamment élevée pour produire des forces radiales déséquilibrées susceptibles de provoquer des frottements entre le stator et le rotor, entraînant une défaillance catastrophique de la machine électrique.




Figure I.7 : Types d'excentricité : (a) rotor concentré ; (b) Excentricité statique
(c) Excentricité dynamique [31]

$$f_{exc} = f_s \cdot \left[1 \pm k \frac{(1-g)}{p} \right] \quad (I.7)$$

Avec : $k = 1, 2, 3, \dots$

Les excentricités peuvent également être détectées en surveillant les harmoniques principales d'encoches de courant ainsi que certaines de leurs composantes latérales du spectre. Le nombre d'encoches de rotor « N_e » doit être connu pour cette procédure. Les fréquences des composantes spectrales de l'encoche et celles liées à l'excentricité dynamique de l'entrefer sont les suivantes :

$$f_{enc+exc} = f_s \cdot \left[(kN_e \pm n_d) \frac{(1-g)}{p} \pm n_w \right] \quad (I.8)$$

Avec :

$n_d = 0$, dans le cas d'une excentricité statique ;

$n_d = 1$, dans le cas d'une excentricité dynamique ;

N_e : est le nombre d'encoches rotoriques ;

$k = 1, 2, 3, \dots$;

$n_w = 1, 3, 5, 7 \dots$; (l'ordre de l'harmonique de la FMM du rotor).

L'existence d'une excentricité statique modifie l'amplitude des harmoniques principales d'encoches de courant statoriques, mais la présence d'une excentricité dynamique fait apparaître de nouvelles raies spectrales.

I.7.5 Défauts au niveau des roulements

Étant donné que les pièces roulantes du roulement supportent le rotor, tout problème dans les roulements entraînera des mouvements radiaux entre le rotor et le stator de la machine. En conséquence, les vibrations de l'entrefer produisent des raies spectrales de fréquence dans le courant du stator :

$$f_{roul} = |f_s \pm kf_V| \tag{I.9}$$

D'où :

$$k = 1, 2, 3, \dots ;$$

f_V : est l'une des fréquences caractéristiques des vibrations « f_b , $f_{b.int}$ ou $f_{b.ext}$ ».

La fréquence caractéristique des vibrations est liée aux propriétés physiques du roulement et dépend de l'élément du roulement affecté par le défaut (figure I.8).




Figure I.8 : Vue éclatée des éléments constitutifs d'un roulement à billes

Les fréquences de vibration suivantes caractérisent les défauts des roulements à billes :

✚ Défaut de bille :

$$f_b = \frac{PD}{2 \cdot BD} \cdot f_{rot} \cdot \left[1 - \left(\frac{BD}{PD} \cdot \cos\beta \right)^2 \right] \tag{I.10}$$

✚ Défaut sur la bague intérieure :

$$f_{b.int} = \frac{n_b}{2} \cdot f_{rot} \cdot \left[1 + \frac{BD}{PD} \cdot \cos\beta \right] \tag{I.11}$$

✚ Défaut sur la bague extérieure :

$$f_{b.ext} = \frac{n_b}{2} \cdot f_{rot} \cdot \left[1 - \frac{BD}{PD} \cdot \cos\beta \right] \quad (I.12)$$

✚ Défaut sur la cage :

$$f_c = \frac{1}{2} \cdot f_{rot} \cdot \left[1 - \frac{BD}{PD} \cdot \cos\beta \right] \quad (I.13)$$

Avec :

n_b : le nombre d'éléments roulants ;

BD : le diamètre d'un élément roulant ;

PD : la distance entre les centres des billes diamétralement opposées ;

β : l'angle du contact des billes avec les bagues du roulement ;

f_{rot} : la fréquence de rotation du rotor.

Les fréquences de vibration peuvent être approchées pour des dimensions courantes, c'est-à-dire des billes de « 6 à 12 », par :

$$f_{b.int} = 0.6 n_b \cdot f_{rot} \quad (I.14)$$

$$f_{b.ext} = 0.4 n_b \cdot f_{rot} \quad (I.15)$$

I.8 Analyse critique des méthodes de diagnostic existantes

La grande diversité des technologies des systèmes industriels « mécaniques, thermiques, électriques, électroniques, numériques, etc. » exclut l'emploi d'une technique universelle avec tous les avantages et aucun inconvénient. Il n'existe pas de procédure de diagnostic industriel commune [32].

De plus, les systèmes de diagnostic étaient caractérisés par diverses limitations liées, entre autres, à l'emploi de la méthode de corrélation. C'est une approche de diagnostic interne qui permet la détection d'un défaut en comparant la signature observée avec la signature prédite à partir d'un modèle. Dans ce scénario, la détection est basée sur la valeur de la différence entre les deux signaux. Ceci complique la phase d'identification des pannes car les perturbations « ou modifications des paramètres de la machine » produisent des écarts très divers.

Dans cette circonstance, la prise de décision sur la présence d'une panne devient ambiguë, et le diagnostic qui doit être fait ne peut être exact. [33, 34, 35, 36].

Par contre, il faut souligner qu'une connaissance a priori du modèle spécifique de la machine asynchrone est nécessaire. De plus, avec le vieillissement et en fonction du climat « environnement », le modèle représentatif de fonctionnement de la machine asynchrone varie. Chose qui modifie les valeurs des grandeurs de ce dernier « signaux de référence », car les modèles actuels n'en tiennent pas compte.

De plus, dans la majorité des travaux publiés [15, 37, 38, 39, 40, 41, 42, 43, 44, 45, 46], une seule grandeur indiquant le défaut "le courant stator" a été utilisée, ce qui conduit à, dans certains cas, la similitude entre deux signaux de défaut différents ; cette situation est possible, notamment dans le cas de la détection de défauts dans le domaine fréquentiel [46]. De plus, du fait de la variété des « défauts statoriques, rotorique et d'alimentation » de la machine asynchrone, ils ne peuvent être obtenus par le même modèle mathématique. Chaque défaut est en effet modélisé indépendamment par son propre modèle [15, 47, 48, 49].

D'autres méthodes de diagnostic externe utilisent des approches automatiques pour détecter des éléments physiques en temps réel ou en temps différé. Les méthodes de diagnostic externe utilisent des « boîtes noires » entre les signatures associées aux causes et leurs effets [8, 23, 24].

Les systèmes experts sont des représentations informatisées du raisonnement d'un expert dans un domaine technique donné. A cet effet, on peut observer que ces systèmes d'aide au diagnostic peuvent modéliser de nombreuses formes de connaissances, à savoir :

- ✚ Les connaissances « surfaces » ;
- ✚ Les connaissances « profondes » ;
- ✚ Les connaissances « mixtes ».

L'analyse de l'application des systèmes d'aide au diagnostic dans différents secteurs industriels révèle que la majorité d'entre eux utilisent des systèmes experts, suivis par ceux basés sur la reconnaissance de formes [50, 51]. Cependant, il convient de mentionner que le développement d'un système de diagnostic basé sur des techniques de systèmes experts nécessite un effort important « pour sa conception et sa réalisation ». De plus, l'installation est d'un coût prohibitif [23]. Lorsque le problème à résoudre est trop complexe ou « difficile à analyser », la logique floue peut être utilisée pour remplacer les systèmes experts par des règles linguistiques. Ces principes sont préférables pour définir avec précision la nature des machines réelles, mais les formes et la quantité des fonctions d'appartenance doivent d'abord être déterminées à l'aide d'une grande base de données [21].

Etant donné que le but principal du système de diagnostic est de créer un catalogue de « défauts /symptômes », les classificateurs universels « réseaux de neurones et forêt aléatoire (RF) » apparaissent très

prometteurs pour la mise en œuvre de la méthode de diagnostic. [8, 23, 24, 52, 53].

De plus, les réseaux de neurones et les forêts aléatoires (RF) ont des propriétés qui leur permettent de résoudre des problèmes complexes, à savoir [23, 54] :

- ✚ La capacité de classer les signatures et les formes, ce qui est pertinent pour l'étude de cas dans cette thèse ;
- ✚ L'ANN peut apprendre des règles à partir d'instances (défauts), c'est-à-dire qu'on peut utiliser un ANN pour créer un modèle non paramétrique qui peut caractériser tous les états de la machine « fonctionnement normal et anormal », et ce modèle peut également généraliser son identification à des cas supplémentaires qui n'ont pas été apprises ;
- ✚ La possibilité de mémoriser des instances en les dispersant sur les poids de connexion de la structure, comme la perte d'un neurone ou d'un lien, n'a aucun effet sur la mémorisation des exemples.

Sur la base de l'étude critique des approches de diagnostics, il est évident que les méthodes internes « basées sur la modélisation physique ou fonctionnelle du procédé » ne peuvent bénéficier de modèles exacts pour les systèmes non linéaires « tels que la machine asynchrone ». En effet, cette stratégie ne peut s'appliquer avec succès qu'aux systèmes linéaires ou aux systèmes avec des modèles bien connus

I.9 Position du problème à résoudre

Suite à un examen approfondi de l'état de l'art, il a été découvert que :

- ✚ Les systèmes électromécaniques qui permettent le transfert de l'énergie électrique en énergie mécanique et le contrôle de l'énergie ainsi obtenue sont à l'origine « source » du mouvement nécessaire à l'exécution de toutes les opérations industrielles. Pour cela, ils consomment plus de 54% de la production mondiale d'énergie ;
- ✚ Les machines asynchrones, qui « représentent 98 % des moteurs utilisés dans le monde », sont les éléments les plus essentiels des systèmes électromécaniques puisqu'elles définissent en grande partie les indices énergétiques « rendement, pertes énergétiques, facteur de puissance, ... etc. » ;
- ✚ Selon des études statistiques, les pannes les plus courantes sont les pannes électriques (stator et rotor) qui représentent 70 à 80 % de l'ensemble des pannes ;
- ✚ Les courants statoriques, les tensions d'alimentation et la vitesse de rotation sont les paramètres les plus indicatifs des défauts électriques ;
- ✚ Des variations des valeurs et du contenu spectral des grandeurs indicatrices sont constatées en présence des

défaillances « reflétant le comportement de la machine en cas de défauts », permettant de considérer les signaux obtenus comme des signatures de référence, permettant de déterminer les types de pannes, être identifié dès leur apparition ;

- ✚ Les systèmes de diagnostic existants impliquent des approches internes et externes, et ils doivent détecter le défaut et identifier sa source afin de pouvoir l'isoler. Pour cela, le système de diagnostic doit : interférer le moins possible avec le système électromécanique, être capable de surveiller et de stocker toutes les données relatives aux valeurs des indicateurs, et être évolutif et contrôlable à distance ;
- ✚ La démarche diagnostique doit permettre de comparer le comportement sain (ou son modèle) avec le comportement du processus défaillant afin de déterminer le type de défaut et son origine ;
- ✚ L'examen des avantages et des inconvénients de diverses méthodes de diagnostic : internes « méthodes du modèle, de redondances, ... etc. » ainsi, externes « réseaux de neurones, forêt aléatoire (RF), système expert et logique floue » permet de conclure que la méthode basée sur les réseaux de neurones artificiels et forêt aléatoire (RF) est la plus rationnelle pour la classification des signaux caractéristiques des défaillances des systèmes électromécaniques en général ;
- ✚ Les failles suivantes ont été découvertes dans les méthodes de reconnaissance des défauts électriques « stator et rotor » des machines asynchrones :
 1. L'insuffisance de l'utilisation de la théorie des champs et des modèles multi-enroulements pour analyser les harmoniques des grandeurs indicatrices (courant, vitesse et couple) ;
 2. Des modèles inexacts sont utilisés ;
 3. Le nombre de modèles doit être multiplié ;
 4. Le vieillissement de la machine n'est pas pris en compte ;
 5. L'utilisation d'un seul indicateur diminue la confiance.
- ✚ Les solutions de diagnostic basées sur les systèmes experts et la logique floue sont compliquées à développer et coûteuses.

I.10 Conclusion

À la suite de ce qui a été mentionné, nous avons présenté dans ce chapitre des composants génériques relatifs à la sûreté de fonctionnement dans les systèmes de génie électrique. Parmi les composants les plus courants de ces systèmes figurent les machines électriques. Compte tenu des diverses formes de pannes qu'ils peuvent avoir, les équipements de surveillance de leur santé revêtent une importance particulière pour les constructeurs et les exploitants. Un certain nombre de méthodes de surveillance et de diagnostic pour ce type de problème ont également été mentionnées.

Dans notre travail, nous nous focaliserons plus particulièrement sur le développement d'un système intelligent de diagnostic et de surveillance « détecter et localiser » automatiquement en temps réel, les défaillances mécaniques et plus spécifiquement encore sur les défauts relatifs aux barres rotoriques cassées de la MAS, en utilisant les réseaux de neurones artificiels et la forêt aléatoire (RF). Une multitude des grandeurs indicatrices extrait du courant statorique « I_{as} » par des paramètres statistiques et des paramètres fréquentielles « transformée en paquet d'ondelette » va adopter.

Pour réaliser cette surveillance de défaut des barres rotoriques cassées, il faut tout d'abord fournir un modèle adéquat qui les prend en considération. Pour cela on a fait l'appel d'un modèle multi-enroulement qu'on va l'aborder au chapitre suivant « Modèle dédié à la simulation des défauts rotorique de la machine asynchrone ».

Chapitre II

Modèle dédié à la simulation des défauts rotorique de la machine asynchrone

II.1 Introduction

La machine asynchrone ou à induction, est actuellement la machine électrique dont l'usage est la plus répandue dans l'industrie particulièrement en fonctionnement moteur. Son principal avantage réside dans l'absence de contacts électriques glissants, ce qui conduit à une structure simple, robuste et facile à construire. Relié directement au réseau industriel à tension et à fréquence constantes, tourne à vitesse peu différente de la vitesse de synchronisme ; il peut être utilisé aussi pour la réalisation de la quasi-totalité des entraînements à vitesse constantes. Il permet aussi la réalisation d'entraînements à vitesses variables, donc sa place qu'il occupe dans ce domaine ne cesse de croître.

De plus, malgré ses avantages, le moteur asynchrone pourrait présenter des défauts structurels. Dans ce chapitre, nous nous intéressons aux défauts de barre rotorique de type rupture (figure II.1). Pour cela, un modèle mathématique prenant en compte la structure du rotor doit être créé.



Figure II.1 : Défaut de rupture de barres [55]

En effet, les principales approches de modélisation de la machine asynchrone pour son diagnostic impliquent :

- ✚ La création des équations de Maxwell, qui prennent en compte les qualités géométriques de la machine et les propriétés magnétiques des matériaux, constitue le fondement de la théorie des champs électromagnétiques, qui utilise l'approche par éléments finis en conjonction avec des modèles d'espace d'état. Cette méthode a l'avantage de simuler avec précision la saturation magnétique, qui est généralement ignorée dans d'autres modèles ;

- ✚ Dans la théorie des circuits électriques, qui est basée sur les équations de Kirchhoff, avec l'utilisation de l'approche multi-circuits à couplage magnétique permet de prendre en compte les défaillances du stator et/ou du rotor dans le modèle ;
- ✚ Relatif au modèle triphasé/triphasé de la machine, qui est utilisé pour l'identification des défauts du type de stator. De très nombreuses études ont été réalisées dans ce domaine du diagnostic. [56, 57, 58, 59, 60, 61, 62, 63].

La modélisation de la machine est donc une étape cruciale dans la construction des règles de commande, l'observation et l'analyse des nombreuses évolutions de ses variables électromécaniques.

Dans ce chapitre, on considère la modélisation par des circuits électriques multi-enroulements couplés magnétiquement avec une alimentation directe au réseau électrique.

II.2 Modèle multi-enroulements de la machine asynchrone

Un modèle du rotor est établi sous forme de mailles reliées électriquement entre elles et couplées magnétiquement, où une maille est constituée de deux barres et deux portions d'anneaux qui les relie, afin de pouvoir se focaliser sur l'étude de la simulation des défauts de type rupture de barre (figure II.2). La résistance et l'inductance sont les caractéristiques déterminantes de chaque section de barre et d'anneau [62].

II.2.1 Hypothèses de départ

L'objectif principal de cette simulation est de montrer comment les défauts de rupture de barre rotorique affectent les grandeurs temporelles de la machine asynchrone, telles que ses « courants, vitesse, couple, etc. ». Pour ce faire, il est indispensable de poser certaines hypothèses simplificatrices qui ont pour but de faciliter la mise en équations des circuits électriques de la machine. Dans le modèle utilisé, nous avons supposé la linéarité du circuit magnétique (perméabilité relative du fer très grande devant « 1 »). Nous avons pu appliquer l'idée d'une inductance propre et mutuelle entre les enroulements du stator et du rotor grâce à cette hypothèse. La saturation du circuit magnétique n'est pas considérée, ni son hystérésis, ce qui entraîne un champs magnétique sinusoïdal. On suppose que la construction mécanique est parfaitement équilibrée, l'entrefer est lisse, et la dispersion du champ magnétique aux deux bouts de la machine est négligeable. L'effet de peau a été négligé. Nous avons supposé que les barres rotoriques étaient isolées les unes aux autres ce qui permet d'éliminer les courants inters-barres et leurs effets au sein même de la cage rotorique. De plus, les pertes fer de la machine, les effets capacitifs et les effets thermiques ont été négligés dans la construction du modèle de la machine asynchrone à cage d'écureuil.




Figure II.2 : Structure du rotor de la MAS [62]

II.3 Calcul des inductances

La machine étudiée possède un stator triphasé. Plusieurs bobines situées dans les encoches du stator forment une phase du stator. Le positionnement de ces bobines est destiné à produire une force magnétomotrice la plus sinusoïdale possible le long de l'entrefer [64].

II.3.1 Inductances statoriques

Commençons par supposer que l'induction qui en résulte est sinusoïdale. Dans ce cas, l'expression FMM de la phase statorique « a » sera [64, 62] :

$$F_m(\theta) = \frac{2 \cdot N_s \cdot i_{sa}}{p \cdot \pi} \cdot \cos(p \cdot \theta) \tag{II.1}$$

Avec :

θ : angle électrique décrivant une position dans l'espace.

Le fondamental est fourni par la décomposition de l'induction en séries de Fourier :

$$B_s(\theta) = \frac{2 \cdot \mu_0 \cdot N_s \cdot i_{sa}}{e \cdot p \cdot \pi} \cdot \cos(p \cdot \theta) \tag{II.2}$$

En intégrant l'expression suivante (II.2), on peut déterminer le flux magnétique par pôles dans l'entrefer :

$$\Phi_s = \iint_S B_s ds = \int_0^1 dz \int_{-\frac{\pi}{2p}}^{\frac{\pi}{2p}} B_s \cdot R \cdot l \cdot d\theta \quad (\text{II.3})$$

On obtient :

$$\Phi_s = \frac{4 \cdot \mu_0 \cdot N_s \cdot R \cdot l}{\pi \cdot e \cdot p^2} \cdot i_{sa} \quad (\text{II.4})$$

Le flux magnétique total causé par le courant « i_{sa} » traversant l'enroulement de la phase « a » est le suivant :

$$\Psi_{saT} = N_s \cdot \Phi_s = N_s \cdot i_{sa} \cdot \frac{2 \cdot \mu_0 \cdot N_s \cdot R \cdot l}{\pi \cdot e \cdot p^2} \cdot \int_{-\frac{\pi}{2p}}^{\frac{\pi}{2p}} \cos(\theta) \cdot d\theta = L_{sp} \cdot i_{sa} \quad (\text{II.5})$$

Par conséquent, l'équation suivante donne l'inductance « magnétisante » principale de la phase statorique « a » :

$$L_{sp} = L_{ms} = \frac{4 \cdot \mu_0 \cdot N_s^2 \cdot R \cdot l}{\pi \cdot e \cdot p^2} \quad (\text{II.6})$$

L'inductance totale « propre » de la phase « a », est la somme de l'inductance de magnétisation et de fuite :

$$L_{as} = L_{sp} + L_{sf} \quad (\text{II.7})$$

Les inductances propres des trois phases sont donc équivalentes car les enroulements statoriques sont supposés symétriques :

$$L_{as} = L_{bs} = L_{cs} = L_s \quad (\text{II.8})$$

Entre les phases du stator, il existe une inductance mutuelle qui est déterminée par :

$$M_s = -\frac{L_{sp}}{2} \quad (\text{II.9})$$

II.3.2 Inductances rotoriques

Le rotor est divisé en simples circuits « maillés » constitués de deux barres et de deux segments d'anneaux les joignant à chaque extrémité [62]. L'expression des différentes inductances peut être donnée en précisant les flux rotoriques concernés et en utilisant la représentation équivalente du rotor. L'allure de l'inductance magnétique dans l'entrefer supposé radiale, produite par la maille de rotor « k », est représentée sur la figure (II.3) en fonction de « θ » dans un repère relié au rotor.

Sous l'hypothèse que les barres du rotor sont similaires, périodiquement espacées par un angle :

$$\alpha = \frac{2\pi}{N_r}; [rad].$$




Figure II.3 : Induction magnétique produite par une maille rotorique

Chaque maille de rotor est considérée comme une bobine à une seule spire, parcourue par un courant « i_{rk} » représente l'emplacement du flux principal tel que décrit par :

$$\Phi_{rk} = \int_0^l dz \int_{k\alpha}^{(k+1)\alpha} \left(\frac{(N_r-1)}{N_r} \cdot \frac{\mu_0}{e} \cdot R \cdot i_{rk} \right) d\theta = \frac{(N_r-1)}{N_r^2} \cdot \mu_0 \cdot \frac{2\pi \cdot R \cdot l}{e} \cdot i_{rk} \quad (\text{II.10})$$

Après cela, l'inductance principale d'une maille rotorique est alors donnée par :

$$L_{rp} = \frac{(N_r-1)}{N_r^2} \cdot \mu_0 \cdot \frac{2\pi \cdot R \cdot l}{e} \quad (\text{II.11})$$

L'inductance totale de la « $k^{\text{ème}}$ » maille de rotor est la somme de son inductance principale, des inductances de fuite des deux barres et des inductances de fuite des deux segments d'anneaux de court-circuit fermant la maille « k ». L'expression est ainsi fournie par [63].

$$L_{rr} = L_{rp} + 2L_b + 2L_e \quad (\text{II.12})$$

Le flux du rotor à entrefer relie magnétiquement les mailles du rotor. Le courant « i_{rk} » circulant dans la maille « k » produit le flux qui traverse la maille « $j^{\text{ème}}$ », et il est représenté par :

$$\Phi_{rjrk} = \int_0^l dz \int_{j\alpha}^{(j+1)\alpha} \left(-\frac{1}{N_r} \cdot \frac{\mu_0}{e} \cdot R \cdot i_{rk} \right) d\theta \quad (\text{II.13})$$

L'équation suivante représente l'inductance mutuelle entre des mailles de rotor non adjacentes :

$$M_{rr} = -\frac{1}{N_r^2} \cdot \frac{2\pi \cdot \mu_0}{e} \cdot R \cdot l \quad (\text{II.14})$$

L'équation suivante décrit l'inductance mutuelle entre la « k^{ème} » maille et les mailles voisines :

$$M_{rk(k-1)} = M_{rk(k+1)} = M_{rr} - L_b \quad (\text{II.15})$$

II.3.3 Inductance mutuelle stator/rotor

L'équation suivante décrit l'induction produite par une bobine de la phase « n » dans la « k^{ème} » maille rotorique :

$$B_s(\theta) = \frac{2 \cdot \mu_0 \cdot N_s \cdot i_{sa}}{\pi \cdot e \cdot p} \cdot \cos\left(p \cdot \theta - n \cdot \frac{2\pi}{3}\right) \quad (\text{II.16})$$

Avec :

$$n = \{0, 1, 2\}.$$

Le courant « i_{sa} » produit un flux qui traverse la maille « k » qui est représenté par l'équation suivante :

$$\Phi_{rksa} = \int_0^l dz \int_{k\alpha}^{(k+1)\alpha} B_s(\theta) \cdot R \cdot l \cdot d\theta \quad (\text{II.17})$$

Le résultat de l'intégrale de l'équation (II.17) est :

$$\Phi_{rksa} = -\frac{2 \cdot \mu_0 \cdot N_s \cdot R \cdot l}{\pi \cdot e \cdot p^2} \cdot i_{sa} \cdot \left[\sin\left(p \cdot \theta - n \cdot \frac{2\pi}{3}\right) \right]_{k\alpha}^{\alpha(k+1)} \quad (\text{II.18})$$

Ainsi, l'expression suivante représente la mutuelle inductance entre la maille « k » et la phase « a » :

$$M_{rksa} = -M_{sr} \cdot \cos\left(p \cdot \theta - n \cdot \frac{2\pi}{3} + k\alpha\right) \quad (\text{II.19})$$

Avec :

$$M_{sr} = \frac{4 \cdot \mu_0 \cdot N_s \cdot R \cdot l}{\pi \cdot e \cdot p^2} \cdot \sin\left(\frac{\alpha}{2}\right) \quad \text{et} \quad \alpha = p \cdot \frac{2\pi}{N_r}$$

α : angle électrique entre deux mailles rotoriques.

Les inductances mutuelles entre les phases « b », « c » et la « k^{ème} » maille s'expriment de la même manière :

$$\begin{cases} M_{rksb} = M_{sr} \cos \left(\omega t + k \cdot \alpha - \frac{2\pi}{3} \right) \\ M_{rksc} = M_{sr} \cos \left(\omega t + k \cdot \alpha - \frac{4\pi}{3} \right) \end{cases} \quad (\text{II.20})$$

Les expressions de chaque inductance de la MAS sont répertoriées dans le tableau suivant.

Tableau II.1 : Inductances de la MAS

Inductances	Expressions
Inductance principale d'une phase statorique	$L_{sp} = L_{ms} = \frac{4 \cdot \mu_0 \cdot N_s^2 \cdot R \cdot l}{\pi \cdot e \cdot p^2}$
Inductance principale entre phases statoriques	$M_s = -\frac{L_{sp}}{2}$
Inductance totale d'une phase statorique	$L_{as} = L_{bs} = L_{cs} = L_s = L_{sp} + L_{sf}$
Inductance principale d'une maille rotorique	$L_{rp} = \frac{(N_r - 1)}{N_r^2} \cdot \mu_0 \cdot \frac{2 \cdot \pi \cdot R \cdot l}{e}$
Inductance mutuelle entre mailles rotoriques non adjacentes	$M_{rr} = -\frac{1}{N_r^2} \cdot \frac{2 \cdot \pi \cdot \mu_0}{e} \cdot R \cdot l$
Inductance mutuelle entre mailles rotoriques adjacentes	$M_{rk(k-1)} = M_{rk(k+1)} = M_{rr} - L_b$
Inductance mutuelle entre une maille rotorique et une phase statorique « a »	$M_{rksa} = -M_{sr} \cdot \cos \left(p \cdot \theta - n \cdot \frac{2\pi}{3} + k\alpha \right)$ Avec : $M_{sr} = \frac{4 \cdot \mu_0 \cdot N_s \cdot R \cdot l}{\pi \cdot e \cdot p^2} \cdot \sin \left(\frac{\alpha}{2} \right)$

II.4 Mise en équations

Afin de réaliser une simulation numérique du modèle de la MAS tenant compte des diverses inductances rotoriques. Les équations doivent être simples que possible mais il faut prendre en compte les défauts sans que cela ne nécessite de reformuler systématiquement toute la mise en équation de la machine et de son environnement. En étudiant la topologie du circuit électrique, on recherche alors l'ensemble des équations différentielles indépendantes guidant l'évolution des courants, ce qui nous amène à la forme classique [60] :

$$\frac{d[I]}{dt} = -[L]^{-1} \cdot [R] \cdot [I] + [L]^{-1} \cdot [V] \quad (\text{II.21})$$

les grandeurs statoriques triphasées « a, b, c » sont transformées en grandeurs diphasiques « α, β » en utilisant la transformation de Clarke. Le stator et le rotor peuvent fonctionner chacun dans un repère distinct tout au long de la simulation. Afin de minimiser le temps de calcul, on supprime l'angle « θ » de la matrice de couplage par le choix du repère rotorique.

Dans ce repère, toutes les grandeurs ont une pulsation « $g \cdot \omega_s$ » en régime permanent. Cette caractéristique peut être utilisée des défauts de type rupture de barres rotoriques dans la machine par l'observation du courant « I_{as} » [62].

Par conséquent, nous recherchons les équations différentielles indépendantes qui définissent le modèle de la MAS.

II.4.1 Equations de tensions au stator

On arrive aux équations de tensions et de flux sous forme matricielle pour chaque phase du stator :

$$[V_{abcS}] = [R_s][I_{abcS}] + \frac{d}{dt}[\phi_{abcS}] \quad (\text{II.22})$$

$$[\phi_{abcS}] = [L_s][I_{abcS}] + [M_{sr}][I_{rk}] \quad (\text{II.23})$$

Avec :

$[V_{abcS}] = [V_{as} \ V_{bs} \ V_{cs}]^T$: vecteur des tensions statoriques ;

$[I_{abcS}] = [I_{as} \ I_{bs} \ I_{cs}]^T$: vecteur des courants statoriques ;

$[I_{rk}] = [I_{r0} \ I_{r1} \ \dots \ I_{rk} \ \dots \ I_{r(N_r-1)}]^T$: vecteur des courants dans les mailles rotoriques ;

$[\phi_{abcS}] = [\phi_{as} \ \phi_{bs} \ \phi_{cs}]^T$: vecteur des flux statoriques

En conséquence, nous écrivons les matrices des résistances, les inductances et mutuelles statoriques respectivement :

$$[R_s] = \begin{bmatrix} R_s & 0 & 0 \\ 0 & R_s & 0 \\ 0 & 0 & R_s \end{bmatrix} \quad (\text{II.24})$$

$$[L_S] = \begin{bmatrix} L_S & M_S & M_S \\ M_S & L_S & M_S \\ M_S & M_S & L_S \end{bmatrix} \quad (II.25)$$

$$[M_{sr}] = \begin{bmatrix} \dots & -M_{sr} \cos(\theta + k\alpha) & \dots \\ \dots & -M_{sr} \cos\left(\theta + k\alpha - \frac{2\pi}{3}\right) & \dots \\ \dots & -M_{sr} \cos\left(\theta + k\alpha - \frac{4\pi}{3}\right) & \dots \end{bmatrix} \quad (II.26)$$

Avec :

$K = 0, 1, 2, \dots, (N_r - 1)$; où : N_r : nombre des barres rotoriques.

A partir de la matrice de transformation de Park et sachant que la composante homopolaire est nulle, on peut réaliser le passage aux composantes diphasées des composants statoriques (Figure II.4) :




Figure II.4 : Modèle de la MAS après transformation de Park

Donc :

$$[X_{\alpha\beta s}] = [P(\theta)][X_{dqs}] \quad (II.27)$$

Avec :

$$P(\theta_s) : \text{matrice de rotation de Park définie comme suit : } P(\theta_s) = \begin{bmatrix} \cos(\theta_s) & -\sin(\theta_s) \\ \sin(\theta_s) & \cos(\theta_s) \end{bmatrix}$$

Et : $\theta_s = \theta$; (orientation vers le repère rotorique)

Donc :

$$\Phi_{\alpha\beta s} = \begin{bmatrix} L_{sc} & 0 \\ 0 & L_{sc} \end{bmatrix} \cdot [I_{\alpha\beta s}] - M_{sr} \cdot \begin{bmatrix} \dots \cos(\theta + k\alpha) \dots \\ \dots \sin(\theta + k\alpha) \dots \end{bmatrix} \cdot [I_{rk}] \quad (\text{II.28})$$

Avec :

$$L_{sc} = L_{sp} - M_s + L_{sf}$$

Où :

L_{sp} : l'inductance principale ;

M_s : la mutuelle entre deux enroulements statoriques ;

L_{sf} : l'inductance de fuite.

En conséquence, le flux et la tension statorique dans le repère de Park « d, q » sont représentés comme suit :

$$\Phi_{dqs} = \begin{bmatrix} L_{sc} & 0 \\ 0 & L_{sc} \end{bmatrix} \cdot [I_{dqs}] - M_{sr} \cdot \begin{bmatrix} \dots \cos(k\alpha) \dots \\ \dots \sin(k\alpha) \dots \end{bmatrix} \cdot [I_{rk}] \quad (\text{II.29})$$

$$V_{dqs} = R_s \cdot I_{dqs} + \omega \cdot P \left(\frac{\pi}{2} \right) \cdot \Phi_{dqs} + \frac{d}{dt} \Phi_{dqs} \quad (\text{II.30})$$

Les équations électriques suivantes sont exprimées dans le repère rotor après transformation et rotation :

$$\begin{bmatrix} V_{ds} \\ V_{qs} \end{bmatrix} = \begin{bmatrix} R_s & 0 \\ 0 & R_s \end{bmatrix} \cdot \begin{bmatrix} I_{ds} \\ I_{qs} \end{bmatrix} + \begin{bmatrix} 0 & -\omega \\ \omega & 0 \end{bmatrix} \cdot \begin{bmatrix} \Phi_{ds} \\ \Phi_{qs} \end{bmatrix} + \frac{d}{dt} \begin{bmatrix} \Phi_{ds} \\ \Phi_{qs} \end{bmatrix} \quad (\text{II.31})$$

L'équation électrique du stator dans la référence du rotor s'exprime donc sous forme matricielle comme suit :

$$\begin{bmatrix} V_{ds} \\ V_{qs} \end{bmatrix} = \begin{bmatrix} R_s & -\omega \cdot L_{sc} & \vdots & \dots + \omega \cdot M_{sr} \cdot \sin(k\alpha) \dots \\ \omega \cdot L_{sc} & R_s & \vdots & \dots - \omega \cdot M_{sr} \cdot \cos(k\alpha) \dots \end{bmatrix} \cdot \begin{bmatrix} I_{dqs} \\ I_{rk} \end{bmatrix} + \begin{bmatrix} L_{sc} & 0 & \vdots & \dots - M_{sr} \cdot \cos(k\alpha) \dots \\ 0 & L_{sc} & \vdots & \dots - M_{sr} \cdot \sin(k\alpha) \dots \end{bmatrix} \cdot \frac{d}{dt} \begin{bmatrix} I_{dqs} \\ I_{rk} \end{bmatrix} \quad (\text{II.32})$$

II.4.2 Equations des tensions au rotor

La figure (II.5) montre le circuit électrique équivalent d'un maillage de cage rotorique, avec les barres rotoriques et les segments d'anneau de court-circuit représentées par les inductances de fuite et les résistances.

