

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université A.MIRA-BEJAIA
Faculté de technologie
Département Génie électrique
Laboratoire de génie électrique

THÈSE

Présentée par

BEHLOUL Fatiha

Pour l'obtention du grade de

DOCTEUR EN SCIENCES

Filière : Automatique et traitement du signal

Option : Système

Thème

**Contribution au diagnostic des systèmes électro-
énergétiques**

Soutenue le : 22/10/2025

Devant le Jury composé de :

Nom et Prénom

Grade

Mr KHIREDDINE Abdelkrim

Prof.

Univ. de BEJAIA

Président

Mr TAFININE Farid

MCA

Univ. de BEJAIA

Rapporteur

Mr ELMIR Youssef

prof.

ESTIN BEJAIA

Examineur

Mr CHELBI Salim

MCA

Univ. de BOUIRA

Examineur

Année Universitaire : 2024/2025

Remerciements

Je tiens, avant tout, à remercier le Tout-Puissant de m'avoir accordé le courage et la force nécessaires pour mener à bien ce travail.

J'adresse ensuite mes plus sincères remerciements à mon directeur de thèse, **Dr Taffine**, pour son encadrement constant et bienveillant tout au long de ce projet. Sa disponibilité, ses précieux conseils et son expertise ont été des piliers essentiels dans l'avancement de cette recherche. Il a su me guider à travers les différentes étapes, en m'encourageant à approfondir ma réflexion et à dépasser mes limites.

Je remercie également très vivement **Pr Elmir**, professeur à l'Ecole Supérieure de Technologie de l'Informatique et du Numérique et **Dr Chelbi**, MCA de l'université de Bouira, d'avoir accepté d'examiner ma thèse et pour l'intérêt qu'ils ont manifesté envers mon travail.

Je remercie aussi vivement **Pr Khireddine** professeur de l'université de Bejaia d'avoir accepté de présider le jury de cette thèse.

Enfin, je tiens à exprimer ma gratitude à toutes les personnes qui ont contribué, de près ou de loin, à la réalisation de ce travail de thèse.

A mon cher mari,

A mes enfants adorés,

A mes très chers parents,

A mes frères et sœurs,

Je vous dédie ce travail avec tout mon amour et ma gratitude.

Liste de production scientifique durant la thèse

Behloul, F., Tafinine, F. & Yaman, O. Induction Motor Fault Diagnosis with Local Ternary Pattern and AI Approaches. *J Fail. Anal. and Preven.* 23, 2533–2541 (2023). <https://doi.org/10.1007/s11668-023-01794-6>

Behloul, F., Tafinine, F. & Yaman, O. A Comparative Study of Local Binary Pattern and Local Ternary Pattern for Fault Detection in Induction Motors. The 2nd Electrical Engineering International Conference (EEIC'23), December 05-06, 2023, Bejaia.

Table des matières

| | |
|--|-----|
| Liste des figures..... | i |
| Liste des tableaux | iii |
| Liste des acronymes | ix |
| Introduction générale..... | 1 |
| Chapitre I : Généralités sur les machines électriques | 4 |
| I.1 Introduction | 5 |
| I.2 Les différents types de machines électriques | 5 |
| I.2.1 Machines à courant continu (MCC) à rotor bobiné | 5 |
| I.2.2 Les machines synchrones à aimants permanents | 6 |
| I.2.3 La machine asynchrone..... | 6 |
| I.2.3.1 Le stator..... | 7 |
| I.2.3.2 Le rotor | 7 |
| I.2.3.3 Principe de fonctionnement de la machine asynchrone..... | 8 |
| I.3 Défaits des machines électriques tournantes | 9 |
| I.3.1 Terminologie dans le diagnostic | 10 |
| I.3.2 Classification des défauts selon leurs origines..... | 10 |
| I.3.3 Type des défauts | 12 |
| I.3.3.1 Défaillances électriques..... | 12 |
| I.3.3.1.1 Court-circuit entre spires | 12 |
| I.3.3.1.2 Court-circuit entre bobine..... | 13 |
| I.3.3.1.3 Court-circuit entre phases..... | 13 |
| I.3.3.1.4 Court-circuit phase-neutre | 13 |
| I.3.3.1.5 Défauts d'isolant dans un enroulement | 13 |
| I.3.3.1.6 Défauts rotoriques | 14 |
| I.3.3.2 Défaillances mécaniques | 15 |
| I.3.3.2.1 Défauts de roulements | 15 |
| I.3.3.2.2 Défaut d'excentricité | 16 |
| I.4 Méthodes de diagnostics..... | 17 |
| I.4.1 Stratégies de Maintenance | 17 |
| I.4.1.1