Sachant que :

$$\begin{cases} I_{ek} = I_{rk} - I_e \\ I_{bk} = I_{rk} - I_{r(k+1)} \end{cases} \quad (\text{II.33})$$




Figure II.5 : Schéma électrique équivalent d'une maille rotorique

Voici l'équation de tension pour la maille « k » de la cage du rotor :

$$-R_{b(k-1)}I_{r(k-1)} + R_{bk}I_{bk} + \frac{R_e}{N_r}I_{ek} + \frac{R_e}{N_r}I_{rk} + \frac{d}{dt}\Phi_{rk} = 0 \quad (\text{II.34})$$

Pour un circuit élémentaire d'indice « k », la somme des composantes suivantes constitue le flux total « Φ_{rk} » :

- ✚ Flux principal : $L_{rp} \cdot I_{rk}$;
- ✚ Flux mutuel avec les autres circuits du rotor : $M_{rr} \cdot \sum_{\substack{j=0 \\ j \neq k}}^{N_r-1} I_{rj}$;
- ✚ Après transformation, le flux mutuel avec le stator est donné par :

$$-\frac{3}{2}M_{sr} \cdot \begin{bmatrix} \vdots & \vdots & \vdots \\ \cos(k\alpha) & \vdots & \sin(k\alpha) \\ \vdots & \vdots & \vdots \end{bmatrix} \cdot [I_{dqs}] \quad (\text{II.35})$$

La formule du flux induit dans la maille du rotor est :

$$\begin{aligned} \Phi_{rk} = & \left(L_{rp} + 2L_b + 2\frac{L_e}{N_r} \right) I_{rk} - M_{rr} \cdot \sum_{\substack{j=0 \\ j \neq k}}^{N_r-1} I_{rj} - L_b (I_{r(k-1)} + I_{r(k+1)}) - \frac{L_e}{N_r} I_e \\ & - L_{sr} \left[\cos(\theta + k\alpha) : \cos\left(\theta + k\alpha - \frac{2\pi}{3}\right) : \cos\left(\theta + k\alpha - \frac{4\pi}{3}\right) \right] \cdot [I_{sabc}] \end{aligned} \quad (\text{II.36})$$

I_{rk} : courant de maille « k » ;

I_{bk} : courant de la barre « k ».

✚ Pour le nœud N° : 01

$$I_{bk} = I_{rk} = I_{r(k+1)}$$

✚ Pour le nœud N° : 02

$$I_{bk} = I_{r(k-1)} - I_{rk}$$

L'équation électrique pour la maille « k » est la suivante :

$$0 = \frac{R_e}{N_r} I_{rk} - R_{b(k-1)} \cdot [I_{r(k-1)} - I_{rk}] + \frac{R_e}{N_r} \cdot [I_{rk} - I_e] + R_{bk} \cdot [I_{rk} - I_{r(k+1)}] + \frac{d\phi_{rk}}{dt} \quad (\text{II.37})$$

La formule du flux induit dans la maille du rotor est :

$$\begin{aligned} \phi_{rk} = & \left(L_{rp} + 2L_b + 2\frac{L_e}{N_r} \right) I_{rk} + M_{rr} \cdot \sum_{\substack{j=0 \\ j \neq k}}^{N_r-1} I_{rj} - L_b \cdot (I_{r(k-1)} + I_{r(k+1)}) \\ & - \frac{3}{2} \cdot M_{sr} \cdot (I_{ds} \cdot \cos(k\alpha) + I_{qs} \cdot \sin(k\alpha)) - \frac{L_e}{N_r} \cdot I_e \end{aligned} \quad (\text{II.38})$$

Avec : $k \in [0, (N_r - 1)]$, $k \in N$.

Une fois les circuits du rotor et l'anneau de court-circuit entièrement intégrés dans le système d'équations, on a alors :

$$\frac{R_e}{N_r} \cdot \sum_{k=0}^{N_r-1} I_{rk} + \frac{L_e}{N_r} \cdot \sum_{k=0}^{N_r-1} \frac{dI_{rk}}{dt} - R_e I_e - L_e \frac{dI_e}{dt} = 0 \quad (\text{II.39})$$

Le système complet est :

$$\begin{bmatrix} V_{ds} \\ V_{qs} \\ 0 \\ \vdots \\ 0 \end{bmatrix} = [L] \cdot \frac{d}{dt} \begin{bmatrix} I_{ds} \\ I_{qs} \\ \vdots \\ I_{rk} \\ \vdots \end{bmatrix} + [R] \begin{bmatrix} I_{ds} \\ I_{qs} \\ \vdots \\ I_{rk} \\ \vdots \end{bmatrix} \quad \Leftrightarrow \quad [L] \cdot \frac{d}{dt} \begin{bmatrix} I_{ds} \\ I_{qs} \\ \vdots \\ I_{rk} \\ \vdots \end{bmatrix} = \begin{bmatrix} V_{ds} \\ V_{qs} \\ 0 \\ \vdots \\ 0 \end{bmatrix} - [R] \begin{bmatrix} I_{ds} \\ I_{qs} \\ \vdots \\ I_{rk} \\ \vdots \end{bmatrix} \quad (\text{II.40})$$

Devient donc :

$$\begin{aligned}
 & \begin{bmatrix} L_{sc} & 0 & \vdots & \dots & \dots & \dots & -M_{sr} \cos(j\alpha) & \dots & \dots & \vdots & 0 \\ 0 & L_{sc} & \vdots & \dots & \dots & \dots & -M_{sr} \sin(j\alpha) & \dots & \dots & \vdots & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \vdots & \dots \\ \vdots & \vdots & \vdots & L_{rp} + \frac{2L_e}{N_r} + 2L_b & M_{rr} - L_b & M_{rr} & \dots & M_{rr} & M_{rr} - L_b & \vdots & -\frac{L_e}{N_r} \\ \vdots & \vdots & \vdots & M_{rr} - L_b & L_{rp} + \frac{2L_e}{N_r} + 2L_b & M_{rr} - L_b & M_{rr} & \dots & M_{rr} & \vdots & \vdots \\ -\frac{3}{2}M_{sr} \cos(k\alpha) & -\frac{3}{2}M_{sr} \sin(k\alpha) & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & M_{rr} - L_b & M_{rr} & \dots & M_{rr} & M_{rr} - L_b & L_{rp} + \frac{2L_e}{N_r} + 2L_b & \vdots & -\frac{L_e}{N_r} \\ \dots & \dots & \vdots & \dots & \dots & \dots & \dots & \dots & \dots & \vdots & \dots \\ 0 & 0 & \vdots & -\frac{L_e}{N_r} & \dots & \dots & \dots & \dots & -\frac{L_e}{N_r} & \vdots & L_e \end{bmatrix} \begin{bmatrix} I_{ds} \\ I_{qs} \\ \dots \\ I_{r0} \\ \vdots \\ I_{rj} \\ \vdots \\ I_{r(N_r-1)} \\ \dots \\ I_e \end{bmatrix} \\
 & = \begin{bmatrix} R_s & -\omega L_{sc} & \vdots & \dots & \dots & M_{sr} \omega \cos(j\alpha) & \dots & \dots & \dots & \vdots & 0 \\ \omega L_{sc} & R_s & \vdots & \dots & \dots & -M_{sr} \omega \sin(j\alpha) & \dots & \dots & \dots & \vdots & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \vdots & \dots \\ 0 & 0 & \vdots & 2\frac{R_e}{N_r} + R_{b0} + R_{b(N_r-1)} & -R_{b0} & 0 & 0 & -R_{b(N_r-1)} & \dots & \vdots & -\frac{R_e}{N_r} \\ \vdots & \vdots & \vdots & -R_{b0} & \dots & \dots & \dots & 0 & \dots & \vdots & \vdots \\ \vdots & \vdots & \vdots & 0 & -R_{b(k-1)} & 2\frac{R_e}{N_r} + R_{bk} + R_{b(k-1)} & -R_{bk} & \dots & \dots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & -R_{b(N_r-2)} & \dots & \vdots & \vdots \\ 0 & 0 & \vdots & -R_{b(N_r-1)} & 0 & 0 & -R_{b(N_r-2)} & 2\frac{R_e}{N_r} + R_{b(N_r-2)} + R_{b(N_r-1)} & \dots & \vdots & -\frac{R_e}{N_r} \\ \dots & \dots & \vdots & \dots & \dots & \dots & \dots & \dots & \dots & \vdots & \dots \\ 0 & 0 & \vdots & -\frac{R_e}{N_r} & \dots & \dots & \dots & -\frac{R_e}{N_r} & \dots & \vdots & R_e \end{bmatrix} \begin{bmatrix} I_{ds} \\ I_{qs} \\ \dots \\ I_{r0} \\ \vdots \\ I_{rj} \\ \vdots \\ I_{r(N_r-1)} \\ \dots \\ I_e \end{bmatrix} \\
 & \tag{II.41}
 \end{aligned}$$

En dérivant la Co-énergie, on peut obtenir le couple électromagnétique :

$$C_{em} = \frac{3}{2} \cdot p \cdot [I_{dqs}]^T \cdot \frac{\delta}{\delta \theta} \begin{bmatrix} \dots & -M_{sr} \cos(\theta + k\alpha) & \dots \\ \dots & -M_{sr} \sin(\theta + k\alpha) & \dots \end{bmatrix} \begin{bmatrix} \vdots \\ I_{rk} \\ \vdots \end{bmatrix} \tag{II.42}$$

L'expression du couple donc est :

$$C_{em} = \frac{3}{2} \cdot p \cdot M_{sr} \cdot \left\{ I_{ds} \cdot \sum_{k=0}^{N_r-1} I_{rk} \cdot \sin(k\alpha) - I_{qs} \cdot \sum_{k=0}^{N_r-1} I_{rk} \cdot \cos(k\alpha) \right\} \tag{II.43}$$

A ces équations, on ajoute l'équation mécanique pour avoir la vitesse mécanique " $\Omega = \omega/p$ " ;

$$\frac{d\Omega}{dt} = \frac{1}{J} p (C_{em} - C_r - \frac{f}{p} \omega) \tag{II.44}$$

Avec :

$$\frac{d\theta}{dt} = \omega ;$$

θ : l'angle de déphasage entre le stator et le rotor ;

ω : pulsation mécanique ;

$\Omega = \omega/p$: la vitesse mécanique en [rad/sec].

II.4.3 Modèle équivalent de la machine à taille réduite

La représentation d'état fait apparaître un système d'ordre très élevé, car il est constitué du nombre de phases statoriques, du nombre de phases rotoriques et des équations électromécaniques. Le rang du système est donc « $N_r + 3$ ». Il est donc nécessaire de réduire la taille des matrices dans le but de réduire le temps de simulation [65]. Pour ce faire, on utilise la matrice de Clarke généralisée étendue au système rotorique. Ce qui permet de passer d'une modélisation à « n-phases multi-enroulements » à une modélisation diphasée équivalente (figure II.6) écrite de la façon suivante :




Figure II.6 : Projection du modèle multi enroulements sur le repère biphasé de Park « dq » [65]

$$[T_{3n}(\theta_r)] = \frac{2}{n} \cdot \begin{bmatrix} \frac{1}{2} & \dots & \dots & \dots & \frac{1}{2} \\ \cos(\theta_r) & \dots & \cos(\theta_r - kp \frac{2\pi}{n}) & \dots & \cos(\theta_r - (n-1)p \frac{2\pi}{n}) \\ -\sin(\theta_r) & \dots & -\sin(\theta_r - kp \frac{2\pi}{n}) & \dots & -\sin(\theta_r - (n-1)p \frac{2\pi}{n}) \end{bmatrix} \quad (II.45)$$

La matrice inverse est donnée par :

$$[T_{3n}(\theta_r)]^{-1} = [T_{n3}(\theta_r)] = \begin{bmatrix} 1 & \cos(\theta_r) & -\sin(\theta_r) \\ \vdots & \vdots & \vdots \\ \vdots & \cos(\theta_r - kp \frac{2\pi}{n}) & -\sin(\theta_r - kp \frac{2\pi}{n}) \\ \vdots & \vdots & \vdots \\ 1 & \cos(\theta_r - (n-1)p \frac{2\pi}{n}) & -\sin(\theta_r - (n-1)p \frac{2\pi}{n}) \end{bmatrix} \quad (\text{II.46})$$

Avec : $k \in [0 \dots (n-1)]$, $k \in N$.

Lorsque cette matrice de transformation est appliquée, Nous pouvons définir un vecteur d'état [X] se traduira par :

$$\begin{cases} [X_{0dqs}] = [T(\theta_s)] \cdot [X_{abcs}] \Leftrightarrow [X_{abcs}] = [T(\theta_s)]^{-1} \cdot [X_{0dqs}] \\ [X_{0dqr}] = [T_{3N_r}(\theta_r)] \cdot [X_{rck}] \Leftrightarrow [X_{rck}] = [T_{3N_r}(\theta_r)]^{-1} \cdot [X_{0dqr}] \end{cases} \quad (\text{II.47})$$

✚ Pour la partie des tensions statoriques :

$$[V_{abcs}] = [R_s][I_{abcs}] + \frac{d}{dt}\{[L_s] \cdot [I_{abcs}]\} + \frac{d}{dt}\{[M_{sr}] \cdot [I_{rck}]\} \quad (\text{II.48})$$

L'équation (II.48) avec la transformation généralisée donne :

$$\begin{aligned} [V_{0dqs}] = \{[T(\theta_s)] \cdot [R_s] \cdot [T(\theta_s)]^{-1}\} \cdot [I_{0dqs}] + \{[T(\theta_s)] \cdot [L_s] \cdot [T(\theta_s)]^{-1}\} \cdot \frac{d}{dt}[I_{0dqs}] + \\ \{[T(\theta_s)] \cdot [M_{sr}] \cdot [T_{3N_r}(\theta_r)]^{-1}\} \cdot \frac{d}{dt}[I_{0dqr}] \end{aligned} \quad (\text{II.49})$$

✚ Pour la partie rotorique :

$$[V_{abcr}] = [R_r][I_{rck}] + \frac{d}{dt}\{[L_r] \cdot [I_{rck}]\} + \frac{d}{dt}\{[M_{sr}] \cdot [I_{abcs}]\} \quad (\text{II.50})$$

On obtient de la même manière :

$$\begin{aligned} [V_{0dqr}] = \{[T(\theta_r)] \cdot [R_r] \cdot [T_{3N_r}(\theta_r)]^{-1}\} \cdot [I_{0dqr}] + \{[T(\theta_r)] \cdot [L_r] \cdot [T_{3N_r}(\theta_r)]^{-1}\} \\ \cdot \frac{d}{dt}[I_{0dqr}] + \{[T(\theta_r)] \cdot [M_{sr}] \cdot [T(\theta_r)]^{-1}\} \cdot \frac{d}{dt}[I_{0dqs}] \end{aligned} \quad (\text{II.51})$$

En sélectionnant un référentiel lié au rotor tel que « $\theta_s = \theta$ et $\theta_r = 0$ ». Cette permutation de repère permet de générer un modèle simplifié de taille réduite de la MAS [60] :

$$\begin{bmatrix} L_{sc} & 0 & -\frac{N_r}{2} M_{sr} & 0 & 0 \\ 0 & L_{sc} & 0 & -\frac{N_r}{2} M_{sr} & 0 \\ -\frac{3}{2} M_{sr} & 0 & L_{rc} & 0 & 0 \\ 0 & -\frac{3}{2} M_{sr} & 0 & L_{rc} & 0 \\ 0 & 0 & 0 & 0 & L_e \end{bmatrix} \cdot \frac{d}{dt} \begin{bmatrix} I_{ds} \\ I_{qs} \\ I_{dr} \\ I_{qr} \\ I_e \end{bmatrix} = \begin{bmatrix} V_{ds} \\ V_{qs} \\ V_{dr} \\ V_{qr} \\ V_e \end{bmatrix} - \begin{bmatrix} R_s & -L_{sc}\omega & 0 & \frac{N_r}{2} M_{sr}\omega & 0 \\ L_{sc}\omega & R_s & -\frac{N_r}{2} M_{sr}\omega & 0 & 0 \\ 0 & 0 & R_r & 0 & 0 \\ 0 & 0 & 0 & R_r & 0 \\ 0 & 0 & 0 & 0 & R_e \end{bmatrix} \begin{bmatrix} I_{ds} \\ I_{qs} \\ I_{dr} \\ I_{qr} \\ I_e \end{bmatrix} \quad (\text{II.52})$$

Avec :

$$\begin{cases} L_{rc} = L_{rp} - M_{rr} + \frac{2L_e}{N_r} + 2 \cdot L_b(1 - \cos(\alpha)) \\ R_r = 2 \frac{R_e}{N_r} + 2 \cdot R_b(1 - \cos(\alpha)) \end{cases} \quad (\text{II.53})$$

Nous créons d'abord un modèle de la MAS qui tient compte de la structure du rotor sans défaut, puis nous passons à la modélisation de la machine qui tient compte du défaut de rotor de type rupture de barre.

Il est possible de modéliser ce type de défaillance en utilisant deux approches distinctes dans le but d'empêcher le courant de traverser la barre défectueuse. Une première approche de modélisation consiste à reconstituer totalement le circuit électrique rotorique. Dans ce type d'approche, la barre rotorique défaillante est retirée du circuit électrique, ce qui nécessite de recalculer les matrices résistances $[R_r]$ et inductances $[L_r]$ de la machine. En effet, la suppression d'une barre de la cage nous donne une matrice $[R_r]$ et $[L_r]$ de rang inférieur à celle développée pour la machine saine. La modification de l'ordre des matrices rotoriques oblige à recalculer les lois électriques de la boucle « k » [65, 60].

La deuxième méthode faisable, consiste à augmenter intentionnellement la résistance de la barre défectueuse d'une quantité suffisamment grande pour garantir que le courant qui la traverse est aussi proche de zéro que possible en régime permanent. Pour ce type de modélisation, nous supposons qu'une rupture de barre ne modifie pas les inductances propres et mutuelles de la cage du rotor, donc contrairement à la méthode précédente, la structure du circuit électrique du rotor n'est pas modifiée. De ce fait, cette dernière approche

permet de modéliser la rupture partielle des barres, cependant elle nécessite de modifier la matrice $[R_r]$. En conséquence, la matrice des défauts du rotor s'écrit comme suite :

$$[R_{rf}] = [R_r] + \begin{bmatrix} 0 & \dots & \dots & 0 & 0 & 0 & \dots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & \dots & 0 & 0 & 0 & 0 & \dots \\ 0 & \dots & 0 & R_{bk} & -R_{bk} & 0 & \dots \\ 0 & \dots & 0 & -R_{bk} & R_{bk} & 0 & \dots \\ 0 & \dots & 0 & 0 & 0 & 0 & \dots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \end{bmatrix} \quad (\text{II.54})$$

Après transformations, la nouvelle matrice de résistance rotorique prend la forme suivante :

$$[R_{rfdq}] = [T(\theta_r)] \cdot [R_{rf}] \cdot [T(\theta_r)]^{-1} \quad (\text{II.55})$$

La matrice résistance dans le repère de Park (d, q) est :

$$[R_{rfdq}] = \begin{bmatrix} R_{rdd} & R_{rdq} \\ R_{rqd} & R_{rqq} \end{bmatrix} \quad (\text{II.56})$$

Voici les termes de cette matrice :

$$\begin{cases} R_{rdd} = 2 \cdot R_b (1 - \cos(\alpha)) + \frac{R_e}{N_r} + \frac{2}{N_r} (1 - \cos(\alpha)) \sum_k R_{bfk} (1 - \cos(2k - 1) \cdot \alpha) \\ R_{rdq} = -\frac{2}{N_r} (1 - \cos(\alpha)) \sum_k R_{bfk} \sin(2k - 1) \cdot \alpha \\ R_{rqd} = -\frac{2}{N_r} (1 - \cos(\alpha)) \sum_k R_{bfk} \sin(2k - 1) \cdot \alpha \\ R_{rqq} = 2 \cdot R_b (1 - \cos(\alpha)) + 2 \cdot \frac{R_e}{N_r} + \frac{2}{N_r} (1 - \cos(\alpha)) \sum_k R_{bfk} (1 + \cos(2k - 1) \cdot \alpha) \end{cases} \quad (\text{II.57})$$

La barre cassée est représentée par l'indice « k ».

Suite à l'application de la transformation généralisée à l'expression du couple pour la partie mécanique, on obtient :

$$C_{em} = \frac{3}{2} \cdot p \cdot \frac{N_r}{2} \cdot M_{sr} \cdot (I_{ds} \cdot I_{qr} - I_{qs} \cdot I_{dr}) \quad (\text{II.58})$$

Nous avons maintenant un modèle de taille réduite « 5x5 » de la MAS. La matrice des inductances peut s'écrire comme suite :

$$[L] = \begin{bmatrix} L_{sc} & 0 & -\frac{N_r}{2} M_{sr} & 0 & 0 \\ 0 & L_{sc} & 0 & -\frac{N_r}{2} M_{sr} & 0 \\ -\frac{3}{2} M_{sr} & 0 & L_{rc} & 0 & 0 \\ 0 & -\frac{3}{2} M_{sr} & 0 & L_{rc} & 0 \\ 0 & 0 & 0 & 0 & L_e \end{bmatrix} \quad (\text{II.59})$$

Le système peut être mis sous la forme canonique (II.21) en posant : $[B] = [L]^{-1}$

Voici une représentation possible de la matrice d'état « A » du système :

$$A = A_{01} + \omega \times A_{02} \quad (\text{II.60})$$

Avec :

$$[A_{01}] = \begin{bmatrix} R_s & 0 & 0 & 0 & 0 \\ 0 & R_s & 0 & 0 & 0 \\ 0 & 0 & R_{rdd} & R_{rdq} & 0 \\ 0 & 0 & R_{rqd} & R_{rqq} & 0 \\ 0 & 0 & 0 & 0 & R_e \end{bmatrix} \quad (\text{II.61})$$

$$[A_{02}] = \begin{bmatrix} 0 & -L_{sc} & 0 & \frac{N_r}{2} M_{sr} & 0 \\ L_{sc} & 0 & -\frac{N_r}{2} M_{sr} & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (\text{II.62})$$

II.5 Résultats de simulation

Après le développement du modèle de la MAS. La simulation à l'aide de Matlab/Simulink, qui offre la possibilité d'observer et d'interpréter en temps réel les phénomènes et les grandeurs visualisés. On présentera la MAS sous différents états, sains et défectueux. Les résultats de la simulation dans ces cas sont les suivants :

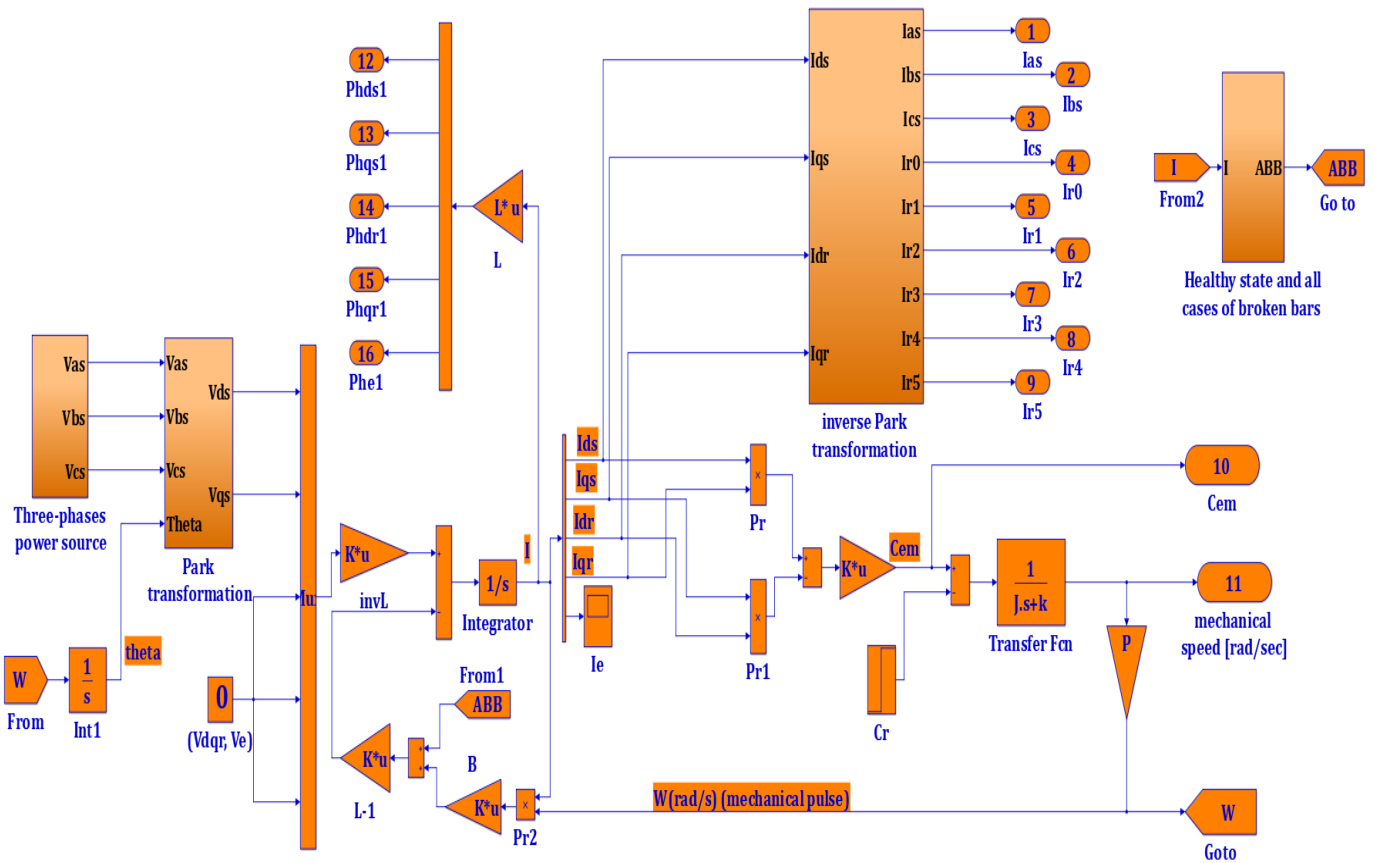


Figure II.7 : Schéma bloc de simulation de la MAS à l'état sain et défectueux

« cas des barres rotoriques cassées »




Figure II.8 : Source de tension triphasée V_{abcs}




Figure II.9 : Tension biphasée statorique de Park Vdq_s




Figure II.10 : Flux statorique Φ_{ds}




Figure II.11 : Flux statorique Φ_{qs}




Figure II.12 : Flux rotorique ϕ_{dr}




Figure II.13 : Flux rotorique ϕ_{qr}




Figure II.14 : Courant statorique I_{as}

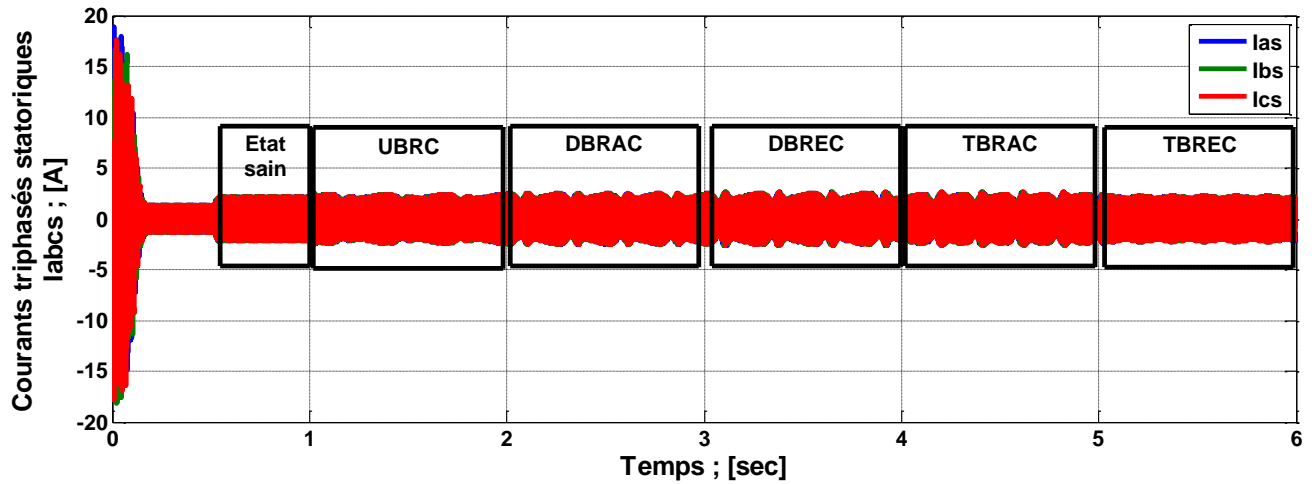

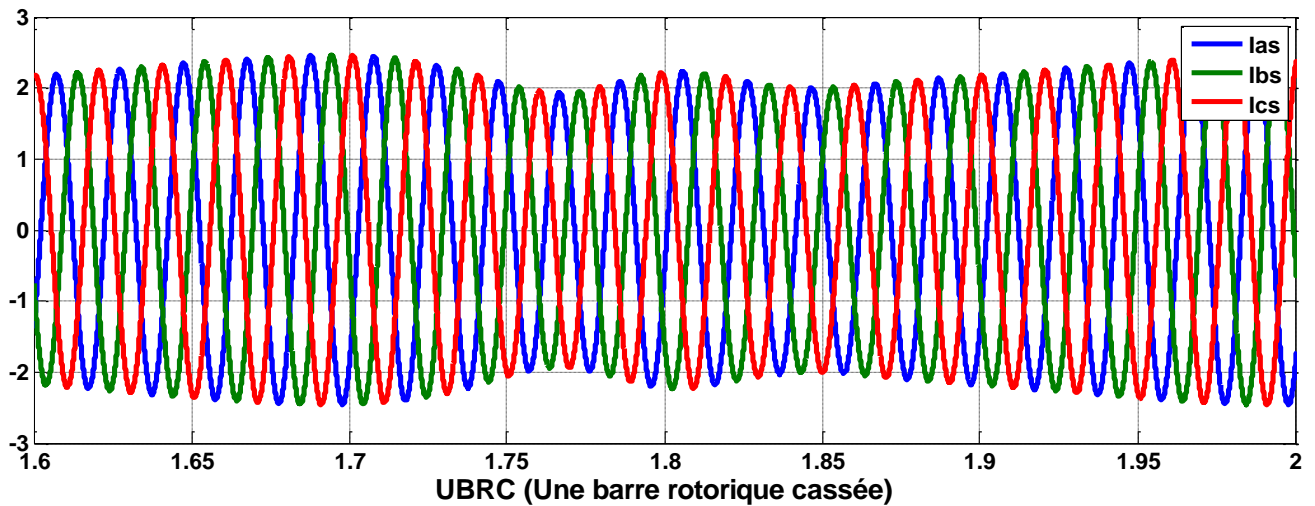


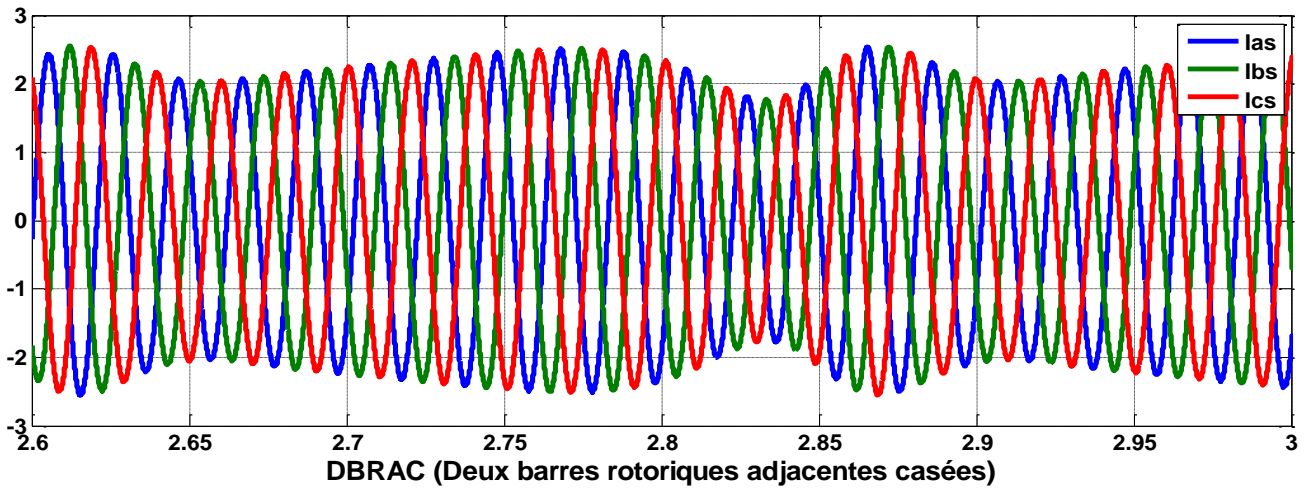
Figure II.15 : Courants triphasés statoriques I_{abcs}



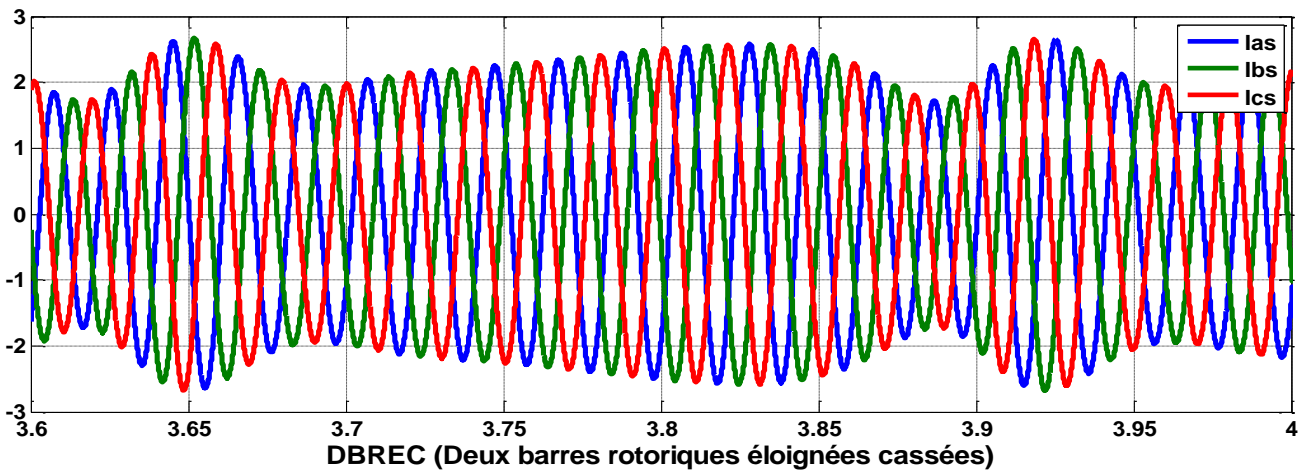
(a) : Zoom des courants statoriques I_{abcs} à l'état sain



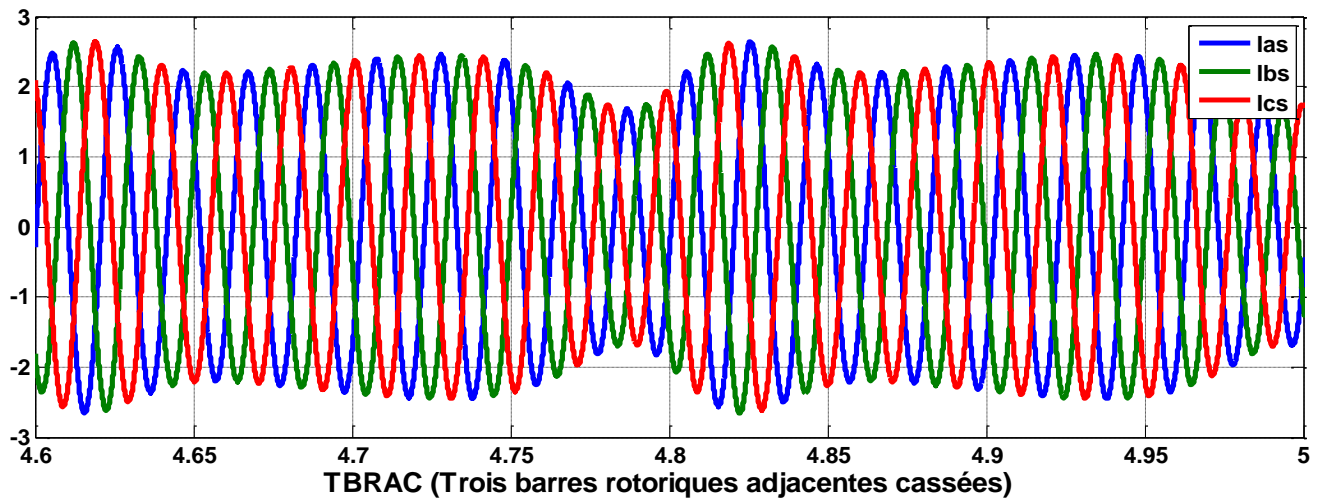
(b) : Zoom des courants statoriques I_{abcs} « cas d'une barre rotorique cassée »




(c) : Zoom des courants statoriques i_{abcs} « cas de deux barres rotoriques adjacentes cassées »



(d) : Zoom des courants statoriques i_{abcs} « cas de deux barres rotoriques éloignées cassées »



(e) : Zoom des courants statoriques i_{abcs} « cas de trois barres rotoriques adjacentes cassées »



(f) : Zoom des courants statoriques I_{abc} « cas de trois barres rotoriques éloignées cassées »

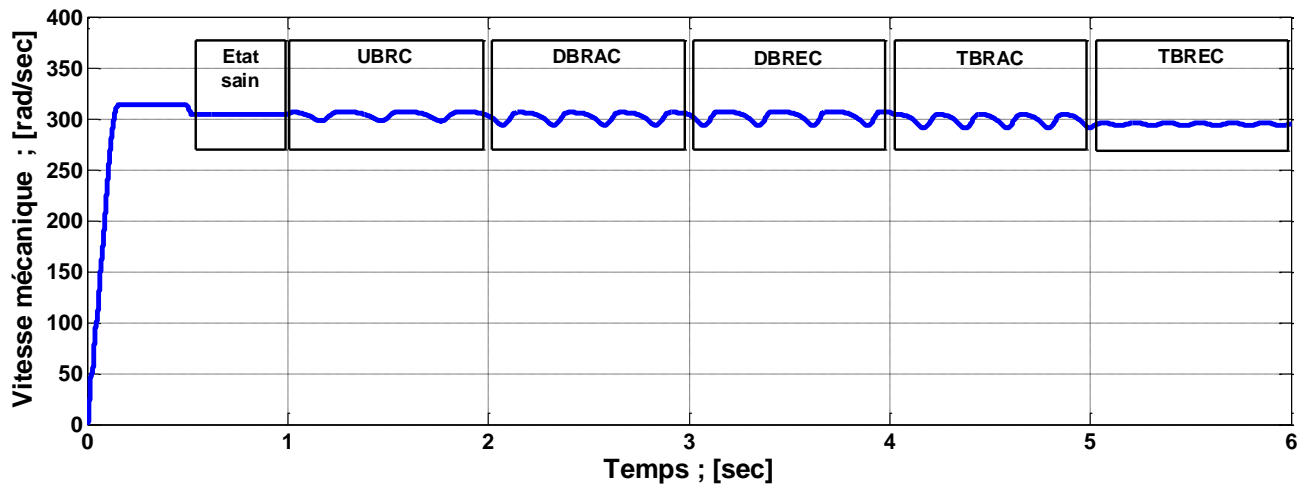


Figure II.16 : Vitesse mécanique « ω »

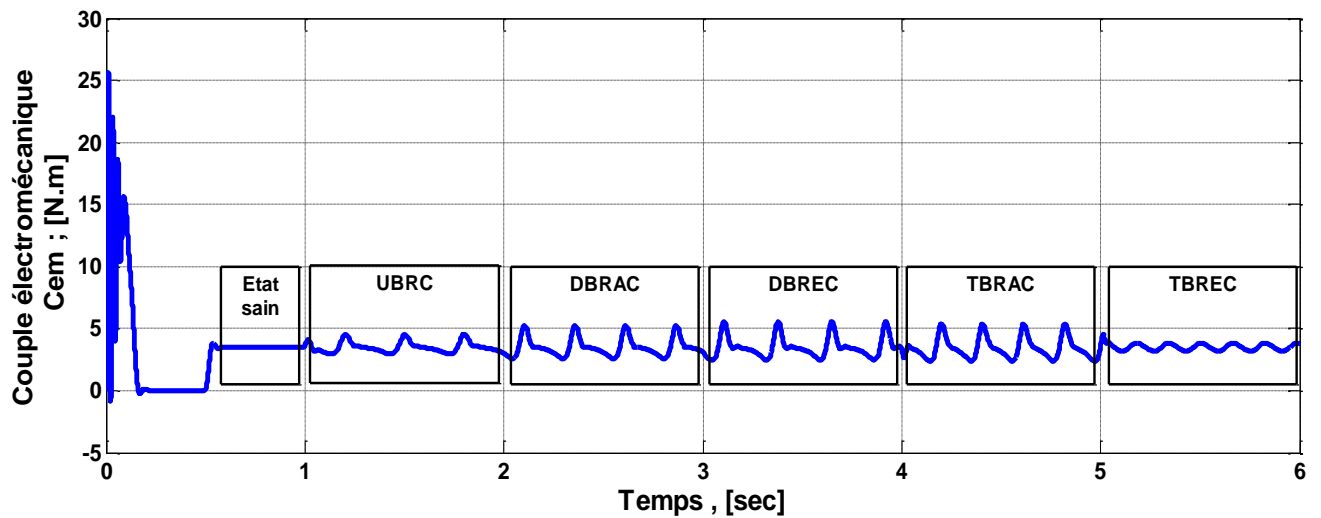





Figure II.17 : Couple électromécanique « C_{em} »




(a) : à l'état sain




(b) : à l'état d'une barre cassée




(c) à l'état de deux barres cassées adjacentes



(d) : à l'état de deux barres cassées éloignées




(e) : à l'état de trois barres cassées adjacentes




(f) : à l'état de trois barres cassées éloignées

Figure II.18 : Diagramme caractéristique couple vitesse



(a) Périodogramme à l'état sain



(b) Périodogramme à l'état de deux barres rotoriques cassées

Figure II.19 : FFT du courant statorique « I_{as} » de la MAS

II.5.1 Interprétation des résultats

Sur l'intervalle « [0, 1] ; [sec] », ce cas la MAS est considérée à l'état sain, alimentée directement par le réseau, on applique à « $t = 0.5$; [sec] » un « C_r » de « 3.5 ; [Nm] » (Tableau II.2), et à partir de « 1 ; (sec) » on a introduit chaque seconde un défaut de barres rotoriques cassées (tableau II.3) pour démontrer comment le glissement affecte les propriétés des courbes des grandeurs électromécaniques (couple et vitesse), et la grandeur électrique (courant statorique « I_{as} ») ; Les résultats pour ce mode de fonctionnement sont illustrés par les figures (II.14), (II.16) et (II. 17).

✚ Machine à l'état sain

Tableau II.2 : Couple, vitesse et courant statorique de la MAS à l'état sain

Etat sain	A vide	En charge « $C_r = 3.5$; [Nm] »
Temps ; [sec]	[0 : 0.5]	[0.5 : 1]
Couple électromécanique C_{em} ; [Nm]	1.907×10^{-7}	3.5
Vitesse mécanique ω ; [rad/sec]	314.2	304.4
Courant statorique I_{as} ; [A]	1.336	1.343

✚ Machine à l'état défectueux

Tableau II.3 : Couple, vitesse et courant statorique de la MAS à l'état défectueux

Etat défectueux en charge « $C_r = 3.5$; [Nm] »					
Défaut	UBRC	DBRAC	DBREC	TBRAC	TBREC
Temps ; [sec]	[1 : 2]	[2 : 3]	[3 : 4]	[4 : 5]	[5 : 6]
Couple électromécanique C_{em} ; [Nm]	2.986	4.29	2.558	2.699	3.279
Vitesse mécanique ω ; [rad/sec]	298.9	304.8	295	291.4	295.7
Courant statorique I_{as} ; [A]	1.574	0.9051	1.547	1.163	1.512

Dans le cas d'une alimentation par un réseau à tension triphasée symétrique, un défaut du rotor produira une certaine dissymétrie qui sera à l'origine d'un champ magnétique tournant inverse de fréquence « $-gf_s$ » dans le circuit rotorique. Cela se traduira par des courants circulant à la fréquence : « $f_{g,bc} = (1 - 2g)f_s$ » dans le circuit du stator. Cette fréquence produit une modulation du courant, qui se traduit par des oscillations du

couple donnant des fluctuations de la vitesse. Alors une autre composante apparaît également dans le spectre du courant statorique à une fréquence : « $f_{d,bc} = (1 + 2g)f_s$ », il a été démontré qu'un processus répétitif va créer une série d'harmoniques dont les fréquences sont données par : « $f_{bc} = (1 \pm 2kg)f_s$ », (figure II.19).

Dans la surveillance des défauts des barres rotoriques cassées, on s'intéresse par le régime permanent en charge. Et comme la montre sur le tableau (II.3), l'influence de ces derniers sur le « C_{em} » et la « ω_m » est difficile à interpréter, même on a pris les valeurs efficaces sur un intervalle du temps d'une seconde pour chaque défaut. On peut prendre comme exemple la valeur du couple électromécanique dans le cas de DBRAC « $C_{em} = 4.29$; [Nm] » est supérieure que sa valeur en charge à l'état sain « $C_{em} = 3.5$; [Nm] » ; cette valeur efficace prouve qu'il y a une oscillation survient sur l'allure du couple mais le temps qu'on la compare avec la valeur efficace de défaut de TBRAC « $C_{em} = 2.699$; [Nm] » on trouve que son influence est plus importante.

Le défi consiste à estimer le nombre de barres cassées. La figure (II.19) illustre la présence de ces composantes spectrales suggérant l'apparition d'un défaut de barre. Il existe diverses formules qui se rapprochent de ce nombre, mais il est très difficile de déterminer le nombre précis de ces barres cassées en raison de la variété des processus qui pourraient provoquer la rupture des barres. Pour cela on a fait l'appel aux méthodes intelligentes comme les RNA et la forêt aléatoire « RF » pour atteindre notre but de détection et localisation de chaque type de défaut des barres rotoriques cassées, c'est l'objectif du quatrième chapitre « Surveillance de défauts des barres cassées rotoriques de la MAS par des méthodes intelligentes ».

Concernant la figure (II.18), on a présenté l'effet de chaque défaut des barres rotoriques cassées sur les caractéristiques (couple /vitesse). Et comme perspective on peut utiliser ses signatures pour l'apprentissage des méthodes intelligentes dans le même objectif de détection et localisation des défauts de la MAS.

II.6 Conclusion

La modélisation de la MAS prenant en compte la structure de type circuit multi-enroulements du rotor a été abordée dans ce chapitre. Un modèle mathématique établi, dont la complexité a été diminuée, repose sur des hypothèses simplifiées. Nous avons découvert que le modèle de la MAS est un système d'équations différentielles dont les coefficients sont des fonctions périodiques du temps ; la transformation de Park nous a permis de simplifier ce modèle avec une source d'alimentation parfaitement sinusoïdale du réseau.

L'effet de défaut des barres rotoriques cassées se manifeste par des ondulations dans les caractéristiques électriques et mécaniques, il est d'autant important que les cassures de barres rotoriques sont adjacentes. Le diagnostic direct du défaut à travers les caractéristiques électriques et mécanique est délicat, Suite à l'existence

d'harmoniques. L'identification directe du défaut à l'aide des propriétés électriques et mécaniques est délicate. Le troisième chapitre « Méthodes de traitement du signal dédiées au diagnostic des défauts du système » couvrira cette étude à l'aide des outils de traitement de signal comme l'analyse du spectre et les ondelettes.

Chapitre III

Méthodes de traitement des signaux dédiées au diagnostic des défauts d'un système

III.1 Introduction

L'analyse dans le domaine temporel possède des limites dans l'identification des défauts dans un composant spécifique parce qu'une machine électrique est composée généralement de nombreux éléments et leurs contributions individuelles au signal des grandeurs de ligne (courants statoriques « I_{abcs} », tension et puissance) sont très difficiles à distinguer. Plusieurs paramètres peuvent être utilisés pour interpréter le signal dans le domaine d'analyse temporel. Certains de ces paramètres sont le pic, le niveau de la racine carrée moyenne (RCM) ainsi que le facteur de crête. Le moment statistique de quatrième ordre, connu sous le nom de Kurtosis, est largement utilisé dans les conditions de surveillance des machines électriques et plus spécifiquement pour la détection des défauts dans les composantes tournantes. Le Kurtosis est un indicateur qui est sensible à l'impulsion d'un signal. Une valeur élevée indique la présence d'éventuels défauts dans le système [66].

C'est pour cette raison que les chercheurs sont attirés par l'analyse dans le domaine des fréquences. Dans cette analyse, la fréquence des principaux pics peut être associée aux composants spécifiques en se basant sur la spécification géométrique et la vitesse opératoire des composants. On peut plus facilement trouver le composant défectueux en surveillant des gammes de fréquences spécifiques.

Parmi Les méthodes les plus connues pour analyser les signaux qui portent des signatures de défaut (comme notre cas les courants statoriques « I_{abcs} ») dans le domaine fréquentiel, la plus connue est la transformée de Fourier qui permet d'exprimer un signal périodique en tant que somme de différentes fréquences sinusoïdales ou exponentielles. Mais avec cette technique on ne peut pas analyser les signaux non stationnaires, pour cela on est allé dans les détails pointus de l'art de traitement des signaux pour résoudre ce problème.

L'objectif du traitement du signal est d'analyser soigneusement, de coder efficacement, de transmettre et de construire un signal à partir de ses fluctuations et oscillations. C'est le long de cet axe que les différents outils de traitement du signal ont pris naissance l'un après l'autre de la transformée de Fourier avec ses variétés aux ondelettes de nos jours utilisées massivement dans le traitement des signaux dans divers domaines.

La transformée de Fourier, ou plus généralement l'analyse fréquentielle ou spectrale, est un outil clé pour appréhender et mettre en pratique de nombreuses approches différentes de traitement numérique du signal. Cet outil a un large éventail d'utilisations dans une variété de domaines, y compris la reconnaissance vocale, l'amélioration de la qualité d'image, la transmission numérique, l'industrie biomédicale et autres. Il a, également, envahi le domaine de diagnostic et de détection des défauts dans les ME (statiques ou tournantes). [67].

De nos jours, l'analyse fréquentielle des grandeurs mesurables, des machines électriques, reste la plus utilisée pour le diagnostic des défauts, car la plupart d'entre eux et qui sont connus peuvent être détectés avec ce type d'approche. Avec les limitations qu'ont connues ces méthodes, les recherches ont poussé vers une autre envergure pour améliorer la qualité et l'efficacité du traitement du signal d'où la naissance des ondelettes. La transformée en ondelettes décompose le signal à la fois en temps et en fréquence et qui introduit une fenêtre dont la taille variant avec la fréquence [68].

Dans ce chapitre, on va tout d'abord aborder à une idée générale sur les signaux et leurs classifications. Puis suivi les différentes panoplies des traitements des signaux qui se focalisent sur la série de Fourier pour les signaux périodique et la TF selon ses diversités et surtout les ondelettes pour les signaux non stationnaires.

III.2 Définition d'un signal

La représentation physique des données qu'un signal transmet de sa source à sa destination s'appelle un signal. Il agit comme un canal d'information. C'est la représentation physique d'une quantité qui peut être mesurée (comme le courant, la tension, la force, la température ou la pression). A l'aide de capteurs, les signaux sont des grandeurs électriques qui évoluent dans le temps « $x(t)$ ». [69].




Figure III.1 : Signal présente une phrase du courrier en attente

Selon l'analyse, un signal est une fonction d'une variable réelle, typiquement le temps. Les exemples comprennent :

- ✚ Onde acoustique : délivré par un microphone (parole, musique, ...) ;
- ✚ Signaux biologiques : EEG, ECG ;
- ✚ Tension aux bornes de composant électronique ;
- ✚ Signaux géophysiques : vibrations sismiques ;
- ✚ Images, vidéos ;
- ✚ Etc.

Les mots signal et information sont communs dans le langage courant. Dans le monde scientifique ; ces mots ont des significations bien précises : en particulier, théorie de l’information, théorie du signal et traitement du signal correspondent à des notions différentes (figure III.2). D'ailleurs généralement [70] :

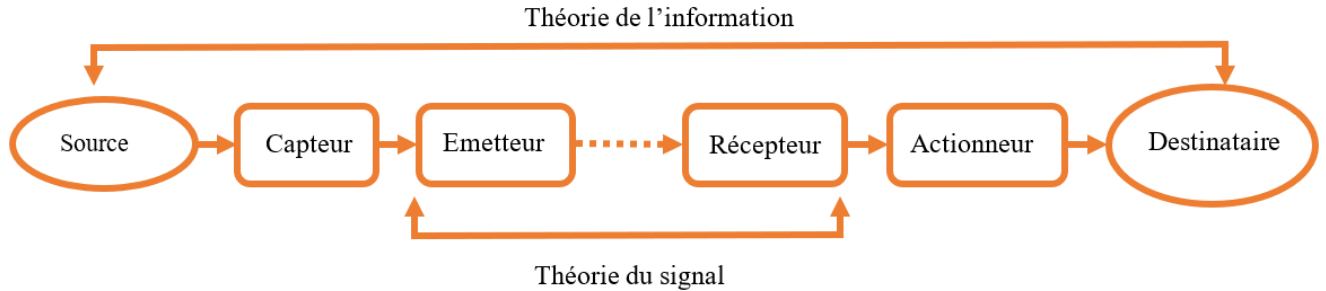


Figure III.2 : Organigramme de la théorie de l’information

- ✚ **La théorie du signal** : est l'ensemble des outils mathématiques utilisés pour décrire les signaux et les bruits produits par des sources ou altérés par des systèmes de traitement.
- ✚ **La théorie de l’information** : est les outils mathématiques utilisés pour expliquer la transmission de messages d'une source à un destinataire.
- ✚ **Le traitement du signal** : est la collection des procédures et des formules utilisées pour créer ou déchiffrer des signaux porteurs d'informations ; Être plus précis
 - **Elaboration** : codage, modulation, changement de fréquence ;
 - **Interprétation** : décodage, démodulation, filtrage, détection, identification, etc.

Avant de passer aux signaux il faut connaître ce qu’est un système :

III.3 Définition d’un système

- Tout dispositif qui transforme un signal d’entrée en un signal de sortie est appelé système.
- Le système, est un modèle mathématique qui représente un dispositif de type entrée/sortie et apporte une déformation au signal (Modulateur, filtre, etc...) [71].




Figure III.3 : Schéma block d’un système

III.4 Classification des signaux

Nous nous intéresserons à la théorie du signal et nous allons commencer par classement des signaux par l'organigramme suivant [69] :

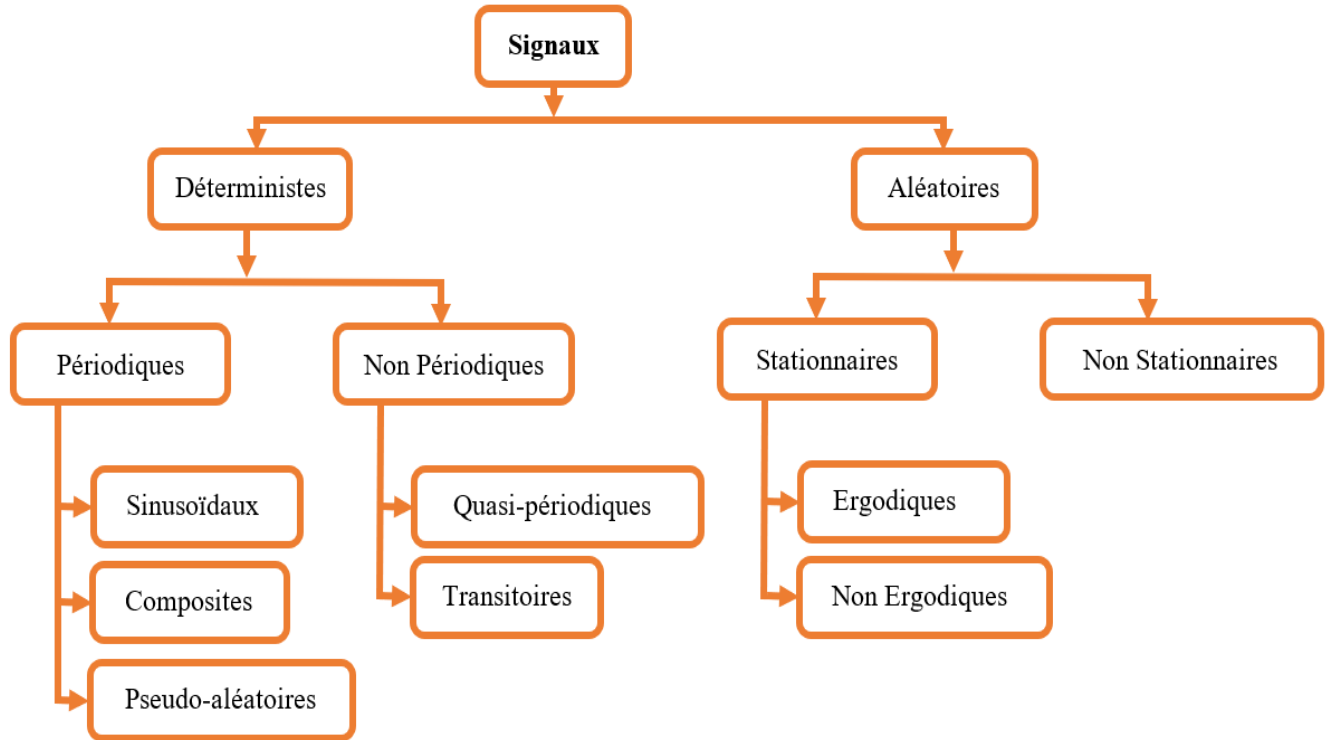


Figure III.4 : Classification des signaux déterministes et aléatoires

III.4.1 Classification phénoménologique (statistique) des signaux

Les signaux que l'on a l'habitude de rencontrer en physique peuvent être classés en deux groupes :

- ✚ **Les signaux déterministes** : dont l'évolution est prédite par un modèle mathématique « c-à-d : leur évolution en fonction du temps peut être parfaitement modélisée par une fonction mathématique » comme une tension aux bornes d'un condensateur.

Les signaux déterministes sont classés en trois catégories :

1. Signaux périodiques ;
2. Signaux apériodiques ;
3. Signaux transitoires.




Figure III.5 : Les signaux déterministes

✚ **Les signaux aléatoires** : leur comportement est imprévisible « on ne peut pas prédire la valeur à un temps t ». Il faut s'appuyer sur leurs propriétés statistiques pour les décrire (la moyenne, loi de probabilité, ...). Ils sont considérés comme stationnaires si leurs caractéristiques statistiques sont invariantes dans le temps. [69].

III.4.2 Classification morphologique (continu/discret)

Il est possible de faire la distinction entre les signaux à évolution temporelle continue et les signaux à évolution temporelle discrète, ainsi qu'entre les signaux à amplitudes continue et discrète. [68].

1. **Les signaux analogiques** : dont l'amplitude et temps sont continus ;
2. **Les signaux numériques** : dont l'amplitude et temps sont discrets ;
3. **Les signaux quantifiés** : dont l'amplitude est discrète et temps continu ;
4. **Les signaux échantillonnés** : dont l'amplitude est continue et le temps discret.

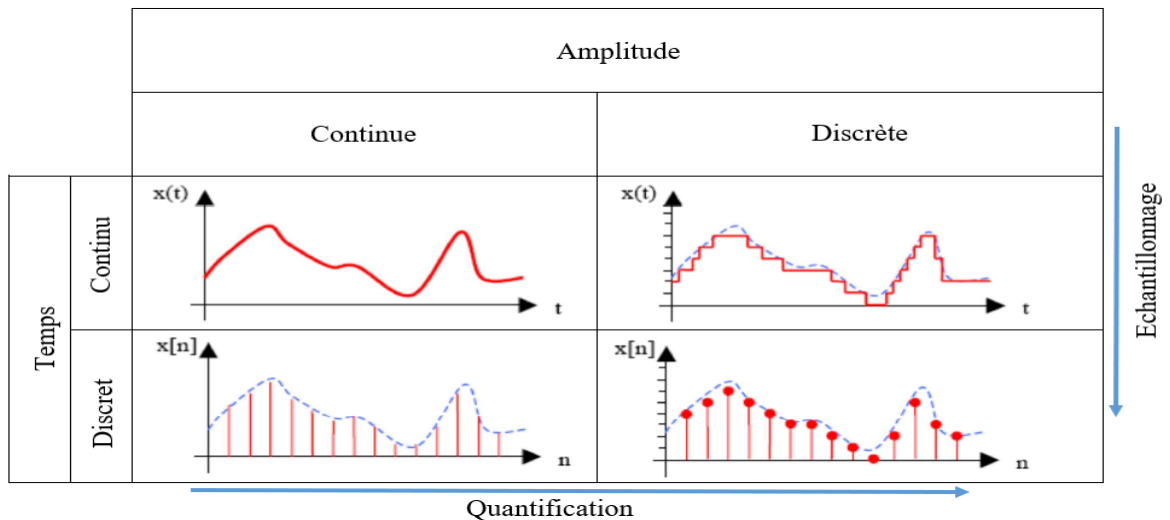


Figure III.6 : La morphologie des signaux (continus/discrets)

III.4.3 Classification énergétique

Une classification peut être établie à partir des notions d'énergie ou de puissance d'un signal [69].

- ✚ **Energie d'un signal** : soit un signal « $x(t)$ » défini sur l'intervalle $]-\infty, +\infty[$. On définit l'énergie « E_x » de « $x(t)$ » fonction réelle ou complexe de « t » :

$$E_x = \int_{-\infty}^{+\infty} |x(t)|^2 dt \quad (\text{III.1})$$

L'énergie est aussi appelée valeur quadratique du signal « $x(t)$ ».

- ✚ **Puissance d'un signal** : l'énergie d'un signal doit être finie pour que la mesure soit significative. Une condition nécessaire pour que l'énergie soit finie : $|x(t)| \rightarrow 0$ quand $t \rightarrow \infty$: figure (a). Dans certains cas. Si $|x(t)| \neq 0$ quand $t \rightarrow \infty$ figure (b). Alors l'énergie est infinie

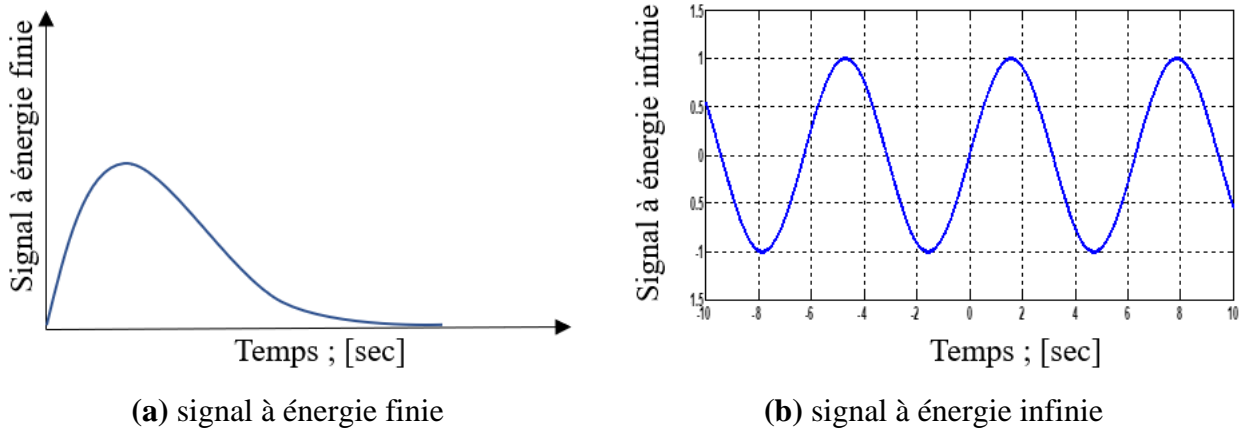


Figure III.7 : Classification énergétique d'un signal

Donc on définit la puissance moyenne « P_x » d'un signal « $x(t)$ » :

$$P_x = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-\frac{T}{2}}^{+\frac{T}{2}} |x(t)|^2 dt \quad (\text{III.2})$$

La puissance moyenne est aussi appelée valeur quadratique moyenne de « $x(t)$ ».

Dans le cas particulier où « $x(t)$ » est un signal périodique de période « T_0 » on a :

$$P_x = \lim_{t \rightarrow \infty} \frac{1}{T_0} \int_{-\frac{T_0}{2}}^{+\frac{T_0}{2}} |x(t)|^2 dt \quad (\text{III.3})$$

Dans cette classe on distingue deux types des signaux :

- **Signaux à énergie finie** : Son énergie est finie et sa puissance moyenne est nulle $0 < E_x < \infty$, (donc $P_x = 0$);
- **Signaux à énergie infinie** : puissance moyenne non nulle $0 < P_x < \infty$ et $E_x \rightarrow \infty$, (cas des signaux périodiques).

✚ **Signaux dimensionnels** : de la variable indépendante (temps, fait intervenir la dimension et la nature, position spatiale, ...) réelle ou complexe :

- **Signal monodimensionnel** « $x(t)$ » : fonction d'un seul paramètre ;
- **Signal bidimensionnel** « $x(x, y)$ » : dépend de deux paramètres (image) ;
- **Signal tridimensionnel** « $x(x, y, t)$ » : dépend de trois paramètres (vidéo).

III.5 Signaux particuliers (utiles)

Un signal échantillonné (discret) « $x(n)$ » est une suite de « N » échantillons régulièrement espacés de « T_e » secondes : « $X(0), X(T_e), X(2T_e), \dots, X((N-1)T_e)$ » où « $f_e = 1/T_e$ » est la fréquence d'échantillonnage, d'un signal « $x(t)$ » déterministe à temps continu qui est supposé à bande limitée « $-f_e/2, f_e/2$ ». Nous noterons « $x(n) = X(nT_e)$ » [71].


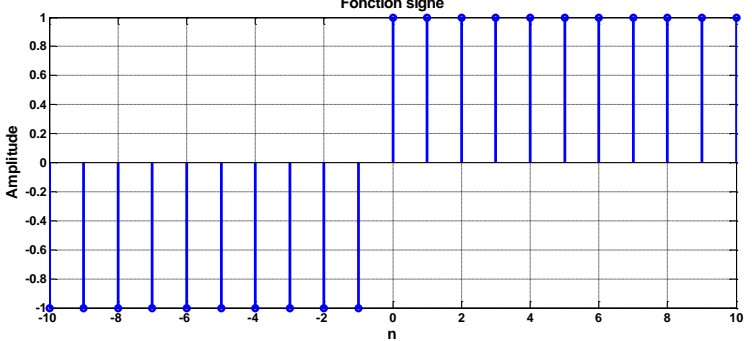
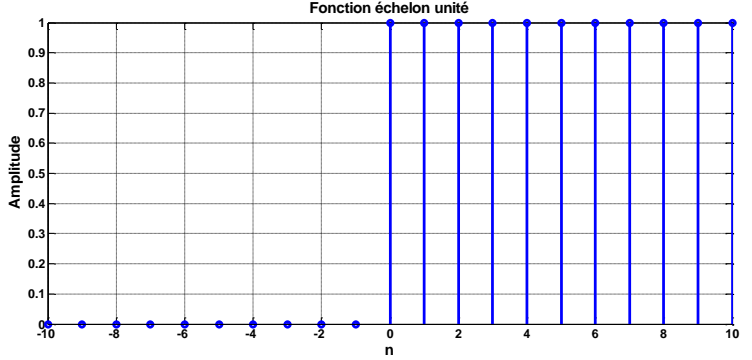
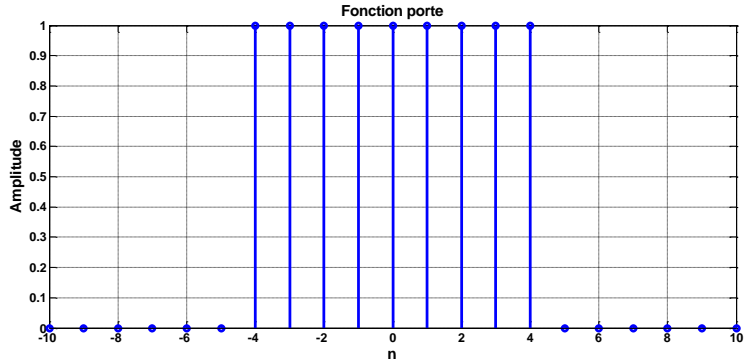
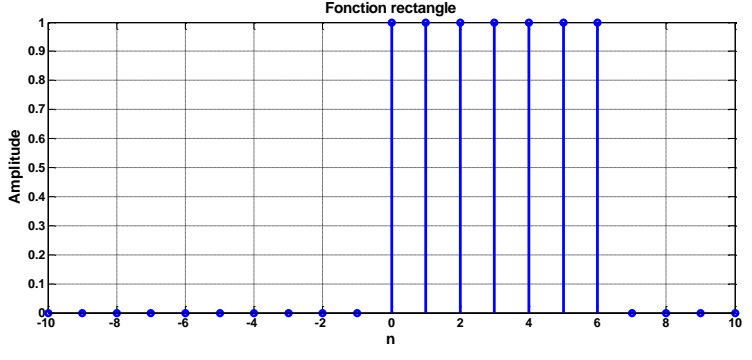


Figure III.8 : Signal échantillonné

Il existe plusieurs signaux régulièrement rencontrés en traitement du signal qui ont leur propre modélisation pour simplifier les opérations et les formules dérivées. On peut les prendre en états échantillonnés.

Tableau III.1 : Les signaux particuliers (utiles) échantillonnés

Fonction d'un signal	Représentation échantillonnée
<ul style="list-style-type: none"> Fonction signe $sgn(n) = \begin{cases} 1 & n \geq 0 \\ -1 & n < 0 \end{cases}$	
<ul style="list-style-type: none"> Fonction échelon (unité) $U(n) = \Gamma(n) = \begin{cases} 1 & n \geq 0 \\ 0 & n < 0 \end{cases}$	
<ul style="list-style-type: none"> Fonction porte $\prod_{N+1}(n) = \begin{cases} 1 & -N/2 \leq n \leq N/2 \\ 0 & \text{ailleurs} \end{cases}$	
<ul style="list-style-type: none"> Fonction rectangle causal $\text{rect}(n/N) = \begin{cases} 1 & 0 \leq n \leq N - 1 \\ 0 & \text{ailleurs} \end{cases}$	

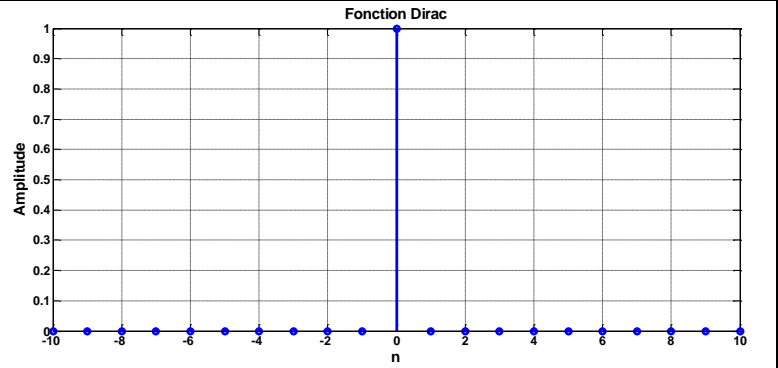
- Fonction Dirac (impulsion unité)

$$\delta(n) = \begin{cases} 1 & n = 0 \\ 0 & n \neq 0 \end{cases}$$

$$= U(n) - U(n - 1)$$

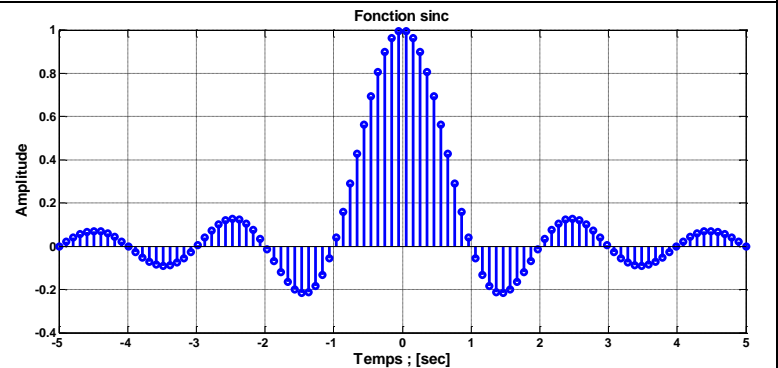
$$x(n) \cdot \delta(n - n_0) = x(n_0)$$

$$x(n) * \delta(n - n_0) = x(n - n_0)$$



- Fonction sinus cardinal

$$\text{sinc}(\theta n) = \frac{\sin(\pi\theta n)}{\pi\theta n}$$



III.6 Système de génération et de traitement du signal

Tout signal physique contient une composante aléatoire, telle que du bruit, une erreur de mesure ou une perturbation externe. Par analogie avec les nuisances acoustiques (interférences, bruit de fond...), le bruit se définit comme tout phénomène gênant qui gêne la perception ou l'interprétation d'un signal. Un ingénieur en télécommunications par satellite considérerait les ondes électromagnétiques d'origine galactique comme du bruit, alors que les radioastronomes pourraient les considérer comme un signal utile. La distinction entre signal et bruit est artificielle et dépend de l'intérêt de l'utilisateur [70].

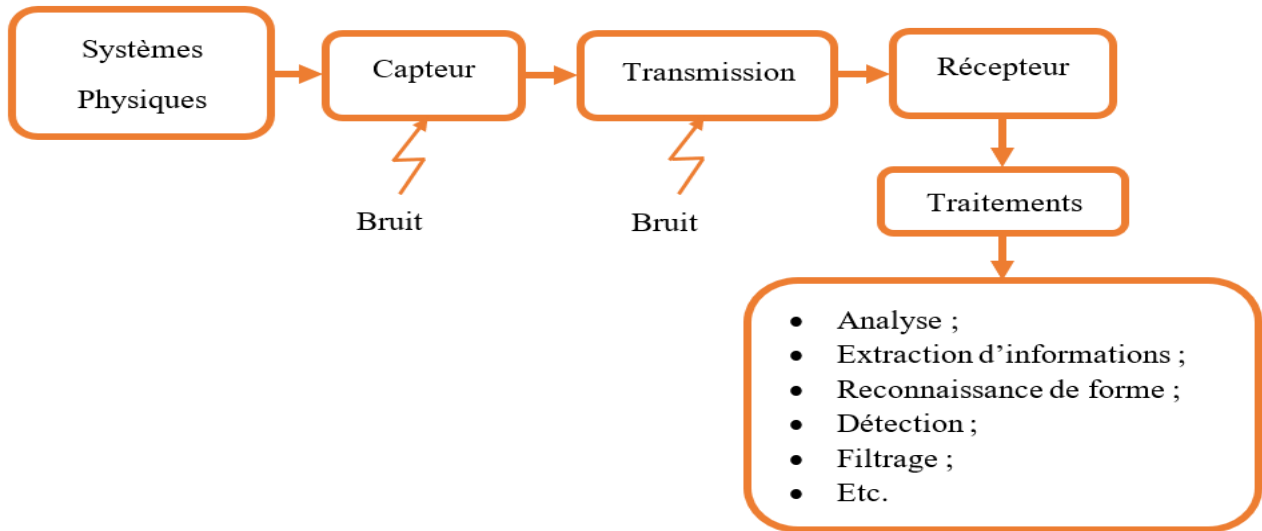


Figure III.9 : Schéma d'un système de génération et de traitement du signal

Le processus de conversion d'un signal de sa représentation dans le domaine des temps et amplitudes continus à celui des temps et amplitudes discrets est connu sous le nom de numérisation. Il est possible de diviser ce processus de numérisation du signal en deux étapes de base :

- + Echantillonnage ;
- + Quantification.




Figure III.10 : Procédure de conversion (Analogique / Numérique)

La restitution (ou l'interpolation) constitue le processus inverse qui intervient lors du passage du signal numérique au signal analogique : commande d'un actionneur. Ces trois étapes sont indissociables. En effet, le signal, étant le support physique d'une information, doit conserver au cours de ces modifications tout le contenu informatif initial. Cette condition, ajoutée à la notion de coût limite d'un système, va être à la base de la numérisation des signaux et de l'étude du traitement numérique [69].

L'utilisation d'additionneurs, de multiplicateurs numériques et de mémoire simplifie le traitement numérique. De plus, les systèmes numériques offrent un certain nombre d'avantages par rapport aux systèmes analogiques, tels que :

- ✚ **Simplicité** : les systèmes numériques sont intrinsèquement plus simples à analyser (et donc à synthétiser) que les systèmes analogiques ;
- ✚ **Possibilités de traitement accrues** : il est possible de réaliser, en numérique, des opérations beaucoup plus complexes qu'en analogique, notamment des opérations non-linéaires ;
- ✚ **Robustesse aux bruits** : les systèmes numériques sont par essence insensibles aux bruits parasites électromagnétiques. Le transcodage de l'information sous forme numérique joue un peu le rôle de « firewall » ;
- ✚ **Précision et stabilité** : puisque les seuls « bruits » sont liés à la précision des calculs, cette dernière dépend uniquement du calculateur utilisé ; elle est insensible à la température et ne varie pas avec l'âge du système ;
- ✚ **Flexibilité** : dans un grand nombre de systèmes numériques, le traitement est défini par un logiciel chargé en mémoire. Il est dès lors très facile de modifier ce traitement, sans devoir modifier la machine qui le réalise.

III.7 Traitement des signaux

Les transformations linéaires ont toujours joué un très grand rôle dans le traitement du signal, parmi elles, la plus anciennement étudiée est la transformation de Fourier (1822). Cette transformation permet d'explorer la composition fréquentielle du signal. Très tôt dans l'histoire du traitement du signal, il s'est avéré que la décomposition obtenue par Fourier n'était pas toujours la plus satisfaisante [72]. Aux années (1940), Gabor découvrait la première forme de la représentation temps-fréquence. Sa technique consiste à découper le signal en différentes plages de longueur fixe ou fenêtre. Chaque segment du signal limité par une fenêtre est étudié séparément des autres par l'analyse de Fourier. L'ensemble de ces transformées localisées forme la transformée de Gabor du signal. L'inconvénient majeur de ce procédé est que la longueur de la fenêtre étant fixée, il n'est pas possible d'analyser simultanément des phénomènes dont les échelles de temps sont différentes. Une autre techniques d'analyse qui privilégie aucune échelle particulière mais qui généralise à toutes les échelles, l'analyse locale des fréquences obtenues par la méthode de Gabor devient plus nécessaire. En 1982, J. Morlet ouvre la voie conduisant à la solution en construisant l'analyse en ondelettes, fondée sur un concept quelque peu différent de celui de fréquence : le concept d'échelle. Cette procédure développée par Stéphane Mallat et systématisée par Ingrid Daubechies, porte le nom de multi-résolution et suggère une interprétation différente de l'analyse par ondelettes. Les ondelettes constituent donc un outil parmi les plus récents du traitement du signal et qui datent de quelques décennies seulement. Elles nous permettent d'effectuer une analyse robuste et mènent à de multitudes applications. Contrairement à la transformée de Fourier à court terme (TFCT), la

transformée en ondelettes (TO) fait appel à la notion de temps-échelle impliquant des fenêtres d'analyse de longueurs dynamiques [73].

III.7.1 Série de Fourier (SF)

Un outil crucial pour l'étude des fonctions périodiques est la série de Fourier. Cette idée a servi de base au développement du domaine de l'analyse mathématique des harmoniques.

L'addition de sinusoides dont les fréquences sont des multiples entiers de « f_0 » aux sinusoides fondamentales donne un signal périodique de fréquence et de forme quelconque. Ces signaux ont des amplitudes et des positions de phase appropriées.

De même, on peut décomposer toute onde récurrente en une somme de sinusoides (fondamentale et harmoniques).

L'étude d'une fonction périodique par la SF comprend deux parties :

- **L'analyse**, qui consiste en la détermination de la suite de ses coefficients de Fourier ;
- **La synthèse**, qui permet de retrouver, en un certain sens, la fonction à l'aide de la suite de ses coefficients.

Considérons un signal périodique $x(t)$ de période $T = \frac{1}{f_0}$. Son développement en série de Fourier est alors le suivant :

$$x(t) = \frac{a_0}{2} + \sum_{k=1}^{\infty} a_k \cdot \cos(2 \cdot \pi \cdot k \cdot f_0 \cdot t) + \sum_{k=1}^{\infty} b_k \cdot \sin(2 \cdot \pi \cdot k \cdot f_0 \cdot t) \quad (\text{III.4})$$

Où $f_0 = \frac{1}{T}$ est la fréquence fondamentale du signal, $\frac{a_0}{2}$ est la valeur moyenne ou composante continue et a_k, b_k sont les coefficients de Fourier du développement en cosinus et sinus.

Les coefficients de Fourier a_k et b_k se calculent comme suit :

$$a_k = \frac{2}{T} \cdot \int_{-\frac{T}{2}}^{+\frac{T}{2}} x(t) \cdot \cos(2 \cdot \pi \cdot k \cdot f_0 \cdot t) \cdot dt \quad k \geq 0 \quad (\text{III.5})$$

$$b_k = \frac{2}{T} \cdot \int_{-\frac{T}{2}}^{+\frac{T}{2}} x(t) \cdot \sin(2 \cdot \pi \cdot k \cdot f_0 \cdot t) \cdot dt \quad k \geq 1 \quad (\text{III.6})$$

Dans le monde réel, la plupart des signaux ne sont pas stationnaires, et la majorité des informations qu'ils véhiculent se trouvent réellement dans l'évolution de leurs caractéristiques (statistiques, fréquentielles, temporelles et spatiales). Les images et les signaux vocaux en sont des exemples typiques [67].

III.7.2 Transformée de Fourier (TF)

La transformation de Fourier a été créée en 1807 et consiste à décomposer tout signal périodique en une collection de signaux sinusoidaux avec des amplitudes et des déphasages variables.

La TF est une approche mathématique permettant de déterminer le spectre fréquentiel des signaux « par exemple son ». La TF correspond à un changement de base dans l'espace des fonctions de carré sommable. Voici la définition mathématique :

$$TF\{x(t)\} = X(f) = \int_{-\infty}^{+\infty} x(t)e^{-2\pi jft} dt \quad (\text{III.7})$$

$$x(t) = TF^{-1}\{X(f)\} = \int_{-\infty}^{+\infty} X(f)e^{2\pi jft} df \quad (\text{III.8})$$

« $x(t)$ » et « $X(f)$ » sont deux explications équivalentes du même signal. Ainsi, tous les signaux à énergie finie ont une TF. Cette dernière est une fonction complexe même si « $x(t)$ » est réel :

- ✚ Si $X(f)$ est une fonction réelle $\Leftrightarrow x(t)$ est paire ;
- ✚ Si $X(f)$ est une fonction imaginaire pure $\Leftrightarrow x(t)$ est impaire ;
- ✚ $X(f)$ Pourra être exprimée sous la forme : $X(f) = |X(f)|\angle\varphi$;
 1. Le module de $X(f)$ est $|X(f)| = \sqrt{A^2(f) + B^2(f)}$;
 2. La phase de $X(f)$ est $\varphi = \arg(X(f)) = \text{arctg} \frac{B(f)}{A(f)}$.

La TFD d'ordre « N » d'un signal numérique « $x(kT_e)$ », $k = 0, \dots, (N - 1)$ est définie par :

$$X(k) = X\left(\frac{k}{N}f_e\right) = \sum_{n=0}^{N-1} x(nT_e)e^{-\frac{2\pi jnk}{N}}, \quad k = -\frac{N}{2} \dots \dots \frac{N}{2} \quad (\text{III.9})$$

Sa transformée inverse (ITFD) est donnée par :

$$x(n) = x(nT_e) = \frac{1}{N} \sum_{k=-\frac{N}{2}}^{\frac{N}{2}-1} X\left(k \frac{f_e}{N}\right) e^{\frac{2\pi jnk}{N}}, \quad n = 0 \dots \dots (N - 1) \quad (\text{III.10})$$

Où « N » représente le nombre total de points de calcul de la TFD. Il joue sur la précision du tracé alors que « X » est lié à la résolution en fréquence [71].

III.7.3 Transformée de Fourier rapide (FFT)

La transformée de Fourier rapide, est une technique mathématique de calcul rapide élaborée en 1965 par J. W. Cooley et J. W. Tuckey. La FFT permet de ramener le calcul de la transformée de Fourier discrète de « N^2 » à « $N \cdot \log(N)$ » opérations. Cette réduction de la complexité de calcul il suffit à faire passer facilement résolubles de nombreux problèmes liés à l'analyse spectrale. Pour une meilleure visualisation d'une analyse fréquentielle, la FFT est utilisée au travers d'une fenêtre glissante d'observation [68]. Malgré sa célébrité et son succès, la FFT reste inadaptable pour les signaux non stationnaires et elle montre assez vite ses limitations, perte de localisation temporelle [74].

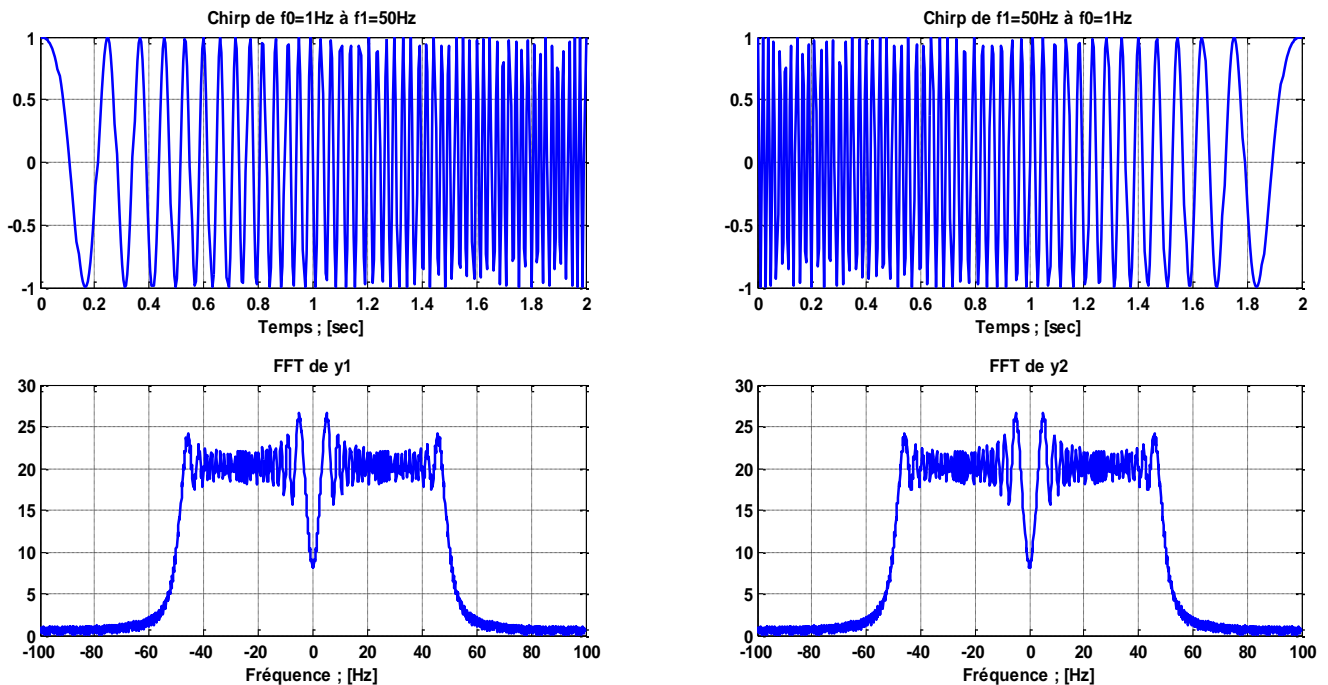


Figure III.11 : Périodogramme d'un signal Chirp allant de « $f1$ à $f2$ » et inversement

Comme illustré ci-haut, on perd toute localisation temporelle puisqu'on obtient la même TF pour les deux signaux. Rappelons que l'analyse de Fourier permet une caractérisation globale du signal (on intègre de $-\infty$ à $+\infty$), on perd toute localisation temporelle ou spatiale, l'idéal est de faire appel à une transformation qui nous apporte l'information sur le contenu fréquentiel tout en préservant la localisation (temporelle ou spatiale) afin d'obtenir une représentation temps/fréquence du signal. C'est la TFCT. Pour y remédier on

calcule la TFCT en effectuant la TFD pour différents intervalles et recouvrements.

III.7.4 Transformée de Fourier à court terme (TFCT)

La TFCT et ses dérivées « notamment le spectrogramme » sont les techniques (temps-fréquence) les plus utilisées dans les applications pratiques [75].




Figure III.12 : Représentation temporelle vers TFCT [88]

En conséquence, cette classe de techniques offre la solution la plus répandue pour éliminer les limitations de la TF. Le concept fondamental est assez simple et efficace : le signal est divisé en petits segments et on applique, sur chacune des sections, la TF en obtenant ainsi le spectre « local ». La totalité des spectres « locaux » montre alors comment le spectre varie au cours du temps. [72].

$$TFCT(x(t, f)) = X(t, f) = \int_{-\infty}^{+\infty} x(\tau) h^*(\tau - t) e^{-j2\pi f \tau} d\tau \quad (\text{III.11})$$

Le module au carré du TFCT est ce qui constitue le spectrogramme.

$$S_{x(t, f)} = \left| \int_{-\infty}^{+\infty} x(\tau) h^*(\tau - t) e^{-j2\pi f \tau} d\tau \right|^2 \quad (\text{III.12})$$

Où $h(n)$ est une fenêtre de pondération (Rectangulaire, Bartlett, Hanning, Hamming, Gaussienne, ...etc.)

Il faut relever n'existe pas qu'une seule TFCT puisqu'elle dépend de : la durée de la fenêtre (choisie pour que le signal soit supposé stationnaire sur cette durée), la forme de la fenêtre (compromis largeur-hauteur des lobes), le taux de recouvrement entre les fenêtres, ...etc.

Tableau III.2 : les fenêtres de la TFCT

Fenêtres	Expression	Largeur de la fenêtre : $L\Delta f$
Rectangulaire	$w_{Rec}(n) = \begin{cases} 1 & \text{pour } 0 \leq n \leq N \\ 0 & \text{ailleurs} \end{cases}$	$\frac{2f_e}{N}$
Triangulaire	$w_{Tri}(n) = \begin{cases} \frac{2n}{N} & \text{pour } 0 \leq n \leq \frac{N}{2} \\ \frac{2 - 2n}{N} & \text{pour } \frac{N}{2} \leq n \leq N \end{cases}$	$\frac{4f_e}{N}$
Hanning	$w_{Han}(n) = 0.5 - 0.5 \cos\left(2\pi \frac{n}{N}\right)$ pour $0 \leq n \leq N$	$\frac{4f_e}{N}$
Hamming	$w_{Ham}(n) = 0.54 - 0.46 \cos\left(2\pi \frac{n}{N}\right)$ pour $0 \leq n \leq N$	$\frac{4f_e}{N}$
Blackman	$w_{Black}(n) = 0.42 - 0.5 \cos\left(2\pi \frac{n}{N}\right) + 0.08 \cos\left(4\pi \frac{n}{N}\right)$ pour $0 \leq n \leq N$	$\frac{6f_e}{N}$

Dans un problème d'analyse spectrale, on utilise généralement plusieurs fenêtres l'une après l'autre afin d'obtenir un bon compromis résolution /déformation.

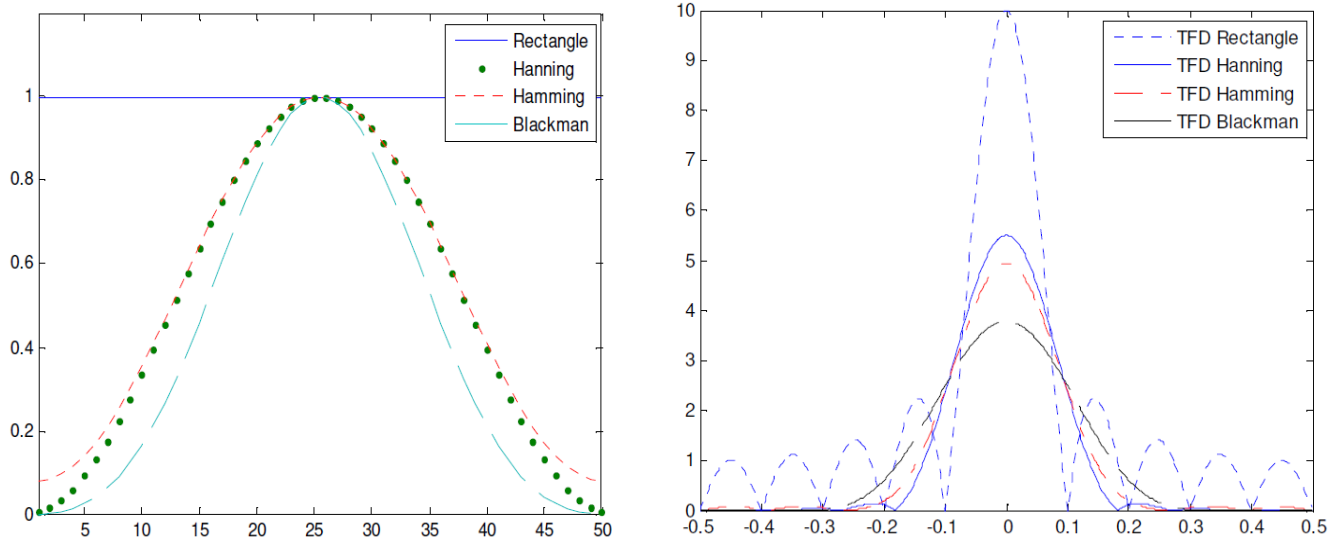


Figure III.13 : Transformée de Fourier discrète de différentes fenêtres

Le rôle de la fenêtre « $h(t)$ » (dont l'énergie doit valoir 1) est de découper un voisinage de longueur « L » du point « t », dans lequel le contenu fréquentiel est analysé. On conçoit qu'il y a un compromis entre la longueur « L » de « $h(t)$ » qui représente la résolution temporelle, qui induit une résolution fréquentielle en « f_e/L », et la capacité de la TFCT à suivre des modulations plus ou moins rapides. Ces deux résolutions évoluent en inverse l'une de l'autre. Il a été montré (principe d'incertitude d'Heisenberg) que la fenêtre qui réalise le meilleur compromis temps-fréquence est la fenêtre gaussienne.

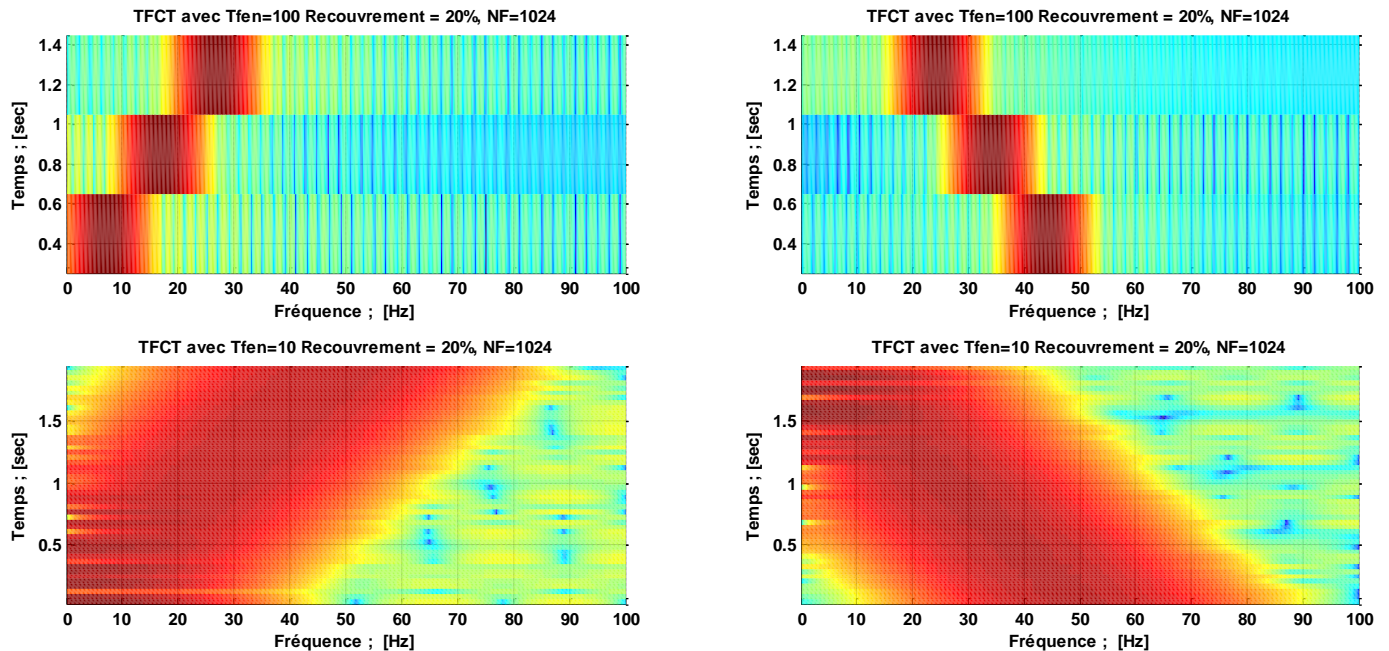


Figure III.14 : Spectrogramme d'un signal Chirp par la transformée de Fourier discrète « TFCT » et fenêtre rectangulaire

Les TFDs sur chaque fenêtre glissante fournissent le spectrogramme qui permet d'adapter la TF à la caractérisation des signaux non stationnaires. On obtient, alors, une représentation temps-fréquence permettant de localiser la distribution de l'énergie simultanément en temps et fréquence. Rappelons que la longueur de la fenêtre choisie va conditionner le nombre de points fréquentiels (résolution fréquentielles) et la résolution temporelle (spectre moyen sur la fenêtre).

Il est clair que pour ce cas, la TFCT opérant avec une taille de fenêtre unique ne permet pas de localiser précisément chaque fréquence. Celle-ci devrait s'adapter en fonction de l'évolution du signal. L'idéal serait de pouvoir choisir une fenêtre et une forme d'onde (signal oscillant dans une fenêtre temporelle donnée) que l'on pourrait dilater (pour les basses fréquences) et contracter (pour les hautes fréquences) à volonté. A partir de cette raison vient la transformée en ondelettes.

III.8 La transformée en ondelettes (TO)

Le terme ondelette présente une fonction qui oscille pendant un « temps donné » (si la variable est le temps) ou pendant un intervalle de longueur finie (si la variable est de type spatial), au-delà, la fonction tend vers zéro très vite.

Le signal étudié peut être soumis à une analyse multi-résolution grâce à la TO. L'analyse multi-résolution de la TO équivaut à une décomposition atomique temps-échelle. Chacun des atomes peut s'interpréter comme étant une projection locale du signal analysé et est obtenu à partir d'une ondelette « $\psi(t)$ » unique par une translation temporelle et une dilatation. Partant d'une fonction bien localisée, dans le plan temps-échelle [76].




Figure III.15 : Représentation temporelle vers ondelettes [88]

Dans la pratique, la plupart des signaux ne sont pas stationnaires, et c'est justement dans l'évolution de leurs caractéristiques (statistiques, fréquentielles, temporelles, spatiales) que réside l'essentiel de l'information qu'ils contiennent. Où l'analyse de Fourier propose une approche globale du signal, les intégrations sont faites de moins l'infinie à plus l'infini, et toute notion de localisation temporelle disparaît dans l'espace de Fourier ; il faut donc trouver un compromis, une transformation qui renseigne sur le contenu fréquentiel tout en préservant la localisation afin d'obtenir une représentation temps/fréquence ou espace/échelle du signal.

Historiquement, les premières ondelettes (introduites par Haar dans les années 1930) qui constituaient également une base de fonctions orthogonales. Les ondelettes de Haar présentent la particularité de ne pas être dérivables. Plus récemment, de nouvelles fonctions ondelettes ont été introduites [77, 70], qui constituent également une base de fonctions orthogonales, et qui, de plus, sont dérivables. Elles ont été notamment mises en œuvre dans le cadre de l'analyse multirésolution de signaux [78].

D'une manière semblable à la théorie d'analyse par la TFCT, les ondelettes sont des fonctions élémentaires principalement employées pour la décomposition d'un signal « f » (figure III.14), est la famille « $C(s, u)$ » coefficients d'ondelettes qui dépend des deux paramètres « s et u » où « s » est l'échelle et « u » est le facteur de position à analyser suivant les besoins de l'analyse du signal « f ».

Une fonction est traitée par ondelettes en l'écrivant comme une somme pondérée de fonctions qui ont été obtenues par des translations et des dilatations effectuées sur une fonction élémentaire dite ondelette mère.

Les paramètres « s, u » peuvent être utilisées de façon continue (TOC) ou discrète (TOD). La transformée continue d'ondelettes exigeant une continuité des valeurs des paramètres « s, u » est plutôt utilisée dans l'analyse de l'allure du signal (approximation) tandis que la transformée discrète d'ondelettes basée beaucoup plus sur l'utilisation de la complémentarité de deux filtres, passe-haut et passe bas, va servir à l'extraction d'informations caractérisant les transitions rapides du signal (détails) [79].




Figure III.16 : La transformée en ondelettes

III.8.1 La transformée en ondelettes continue (TOC)

Jean Morlet l'a développé en 1981 pour répondre aux problématiques des ondes sismiques dans la prospection pétrolière. En utilisant des paramètres de translation et de dilatation qui peuvent varier continûment sur l'ensemble des réels \mathfrak{R} , « notons que les dilatations doivent avoir des valeurs positives ». La transformée continue en ondelettes permet d'analyse des signaux.

Une ondelette mère est une fonction élémentaire qui sera translatée et dilatée pour couvrir le plan temps-fréquences et permettre d'analyser le signal.

L'ondelette mère est une fonction de moyenne nulle qui doit vérifier la condition suivante [69, 78, 80] :

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (\text{III.13})$$

On introduit une fenêtre « h » (dite fonction mère) ayant pour symbole « ψ » dépendant de « t », on peut générer un ensemble de fonctions de base similaire par dilatation (indice s) et translation (indice u) d'un seul prototype « $\psi_{u,s}(t)$ » :

$$\psi_{u,s}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-u}{s}\right); \quad s > 0 \tag{III.14}$$

Où « $s > 0$ » est un paramètre d'échelle de contraction « $s < 1$ » ou de dilatation « $s > 1$ » de la fenêtre, et « u » une translation de la fenêtre. On notera que la norme de « $\psi_{u,s}(t)$ » est conservée lors du changement de facteur d'échelle (voir figure ci-dessus) :

$$\|\psi_{u,s}\| = \int_{-\infty}^{+\infty} \frac{1}{s} \left| \psi\left(\frac{t-u}{s}\right) \right|^2 dt = \|\psi\|^2 \tag{III.15}$$

On peut prendre un exemple pour bien comprendre la représentation de l'ondelette continue « $\psi_{u,s}(t)$ » :

La fonction de Haar (ondelette mère) :

$$\psi(t) = \begin{cases} 1 & \text{si } 0 \leq t \leq \frac{1}{2} \\ -1 & \text{si } \frac{1}{2} \leq t \leq 1 \\ 0 & \text{ailleurs} \end{cases} \tag{III.16}$$

Ainsi

$$\psi_{u,s}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-u}{s}\right) = \begin{cases} \frac{1}{\sqrt{s}} & \text{si } u \leq t \leq u + \frac{s}{2} \\ -\frac{1}{\sqrt{s}} & \text{si } u + \frac{s}{2} \leq t \leq u + s \\ 0 & \text{ailleurs} \end{cases} \tag{III.17}$$

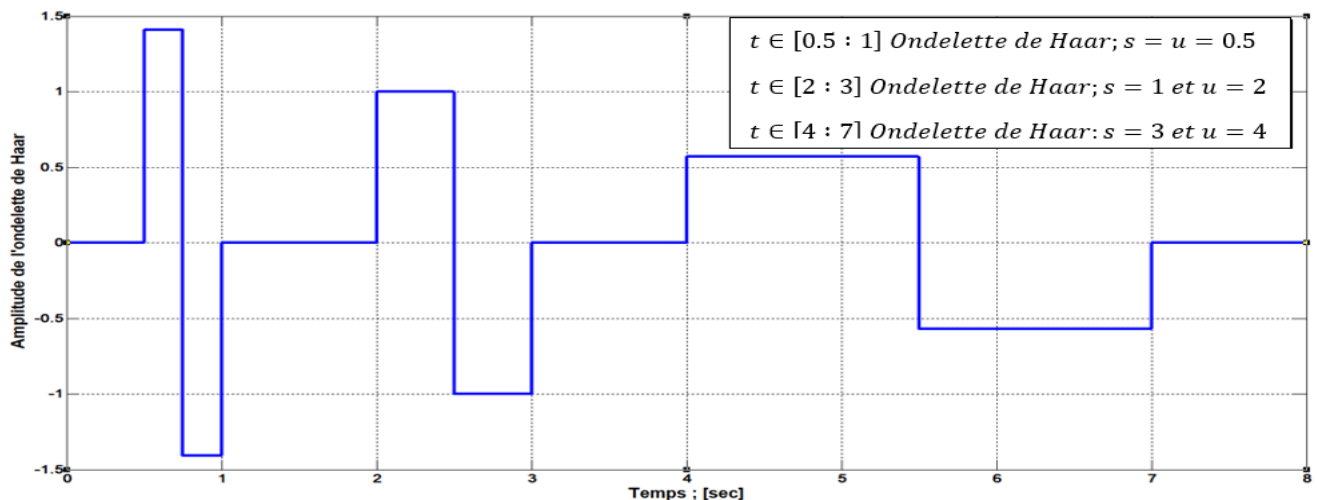


Figure III.17 : Ondelettes continue de Haar

L'ondelette la plus simple est l'ondelette de Haar, bien qu'il existe de nombreux types d'ondelettes, notamment :

- ✚ Ondelette chapeau mexicain (*Paul* à l'ordre 2) $\rightarrow \psi(t) = \frac{1}{\sigma\sqrt{2\pi}} \left(1 - \frac{t^2}{\sigma^2}\right) e^{-\frac{t^2}{2\sigma^2}}$;
- ✚ Ondelette de Morlet $\rightarrow \psi(t) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{t^2}{2\sigma^2}} e^{-2\pi jft}$;
- ✚ Etc. ...

Tableau III.3 : Famille des ondelettes [81]

Ondelette	Symbole
Haar	Haar
Daubechies	Db
Symlets	Sym
Coiflets	Coif
BiorSplines	Bior
ReverseBior	Rbio
Meyer	Meyr
Dmeyer	Dmey
Gaussian	Gaus
Mexican_hat	Mexh
Morlet	Mol
Complex Gaussian	Cgau
Shannon	Shan
Frequency B-Spline	Fbsp
Complex Morlet	Cmor

Une sinusoïde complexe modulée par une gaussienne est l'ondelette de *Morlet*. Les ondelettes de *Paul* permettent des localisations plus précises dans le temps et diminuent plus rapidement que les ondelettes de *Morlet*. L'ondelette est créée en utilisant une dérivée gaussienne, et elle permet des localisations temporelles de qualité légèrement inférieure à *Paul*.

En décomposant le signal « $x(t)$ » sur cette famille, on obtient ainsi les coefficients d'ondelettes « $WT_{x,\psi}(u, s)$ » qui caractérisent le coefficient de la décomposition du signal « $x(t)$ » dans cette base, soit :

$$WT_{x,\psi}(u, s) = \int_{-\infty}^{+\infty} x(t)\psi_{u,s}^*(t)dt = \frac{1}{\sqrt{s}} \int_{-\infty}^{+\infty} x(t)\psi\left(\frac{t-u}{s}\right)^* dt \quad (\text{III.18})$$

Où :

u : est le paramètre de localisation temporelle ;

s : est le paramètre de localisation fréquentielle ;

\sqrt{s} : assure que l'ondelette dilatée a la même énergie.

L'analyse par ondelettes commence avec une fenêtre d'analyse « s » de largeur très fine, la translate sur tout le signal puis recommence en augmentant l'échelle. Ses coefficients mesurent, en un certain sens, les fluctuations du signal « $x(t)$ » autour du point « $t = u$ », à l'échelle fournie par « s ». En diminuant « s », le support de « $\psi_{u,s}$ » réduit en temps et donc couvre une plage en fréquence plus grande et vice versa. Donc « $1/s$ » est proportionnel à une fréquence.

Pour un facteur d'échelle assez grand, la représentation des coefficients d'ondelettes en fonction de « u », la position, donne une représentation de (la forme générale de la fonction). Par contre un facteur d'échelle faible correspond à une représentation des singularités.

La transformée en ondelettes est un opérateur linéaire, invariant par translation, et par dilatation. Quelle que soit l'échelle et quel que soit l'endroit, l'analyse du signal se fait avec la même fonction. La transformée en ondelettes d'un signal n'est pas unique, elle dépend de l'ondelette mère utilisée. En effet, l'ondelette mère « $\psi(t)$ » devra avoir une bonne localisation (nulle en dehors d'un certain intervalle), et devra être oscillante, le nombre de moments nuls correspond au nombre d'oscillations).

On peut démontrer que la transformation en ondelettes est inversible si la fonction d'analyse « l'ondelette » est correctement sélectionnée. Le facteur d'échelle « a » et le paramètre de translation « b » permettent de reconstruire le signal « $x(t)$ » après double intégration :

$$x(t) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \frac{1}{a^2} WT_{x,\psi}(u, s)\psi_{u,s}^*(t) ds du \quad (\text{III.19})$$




Figure III.18 : Scalogramme du signal Chirp avec l'ondelette contenue de Haar (2D)

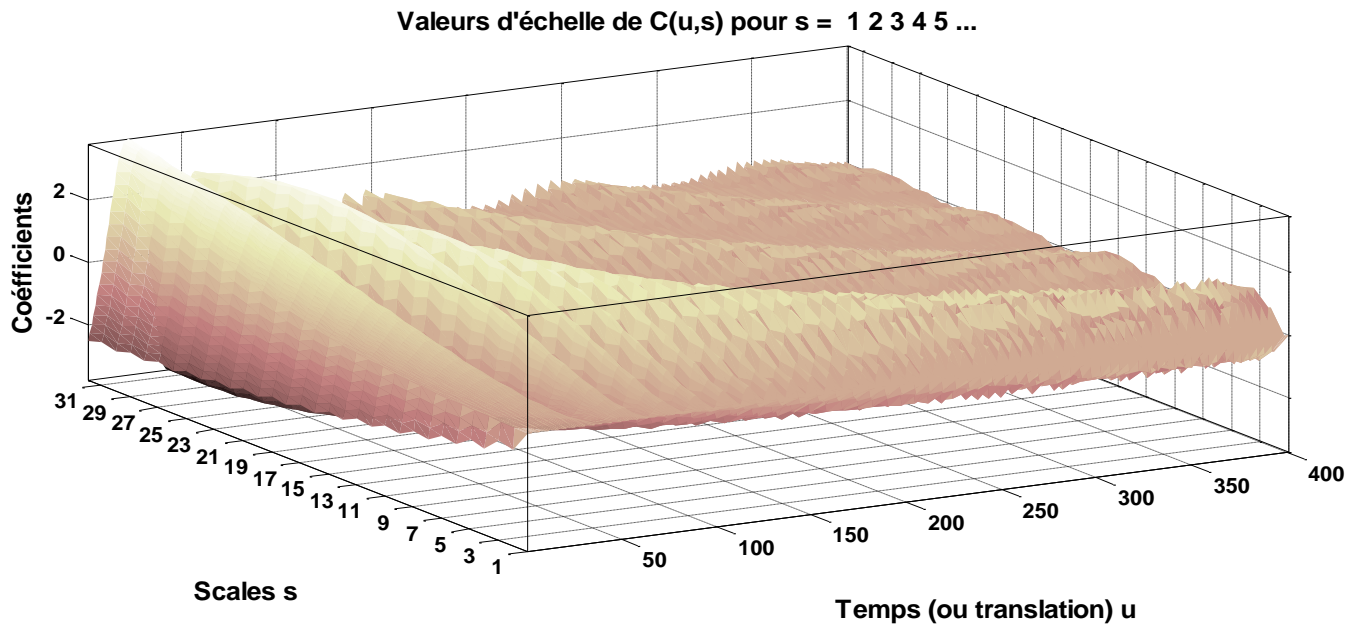


Figure III.19 : Scalogramme du signal Chirp avec l'ondelette contenue de Haar (3D)

Les coefficients de l'ondelette sont représentés en fonction du temps où les valeurs les plus élevées sont de couleur claire. On note qu'un coefficient à une amplitude d'autant plus grande que l'ondelette ressemble au signal sur la portion analysée. Lorsque la fenêtre est étroite (onde étroite), on observe les hautes fréquences et lorsqu'elle est large, ce sont les coefficients des basses fréquences qui sont élevés.

Toutefois bien que la transformation continue en ondelettes permette d'obtenir une bonne localisation temps-fréquence, toutefois, l'information engendrée par la transformation est infiniment redondante (« s » et « u » sont continus engendrant une sur analyse). Pour y remédier, on a recours à l'emploi d'ondelettes discrètes dyadiques.

III.8.2 La transformée en ondelettes discrète (TOD), ondelettes dyadiques et analyse multi-résolution

La TOC donne lieu à la version discrète, tandis que le TOD utilise un facteur d'échelle et une translation discrétisée. Toute base d'ondelettes qui fonctionne avec un facteur d'échelle de « $s = i/2$ » est appelée transformée en ondelettes discrète dyadique [82]. En analysant un signal dans de nombreuses bandes de fréquences, l'analyse multi-résolution permet une vue de la plus fine à la plus grossière.

Supposons que « φ » est la fonction de mise à l'échelle. Il doit y avoir une moyenne non nulle et elle doit être en « L^2 ».

Nous établissons les bases suivantes pour les fonctions d'échelle pour tout « $i \in \mathbb{Z}$ » :

$$\varphi_{i,j}(t) = 2^{-\frac{i}{2}}\varphi(2^{-i}t - j) \quad (\text{III.20})$$

De même, la base des ondelettes est la suivante :

$$\psi_{i,j}(t) = 2^{-\frac{i}{2}}\psi(2^{-i}t - j) \quad (\text{III.21})$$

En raison du facteur d'échelle dyadique :

$$\begin{cases} \varphi(t) = \sum_j 2h(j)\varphi(2t - j) \\ \psi(t) = \sum_j 2g(j)\varphi(2t - j) \end{cases} \quad (\text{III.22})$$

L'équation (III.22) représente la décomposition de la fonction échelle et de l'ondelette en combinaisons linéaires de la fonction échelle à la haute résolution directement.

On note que « $h(j)$ » et « $g(j)$ » sont les filtres passe bas et passe haut respectivement lors d'une décomposition par ondelettes.

La transformation en ondelettes peut aussi être considérée comme un processus de décomposition du signal en approximation et en détails. Le signal d'origine « $S(t)$ », traverse deux filtres complémentaires, passe-haut et passe-bas, et émerge en tant que deux signaux respectivement le signal d'approximations « A » et le signal de détails « D », comme la montre la figure (III.20) [83] :

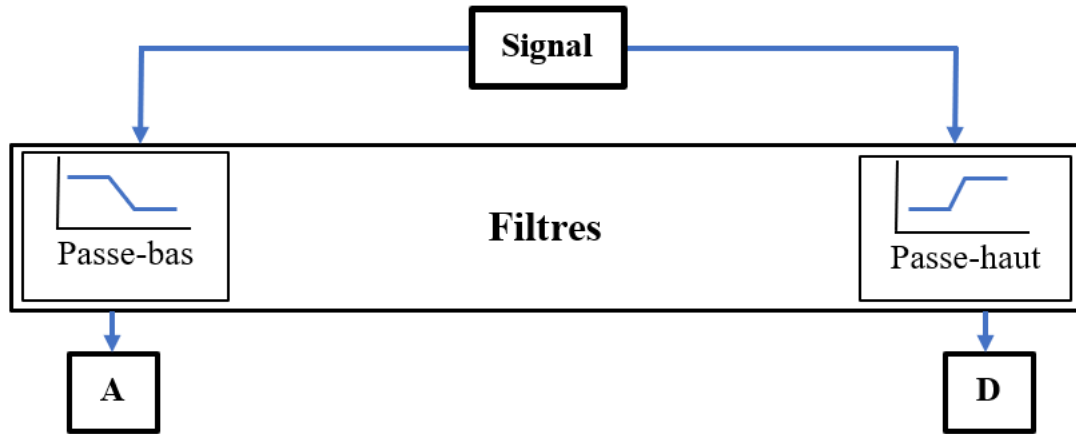


Figure III.20 : Décomposition du signal « S » en approximations et détails [88]

La partie de nombreux signaux qui a une basse fréquence est cruciale. Le signal est identifié par ceci. La partie dans les hautes fréquences, en revanche, est une caractéristique de saveur ou de nuance.

Dans l'analyse par ondelettes, seules les approximations et les détails sont discutées :

- **L'approximation** : est la partie grand échelle, basse-fréquence du signal ;
- **Le détail** : est la partie petit-échelle, haute-fréquence du signal.

III.8.2.1 Décompositions multi-niveaux par l'ondelette discrète

✚ Algorithme de Mallat

La structure suivante schématise cet algorithme :




Figure III.21 : Algorithme de *Mallat* unidimensionnel

Le signal « $f(n)$ » est divisé en différents niveaux par la technique de *Mallat* comme indiqué :

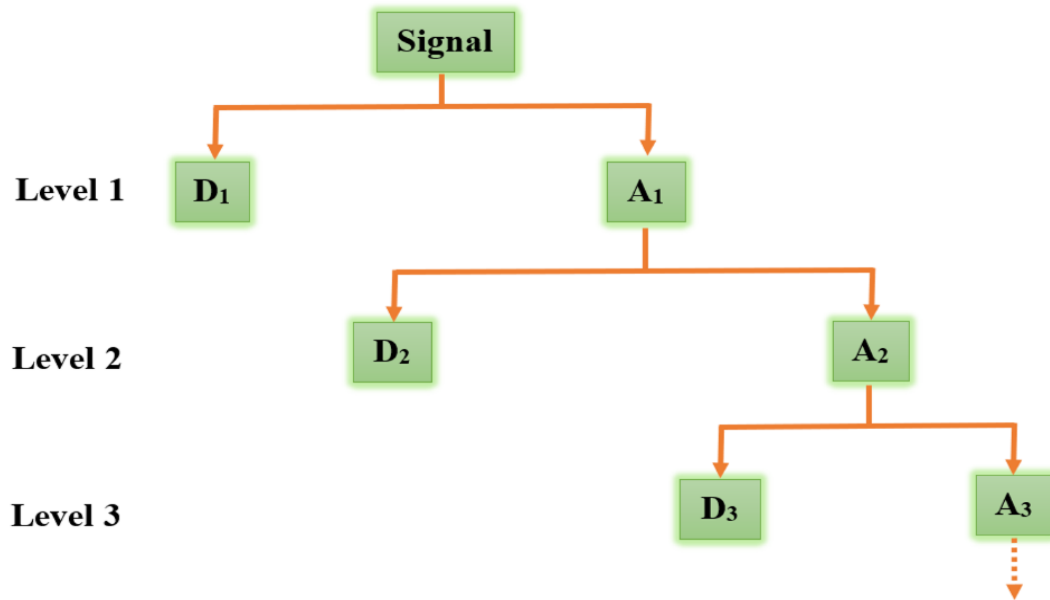


Figure III.22 : Décomposition en multi-niveaux

Nous obtiendrons « 2^l » bandes de fréquence chacune avec la même largeur de bande [84, 85] : $\left[\frac{(i-1)f_n}{2}, \frac{if_n}{2} \right]$ avec « $i = 1, 2, \dots, 2^l$ ». Telle que « f_n » est la fréquence de Nyquist dans la bande « i » de fréquence. Lorsque « $h(n)$ » et « $g(n)$ » sont les filtres de décomposition de « f_n » dans « D_1 » et « A_1 » respectivement. Le prochain (en second lieu) niveau de décomposition est basé sur « A_1 » et les coefficients sont exprimés comme suit :

$$\begin{cases} A_2(n) = \sum_k h(k - 2n)A_1 \\ D_2(n) = \sum_k g(k - 2n)A_1 \end{cases} \quad (III.23)$$

Sachant que la forme générale de l'équation (III.23) est l'équation (III.24) :

$$\begin{cases} A_j(n) = \sum_k h(k - 2n)A_{j-1} \\ D_j(n) = \sum_k g(k - 2n)A_{j-1}; n = 1, 2, \dots \end{cases} \quad (III.24)$$

III.8.3 La transformée en paquets d'ondelettes (TPO)

Le signal d'origine, qu'il soit stationnaire ou non, est divisé en plusieurs bandes de fréquence par le paquet d'ondelettes. Les bandes de fréquences séparées ne comprennent aucune donnée redondante.

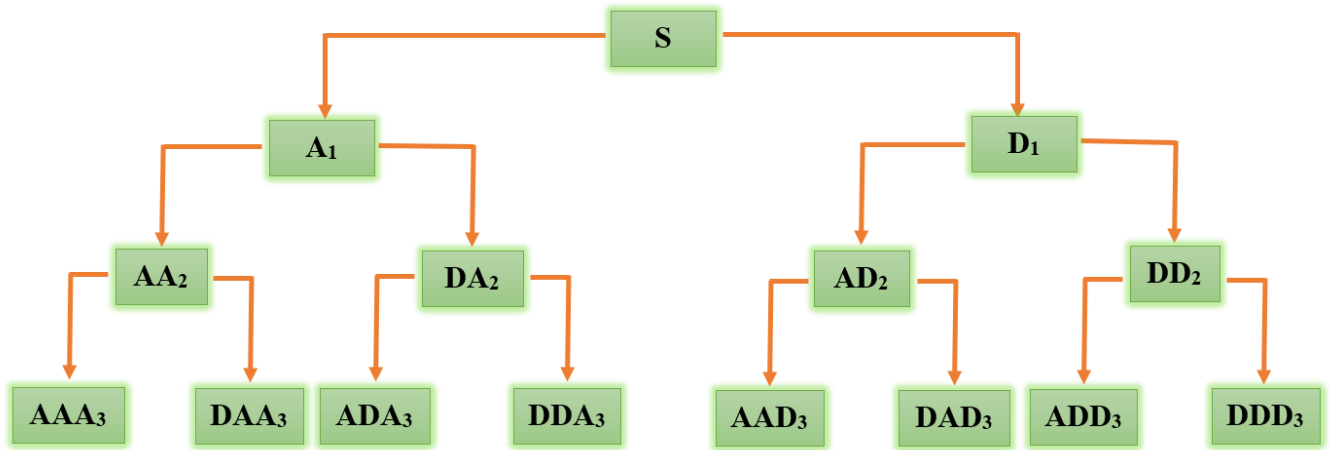


Figure III.23 : Décomposition en paquet d'ondelettes [86]

La TPO est une technique d'analyse puissante basée sur la multi-résolution, et elle pourrait être suggérée comme moyen de détection de défauts. La TPO est une génération de la TO. En spécifiant les deux fonctions suivantes [87] :

$$\begin{cases} W_0(t) = \varphi(t) \\ W_1(t) = \psi(t) \end{cases} \tag{III.25}$$

De sorte que, respectivement, « $\varphi(n)$ » et « $\psi(n)$ » représentent la fonction d'échelle et l'ondelette mère. La fonction « $W_m(n)$ » est issue de la décomposition d'ordre « m » et s'exprime comme suit :

$$W_{2m}(t) = 2 \sum_{n=0}^{2^N-1} h(n)W_m(2t - n) \tag{III.26}$$

$$W_{2m+1}(t) = 2 \sum_{n=0}^{2^N-1} g(n)W_m(2t - n) \tag{III.27}$$

$$W_{j,m,n}(t) = 2^{j/2}W_m(2^{-j}t - n) \tag{III.28}$$

Tels que :

j : paramètre d'échelle ;

n : paramètre de localisation en temps.

Dans la pratique, un algorithme rapide est appliqué en utilisant l'étape de base de la figure (II.20) (Algorithme de Mallat). La différence est maintenant que les détails et les approximations sont coupés en composant plus fins, ayant pour résultat un arbre de paquet d'ondelettes. Dans la figure (II.22) un exemple

d'un arbre de décomposition par paquet d'ondelettes de trois niveaux est illustré. Chaque nœud de l'arbre de la décomposition en paquet d'ondelettes est classé avec une paire de nombres entiers (j, k) , où « j » est le niveau correspondant à la décomposition et « k » est l'ordre de la position du nœud au spécifique niveau. Dans chaque niveau « j », il y a « 2^j » nœuds et leur ordre est « $k = 0, 1, 2, \dots, 2^j - 1$ ». Un vecteur de « C_{jA} » de coefficients de paquet d'ondelettes correspond à chaque nœud (j, k) . La longueur d'un « C_{jA} » du vecteur est approximativement « $N_t/2^j$ ». La reconstitution des signaux est basée sur les coefficients d'approximation et les détails [88].




Figure III.24 : Répartition des nœuds dans un arbre de décomposition par paquet d'ondelettes

III.9 Conclusion

Les techniques de traitement du signal ont été abordées dans ce chapitre de manière progressive, en commençant par la série de Fourier et en terminant par les ondelettes. Des exemples démontrant clairement la contribution de chacune de ces technologies à l'analyse du signal. L'analyse du signal par FFT trouve ses limites par son incapacité de reconnaissance des signaux non stationnaires alors que la TFCT semble avoir surmonté cet inconvénient dans le plan temps-fréquences. Avec ses inconvénients d'utiliser une fenêtre à taille unique et son choix est très délicat pour assurer un compromis de résolution temporelle et fréquentielle, pour cela on a fait l'appel de la transformée en ondelette avec ses variétés continue, discrète et en paquet.

D'après ce que nous avons dit, La méthode de paquets d'ondelettes est une généralisation de la décomposition en ondelettes qui offre une gamme plus riche de possibilités pour l'analyse du signal.

Cette approche (TPO) avec les paramètres statistiques présentent la première étape d'un algorithme de détection de défauts puisqu'elles permettent uniquement d'extraire l'information liée au défaut (visualisation de l'impact du défaut sur le courant statorique « I_{as} »). Une seconde étape doit être mise en place afin de réaliser le diagnostic (classification, mesure de sévérité et prise de décision). Cette seconde étape peut être réalisée en se basant sur les techniques d'intelligence artificielle (ou outils de reconnaissance de formes) telles que les réseaux de neurones (ANN), et la forêt aléatoire (Random Forest « RF »). C'est exactement le but du quatrième chapitre « Surveillance de défauts des barres cassées rotoriques de la MAS par les méthodes intelligentes ».

Chapitre IV

Surveillance de défauts des barres cassées

rotoriques de la MAS par

les méthodes intelligentes

IV.1 Introduction

Les sujets d'ingénierie, notamment la surveillance de l'état des installations industrielles, l'identification précoce des défauts, le diagnostic et la classification, sont cruciaux. Parmi les nombreux systèmes d'ingénierie on trouve les machines électriques qui fonctionneront de manière plus rentable, sûre et fiable grâce à une surveillance améliorée à l'aide d'un mécanisme automatique de détection des défauts [89].

La détection et le diagnostic automatique des défauts sont devenus des techniques cruciales dans l'industrie en raison de l'intégration des procédures intelligentes dans les systèmes de surveillance des machines électriques tournantes. Parmi ces machines on trouve la MAS est de plus en plus utilisée à cause de leur robustesse. Mais comme toute autre machine, elle n'est pas à l'abri d'un dysfonctionnement. Elle peut être affectée par des défauts électriques ou mécaniques au niveau du stator, ou du rotor, ou les deux à la fois.

La planification, l'inspection de routine, le remplacement de pièces et la maintenance préventive sont des méthodes classiques pour prévenir les dysfonctionnements des machines tournantes. Malgré leur efficacité, ces technologies sont toujours incapables de fournir une alerte précoce des conditions de fonctionnement typiques de la machine.

Dans la plupart des cas, pour identifier les détériorations des composantes, la méthode générale est de classer les images par le biais d'une inspection visuelle faite par un technicien. Ceci est clairement dépendant de l'expérience humaine et introduit de nombreux facteurs subjectifs et des erreurs de diagnostic. Sans surprise, les résultats de la reconnaissance ne sont généralement pas très bons et pour cette raison, il est nécessaire de développer des systèmes de surveillance automatiquement pour détecter les défauts de façon plus fiable et plus efficace. Pour cette raison, la détection automatique des défauts et les méthodes de diagnostic qui surveillent la machine en fonctionnement sont de plus en plus courantes.

Ce présent chapitre s'intéresse au défaut mécanique de la MAS : le défaut rotor du type rupture de barres de la cage rotorique. Les exigences de sûreté de fonctionnement et de productivité des installations industrielles ont motivé un effort important de recherche pour la détection et le diagnostic des défauts. Par conséquent, plusieurs stratégies sont utilisées dans ce domaine.

Parmi les approches ou les méthodes que nous avons adopté sont les méthodes intelligentes (ANN et RF) ont fourni de bonnes performances pour résoudre les problèmes de diagnostic de défauts et l'automatisation de la procédure de surveillance.

Les ANN et RF ont montré par ailleurs leur pertinence pour la détection de défauts par reconnaissance de formes. Pour cette raison ce chapitre propose un système de surveillance basé sur l'application des réseaux de neurones (ANN) et la forêt aléatoire (RF), avec l'assistance de quelques algorithmes d'optimisations comme BPSO, BBAT, et l'algorithme de réduction de dimensions PCA, pour la détection et la localisation des défauts de ruptures des barres rotoriques de la MAS.

Pour réaliser le but de ce chapitre, on va commencer par une présentation des RNA, leurs différentes architectures, leurs applications et éventuellement les règles et les algorithmes d'apprentissage. On s'attardera un petit plus sur le perceptron multicouche de réseau Feedforward, c'est le type que nous allons utiliser dans notre application pour la classification des différents défauts des cassures de barres rotoriques de la MAS. Ensuite, la méthode de la forêt aléatoire (RF), leurs applications dans le même contexte de détection des défauts rotoriques sans algorithmes d'optimisation, et finalement on va assister la procédure de classement des défauts par les algorithmes BPSO, BBAT, et PCA pour améliorer la précision de détection et la localisation de défaut des barres cassées.

IV.2 Méthodologie d'utilisation des ANN et RF dans le domaine du diagnostic

Les RNA et RF constituent aujourd'hui une technique de traitement de données bien comprise et maîtrisée, qui devrait faire partie de la boîte à outils de tout chercheur soucieux de tirer le maximum d'informations pertinentes des données dont il dispose : effectuer des prévisions, de la fouille de données ; élaborer des modèles, reconnaître des formes ou des signaux. Dans ce chapitre, les ANN et RF sont utilisés pour la détection et le diagnostic des défauts de la machine asynchrone en se basant sur la reconnaissance des signatures de défauts extraits à partir de signaux mesurables (les courants statoriques « I_{abcs} »).

Avant d'aborder les performances des méthodes intelligentes (ANN et RF) dans le domaine de diagnostic de défauts, il faut prendre une idée un peu détaillée sur leurs types, et leur principe de fonctionnement.

IV.3 Réseaux de neurones (ANN)

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

- ✚ **Le parallélisme** : les neurones sont des entités réalisant une fonction très simple, mais ils sont très fortement interconnectés entre eux, ce qui rend le traitement du signal massivement parallèle.
- ✚ **Les poids synaptiques** : les connexions entre les neurones ont des poids variables, qui déterminent la force de l'interaction entre chaque paire de neurones.
- ✚ **L'apprentissage** : ces coefficients synaptiques sont modifiables lors de l'apprentissage, dans le but de faire réaliser au réseau la fonction désirée. La fonction que réalise un réseau dépend de sa structure (connexions et forces des connexions) ainsi que de l'opération effectuée par les neurones [90].

IV.3.1 Neurone biologique

Le neurone biologique est une cellule vivante spécialisée dans le traitement des signaux électriques. Les neurones sont reliés entre eux par des liaisons appelées axones. Ces axones vont eux-mêmes jouer un rôle important dans le comportement logique de l'ensemble. Ces axones conduisent les signaux électriques de la sortie d'un neurone vers l'entrée (synapse) d'un autre neurone [91].

Les neurones font une sommation des signaux reçus en entrée et en fonction du résultat obtenu vont fournir un courant en sortie (figure IV.1).




Figure IV.1 : Le neurone biologique [91]

Les neurones sont constitués de quatre parties principales :

- **Les dendrites** : sur lesquelles les autres cellules entrent en contact synaptique : c'est par les dendrites que se fait la réception des signaux.
- **Le noyau** : le corps de la cellule, c'est l'unité de traitement.
- **L'axone** : où passent les messages accumulés dans le corps de la cellule : l'envoi de l'information se fait par l'axone.
- **Les synapses** : par lesquelles la cellule communique avec d'autres cellules, ce sont des points de connexion par où passent les signaux de la cellule.

IV.3.2 Neurone artificiel

Un neurone artificiel est un modèle simplifié de neurone biologique (figure IV.1), ce modèle imite quelques fonctions du neurone biologique, comme la mémorisation associative, l'apprentissage et le travail parallèle.

IV.3.3 Présentation des réseaux de neurones artificiels

IV.3.3.1 Principe de fonctionnement

Chaque entrée est affectée d'un poids. Le passage des entrées dans le corps du neurone se fait en deux étapes. La première étape consiste à faire une somme pondérée des entrées par les poids respectifs de connexions sur lesquelles ces entrées se propagent. La seconde étape consiste à calculer l'image de cette somme pondérée par une fonction de transfert binaire. Le résultat obtenu provoque ou non le déclenchement d'un potentiel d'action suivant le dépassement d'un seuil, et sert à son tour d'entrée à d'autres neurones [92].

IV.3.3.2 Bref historique

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

le résoudre. Dès lors, une machine, reprenant les règles de toutes les autres, est universelle.

D. Hebb, en 1949 propose une règle d'apprentissage dans son livre « *The Organization of Behavior* ». De nombreux modèles de RN aujourd'hui s'inspirent encore de la règle de *Hebb*.

F. Rosenblatt a créé le modèle perceptron en 1958. Il s'agit d'un RN inspiré du système visuel. Il a deux couches de neurones : une couche pour la perception et une autre pour la prise de décision. C'est le premier système artificiel capable d'acquérir des connaissances par l'expérience. *B. Widrow* et *Hoff* ont également présenté le modèle Adaline (Adaptive Linear Element) au même moment. Par la suite, Ce modèle sera la base des réseaux multicouches.

Une critique des caractéristiques du Perceptron a été publiée en (1969) par *M. Minsky* et *S. Papert*. Cela aura un effet significatif sur ce domaine de recherche. Elle va fortement diminuer jusqu'en (1972), où *T. Kohonen* présente ses recherches sur les mémoires associatives et propose des applications à la reconnaissance des formes. *J. Hopfield* a présenté ses recherches sur un réseau entièrement bouclé dans (1982), dans lesquelles il a examiné la dynamique.

La technique de rétropropagation du gradient de *Werbos*, qui permet d'entraîner les couches cachées des réseaux de neurones, s'est généralisée en (1985) grâce à *Rumelhart* [90].

IV.3.4 Modélisation générale d'un réseau de neurones artificiel

Par analogie avec la biologie, un neurone artificiel (figure IV.2), reçoit l'information provenant des entrées « x_i » avec « $i = (1, 2, 3 \dots n)$ » par l'intermédiaire des connexions dont on affecte à chacune d'elles un poids « w_i » abréviation de (Wight en Anglais) pondérant l'information, et aussi représentatif de la force de la connexion.

Le neurone artificiel fonctionne en deux étapes :

- ✓ **La première phase** : représente les prétraitements des données reçus en calculant le potentiel « v_j » des neurone « j » par la fonction suivante :

$$v_j = b_j + \sum_{i=1}^n w_{j,i} \cdot x_i \quad (\text{IV.1})$$

Où :

$w_{j,i}$: Désigne le poids de la connexion liant le neurone « j » à l'entrée « i » ;

b_j : Terme constant appelé biais, il est considéré comme le poids d'une entrée « x_0 » égal à « 1 ».

Ainsi que la relation s'écrit plus simplement :

$$v_j = \sum_{i=0}^n w_{j,i} \cdot x_i \quad (\text{IV.2})$$

✓ **La deuxième phase** : une fonction de transfert « g » appelée également **fonction d'activation**, calcule la valeur de l'état interne « S_j » du neurone « j » à partir de la valeur du potentiel « v_j ». Cette valeur désignera la sortie du neurone :

$$S_j = g(v_j) = g(\sum_{i=0}^n w_{j,i} \cdot x_i); \quad i = (1, 2, 3 \dots n) \quad (\text{IV.3})$$

Le choix de la fonction d'activation se révèle dans certains cas être un élément constitutif important des réseaux de neurones. Ainsi, le neurone peut être défini mathématiquement comme étant une fonction algébrique, non linéaire (suivant « g ») et bornée, des entrées « x_i » et paramétrée par les poids « $w_{j,i}$ » [93].

$$S_j = g(x_i, w_{j,i}) = g_{w_{j,i}}(x_i); \quad i = (1, 2, 3 \dots n) \quad (\text{IV.4})$$




Figure IV.2 : Neurone artificiel [94]

Après cela, le neurone exécute trois opérations sur ses entrées [95] :

- ✚ **Pondération** : chaque entrée est multipliée par une variable appelée poids de connexion.
- ✚ **Somme** : les entrées pondérées sont additionnées pour générer une somme.

✚ **Une fonction d'activation** : Le fonctionnement du neurone et du réseau dépend de cette fonction d'activation, qui est cruciale pour générer les sorties. Comme nous le verrons dans la section suivante, il peut prendre diverses formes. Le tableau (IV.1) fournit une liste de diverses fonctions de transfert qui peuvent être utilisées comme fonction d'activation du neurone. Les fonctions « seuil » (en anglais « hard limit »), « linéaire et sigmoïde » sont les fonctions d'activation les plus fréquemment utilisées. La fonction de seuil, comme son nom l'indique, applique un seuil à son entrée. Plus précisément, si une entrée négative n'atteint pas le seuil, la fonction renvoie la valeur « 0 » (que nous pouvons interpréter comme signifiant faux), alors que si une entrée positive ne franchit pas le seuil, la fonction renvoie la valeur « 1 » (que nous pouvons lire comme signifiant vrai). La figure (IV.3.a) montre comment cette fonction est utilisée dans le contexte d'un neurone.




Figure IV.3 : Fonctions d'activations des neurones

On remarque alors que le biais « b » dans l'expression de « $y = \text{hadlim}(w^T x - b)$ » de l'équation :

$$y = f(s) = f(w^T x \pm b) \quad (\text{IV.5})$$

Détermine l'emplacement du seuil sur l'axe « $w^T x$ », où la fonction passe de « 0 à 1 ».

La fonction linéaire est relativement simple ; elle relie simplement son entrée avec sa sortie :

$$y = s \quad (\text{IV.6})$$

La figure (IV.3.b) fournit une illustration de cette fonction en ce qui concerne un neurone. Dans ce cas, la sortie du neurone reflète son niveau d'activation dont le passage à zéro se produit lorsque « $w^T x = b$ ».

La fonction « sigmoïde » se présente comme une approximation continûment dérivable de la fonction d'activation linéaire par morceaux ou de la fonction seuil. Elle présente l'avantage d'être régulière, monotone continûment dérivable, et bornée entre « 0 et 1 » [95] :

$$f(x) = \frac{1}{1+e^{-s}} \tag{IV.7}$$

Tableau IV.1 : Différentes fonctions d’activations utilisées dans les RNA (ANN)

Nom de la fonction	Relation entrée/sortie	Icône	Nom au Matlab
Seuil	$\begin{cases} y = 0 & \text{si } s < 0 \\ y = 1 & \text{si } s \geq 0 \end{cases}$		hardlim
Seuil symétrique	$\begin{cases} y = -1 & \text{si } s < 0 \\ y = 1 & \text{si } s \geq 0 \end{cases}$		hardlims
Linéaire	$y = s$		purelin
Linéaire saturée	$\begin{cases} y = 0 & \text{si } s \leq 0 \\ y = s & \text{si } 0 < s \leq 1 \\ y = 1 & \text{si } s > 1 \end{cases}$		satlin
Linéaire saturée symétrique	$\begin{cases} y = -1 & \text{si } s < -1 \\ y = s & \text{si } -1 \leq s \leq 1 \\ y = 1 & \text{si } s > 1 \end{cases}$		satlins
Linéaire positive	$\begin{cases} y = 0 & \text{si } s \leq 0 \\ y = s & \text{si } s > 0 \end{cases}$		poslin
Sigmoïde	$y = \frac{1}{1 + e^{-s}}$		logsig
Tangente hyperbolique	$y = \frac{e^s - e^{-s}}{e^s + e^{-s}}$		tansig
Compétitive	$\begin{cases} y = 1 & \text{si } s \text{ maximum} \\ y = 0 & \text{si autrement} \end{cases}$		compet

IV.3.5 Domaines d'application des réseaux de neurones

Les réseaux de neurones offrent un large éventail d'applications, et nous avons sélectionné le domaine du diagnostic des défauts de la MAS. Les réseaux ANN sont bien adaptés à la résolution des problèmes de diagnostic, utilisant la classification automatique des signaux et des formes. Dans ce contexte le tableau suivant présente quelques modèles [96] :

Tableau IV.2 : Correspondance RNA-Domains d'applications

Caractéristiques fonctionnelles	Type de RNA (ANN)
Reconnaissance de formes	MLP, Hopefield, Kohonen, PNN
Mémoires associatives	Hopefield, MLP récurrents, Kohonen
Optimisation	Hopefield, ART, CNN
Approximation de fonctions	MLP, RBF
Modélisation et contrôle	MLP, MLP récurrent, FLN
Traitement des images	CNN, Hopefield
Classification et clustering	MLP, Kohonen, RBF, ART, PNN

IV.3.6 Structure d'interconnexion

La topologie du réseau est représentée par les connexions entre les neurones qui composent le réseau. Cela peut être n'importe quoi, mais la plupart du temps, il est capable d'identifier une certaine cohérence.

IV.3.6.1 Réseau multicouches

Les couches sont utilisées pour organiser les neurones. Seules des connexions sont créées avec les neurones des couches aval ; il n'y a pas de lien entre les neurones d'une même couche (Figure IV.4). habituellement, chaque neurone d'une couche est connecté à tous les neurones de la couche suivante et à celle-ci seulement.




Figure IV.4 : Les couches d'un réseau multicouche

Cela nous permet de créer les notions de neurone d'entrée et de neurone de sortie et d'introduire l'idée de direction du flux d'information (activation) au sein d'un réseau. Par extension, on désigne l'ensemble des neurones d'entrée dans la couche d'entrée et l'ensemble des neurones de sortie dans la couche de sortie. Les couches cachées sont des couches intermédiaires qui n'interagissent pas avec l'environnement extérieur.

IV.3.6.2 Réseau à connexions locales

C'est une structure multicouche qui conserve néanmoins une topologie particulière et l'aspect de la rétine. Chaque neurone conserve des connexions avec un nombre réduit et localisé de neurones de la couche avale (Figure IV.5). Par conséquent, il y a moins de connexions que dans un réseau multicouche classique.

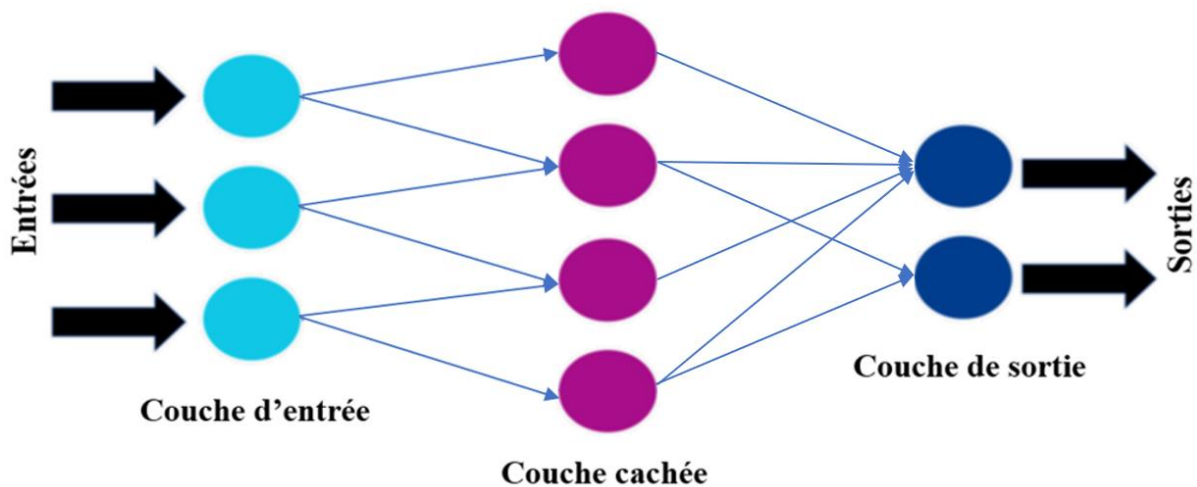


Figure IV.5 : Réseau à connexions locales

IV.3.6.3 Réseau à connexions récurrentes

Les connexions récurrentes ramènent l'information en arrière par rapport au sens de propagation défini dans un réseau multicouches. Ces connexions sont le plus souvent locales (Figure IV.6).




Figure IV.6 : Réseau à connexions récurrentes

Les connexions récurrentes rendent les réseaux plus puissants car ils sont séquentiels plutôt que combinatoires, comme l'étaient ceux décrits précédemment. Un tel réseau peut présenter un comportement temporel grâce à la rétroaction de la sortie vers l'entrée.

IV.3.6.4 Réseau à connexions complexes

La structure d'interconnexion la plus générale est illustrée à la (Figure IV.7). Chaque neurone du réseau est lié à tous les autres neurones ainsi qu'à lui-même. Chaque vecteur d'activation décrit la réponse du réseau à une date particulière.




Figure IV.7 : Réseau à connexions complexes

IV.3.7 Apprentissage

La caractéristique la plus intrigante des réseaux de neurones est probablement l'apprentissage. Cependant, seuls les modèles les plus utilisés sont concernés. Dans le cas des RNA, on ajoute souvent à la description du modèle l'algorithme d'apprentissage. Le modèle sans apprentissage présente en effet peu d'intérêt. Dans la majorité des algorithmes actuels, les variables modifiées pendant l'apprentissage sont les poids des connexions. Choisir a priori les valeurs des poids de connexions d'un réseau pour une application spécifique est souvent impossible.

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

Au niveau des algorithmes d'apprentissage, il a été défini deux grandes classes selon que l'apprentissage est dit supervisé ou non supervisé. Cette distinction repose sur la forme des exemples d'apprentissage. Dans le cas de l'apprentissage supervisé, les exemples sont des couples (entrées, sortie associée) alors que l'on ne dispose que des valeurs (entrées) pour l'apprentissage non supervisé. Remarquons cependant que les modèles à apprentissage non supervisé nécessitent avant la phase d'utilisation une étape de labélisation effectuée par l'opérateur, qui n'est pas autre chose qu'une part de supervision [97].

IV.3.7.1 Réseaux statiques (Apprentissage par « paquet ») et Réseaux dynamiques (Apprentissage « séquentiel »)

La structure des données aura un impact sur l'évolution des poids et des biais des RN lors de leur apprentissage. Un réseau qui n'a pas de connexion en arrière (feedback or delay) est appelé statique. Cela n'affectera pas l'évolution de ses poids tout au long de la phase d'apprentissage car nous pouvons lui donner les données d'entrée dans n'importe quel ordre. L'ensemble des données doit alors être envoyé en une seule fois pendant la phase d'apprentissage ; c'est ce qu'on appelle le « batch training » ou apprentissage par paquet.

Les processus dépendant du temps ne peuvent pas être simulés par des réseaux à anticipation « Feedforward ». D'autre part, un réseau de neurones avec des connexions arrière peut être utilisé pour simuler un processus dépendant du temps. La séquence dans laquelle l'ensemble de données est présenté au réseau de neurones sera donc cruciale. On parle alors d'apprentissage séquentiel.

IV.3.7.2 Règle de *HEBB*

La plus ancienne stratégie d'apprentissage remonte à 1940 et est basée sur la biologie. L'idée est que lorsque deux neurones sont activés en même temps, leurs connexions deviennent plus fortes. Nous sommes capables de calculer immédiatement les poids correspondant à l'apprentissage d'un nombre précis d'exemples, ce qui nous permet de classer cette règle en apprentissage supervisé ou non supervisé.

IV.3.7.3 Règle du DELTA (ou règle de *Widrow Hoff*)

Son objectif est de faire évoluer le réseau vers le minimum de sa fonction d'erreur « erreur commise sur l'ensemble des exemples ». Le modèle ADALINE l'utilise. L'apprentissage se fait de manière itérative « les poids sont modifiés après chaque exemple présenté », et on obtient le poids à l'instant « $t + 1$ » par la formule :

$$W(t + 1) = W(t) + \eta \cdot (T - O) \cdot E \quad (\text{IV.8})$$

Si « W » est le poids, « T » la sortie théorique et « O » la sortie réelle, « E » l'entrée et « η » un coefficient d'apprentissage (entre 0 et 1) que l'on peut diminuer au cours de l'apprentissage. Cette règle s'interprète par le fait que l'on modifie le poids proportionnellement à l'erreur (différence entre sortie théorique et sortie donnée) et à l'état d'excitation de l'entrée gérée par le poids. Ainsi le poids ne sera pas modifié si la sortie est celle voulue, ou si le poids n'a joué aucun rôle dans le résultat. C'est en fait un cas particulier de l'algorithme de rétropropagation du gradient pour un réseau à une couche [90].

VI.3.8 Principaux types de réseaux de neurones

Il existe différents modèles de RNA ; nous en présenterons quelques-uns que nous avons sélectionnés principalement pour leur valeur pédagogique. Le premier modèle était historiquement le perceptron. En fait, il sert toujours de modèle fondamental pour le Perceptron multicouche, qui est considéré comme plus plausible sur le plan biologique. Ce modèle nous permet d'introduire le concept d'apprentissage supervisé. Pour la suite de notre application, son fonctionnement est extrêmement important. Des modèles plus élaborés sont étudiés par la suite tant au niveau de leurs architectures que des techniques d'apprentissage. Ce sont les réseaux récurrents, le réseau à fonction de base radiale et le réseau ART [97].

VI.3.8.1 Réseaux de neurones compétitifs

Ces réseaux peuvent détecter des régularités et des corrélations dans les données d'entrées et peuvent adapter leurs réponses en fonction de ces entrées. Les neurones de ces réseaux peuvent reconnaître des groupes dans

les vecteurs d'entrée. Les cartes auto organisatrices peuvent apprendre à reconnaître des groupes de vecteurs similaires, ce qui entraîne que les neurones, physiquement proches les uns des autres dans la couche de neurones, à répondre à ces vecteurs d'entrée similaires.

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

✚ Réseau de neurone compétitif ou réseau de *Kohen* (loi d'apprentissage de *Kohen*)

Selon la loi de *Kohen*, qui stipule que le poids d'un neurone doit être ajusté dans la phase suivante s'il est proche des données d'entrée. Ainsi, ce type de réseau est capable d'apprendre à catégoriser des vecteurs d'entrée. L'évolution de la colonne « i » de la matrice des poids du réseau est présentée par la règle de *Kohen* :

$$W_i(q) = W_i(q - 1) + \alpha[p(q) - W_i(q - 1)] \quad (\text{IV.9})$$

Par conséquent, s'il y a suffisamment d'exemples et de neurones, il se peut même que la sortie des neurones gagnants prend la valeur « 1 », tandis que les autres prennent la valeur « 0 ».

Réseaux de neurones LVQ

Une première couche de neurones compétitifs et des neurones à fonction de transfert linéaire dans la seconde constituent les réseaux LVQ. Ce type de réseaux apprend à classifier mais grâce à la deuxième couche, ce réseau classera selon les critères de classification exigés par l'utilisateur.

VI.3.8.2 Réseaux de neurones à fonctions de base radiales (Radial Basis Network)

Ces réseaux sont des réseaux multicouches à couche cachée et sont appelés réseaux RBF « *Radial Basis Functions* ». Les fonctions de transfert de cette couche cachée, contrairement aux perceptrons multicouches, dépendent de la séparation entre le vecteur d'entrée et un vecteur central. Cette fonction de transfert est fréquemment le noyau gaussien en pratique :

$$s = \exp \left[- \left[\frac{|e-c|}{\sigma} \right]^2 \right] \quad (\text{IV.10})$$

Où :

σ : est le facteur de largeur ;

c : est le vecteur centre.

La fonction de transfert dans ce cas est exponentielle. L'opération de multiplication (des matrices, élément par élément) remplace l'opérateur de sommation. Par rapport à un réseau « Feedforward », les réseaux à base radiale ont besoin de beaucoup plus de neurones [97].

Si la fonction d'activation de la couche de sortie est linéaire. Pour éviter d'avoir trop de complexité des calculs, les trois différents types de paramètres (centres, largeurs et poids) sont optimisés séparément [90].

✚ Réseaux de neurones à régression généralisée (Generalized regression neural networks)

Dans un GRNN, il y a un réseau à base radiale auquel on ajoute une couche de sortie constituée d'une fonction de transfert linéaire. Bien qu'ils soient plus compliqués que les perceptrons multicouches, ces réseaux sont également utilisés comme approximations de fonctions.

✚ Réseaux de neurones probabilistes (Probabilistic Neural Networks)

Les applications courantes de ces réseaux incluent les problèmes de classification. Un réseau à base radiale dans la première couche, fournit des informations sur la similitude entre la donnée d'entrée et le l'ensemble de données utilisé lors de l'apprentissage. Un vecteur de probabilité est la sortie de la deuxième couche. Une fonction de transfert compétitive donne finalement « 1 ou 0 ».

VI.3.8.3 Réseaux récurrents

✚ Réseaux de Elman

Le réseau d'*Elman* a un neurone linéaire dans sa couche de sortie et des neurones « **tansig** » dans sa couche cachée récurrente. Si la couche cachée contient suffisamment de neurones, cette forme de réseau peut également se rapprocher de n'importe quel type de fonction. Ce réseau peut apprendre des corrélations temporelles et spatiales puisqu'il peut stocker des informations pour une utilisation ultérieure.

✚ Réseaux de Hopfield

Le modèle de *Hopfield* est une mémoire auto-associative dans laquelle les neurones répondent de manière asynchrone et dont la fonction de transfert est la fonction « **signe** », avec une réponse binaire. Les fondements mathématiques de ces réseaux sont largement compris et la règle de *Hebb* généralisée permet d'apprendre directement à partir d'instances qui doivent être apprises. Les réseaux récursifs, comme ceux-ci, sont un peu

plus complexes que les perceptrons multicouches. Toutes les cellules sont interconnectées, de sorte que les modifications de la valeur d'une cellule affectent toutes les autres jusqu'à ce qu'un état stable soit atteint. Ces réseaux sont excellents pour la reconnaissance de formes.

✚ VI.3.8.4 Réseau à architecture évolutive « ART »

Carpenter et Grossberg ont créé le modèle de réseau neuronal évolutif connu sous le nom ART « Adaptive Resonance Theory » en 1987. La majorité des réseaux neuronaux prennent en compte deux phases. La première est la phase d'apprentissage : les poids des connexions sont modifiés selon une règle d'apprentissage.

La deuxième étape est la phase d'exécution, au cours de laquelle les poids ne sont plus modifiés. Ces deux processus sont réalisés simultanément à l'aide du réseau ART. Le réseau en phase de test minimise les connaissances déjà retenues tout en créant de nouvelles classes (ajout de neurones) pour répondre aux entrées inconnues. Le réseau « ART1 » est un réseau d'entrées binaires, et il existe d'autres variantes de réseau « ART2, ART3 » [97].

VI.3.8.5 Réseau PMC (Perceptron Multi Couches)

Le réseau MLP (*Multi-Layer Perceptron*) est un modèle de réseau comprenant une ou plusieurs couches cachées, dont les connexions sont directes et totales entre les couches. Les MLP, forment la très grande majorité des réseaux. Ils sont intemporels (ce sont des réseaux statiques et non dynamique) [98]. Apparus en 1985, les réseaux multicouches sont aujourd'hui les modèles les plus employés. Plusieurs couches de traitement leurs permettent de réaliser des associations non linéaires entre l'entrée et la sortie. Ils sont ainsi capables de résoudre le cas du « ou exclusif » (Perceptron) [97]. Il a été démontré que moyennant le choix d'une architecture appropriée (i.e. nombre de neurones cachés), les réseaux multicouches sont capables d'approcher n'importe quelle fonction. On parle d'approximateurs universels de fonctions. Cependant un certain nombre de problèmes sont liés à l'utilisation de ce type de réseau (et de manière plus générale de la majeure partie des RNA). On peut remarquer notamment la lenteur de l'apprentissage et surtout l'absence de résultats théoriques garantissant sa convergence. On constate souvent des problèmes liés au blocage de l'apprentissage dans des minima locaux de la fonction d'erreur. Ce point qui est souvent cité comme l'inconvénient principal des réseaux de neurones multicouches doit cependant être tempéré par l'existence de nombreuses approches permettant d'éviter de tels minima [99].

✚ Structure

Les neurones sont organisés en couches : chaque neurone est connecté à toutes les sorties des neurones de la couche précédente, et nourrit de sa sortie tous les neurones de la couche suivante (ces réseaux sont d'ailleurs qualifiés de « **Feedforward** » : « **nourrit devant** »). Pour la première couche ses entrées sont l'entrée du réseau. D'ailleurs une couche est souvent rajoutée pour constituer les entrées, appelée couche d'entrée, mais elle n'en est pas une puisqu'elle ne réalise aucun traitement. Les fonctions d'entrée et de transfert sont les mêmes pour les neurones d'une même couche, mais peuvent différer selon la couche [90].

Apprentissage

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

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

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

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

La librairie « Network » de MATLAB contient plusieurs variantes de l'algorithme de rétropropagation du gradient de l'erreur, la variante la plus intéressante étant l'algorithme de *Levenberg-Marquardt* communément appelé « Faster Propagation » [100].

Algorithme de la rétropropagation du gradient

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




Figure IV.8 : Recherche de la zone minimale dans l'espace de configuration des poids du réseau (ramener ici en deux dimensions) pour les exemples de la base d'apprentissage

Le problème peut être résolu en estimant la valeur prévue pour chaque neurone de la couche cachée. La rétropropagation du gradient est une méthode pour résoudre ce problème. La minimisation d'une fonction dépendante de l'erreur est l'idée fondamentale de la rétropropagation « Back propagation » du gradient. Il s'agit d'une approche générique fréquemment utilisée dans d'autres domaines tels que la physique. Elle consiste simplement en une descente du gradient, qui est une technique d'optimisation universelle. On cherche à minimiser une fonction d'énergie d'erreur (qui représente l'erreur entre la sortie désirée et la sortie obtenue), en suivant les lignes de plus grande pente.

On peut représenter la descente du gradient comme une bille que l'on poserait sur la courbe, et qui descendrait logiquement la pente (le gradient représente la pente selon chaque dimension). L'inconvénient de cette méthode est qu'elle va s'arrêter dans le premier minimum local rencontré [97].

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

$$Q = \frac{1}{2} \sum_i (a_i - s_i)^2 \quad (\text{IV.11})$$

Où « a_i et s_i » représentent respectivement l'activation mesurée et l'activation désirée pour les neurones, et « i » parcourt les indices des neurones de sortie. La règle suivante est utilisée pour modifier les poids du réseau :

$$\Delta W_{ij} = -n \frac{\partial Q}{\partial w_{ij}} \quad (\text{IV.12})$$

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

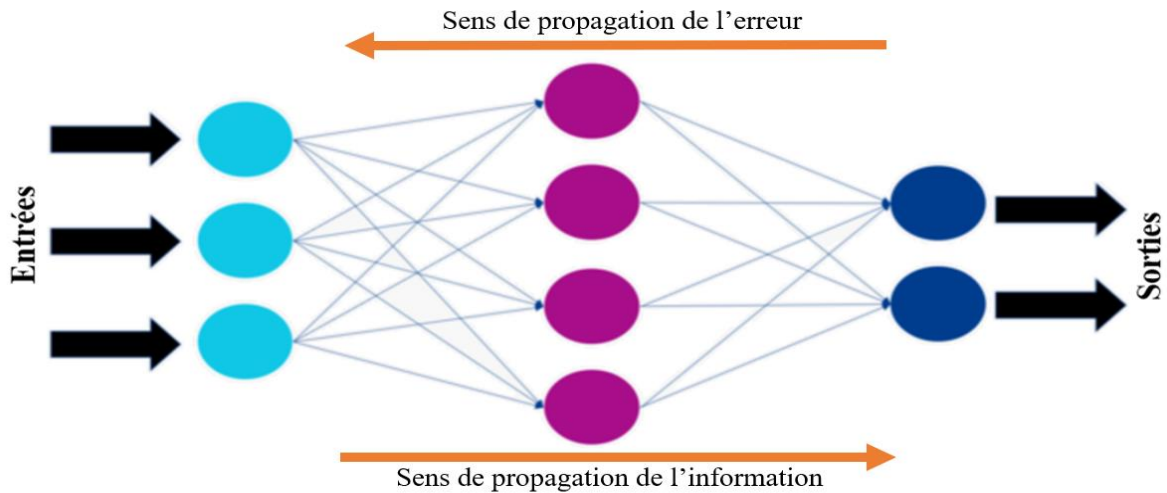


Figure IV.9 : Un réseau multicouche comportant deux neurones d'entrées, quatre neurones cachés et un neurone de sortie

Justifie le nom de l'algorithme. Le calcul est de cette façon :

$$\frac{\partial Q}{\partial w_{ij}} = \frac{\partial Q}{\partial a_i} \frac{\partial a_i}{\partial e_i} \frac{\partial e_i}{\partial w_{ij}} \quad (\text{IV.13})$$

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

$$\frac{\partial Q}{\partial w_{ij}} = \delta_i \frac{\partial e_i}{\partial w_{ij}} \quad (\text{IV.14})$$

Et puisque ; « $\frac{\partial e_i}{\partial w_{ij}} = a_j$ » donc :

$$\Delta W_{ij} = -n\delta_i a_j \quad (\text{IV.15})$$

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

$$\begin{cases} \frac{\partial a_i}{\partial e_i} = (a_i - s_i) \\ \frac{\partial Q}{\partial a_i} = g'(e_i) \end{cases} \quad (\text{IV.16})$$

Et donc :

$$\delta_i = \frac{\partial Q}{\partial a_i} \frac{\partial a_i}{\partial e_i} = (a_i - s_i)g'(e_i) \quad (\text{IV.17})$$

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

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

$$\frac{\partial Q}{\partial a_k} \frac{\partial a_k}{\partial a_i} = \frac{\partial Q}{\partial a_k} \frac{\partial a_k}{\partial e_k} \frac{\partial e_k}{\partial a_i} = \delta_k W_{ij} \quad (\text{IV.18})$$

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

$$\delta_i = g'(e_i) \sum_k \delta_k W_{ij} \quad (\text{IV.19})$$

Il existe de nombreuses variantes de l'algorithme présenté ici dans sa forme la plus élémentaire. Ils correspondent typiquement à l'utilisation de valeurs variables pour la constante « n », ou au calcul du gradient à l'aide de techniques du second ordre.

La quantité dont les poids doivent être modifiés est fréquemment déterminée à l'aide d'une version légèrement différente de l'équation (IV.17) :

$$\Delta W_{ij} = -n \frac{\partial Q}{\partial W_{ij}} + \mu \Delta W_{ij}(t-1) \quad (\text{IV.20})$$

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

Les ajustements des poids peuvent intervenir après chaque présentation d'un patron (poids du réseau), ou après la présentation de l'ensemble de la base d'exemples. Pour parvenir à un résultat souhaitable, l'apprentissage nécessitera dans tous les cas de nombreuses présentations de tous ces exemples [99].

IV.4 La forêt aléatoire (Random Forest)

Le terme « forêt de décision aléatoire » a été proposé pour la première fois en 1995 par *Tin Kam Ho*. *Ho* a développé une formule permettant d'utiliser des données aléatoires pour créer des prédictions. Puis, en 2006,

Leo Breiman et *Adele Cutler* ont étendu l'algorithme et créé les forêts aléatoires telles que nous les connaissons aujourd'hui. Cela signifie que cette technologie qui appartient à la classification supervisée, ainsi que les mathématiques et la science qui la soutiennent, sont encore relativement récentes.

Cet algorithme est appelé « forêt » parce qu'il génère la croissance d'une forêt d'arbres de décision. Les données de ces arbres sont ensuite fusionnées pour garantir les prédictions les plus précises. Alors qu'un arbre de décision isolé a un seul résultat et une gamme étroite de groupes, la forêt assure un résultat plus précis en comptant sur un plus grand nombre de groupes et de décisions. Elle présente l'avantage supplémentaire d'ajouter un caractère aléatoire au modèle en trouvant la meilleure caractéristique parmi un sous-ensemble aléatoire de caractéristiques.

Un arbre de décision est quelque chose que vous utilisez probablement tous les jours dans votre vie. C'est comme si vous demandiez à vos amis de vous conseiller sur le choix d'un micro portable. Vos amis vous demanderont ce qui est important pour vous. La Taille de la RAM ? La marque (Dell ou HP) ? I5 ou I7 ? sur la base de ces informations, vous pouvez faire des recherches pour trouver le micro portable idéal en fonction de vos choix. Un arbre de décision pose essentiellement une série de questions « vrai ou faux » qui mènent à une certaine réponse.

Chaque « test » (I5 ou I7 ?) est appelé un nœud ; chaque branche représente le résultat de ce choix (I5). Chaque nœud (feuille) est une étiquette de cette décision. Evidemment, dans les scénarios réels, il s'agit de diviser les observations de façon à ce que des groupes entiers soient différents, ce qui donne des sous-groupes qui sont similaires les uns aux autres, mais différents des autres groupes.

Une forêt aléatoire est un groupe d'arbres de décision. Cependant, il existe quelques différences entre les deux. Un arbre de décision a tendance à créer des règles, qu'il utilise pour prendre des décisions. Une forêt aléatoire choisit au hasard des caractéristiques et fait des observations, construit une forêt d'arbres de décision, puis fait la moyenne des résultats.

La théorie veut qu'un grand nombre d'arbres non corrélés crée des prédictions plus précises qu'un arbre de décision individuel. Cela s'explique par le fait que le volume d'arbres contribue à protéger des erreurs individuelles et du surajustement.

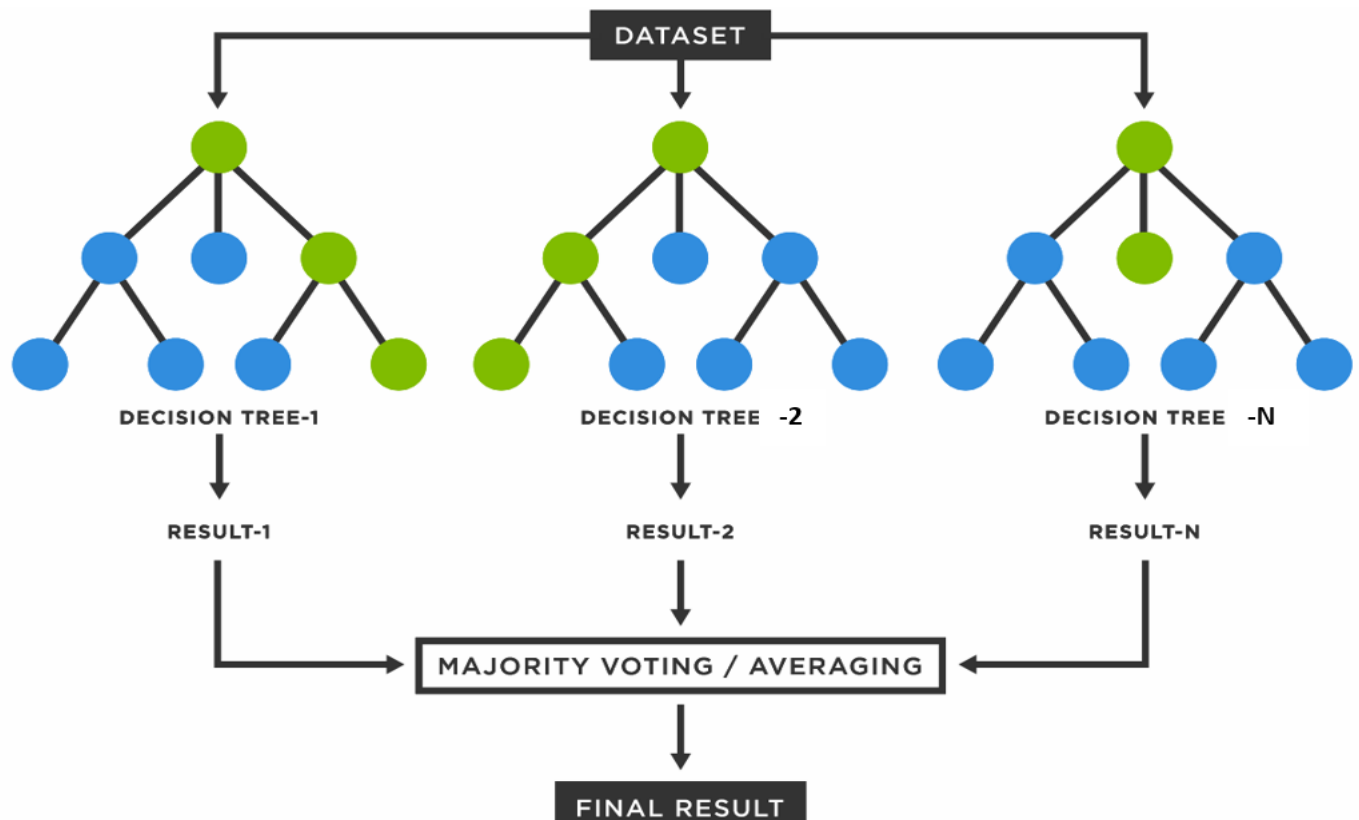


Figure IV.10 : Organigramme global d'une forêt aléatoire [101]

Une forêt a besoin de trois choses pour bien fonctionner :

- Un signal qui peut être identifié, afin que les modèles ne se contentent pas de deviner ;
- Les prédictions faites par les arbres doivent avoir de faibles niveaux de corrélation avec les autres arbres ;
- Caractéristiques avec un certain degré de pronostic.

IV.4.1 Le bagging dans les forêts de décision

Le bagging, autrement appelée agrégation bootstrap, permet aux arbres décisionnels individuels d'échantillonner aléatoirement l'ensemble de données et de remplacer les données, créant ainsi des résultats très différents dans les arbres individuels. Cela signifie qu'au lieu d'inclure toutes les données disponibles, chaque arbre ne prend qu'une partie des données. Ces arbres individuels prennent alors des décisions en fonction des données dont ils disposent et président les résultats en se basant uniquement sur ces points de données [101].

Cela signifie que dans chaque forêt aléatoire, il y a des arbres qui ont été formés sur des données différentes et qui ont utilisé des caractéristiques différentes pour prendre des décisions. Cela constitue un tampon pour les arbres qui les protège contre les erreurs et les prédictions incorrectes.

Le processus de bagging n'utilise qu'environ deux tiers des données, de sorte que le tiers restant peut être utilisé comme ensemble de test.

IV.4.2 La méthode de la forêt aléatoire

RF choisit le meilleur mode fractionné dans un sous-ensemble de caractéristiques choisi au hasard sur la base d'une idée d'ensachage. Bootstrap, bagging et boosting sont trois stratégies d'échantillonnage. Bootstrap est un échantillonnage aléatoire avec remplacement. Dans cet article, nous utilisons le bootstrap pour obtenir « k » échantillons et obtenir les résultats finaux par le vote majoritaire.

RF contient « T » arbres de décision $\{t_i(x), i = 1, 2, \dots, T\}$, où $x = \{x_1, x_2, \dots, x_N\}$. « x » est les vecteurs caractéristiques à « N » dimensions du signal. Les sorties finales $\{y_j = t_i(x), i = 1, 2, \dots, T\}$, où $\{j = 1, 2, \dots, T\}$, prennent les décisions finales pour « T » arbres. Donné un signal, chaque classificateur arborescent émet un vote unitaire pour obtenir les résultats. La figure 8 montre l'organigramme de RF et l'algorithme de RF est comme suit :

1. À partir des données d'apprentissage données, choisissez « k » échantillons au hasard en utilisant le bootstrap ;
2. Supposons que les « k » échantillons avec « N » caractéristiques, choisissent un sous-ensemble de n caractéristiques parmi N caractéristiques au hasard. Chaque arbre pousse à la taille maximale et aucune coupe ;
3. Répétez deux étapes ci-dessus « T » fois et construisez des arbres « T » ;
4. Testez les données d'apprentissage en RF et accédez aux sorties des arbres « T ». Les résultats sont déterminés à la majorité des voix.

De la Figure (IV.11), certains échantillons sont laissés de côté, tandis que d'autres continuent. Il a mentionné que dans chaque donnée de formation bootstrap, environ 1/3 des échantillons nommés échantillons Out of Bag (OOB) sont omis [102, 103]. Le taux d'erreur de classification des arbres peut être estimé avec ces échantillons. Les 2/3 échantillons restants sont utilisés pour construire les arbres, qui sont des échantillons In Bag.

Dans la méthode RF, deux paramètres sont très importants pour la classification. L'un est le sous-ensemble

aléatoire de chaque nœud (n), et l'autre on est le nombre d'arbres « T » dans la forêt. Deux variables sont définies comme suit :

- Le nombre de sous-ensembles sélectionnés au hasard est défini comme « $n = \sqrt{N}$ », où « N » est le nombre total d'entités.

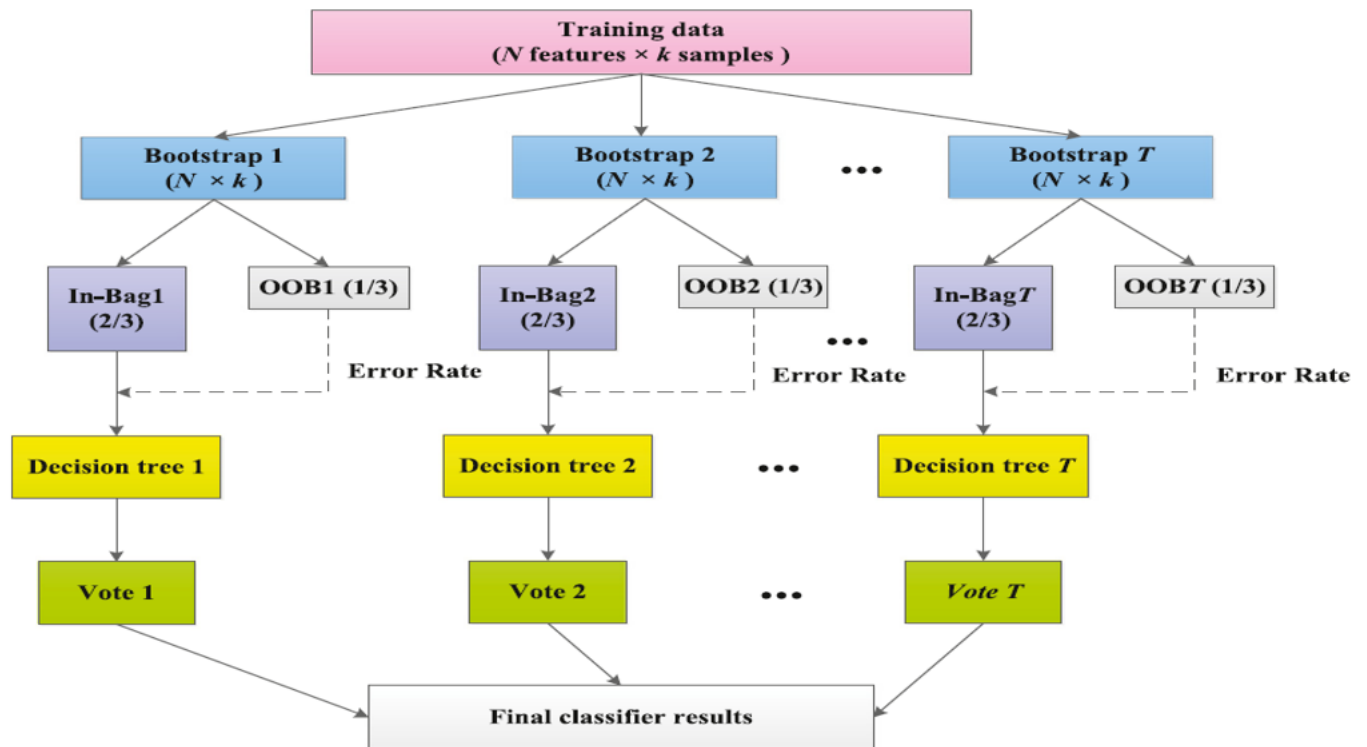


Figure IV.11 : Organigramme détaillé d'une forêt aléatoire

- Compte tenu de la précision de la classification et du temps de formation, la portée des arbres de décision est généralement définie comme $T = [10, 500]$.

Dans cet article, « T » est fixé à (20 arbres). La forêt aléatoire peut gérer le signal avec de nombreuses fonctionnalités et il ne sera pas trop ajusté [104]. La RF, en tant que type d'algorithme d'apprentissage d'ensemble, a été largement appliquée dans de nombreux domaines de recherche [105].

IV.4.3 Les avantages de la forêt aléatoire

✚ Importance relative facile à mesurer

Il est important de mesurer l'importance d'une caractéristique en examinant les nœuds qui utilisent cette caractéristique pour réduire l'impureté dans tous les arbres de cette forêt. Il est facile de voir la différence avant

et après la permutation de la variable, ce qui donne une mesure de l'importance de cette variable [101].

Polyvalence

Comme une forêt aléatoire peut être utilisée à la fois pour des tâches de classification et de régression, elle est très polyvalente. Elle peut facilement traiter des caractéristiques binaires et numériques ainsi que des caractéristiques catégorielles, sans qu'il soit nécessaire de les transformer ou de les remettre à l'échelle. Contrairement à presque tous les autres modèles, elle est incroyablement efficace avec tous les types de données.

Pas de surajustement

Tant qu'il y a suffisamment d'arbres dans la forêt, le risque de surajustement est faible, voire nul. Les arbres de décision peuvent également finir par s'adapter de manière excessive. Les forêts aléatoires empêchent cela en construisant des arbres de tailles différentes à partir de sous-ensembles et en combinant les résultats.

Haute précision

L'utilisation d'un certain nombre d'arbres avec des différences significatives entre les sous-groupes fait des forêts aléatoires un outil de prédiction très précis.

Réduction du temps consacré au data management

Avec le traitement traditionnel des données, une grande partie du temps précieux est consacrée au nettoyage des données. Les forêts aléatoires minimisent ce traitement, car elles traitent bien les données manquantes. Les tests effectués pour comparer les prédictions résultant de données complètes et incomplètes ont montré des niveaux de performance presque identiques. Les données aberrantes et les caractéristiques non linéaires sont essentiellement éliminées [101].

Les techniques de forêt aléatoire permettent également d'équilibrer les erreurs dans les populations et autres ensembles de données déséquilibrés. Pour ce faire, elles minimisent le taux d'erreur, de sorte qu'une classe plus grande aura un taux d'erreur plus faible, et une classe plus petite, un taux plus élevé.

Vitesse de formation rapide

Comme les forêts aléatoires utilisent un sous-ensemble de caractéristiques, elles peuvent évaluer rapidement des centaines de caractéristiques différentes. Cela signifie que la vitesse de prédiction est également plus rapide que celle d'autres modèles, car les forêts générées peuvent être sauvegardées et réutilisées à l'avenir.

IV.4.4 Les défis de la forêt aléatoire

Des résultats plus lents

Comme l'algorithme construit de nombreux arbres, il augmente la sophistication et la précision des prédictions. Cependant, il ralentit la vitesse du processus, car il construit des centaines ou des milliers d'arbres. Cela le rend inefficace pour les prédictions en temps réel. Et comme solution, il est possible d'utiliser l'échantillonnage out-of bag (OOB), où seuls deux tiers des données sont utilisées pour faire des prédictions. Le processus de la forêt aléatoire est également parallélisable, de sorte que le processus peut être réparti sur de nombreuses machines et s'exécuter beaucoup plus rapidement que dans un système unique.

Impossible d'extrapoler

La prédiction d'une forêt aléatoire repose sur une moyenne des étiquettes précédemment observées. Sa plage est limitée par les étiquettes les plus basses et les plus hautes des données d'apprentissage. Bien que cela ne soit un problème que dans un scénario où les données d'apprentissage et de prédiction ont une portée et une distribution différente, ce décalage des covariables est un problème qui signifie qu'un modèle différent doit être utilisé dans certaines situations [101].

Interprétabilité faible

Les modèles de forêt aléatoire sont l'ultime boîte noire. Ils ne sont pas explicables, il est donc difficile de comprendre comment ou pourquoi ils sont arrivés à une certaine décision. Cette impénétrabilité signifie qu'il faut simplement faire confiance au modèle tel quel et accepter les résultats tels quels.

Afin d'avoir une idée claire et précise sur l'application des (ANN et RF) dans le domaine de diagnostic des défauts rotoriques de la MAS, l'étude en simulation est réalisée avec un modèle qui représente au mieux le comportement réel de la machine. Une analyse fine des grandeurs simulées de la machine (courants statoriques « I_{abc} ») a permis d'identifier la signature de chacun des cinq cas de défauts de cassures des barres rotoriques et l'état sain.

En effet, le défaut rotorique se manifeste par une modulation d'amplitude basse fréquence des trois courants statoriques tout en restant toujours déphasés de 120° entre eux. Suite à ces considérations, le choix des entrées s'est basé essentiellement sur la surveillance du courant statorique puisqu'il reflète d'une manière significative et discriminante l'existence de défaut rotor. De plus, le capteur de courant est simple, peu onéreux, présent

dans tous les variateurs de vitesse et offre donc un accès aisé à la mesure [106].

Dans cette étude, le diagnostic de défaut s'appuie sur la conception des (RNA et RF) qui ont pour rôle de faire correspondre automatiquement chaque signature de fonctionnement de la machine à son état de fonctionnement correspondant (sain ou défectueux). Afin de mieux comprendre l'utilisation des (RNA et RF) dans le domaine du diagnostic, il est judicieux de rappeler les différentes étapes suivies pour la mise en œuvre de ces méthodes intelligentes dans ce domaine :

- Codage des états de fonctionnement de la machine asynchrone ;
- Choix des indicateurs de défauts ;
- Construction de la base d'apprentissage et de test ;
- Résultats de classement des états (sain et défectueux).

IV.5 Codage des états de fonctionnement de la MAS

Le codage des états de fonctionnement de la MAS est effectué selon le type de classification multi classes ; où la séparation sera faite entre une machine saine, et une machine avec une panoplie des barres rotoriques cassées. Les codes attribués pour ce genre de classification sont :

La taille de l'ensemble de données d'entrée utilisée est une matrice de 600 par 17 et les données de sortie cible sont une matrice de 600 par 6 dont les sorties sont de nature binaire où une sortie vectorielle de [1 ; 0 ; 0 ; 0 ; 0 ; 0] condition machine saine, [0 ; 1 ; 0 ; 0 ; 0 ; 0] présence une barre rotorique cassé jusqu'à [0 ; 0 ; 0 ; 0 ; 0 ; 1] présente trois barres rotoriques éloignées cassées (Tableau IV.3). 70% de l'ensemble de données est utilisées pour l'apprentissage des (ANN et RF) et le reste pour leurs tests.

Tableau IV.3 : Codage des états de fonctionnement de la machine asynchrone

Etats de fonctionnement de la MAS	Symbole	Code					
		S1	S2	S3	S4	S5	S6
Etat sain	Etat sain	1	0	0	0	0	0
Une barre rotorique cassée	UBRC	0	1	0	0	0	0

Deux barres rotoriques adjacentes cassées	DBRAC	0	0	1	0	0	0
Deux barres rotoriques éloignées cassées	DBREC	0	0	0	1	0	0
Trois barres rotoriques adjacentes cassées	TBRAC	0	0	0	0	1	0
Trois barres rotoriques éloignées cassées	TBREC	0	0	0	0	0	1

IV.6 Choix des indicateurs de défauts

Pour une exploitation efficace des RNA et RF, une analyse préalable, aussi soignée que possible des différentes variables simulées de la machine en fonctionnement défectueux et normal, doit être menée par des experts du diagnostic de la machine asynchrone. Cette analyse permet de choisir les indicateurs les plus représentatifs du défaut de manière significative et discriminante. Ces derniers sont utilisés comme étant les entrées pertinentes du réseau de neurones et la forêt aléatoire.

L'élaboration d'une représentation discriminante des indicateurs de défaut est une étape extrêmement importante qui conditionne en grande partie l'efficacité de la classification par (RNA et RF). Le choix des indicateurs de défauts adéquats permet de fixer le nombre des entrées de chaque RNA, et chaque RF. De ce fait, il y aura autant d'entrées des (RNA et RF) que d'indicateurs de défauts.

IV.6.1 Structure du réseau de neurones (RNA)

Le choix des indicateurs de défaut et des sorties du réseau RNA permet de fixer l'architecture externe du réseau. Par ailleurs, dans la littérature, il existe plusieurs types d'architecture de RNA comme on les a cités. Le réseau de neurones RNA que nous avons adopté à détecter les défauts rotoriques est un réseau MLP du type Feedforward où ses entrées sont fixées comme suit :

1. Neuf entrées (09) si on utilise l'apprentissage par les paramètres statistiques ;
2. Huit entrées (08) si on utilise l'apprentissage par les paramètres fréquentiels en paquets d'ondelettes ;
3. Dix-sept (17) si on utilise l'apprentissage par les paramètres hybrides (statistiques et fréquentiels).

Le nombre de neurones de la couche de sortie correspond aux « six classes » (un cas sain et cinq cas de défauts de cassures des barres rotoriques) choisies.

Pour chercher le nombre de couches cachées ainsi que le nombre de neurones qui les constituent, plusieurs séquences d'apprentissage sont réalisées, suivies successivement par des séquences de test pour éviter le sur ou le sous-apprentissage.

La structure optimale du réseau RNA est celle qui donne les meilleures performances d'apprentissage et de test. Cette structure est représentée sur les figures (IV.15 ; IV.20 ; IV.26 ; IV.33). Elle est formée d'une seule couche cachée composée de dix (**10**) neurones activés par la fonction sigmoïde de type « **logsig** », et les neurones de la couche de sortie sont activés par la fonction linéaire de type « **purelin** ». Sous les caractéristiques suivantes :

- `net_work = feedforwardnet(10);`
- `net_work.layers{1}.transferFcn = 'logsig';`
- `net_work.trainParam.max_fail=60000;`
- `net_work.trainParam.epochs=2000;`
- `net_work.trainParam.min_grad=10^(-16).`

Les performances des méthodes intelligentes (ANN et RF) dans le domaine de diagnostic de défauts sont directement liées à la qualité et la nature des entrées pertinentes, qui font la base d'apprentissage de ces dernières.

IV.7 Les paramètres d'apprentissage de (ANN et RF)

Pour la procédure de détection des défauts, une approche directe utilisant les signatures des défauts dans les courants statoriques MCSA « Motor Current Signature Analysis » au régime permanent. Pour cela on a utilisé deux techniques de traitement du signal « I_{as} » :

- ❖ La première est basée sur les paramètres statistiques ;
- ❖ La deuxième est basée sur la transformée en paquets d'ondelettes qui est considéré comme un outil idéal en raison de son aptitude d'analyse des signaux en régime stationnaire.

Les tests sont validés par simulation numérique et les résultats obtenus montrent clairement la possibilité d'extraire les signatures pour détecter et localiser les défauts rotoriques.

IV.7.1 Les paramètres statistiques

Comme indiquant dans le tableau (IV.4), la caractérisation d'un signal du courant statorique « I_{as} » est effectuée en utilisant plusieurs paramètres ou des indicateurs statistiques temporelles tel que : le minimum (Min), la valeur crête à crête (PPV), la valeur efficace (RMS), la dérivation standard (SD), le facteur de crête (CRF), le kurtosis (Kur),...,etc.

Tableau IV.4 : les paramètres statistiques

paramètre statistique	Equation	La commande sur MATLAB
Le minimum	$Min = \min(X)$	min(X)
Le maximum	$Max = \max(x)$	max(X)
la déviation Standard	$SD = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}$	Std(X)
La valeur efficace	$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$	rms(X)
Le kurtosis	$Kur = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4}{(\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2)^2}$	kurtosis(X)
La valeur crête à crête	$PPV = \frac{1}{2} [Max(x) - \min(x)]$	peak2peak(X)
La moyenne	$moy = \frac{1}{N} \sum_{i=1}^N x_i = \bar{x}$	mean(X)

Skewness	$Skw = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^3}{\left(\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \right)^{\frac{3}{2}}}$	skewness(X)
Le facteur de crête	$CRF = \frac{\max(x) - \min(x)}{\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}}$	peak2rms(X)

IV.7.2 Les paramètres temps/fréquences en paquets d’ondelettes

La classification des signatures des défauts à l’aide de variables extraites d’une représentation temps-fréquence (RTF) en paquets d’ondelettes d’un signal du courant statorique « I_{as} » est une approche où cette dernière est l’outil le plus approprié, en raison de l’information détaillée de la composition du signal qui peut être extraire du plan temps-fréquence. Parmi ces ondelettes on a utilisé l’ondelette de *Daubechies* (**db8**).




Figure IV.12 : Courant statorique « I_{as} » du cas de trois barres rotorique adjacentes cassées




Figure IV.13 : Arbre de décomposition du signal « I_{as} » par la méthode paquets d’ondelettes

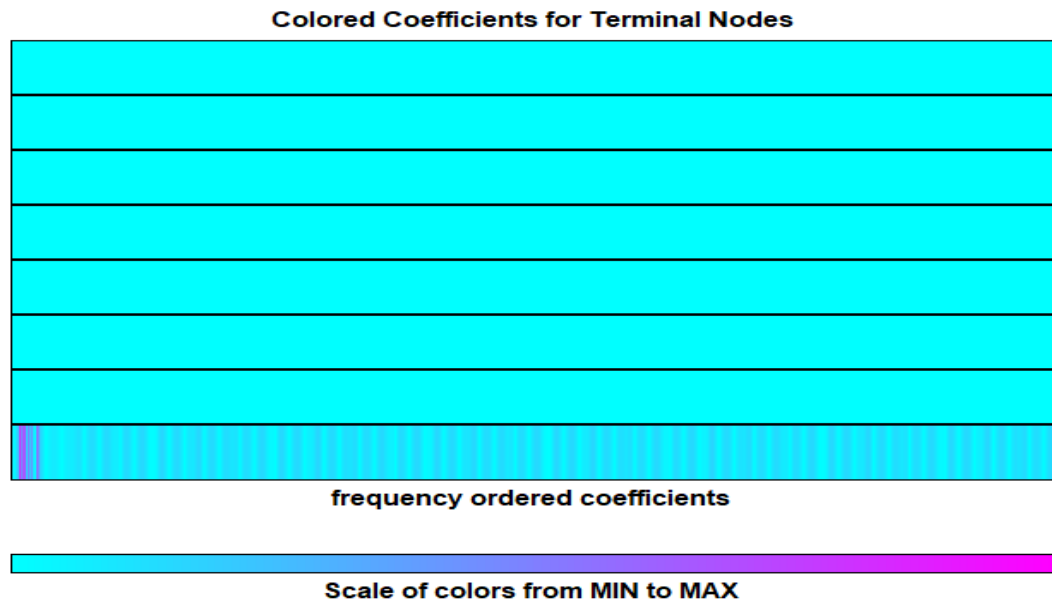


Figure IV.14 : Analyse du signal « I_{as} » de défaut de trois barres rotorique adjacentes cassées par la méthode paquets d’ondelettes

Pour l’extraction de ces paramètres, nous avons développé un programme sous MATLAB permettant de les calculer d’une manière automatique à partir du signal du courant statorique « I_{as} »

IV.8 Résultats de classifications des défauts de cassures des barres rotoriques

IV.8.1 Classification utilisant des paramètres hybrides sans optimisation

IV.8.1.1 Classification à l’aide de réseaux de neurones artificiels (ANN)

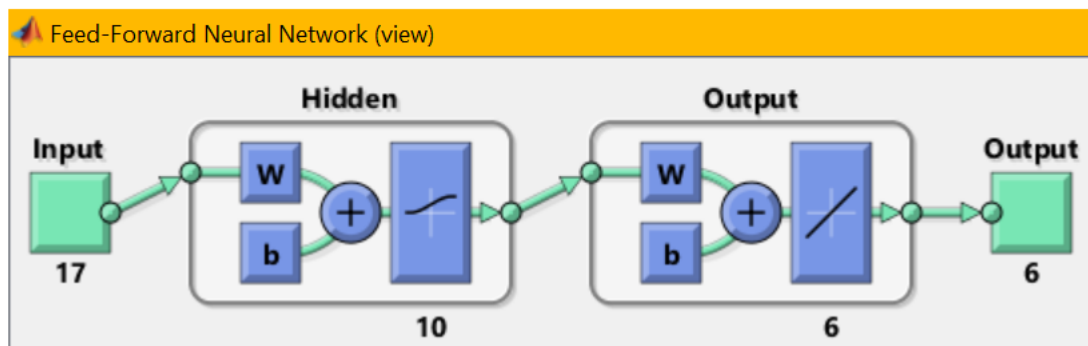


Figure IV.15 : Réseau de neurones Feedforward sans optimisation




Figure IV.16 : Histogramme d'erreur entre les valeurs cibles (Target values) et les valeurs prédites D'ANN sans optimisation




Figure IV.17 : État d'entraînement d'ANN sans optimisation




Figure IV.18 : Courbe de performance d'apprentissage du classificateur de réseau neuronal sans optimisation

IV.8.1.2 Classification à l'aide de la forêt aléatoire (RF)




Figure IV.19 : Le taux d'erreur équilibré de RF sans optimisation

IV.8.2 Classification utilisant des paramètres hybrides avec l'algorithme d'optimisation BBAT.

IV.8.2.1 Optimisation par BAT (OEP) et Optimisation par BAT binaire (BBAT)

✚ Algorithme de chauve-souris binaire (BBA)

Bat Algorithm (BA) est un algorithme d'optimisation heuristique qui a été piloté par le comportement d'écholocation des chauves-souris [107]. L'algorithme utilise les deux caractéristiques clés des chauves-souris pour trouver des proies. Les chauves-souris augmentent le taux d'émission des ultrasons et diminuent le volume lors de la chasse aux proies. L'algorithme Bat modélise mathématiquement ce comportement en utilisant le vecteur vitesse « S », le vecteur position « X » et le vecteur fréquence « F », pour chacune des chauves-souris artificielles comme suit :

$$S_{i+1} = S_i + (X_i - G_{best}) * F_i \quad (IV.21)$$

$$X_{i+1} = X_i + S_{i+1} \quad (IV.22)$$

$$F = F_{min} + (F_{max} - F_{min}) * \beta \quad (IV.23)$$

Le vecteur vitesse « S », le vecteur position « X » et la fréquence « F » sont mis à jour comme dans les équations (IV.21, IV.22 et IV.23) respectivement. « G_{best} » est la solution qui fonctionne le mieux parmi toutes les solutions obtenues jusqu'à présent et « β » est un nombre aléatoire d'une distribution uniforme dans [0, 1], l'exploitation dans l'algorithme est effectuée en utilisant un pas aléatoire comme indiqué dans l'équation (IV.24)

où « A » est l'intensité du son émis que les chauves-souris utilisent pour atteindre l'exploration et « ϵ » est un nombre aléatoire dans $[-1, 1]$.

$$X_{new} = X_{old} + \epsilon A \tag{IV.24}$$

La version binaire de BA, « Binary Bat Algorithm (BBA) », explore l'espace de recherche binaire. L'espace de recherche binaire peut être considéré comme un hypercube. Les agents de recherche artificiels de l'algorithme renvoient différents nombres de bits pour se déplacer vers des coins plus proches ou plus éloignés de cet hypercube [108]. Le BA renvoie les valeurs de vitesse dans l'espace réel et la mise à jour de la position est effectuée à l'aide de l'équation (IV.22). Cependant, dans le cas de BBA, les valeurs réelles doivent être mises en correspondance avec des valeurs binaires pour mettre à jour les positions. La position peut être mise à jour en fonction de la probabilité des valeurs de vitesse à l'aide de la fonction de transfert [109].

IV.8.2.2 Classification à l'aide de réseaux de neurones artificiels (ANN)

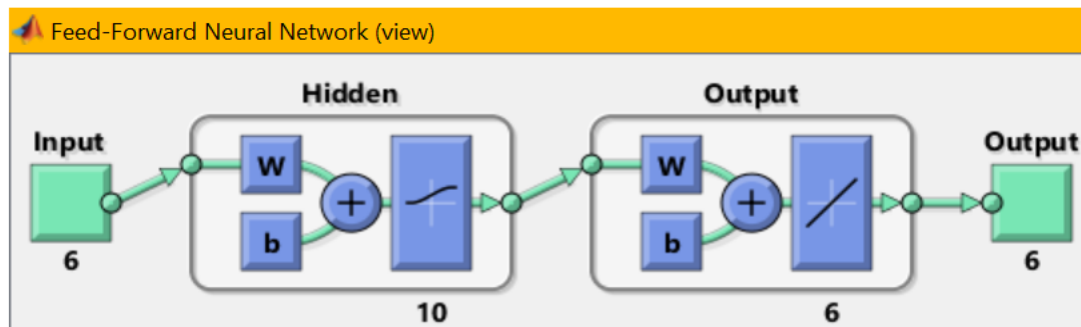


Figure IV.20 : Réseau de neurones Feedforward avec BBAT




Figure IV.21 : Histogramme d'erreur entre les valeurs cibles (Target values) et les valeurs prédites D'ANN avec BBAT




Figure IV.22 : État d'entraînement d'ANN avec BBAT




Figure IV.23 : Courbe de performance d'apprentissage du classificateur de réseau neuronal avec BBAT

IV.8.2.3 Classification à l'aide de la forêt aléatoire (RF)




Figure IV.24 : Le taux d'erreur équilibré de RF avec BBAT




Figure IV.25 : Résultats de fitness pour l'algorithme BBAT avec RF

IV.8.3 Classification utilisant des paramètres hybrides avec l'algorithme d'optimisation BPSO

IV.8.3.1 Optimisation par essaim particulaire (OEP) et Optimisation par essaim particulaire binaire (OEPB)

Kennedy et Eberhart, proposent en 1995 une nouvelle méthode d'optimisation nommée optimisation par Essaim de Particule PSO, (en anglais : Particles Swarm Optimization). PSO est une méthode d'optimisation stochastique basée sur une population de particules, un Essaim regroupe plusieurs particules (individus). Chaque particule prend sa décision en utilisant sa propre expérience et les expériences de leur voisinage.

PSO est inspiré du comportement social des nuées d'oiseaux et des bancs de poissons qui ont tendance à imiter les comportements réussis qu'ils observent dans leurs entourages, tout en y apportant leurs variations personnelles.

PSO démarre le processus d'optimisation par une population des solutions aléatoires qui se déplacent dans l'espace de recherche. Le déplacement de chaque particule dans l'espace de recherche, est basé sur sa position actuelle et la mise à jour de sa vitesse [110, 111, 112]

$$Z_{id}^k = Z_{id}^{k-1} + V_{id}^k \quad (\text{IV.25})$$

Tel que [112] :

Z_{id}^k, Z_{id}^{k-1} : Position de la particule « i_d » à l'itération « k et $k - 1$ » respectivement.

Z_{id}^k : Vitesse de la particule « i_d » à l'itération « k ».

Chaque particule dans l'essaim, change sa vitesse suivant deux informations essentielles. Une, est liée à son expérience personnelle, qui est la meilleure position trouvée par la particule durant le processus de recherche « ***pbest*** ». La deuxième information, concernant la meilleure position trouvée par les voisins « ***lbest*** » (ou par tout l'essaim, dans la version globale de l'algorithme « ***gbest*** »). Cette information est obtenue à partir de la connaissance de la façon dont les autres agents ont exécuté leurs recherches.

Le principe de changement de la vitesse est défini par [110, 112] :

$$V_{id}^k = \omega \cdot V_{id}^{k-1} + c_1 \cdot r_1 \cdot (P_{id} - Z_{id}^{k-1}) + c_2 \cdot r_2 \cdot (P_{Gd} - Z_{id}^{k-1}) \quad (IV.26)$$

Où :

V_{id}^k : Vitesse de la particule « i_d » à l'itération « k » ;

ω : Fonction de pondération ;

c_1, c_2 : Facteurs de pondération ;

r_1, r_2 : Nombre aléatoire entre « 0 et 1 » ;

Z_{id}^{k-1} : Position actuelle de la particule « i_d » à l'itération « $k - 1$ » ;

P_{id} : Meilleure position trouvée par la particule « i_d » jusqu'ici ;

P_{Gd} : Meilleure position trouvée par l'essaim jusqu'ici ;

La fonction de pondération « ω » est donnée par l'équation suivante :

$$\omega(k) = \omega_{max} - \frac{(\omega_{max} - \omega_{min})}{k_{max}} \cdot k \quad (IV.27)$$

Tel que :

ω_{max} : Poids initial.

ω_{min} : Poids final.

k_{max} : Nombre d'itérations maximum.

k : Itération courante.

La fonction de pondération « ω » joue un rôle important dans la procédure de recherche. Elle garantit un équilibre entre la recherche locale et la recherche globale, un bon choix de cette fonction augmente l'efficacité de la méthode pour avoir une solution globale.

Algorithme général de l'OEP

Les concepts de l'OEP présentés dans les sections précédentes est donné comme suit :

- **Etape 1** : Génération d'état initial de chaque agent ;
Les points de recherche initiaux, position et vitesse de chaque agent sont produits aléatoirement. Pour chaque agent le point de recherche courant est placé à « ***pbest*** »
- **Etape 2** : Evaluation du point de recherche de chaque agent ;
Les points de recherche courants sont évalués au moyen de la fonction objective relative au système d'étude. Si la valeur d'un agent est meilleure que son « ***pbest*** » courant, « ***pbest*** » prend cette nouvelle valeur. Si la meilleure valeur de « ***pbest*** » est meilleure que « ***gbest*** » courant, « ***gbest*** » est remplacé par cette meilleure valeur et l'agent qui correspond à cette meilleure valeur est ainsi stocké.
- **Etape 3** : Modification du point de recherche ;
La modification du point de recherche se fait en moyennant les équations (IV.25), (IV.26).
- **Etape 4** : Critère d'arrêt ;
La procédure de recherche est arrêtée lorsque le nombre courant d'itération devient égal à la valeur maximale d'itérations préalablement déterminée. Dans ce cas de figure, la dernière valeur « ***gbest*** » peut être considérée comme solution. Dans l'autre cas, la recherche continue en revenant à l'étape 2

Les avantages d'optimisation par Essaims de particules peut être présentée par les points suivants :

- ✓ La méthode OEP peut essentiellement manipuler le problème d'optimisation continu ;
- ✓ L'OEP utilise plusieurs points de recherche qui convergent graduellement vers le point optimal en utilisant les valeurs « ***pbest*** » et « ***gbest*** » ;
- ✓ La méthode OEP utilise la diversification et l'intensification pour une recherche efficace ;
- ✓ L'OEP présente un avantage certain sur les méthodes classiques dans le sens où elle permet une exploration aléatoire de l'espace des solutions. De plus, elle est simple à mettre en œuvre et son exécution conduit à l'obtention de très bons résultats, rapidement et efficacement avec peu des paramètres à ajuster [110, 111, 113, 114].

Par rapport à d'autres algorithmes d'optimisation heuristiques, OEP est efficace et facile à mettre en œuvre. Néanmoins, il présente l'inconvénient que sa performance peut diminuer quand le nombre d'itération augmente. De plus, dans le cas de traitement des problèmes complexes, OEP convergera facilement vers des solutions optimales locales. Pour surmonter ces lacunes, plusieurs variantes ont été développées telles que OEP avec un Facteur de Constriction (OEPFC) et OEP avec Congrégation Passive (OEPCP) ou Particle Swarm Optimizer with Passive Congrégation (PSOPC) en anglais. L'OEPCP a été appliqué avec succès dans de

nombreux domaines, il donne de meilleurs résultats que ceux générés par d'autres variantes de PSO. La mise à jour de la vitesse de chaque particule, dans le cas de l'algorithme OEPCP est exprimée comme suit :

$$V_{id}^k = \omega \cdot V_{id}^{k-1} + c_1 \cdot r_1 \cdot (P_{id} - Z_{id}^{k-1}) + c_2 \cdot r_2 \cdot (P_{Gd} - Z_{id}^{k-1}) + c_3 \cdot r_3 \cdot (P_R - Z_{id}^{k-1}) \quad (IV.28)$$

Avec : « P_R » est une particule choisie aléatoirement à partir de l'essaim.

Dans l'algorithme BPSO, la position de chaque particule est exprimée sous la forme d'un vecteur de bits binaires composé de zéros « 0 » et des uns « 1 ». Chaque position est mise à jour en fonction de la valeur de sa vitesse qui sera convertie en valeurs de probabilité à l'aide de la fonction suivante [115] :

$$F(V_{id}^k) = 2 * |sigmoid(V_{id}^k) - 0.5| \quad (IV.29)$$

Après avoir transformé les vitesses aux valeurs de probabilité en utilisant l'équation (IV.30), la nouvelle position binaire de chaque particule est déterminée comme suit :

$$Si \text{ randn} < F(V_{id}^k), \text{ Alors } Z_{id}^k = \text{échanger } Z_{id}^{k-1} \text{ Sinon } Z_{id}^k = Z_{id}^{k-1} \quad (IV.30)$$

IV.8.3.2 Classification à l'aide de réseaux de neurones artificiels (ANN)

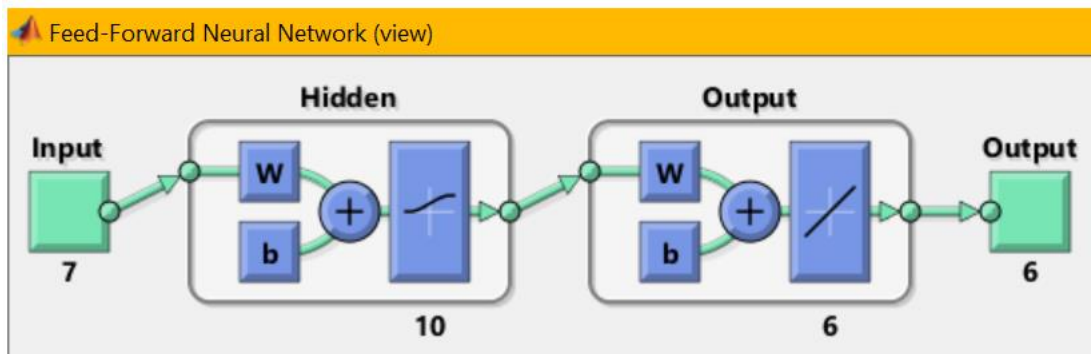


Figure IV.26 : Réseau de neurones Feedforward avec BPSO




Figure IV.27 : Histogramme d'erreur entre les valeurs cibles (Target values) et les valeurs prédites D'ANN avec BPSO




Figure IV.28 : État d'entraînement d'ANN avec BPSO




Figure IV.29 : Courbe de performance d'apprentissage du classificateur de réseau neuronal avec BPSO




Figure IV.30 : Résultats de fitness pour l'algorithme BPSO avec ANN

IV.8.3.3 Classification à l'aide de la forêt aléatoire (RF)




Figure IV.31 : Le taux d'erreur équilibré de RF avec BPSO




Figure IV.32 : Résultats de fitness pour l'algorithme BPSO avec RF

IV.8.4 Classification utilisant des paramètres hybrides avec l'algorithme de réduction de dimension PCA.

IV.8.4.1 Analyse en Composantes Principales (ACP)

L'analyse en composantes (ACP) ou (**PCA** : Principal Component Analysis) en anglais, est une technique qui permet de caractériser un système complexe multidimensionnel en dimension inférieure. Donc, le but est de définir un sous-espace de dimension « d' », inférieur à « d », pour mieux représenter l'ensemble d'apprentissage

Soit « $X = \{x_1, x_2, \dots, x_N\}$ » l'ensemble des « N » vecteurs (matrice des données) de dimension « d ». Si

les composantes de ces vecteurs ne sont pas homogènes, alors les résultats de l'ACP et de la classification risquent d'être biaisés.

Afin de parer à cette éventualité les données sont normalisées de la manière suivante : le centre de gravité de l'ensemble d'apprentissage est le vecteur défini par : « $m = \frac{1}{N} \cdot \sum_{k=1}^N x_k$ », et les composantes de la variance sont : « $\sigma_j^2 = \frac{1}{N} \cdot \sum_{k=1}^N (x_{kj} - m_j)^2$ avec $j = 1, \dots, d$ ».

Ainsi, à partir des deux relations précédentes on en déduit les vecteurs formes normalisés (c'est-à-dire de moyenne nulle et d'écart type unité) : « $x_{knorm} = \Delta^{-\frac{1}{2}} (x_k - m)$ ».

Avec « Δ » est la matrice diagonale des variances « σ_j^2 » :

$$\Delta = \begin{bmatrix} \sigma_1^2 & & & 0 \\ & \sigma_2^2 & & \\ & & \ddots & \\ 0 & & & \sigma_d^2 \end{bmatrix} \quad (\text{IV.31})$$

Pour la suite de l'étude, les données seront considérées comme étant normalisées. La base du sous-espace est définie par les vecteurs propres de la matrice de « variance – covariance » [116] : $S = \frac{1}{N} \cdot \sum_{k=1}^N x_k \cdot x_k^t$

Avec « S » est une matrice carrée ($d \times d$), réelle et symétrique, c'est aussi la matrice d'inertie du nuage de points considéré. Ses éléments diagonaux sont les variances de l'ensemble d'apprentissage.

Elles valent « 1 » car les données sont centrées et réduites. Et les éléments non diagonaux sont les covariances.

Les vecteurs propres (IV.32) de la matrice de variance-covariance « S » sont les vecteurs « v_j » tels que « $S \cdot v_j = \lambda_j \cdot v_j$ ». Les scalaires « λ_j », repris dans la matrice diagonale (IV.33), sont les valeurs propres.

$$V = [v_1, v_2, \dots, v_{d'}, \dots, v_d] \quad (\text{IV.32})$$

$$\lambda = \begin{bmatrix} \lambda_1 & & & & 0 \\ & \lambda_2 & & & \\ & & \dots & & \\ & & & \lambda_{d'} & \dots \\ 0 & & & & \lambda_d \end{bmatrix} \quad (\text{IV.33})$$

Les premiers « d' » vecteurs propres, rangés par ordre décroissant des valeurs propres vont constituer la base du sous-espace de dimension « d' ». Le vecteur « x_j^p » dont les « N » composantes sont les projections des « N » vecteurs « x_k » sur le vecteur « v_j » est appelé « $j^{\text{ième}}$ » composante principale.

Chaque composante « x_{kj}^p » du vecteur « x_j^p » aura pour expression : « $x_{kj}^p = x_k^t \cdot v_j$ » avec « $k = 1, \dots, N$ ».

La nouvelle matrice des données s'écrit : « $X = [x_1^p, x_2^p, \dots, x_{d'}^p, \dots, x_d^p] = X^t \cdot V$ ».

Les axes définis par ces vecteurs « x_j^p » sont dits factoriels, et sont les vecteurs propres. Ces axes sont les combinaisons linéaires des « d » axes initiaux.

On aboutit ainsi à une représentation optimale de la matrice des données « X » dans un espace de dimension inférieure. L'ACP garantit que la déformation du nuage de points est minimale au sens d'un critère « j_p » basé sur la moyenne des carrés des distances entre les vecteurs « x_k » et leurs projections notées « x_k^p » (telle que $x_k^p = [x_{k1}^p, x_{k2}^p, \dots, x_{kd'}^p, \dots, x_{kd}^p]^t$) : « $j_p = \frac{1}{N} \cdot \sum_{k=1}^N d^2(x_k, x_k^p)$ » [116].

Les résultats de l'ACP peuvent être visualisés en considérant la projection du nuage de points sur les deux ou trois premiers axes factoriels. Autrement dit, en visualisant la matrice des données dans l'espace défini par les deux ou trois premiers vecteurs propres.

Enfin la qualité de la représentation peut être quantifiée par le calcul du pourcentage d'inertie expliqué sur chaque axe factoriel ou sur le sous-espace de dimension « d' » obtenu. Ce pourcentage d'inertie est défini en fonction des valeurs propres :

- Pourcentage d'inertie sur l'axe « i » : $\Gamma_i = \frac{\lambda_i}{\sum_{j=1}^d \lambda_j}$
- Qualité de la représentation dans le sous-espace de dimension « d' » : $\Gamma = \frac{\sum_{j=1}^{d'} \lambda_j}{\sum_{j=1}^d \lambda_j}$

Ce rapport doit tendre vers « 1 » pour une représentation la plus proche possible de la réalité. Mais en pratique l'utilisateur fixe un seuil de qualité autour de 80%, 90%, puis sélectionne les vecteurs propres correspondant aux valeurs propres ayant permis d'atteindre ce seuil, afin de définir la base du sous-espace.

Une fois le sous-espace « $R^{d'}$ » défini, il est possible d'évaluer la qualité de la représentativité de la projection « x_k^p » du vecteur « x_k », dans ce sous-espace, en calculant le cosinus de l'angle « α_k » que forme

ce dernier avec « R^d » : $\cos^2(\alpha_k) = \frac{\sum_{j=1}^{d'} (x_{kj}^p)^2}{\sum_{j=1}^d (x_{kj})^2}$.

Ainsi, plus « $\cos^2(\alpha_k)$ » est proche de l'unité plus la projection de « x_k » en « x_k^p » est représentative.

IV.8.4.2 Classification à l'aide de réseaux de neurones artificiels (ANN)

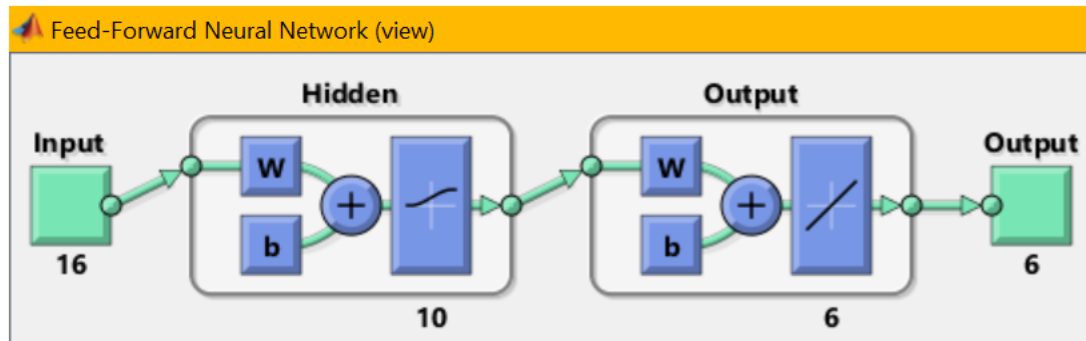


Figure IV.33 : Réseau de neurones Feedforward avec PCA




Figure IV.34 : Histogramme d'erreur entre les valeurs cibles (Target values) et les valeurs prédites D'ANN avec PCA




Figure IV.35 : État d'entraînement d'ANN avec PCA




Figure IV.36 : Courbe de performance d'apprentissage du classificateur de réseau neuronal avec PCA

IV.8.4.3 Classification à l'aide de la forêt aléatoire (RF)




Figure IV.37 : Le taux d'erreur équilibré de RF avec PCA

IV.8.5 Interprétations des résultats

Sans aller dans les détails les plus pointus on a mis l'essentiel de toutes ses figures, c'est le pourcentage de classification des défauts des barres rotoriques cassées de la MAS dans le tableau (IV-5).

Tableau IV.5 : Résultats des classificateurs ANN et RF sans et avec algorithmes d'optimisation

		Paramètres statistiques				Paramètres fréquentiels en paquets d'ondelettes				Paramètres statistique et fréquentiels en paquets d'ondelettes			
		Apprentissage		Test		Apprentissage		Test		Apprentissage		Test	
		ANN	RF	ANN	RF	ANN	RF	ANN	RF	ANN	RF	ANN	RF
Sans optimisation	précision %	81.1905	100	76.1111	87.2222	86.1905	98.8095	78.8889	79.4444	95.4762	100	87.7778	90
	Temps (s)	109.8219	13.5052	2.7616	8.1943	63.207	12.0571	2.6618	4.9598	127.3953	12.0414	6.3246	4.6141
BBAT	précision%	78.3333	99.7619	75.5556	87.2222	85.4762	99.2857	81.1111	78.3333	90.9524	99.7619	91.1111	92.7778
	Temps (s)	41.2341	11.5924	2.5658	4.7801	54.2727	11.9094	2.5868	5.1606	55.3485	11.5786	2.556	4.7123
BPSO	précision %	84.0476	99.7619	83.8889	88.3333	82.8571	99.7619	78.3333	78.8889	94.7619	99.7619	93.8889	95
	Temps (s)	50.7143	11.8571	2.5342	4.9335	46.0295	11.8125	2.6083	4.8937	88.9211	11.6481	2.5552	4.8687
PCA	précision %	75.4762	99.7619	81.1111	89.4444	93.8095	100	93.8889	96.1111	98.0952	100	97.2222	98.3333
	Temps (s)	63.5083	12.2038	2.7196	4.9923	103.6447	13.513	3.8241	6.1582	77.4085	11.7981	2.8647	4.8404

IV.9 Conclusion

Dans ce chapitre, nous avons utilisé l'analyse des signatures des défauts dans les courants statoriques MCSA « Motor Current Signature Analysis » au régime permanent pour déterminer les composantes spécifiques aux défauts étudiés afin de former une base de données fiable pour l'apprentissage de deux types des Learning machines « réseau de neurones (ANN) et la forêt aléatoire (RF) » à l'aide de deux techniques de traitement du signal « I_{as} » :

- ❖ La première est basée sur les paramètres statistiques ; qui sont des outils de suivi et de diagnostic de l'état des barres rotoriques, ils sont efficaces et simples à réaliser.
- ❖ La deuxième est basée sur la transformée en paquets d'ondelettes qui est considéré comme un outil idéal en raison de son aptitude d'analyse des signaux non stationnaires.

Et comme le tableau (IV.5) montre l'incapacité de ANN et RF sans optimisation de classer les défauts des barres rotoriques cassées avec une grande précision (de **90%** avec RF, jusqu'à **95.4762%** avec ANN). On a fait l'appelle des algorithmes d'optimisations BBAT, BPSO et l'algorithme de réduction de dimension PCA.

Finalement, Nous pouvons conclure que la forêt aléatoire (RF) avec l'assistance d'algorithme de réduction de dimension (PCA) est plus performant par rapport au réseau de neurones de type Feedforward avec une précision (**98.33%**) de classification des défauts de cassures de barres rotoriques.

Conclusion générale

Conclusion générale

Dans notre travail, nous nous sommes focalisés plus particulièrement sur le développement d'un système intelligent de surveillance et de diagnostic « détecter et localiser » automatiquement (reconnaissance des formes) en temps réel, des défaillances mécaniques et plus spécifiquement encore sur les défauts relatifs aux barres rotoriques cassées de la MAS, en utilisant les réseaux de neurones artificiels et la forêt aléatoire (RF). Une multitude des grandeurs indicatrices extrait du courant statorique « I_{as} » par des paramètres statistiques et des paramètres fréquentielles « transformée en paquet d'ondelette » va adopter.

Pour réaliser cette surveillance par reconnaissance des formes de défaut des barres rotoriques cassées, notre thèse a été organisée selon le plan suivant :

- Les éléments génériques relatifs à la fiabilité dans les systèmes de génie électrique ont été introduits dans le premier chapitre. L'une des parties les plus typiques de ces systèmes est la machinerie électrique. Les dispositifs de suivi de leur état sont particulièrement intéressants pour les producteurs et exploitants en raison des diverses pannes auxquelles ils peuvent être soumis. Plusieurs techniques de surveillance et de diagnostic pour ce type de problème étaient également répertoriées ;
- Dans le deuxième chapitre, nous nous sommes penchés sur la modélisation de la MAS qui tient compte de la structure de type circuit multi-enroulements du rotor. Un modèle mathématique établi, dont la complexité a été diminuée, repose sur des hypothèses simplifiées. Nous avons rappelé que le modèle de la MAS est un système d'équations différentielles dont les coefficients sont des fonctions périodiques du temps ; la transformation de Park nous a permis de réduire ce modèle avec une alimentation complètement sinusoïdale à partir du réseau ;
- Pour confirmer la présence de défauts rotoriques dans le troisième chapitre, une investigation à l'aide de technologies basées sur l'analyse spectrale et en ondelettes apparaît nécessaire. Pour ce faire, nous avons introduit les instruments de traitement du signal de manière progressive, en commençant par la série de Fourier et en terminant par les ondelettes. Des exemples démontrant clairement l'apport de chacune de ces technologies de traitement du signal ont été utilisés pour présenter de manière didactique l'analyse du signal. L'analyse du signal par FFT trouve son incapacité à reconnaître les signaux non stationnaires, mais le TFCT semble avoir surmonté cet inconvénient dans le plan temps-fréquence. L'utilisation d'une fenêtre de taille unique présente des inconvénients, et le choix fait pour assurer un compromis entre résolution temporelle et fréquentielle est particulièrement délicat. Pour cela on a fait l'appel de la transformée en

ondelette avec ses variétés continue, discrète et en paquet ;

- Au dernier chapitre, nous avons utilisé l'analyse des signatures des défauts dans les courants statoriques MCSA « Motor Current Signature Analysis » au régime permanent pour déterminer les composantes spécifiques aux défauts étudiés afin de former une base de données fiable pour l'apprentissage de deux types des Learning machines « réseau de neurones (ANN) et la forêt aléatoire (RF) » à l'aide de deux techniques de traitement du signal « I_{as} » :
 1. La première est basée sur les paramètres statistiques ; qui sont des outils de suivi et de diagnostic de l'état des barres rotoriques, ils sont efficaces et simples à réaliser.
 2. La seconde est basée sur la transformée en paquets d'ondelettes qui est considéré comme un outil idéal en raison de son aptitude d'analyse des signaux non stationnaires.

Et comme le tableau (IV.5) montre l'incapacité de ANN et RF sans optimisation de classer les défauts des barres rotoriques cassées avec une grande précision (de **90%** avec RF, jusqu'à **95.4762%** avec ANN). On a fait l'appelle des algorithmes d'optimisations BBAT, BPSO et l'algorithme de réduction de dimension PCA.

Finalement, Nous avons pu conclure que la forêt aléatoire (RF) avec l'assistance d'algorithme de réduction de dimension (PCA) est plus performant par rapport au réseau de neurones de type Feedforward avec une précision (**98.33%**) de classification des défauts CBR.

Perspectives

Les recherches effectuées pour cette thèse pourraient inspirer d'autres recherches sur un certain nombre de sujets, notamment :

- On peut appliquer les mêmes méthodes intelligentes (ANN et RF) sur une MAS avec différentes charges ;
- Remplacer le réseau de neurone par les méthodes de classifications (SVM, Extrême Learning machine, ...etc.) ;
- On peut appliquer les mêmes méthodes intelligentes (ANN et RF) sur un modèle comporte plusieurs défauts (roulement, court-circuit des bobines statorique, déséquilibre d'alimentation, ...etc.) ;
- L'application de ces méthodes intelligentes (ANN et RF) sur des signaux des défauts réels qui affectent les machines électriques tournantes.

Références bibliographiques

Références bibliographiques

- [1] : A. Villemeur ; « *Sûreté de fonctionnement des systèmes industriels -Fiabilité – Facteurs humains – Information* », vol 67 de collection de la direction des Etudes et Recherche d'Electricité de France, Eyrolles, 1998.
- [2] : G. Rostaing ; « *Diagnostic de défauts dans les entraînements électriques* », Thèse de Doctorat, laboratoire d'électrotechnique de Grenoble, sous la direction de J. C. Trigeassou, 1997
- [3] : G. Grellet ; « *Les essais et la surveillance des machines tournantes* », Revue générale d'électricité, N°8, pp 22-28, 1994.
- [4] : G. Zwinngelstan ; « *Diagnostic des défaillances : théorie et pratique pour les systèmes industriels* », Edition Hermès, Paris, 1995.
- [5] : S. Amrane ; « *Diagnostic de défauts des moteurs d'induction* », Mémoire de magistère, université A. Mira de Bejaia, 2000.
- [6] : J. N. Chatain ; « *Diagnostic expert* », Edition Hermès, Paris, 1993.
- [7] : B. Dubuisson ; « *Détection et diagnostic des pannes sur processus* », Technique de l'ingénieur, R7597, 1992.
- [8] : J. Morel ; « *Vibrations des machines et diagnostic de leur état mécanique* », Edition Eyrolles, 1996.
- [9] : J. Richalet ; « *Modélisation et identification des processus* », technique de l'ingénieur, R7140, Avril, 1987.
- [10] : R. Casimir ; « *Diagnostic des défauts des machines asynchrones par reconnaissance des formes* », Thèse de Doctorat, l'école doctorale d'électronique, d'électrotechnique et d'automatique de Lyon, Décembre, 2003.
- [11] : F. Felippitti, G. Francescini, C.Tassoni, S.Zond, P.Vas ; « *AI techniques in induction machines diagnosis including the speed ripples effect* », IEEE transaction on industries applications, vol.34, N°1, Junnuary/February, PP.98-108, 1998.
- [12] : D. Pomorski, P.B.Perche; « *Diagnostic et arbre de décision : Application à la surveillance partielle d'un moteur asynchrone* », Journal européen des systèmes automatisés 'JESA', vol 34 - N°4, PP.441-477, 2000.
- [13] : F. Felippitti, G. Francescini, C.Tassoni, S.Zond, P.Vas ; « *A fuzzy logic approach to on-line induction motor diagnosis based on stator current monitoring* », IEEE-KTH, Stockholm, Sweden, June, PP. 156-161, 1995.
- [14] : R.K.Rayandu, S. Samarasinghe, D. Kulasivi ; « *A comparison of model based reasoning and learning approaches to power transmission fault diagnosis* », Artificial neural network and expert system, proceeding, second New Zealand international tow-stream conference on published. IEEE, PP. 218-222, 1995.

- [15] : R. Bigret, J. L.Ferson ; « *Diagnostic, maintenance et disponibilité des machines tournantes* », Edition Masson, Paris, 1994.
- [16] : C. Faure, L. Miclet ; « *Intelligence artificielle et reconnaissance des formes* », Technique de l'ingénieur H1900, Juin, 1990.
- [17] : J. Hato ; « *Intelligence artificielle et reconnaissance des formes, introduction* », Technique de l'ingénieur, H1900, Juin 1990.
- [18]: F. Filippetti, G. Franceschini, C. Tassoni; « *Neural networks approach to electric machine on-line diagnostics* », EPE Brighton, PP. 213-218, 1993.
- [19] : H. Büller ; « *Réglage par logique floue* », Presse Polytechnique Romandes, Lausanne, 1994.
- [20] : E. Davalo, P. Naim ; « *Des réseau de neurones* » ; Edition Eyrolles, Paris, 1993.
- [21] : M. Gondran, C. Miller ; « *Réseaux de neurones et apprentissage* », Revue REE, N° 3, PP. 6-9, Mars 1997.
- [22] : M. Sahraoui ; « *Contribution au diagnostic d'une machine asynchrone triphasée à cage* », Mémoire de magistère, université de Biskra, Algérie, 2003.
- [23]: M. E. H. Benbouzid and G. B. Kliman; « *What stator current processing-based technique to use for induction motor rotor faults diagnosis?* », IEEE Transaction on energy conversion, vol. 18, N° 2, PP. 238-244, June 2003.
- [24]: Chouidira, I., Khodja, D., Chakroune, S; « *Induction machine faults detection and localization by neural networks methods* », Rev. d'Intelligence Artif., vol. 33, N°6, PP. 427-434, <https://doi.org/10.18280/ria.330604>, 2019.
- [25] : N. Halem ; « *Modélisation des machines asynchrone triphasée à cage en vue du diagnostic par les méthodes des éléments finis* », Thèse de Doctorat, université de Biskra, Algérie, 2015.
- [26]: R. Scattolini and N. Cattane; « *Detection of sensor faults in a large flexible structure* », IEEE proceeding, control, theory and application, vol. 146, N° 5, PP. 383-388, September 1999.
- [27]: B. Chetate, A. Lebaroud; « *Development of an automated system of forecasting and diagnosis of the anomalies* », Proceeding of the second Maghreb conversion in electrical engineering (CMGE'95), Volume II, School of instructor's training, Tunisia, PP. GL17, 2017.
- [28]: B. Chetate, A. Lebaroud; « *Approach for the elaboration of a diagnosis automated system of electric machine breakdowns* », Cements concretes plasters lime journal, Revue Ciments Betons Platers Chaux, N° 823, PP. 428-431, ISSN 0397, France, Juin 1996.
- [29]: B. Chetate; « *Automatic diagnosis of electromechanical system anomalies* », Proceeding, university of Batna (Algeria), 07-09 December 1997.

- [30] : A. Lebaroud ; « *Le diagnostic automatique des défaillances des systèmes électromécaniques* », Mémoire de magistère, INHC, 1997.
- [31] : M. Jufer et A. Abdelaziz ; « *Influence d'une rupture de barre ou anneau sur les caractéristiques externes d'un moteur asynchrone à cage* », Bull. SEV/VS69, PP. 921-925, 05 Septembre 1978.
- [32]: E. Ritchie, X. Deng and T. Jokinen; « *Dynamic model of three phase squirrel cage induction motors with rotor faults* », ICEM, PP. 694-698; 1994.
- [33]: S. Williamson and A. C Smith; « *Steady-state analysis of 3-phases cage motors with rotor bar and end-ring faults* », IEE Proceeding, vol. 129, N° 3, PP. 93-100, May 1982.
- [34]: W. Deleroi; « *Broken bar in squirrel-cage rotor of an induction motor, part1: Description by super imposed faults currents* », Archiv für electrotechnik 67, PP. 91-99, 1984.
- [35] : H. Yahoui ; « *Contribution à la surveillance et au diagnostic des machines électriques* », Thèse de Doctorat, Lyon ; France, Juillet 1995.
- [36]: P.Vas , F. Felippitti, G. Francescini and C.Tassoni ; « *Transient modelling oriented to diagnostics of induction machines with rotor asymmetries* », ICEM. C3(1), PP. 62-67, 1994
- [37]: R. F. Walliser, C. F. Landy; « *The influence of interbar currents of the detection of broken rotor bar* », ICEM, PP. 1246-1250, Paris, Septembre 1991.
- [38]: N. M. Elkasabgy, A. R. Easthan and G. E. Dawson; « *Detection of broken bars in the cage rotor on an induction machine* », IEEE Transaction, On Industry Application vol. 28, N° 1, PP. 165-171, January/February 1992.
- [39]: D. G. Dorrell, N. C. Paterson, J. F. Watson; « *The causes and quantification of sideband currents for us in rotor fault systems for cage induction motors* », ICEM, PP. 414-419, Spain, 1996.
- [40] : A. Lebaroud ; « *Le diagnostic automatique des défaillances des systèmes électromécaniques* », Mémoire de magistère, INHC, 1997.
- [41] : E. Schaeffer, « *Diagnostic des machines asynchrones : modèle et outils paramétriques dédiés à la simulation et à la détection des défauts* », Thèse de Doctorat, Ecole générale de Nantes, France, Décembre 1999.
- [42] : G. Didier ; « *Modélisation et diagnostic de la machine asynchrone en présence de défaillances* », Thèse de Doctorat, Université de Nancy, France, Octobre 2004.
- [43] : B. Smail ; « *Contribution au diagnostic de la machine asynchrone par estimation paramétrique* », Thèse Doctorat, Ecole supérieure d'ingénieur de Poitiers, France, Décembre 2002.
- [44]: B. Chetate; « *Elaboration of an expert system allowing the rational choice of asynchronous motors* », Proceeding of conference on modeling and simulation in electrical systems (CMSSES), University of Guelma,

Algeria, PP.163-169, 07-08 November 1995.

[45]: B. Chetate, A. Lebaroud; « *Interpretation module elaboration of information and its application for the recognition of asynchronous motor faults* », Proceeding of international annual conference of the university of Batna, Algeria (IEEA), PP.94-97, December 1997.

[46]: B. Chetate, A. L ebaroud; « *About real-time intelligent failure diagnosis of electromechanical systems* », Proceeding of the third Maghreb days on mechanics, University of Guelma Hammam Debagh, Algeria, PP. 404-409, 29-30 April 1997.

[47]: T. Sorsa, H. N. Koivo; « *Neural networks in process fault diagnosis* », IEEE Transaction on systems, vol. 21, N° 4, PP. 815-825, July-August 1991.

[48]: Y. Shimakura, J. Inagaki, S. Hori; « *An artificial neural network and knowledge-based method for reasoning causes of power network faults* », Edition Technology update series, IEEE, PP.250-254, 1996.

[49] : B. Chetate, D. J. Khodja ; « *Diagnostic en temps réel des défaillances d'un ensemble moteur asynchrone-convertisseur électronique en utilisant les réseaux de neurones artificiel* », Journal Electrotekhnika, Moscou, PP.16-20, Décembre 2003 ;

[50] : L. Baghli ; « *Contribution à la commande de la machine asynchrone, utilisant de la logique floue, des réseaux de neurones et des algorithmes génétiques* », Thèse de Doctorat, Nancy, France, 1999.

[51] : M. Khov ; « *Surveillance et diagnostic des machines synchrones à aimants permanents : Détection des courts-circuits par suivi paramétrique* », Thèse de Doctorat, université de Toulouse, France, 2009.

[52] : M. Sahraoui ; « *Etude comparative des méthodes de diagnostic des machines asynchrones* », Thèse de Doctorat, université de Biskra, Algérie, 2010.

[53] : A. M. Mohamed ; « *Observation et diagnostic de processus industriels à modèle non linéaire applications aux machines électriques* », Thèse de Doctorat, Ecole centrale de Nantes, 2010.

[54] : O. Olivier ; « *Diagnostic par reconnaissance de formes : applications à un ensemble convertisseur /machine asynchrone* », Thèse de Doctorat à l'école centrale de Lyon, France, 2006.

[55]: G Muller, C. Landy; « *Vibration produced in squirrel-cage induction motors having broken rotor bars and interbar currents* », International conference on electrical machines, 1994.

[56] : A. Bouzida ; « *Diagnostic de défauts de la machine asynchrone à cage par la technique des ondelettes* », Mémoire de magistère, Ecole nationale polytechnique d'Alger, 20 janvier 2008.

[57] : M. Amar ; « *Surveillance et diagnostic des défauts électriques : Application aux moteurs asynchrone* », Thèse de Doctorat, université du 20 août 1955 Skikda, 2012.

[58] : D. Gaëtan ; « *Modélisation et diagnostic de la machine asynchrone en présence de défaillances* », Thèse de Doctorat, Université Henri Poincaré, France, 2004.

- [59] : A. Ibrahim ; « *Contribution au diagnostic des machines électriques : Exploitation des signaux électriques et de la vitesse instantanée* », Thèse de Doctorat, 2009.
- [60] : L. Baghli ; « *Contribution à la commande de la machine asynchrone, utilisant de la logique floue, des réseaux de neurones et des algorithmes génétiques* », Thèse de Doctorat, Nancy, France, 1999.
- [61] : B. Smail ; « *Contribution au diagnostic de la machine asynchrone par estimation paramétrique* », Thèse Doctorat, Ecole supérieure d'ingénieur de Poitiers, France, Décembre 2002.
- [62] : R. Kechida ; « *Utilisation du contrôle direct du flux statorique et du filtre de Kalman en vue du contrôle du couple d'un moteur asynchrone : Application au diagnostic des défauts* », Mémoire de magistère en électromécanique, centre universitaire d'El Oued, Algérie, 2010.
- [63] : A. Radia ; « *Perturbations singulières appliquées au modèle de machine asynchrone avec défaut au stator et rotor* », Mémoire de magistère, Ecole nationale polytechnique d'Alger, 2007.
- [64] : M. Sahraoui ; « *Contribution aux diagnostics des machines asynchrones triphasées à cage* », Mémoire de magistère, université de Biskra, Algérie, 2003.
- [65] : A. Abed ; « *Contribution à l'étude et au diagnostic de la machine asynchrone* », Thèse de Doctorat, Université Henri Poincaré, Nancy, France, 2002.
- [66] : R.B. Randall, J. Antoni, S. Chobsaard ; « *The relationship between spectral correlation and envelope analysis in the diagnostics of bearing faults and other cyclostationary machine signals* », Mechanical systems and signal processing, vol.15, PP.9445-962, 2001.
- [67] : G. M. Jokosimovic, J. Penman; « *The detection of inter-turn short circuits in the stator windings of operating motors* », IEEE Transaction Ind. Elec, vol.47, N° 47, PP. 1078-1084, October 2000.
- [68] : M. E. H. Benbouzid, M. Veira and C. Theysal; « *Induction motors faults detection and localization using stator current signal processing techniques* », IEEE Transaction, Power electron, vol. 14, N° 1, PP.14-22, January 1999.
- [69] : L. Dernath; « *Wavelet transforms and their applications* », Birkhauser Boston, 2002.
- [70] : Y. Meyer ; « *Ondelettes et opérateurs : Ondelettes* », Edition Hermann1, 1990.
- [71] : T. S. Karris; « *Signals and systems with MATLAB computing and Simulink modeling* », Fourth edition, Orchard publications, 2008.
- [72] : V. Perrier ; « *Idée de la base d'application de la théorie des ondelettes* », Laboratoire de modélisation et calcul de l'IMAG institut national polytechnique de Grenoble, 2005.
- [73] : M. Ayad, D. Chikouche ; « *Application de la transformée en ondelette à l'analyse des signaux vibratoires d'un système d'engrenage en vue d'un diagnostic précoce* », Fourth international conference on computer integrated manufacturing CIP, 2007.

- [74]: J. Cusidó, L. Romeral, Juan A. Ortega, Javier A. Rosero and A. G. Espinosa; « *Fault detection in induction machine using power spectral density in wavelet decomposition* », IEEE Transaction. Ind. Elec, vol. 55, N° 2, February 2008.
- [75] : Technique de l'ingénieur, 2009.
- [76] : A. Bouzida ; « *Diagnostic de défauts de la machine asynchrone à cage par la technique des ondelettes* », Mémoire de magistère, Ecole nationale polytechnique d'Alger, 20 janvier 2008.
- [77] : Y. Meyer ; « *Principe d'incertitude, bases hilbertiennes et algèbres d'opérateurs* », Séminaire Bourbaki, 1986.
- [78]: S. Mallat; « *A theory for multiresolution signal decomposition: The wavelet transforms* », IEEE Transaction, Pattern anal. Machine Intell 11, pages 674-693, 1989.
- [79]: A.N. Akansu et R. A. Haddad; « *Multiresolution signal decomposition: Transforms sub bands, and wavelets* », Academic press, 2001.
- [80]: S. Mallat; « *A wavelet tour of signal processing* », Elsevier Inc, 2009.
- [81] : M. Bazi Smail ; « *Contribution à la détection et au diagnostic des défauts dans un système machine à induction/convertisseur* », Thèse de Doctorat, Université de Batna 2, Décembre 2016.
- [82] : R. Benzid, ; « *Ondelettes et Statistiques d'Ordre Supérieur Appliquées aux Signaux Uni et Bidimensionnels* », Thèse Doctorat, Faculté des Sciences de l'Ingénieur, Université de Batna, 2005.
- [83] : : G. Didier ; « *Modélisation et diagnostic de la machine asynchrone en présence de défaillances* », Thèse de Doctorat, Université de Nancy, France, Octobre 2004.
- [84]: K. Abbaszadeh, J. Milimonfared, M. Haji and H.A. Toliyat; « *Broken Bar Detection in Induction Motor via Wavelet Transformation* », IEEE Industrial Electronics Society, Vol. 1, PP. 95 - 99, 2001.
- [85]: C. Zhitong, C. Hongping, H. Guoguang and E. Ritchie; « *Rotor Fault Diagnosis of Induction Motor based on Wavelet Reconstruction* », IEEE, Proceedings of the Fifth International Conference on Electrical Machines and Systems, ICEMS, Vol. 1, PP. 374 – 377, 2001.
- [86] : R.Besaadi and H. Mouss; « *Diagnostic de défaillances par reconnaissance de formes* », ICEM. Vol. 3, PP. 79-87, 2010.
- [87] : N. Leila ; « *Diagnostic des défauts dans les machines tournantes par l'analyse vibratoire* », Thèse de Doctorat en science, Université Badji Mokhtar Annaba, 2015.
- [88]: M. Misiti, Y. Misiti, G. Oppenheim, J. M. Poggi; « *Wavelet toolbox for use with MATLAB* », 2010.
- [89]: M. Y. Chow; « *Methodologies of using neural network and fuzzy logic technologies for motor incipient fault detection* », World scientific publishing company, 1998.

- [90] : R. Cyril ; « *Prévision de la température par réseaux neurones* », Lycée Victor Hugo Besançon, dossier TIPE 2003-204.
- [91] : M. Chaherdine ; « *Mise point d'un programme d'optimisation pour le stockage d'énergie thermique* », Université Mohamed Boudiaf d'Oran, Algérie, 2013.
- [92] : I.Kada and M. B. Chaïmaa; « *Diagnostic des défauts de la MAS à l'aide des réseaux de neurones artificiels* », Mémoire de master, Université Saad DAHLAB, Blida, Algérie, 2020.
- [93] : M. C. Laoubi ; « *Contrôle d'un pendule inverse par un réseau de neurones artificiels* », Mémoire de master, Université Akli Mohamed Oulhadj, Bouira, Algérie, 2018.
- [94] : M. Sihali ; « *Diagnostic de défauts à base d'observateurs à entrée inconnues : Application au système hydraulique* », Mémoire de master, Université Mouloud MAMMERI, Tizi-Ouzou, Algérie, 2019.
- [95] : M. Y.Ammar ; « *Mise en œuvre de réseaux de neurones pour la modélisation de cinétiques réactionnelles en vue de la transposition Batch/Continu* », Thèse PHD, Ecole nationale d'ingénieurs de Sfax, Tunisie, 2007.
- [96] : K. M. Tarek ; « *Principe de base des réseaux de neurones artificiels et apprentissage* », Thèse de magistère, Université d'Annaba, 2010.
- [97] : C. Touzet ; « *Les réseaux de neurones artificiels : Introduction au connexionnisme* », Cours, Exercices et Travaux pratique, Université des sciences et technologiques du Languedoc, Montpellier, France, Juillet 1992.
- [98] : G. Zwingelstein ; « *Diagnostic des défaillances : Théorie et pratique pour les système industriels, Traité des nouvelles technologies, séries diagnostic et maintenance* », Editions Hermès, Paris, France, 1995.
- [99] : E. Gauthier ; « *Utilisation des réseaux de neurones artificiels pour la commande d'un véhicule autonome* », Thèse de Doctorat en informatique, Systèmes et communications, Institut nationale polytechnique de Grenoble, France, Janvier 1999.
- [100] : R. Lepage ; « *Reconnaissance d'algues toxique par vision artificielle et réseau de neurones* », Mémoire de recherche, Université du Québec à Rimouski, Canada, Septembre 2004.
- [101] : <https://www.tibco.com/fr/reference-center/what-is-a-random-forest>.
- [102]: L. Bierman; « *Random forests: Machine Learning* », vol. 45, N° 1, PP. 5–32. 2001
- [103]: T. Han, D. J; « *Rolling bearing fault diagnostic method based on VMD-AR model and random forest classifier* », Shock Vibration, PP.1-11, 2016.
- [104]: X. Qin, Q. Li, X. Dong, S. Lv; « *The fault diagnosis of rolling bearing based on ensemble empirical mode decomposition and random forest* », Shock Vibration, PP.1–9, 2017.
- [105]: N. Morizet, N. Godin, J. Tang, E. Maillet, M. Fregonese, B. Normand; « *Classification of acoustic emission signals using wavelets and random forests: Application to localized corrosion* », Mech Syst Signal

Process, PP. 1026–37, 2016.

[106]: S. Rajakarunkaran, P. Venkumar, K. Devaraj, K. P. S. Rao; « *Artificial neural network approach for fault detection in rotary system* », Applied soft computing, vol. 8, Issue 1, PP.740-748, January 2008.

[107]: Mirjalili, S., Mirjalili, S.M., Yang, X.S; « *Binary bat algorithm. Neural Computing and Applications* », vol. 25, N° 3, PP. 663-681, <https://doi.org/10.1007/s00521-013-1525-5>, 2014.

[108]: G. Li, C. Le; « *Hybrid binary bat algorithm with cross-entropy method for feature selection* », 4th International Conference on Control and Robotics Engineering (ICCRE), PP.165-169, <https://doi.org/10.1109/ICCRE.2019.8724270>, 2019.

[109]: S. Mirjalili, Hashim; « *BMOA: binary magnetic optimization algorithm. International Journal of Machine Learning and Computing* », vol. 2, N° 3, PP. 204-210, <https://doi.org/10.7763/IJMLC.2012.V2.114>, 2012.

[110]: R. Yuan et B. Guangchen; « *Determination of optimal SVM parameters by using GA/PSO* », Journal of computers, vol. 5, N° 8, 2010.

[111]: H. Cheng-Lung and D. Jian-Fan; « *A distributed PSO-SVM hybrid system with feature selection and parameter optimization* », Applied soft computing, vol. 8, N° 4, PP.1381-1391, 2008.

[112]: B. K. Panigrahi, Y. Shi et L. M. Hiot ; « *Handbook of swarm intelligence concepts, principles and applications* », Springer 2011.

[113]: X. Yun-Jie et X. Shu-Dong; « *A new and effective method of bearing fault diagnosis using wavelet packet transform combine with vector machine* », Journal of computers, vol.6, N° 11, November 2011.

[114]: J. L; « *A combination of PSO and SVM for road icing forecast* », Journal of computers, vol. 5, N° 9, September 2010.

[115]: H. Nezambadi-Pour, M. Rostami-Shahrbabaki et M. M. Farsangi; « *Binary particle swarm optimization: challenge and new solutions* », The journal of computer society of Iran (CSI) on computer science and engineering, PP. 21-32, 2008.

[116]: B. Pinkowski; « *Principal component of speech spectrogram images* », Pattern recognition, vol.30, PP.777-787, 1997.

Annexe

Paramètres de la MAS

paramètres	Signification des paramètres	Valeurs
P	La puissance nominale	1.1 KW
V	La tension nominale de ligne	220 V
f_s	La fréquence d'alimentation	50 Hz
p	Nombre de paires de pôle	1
R	Le rayon moyen de l'entrefer	35.76 mm
N_s	Nombre de spires par phase statorique	160
l	La longueur active du circuit magnétique	65 mm
R_e	La résistance d'une portion d'anneau de court-circuit	150 $\mu\Omega$
R_b	Resistance d'une barre rotorique	150 $\mu\Omega$
L_e	L'inductance de fuite d'anneau de court-circuit	0.1 μH
L_b	L'inductances de fuite d'une barre rotorique	0.1 μH
e	L'épaisseur de l'entrefer	0.2 mm
R_s	La résistance statorique	7.58 Ω
N_r	Nombre de barres rotoriques	16
L_{sf}	L'inductance de fuite statorique	26.5 mH
f	Coefficient de frottement visqueux	0
J	Moment d'inertie	0.00541 Kg m^2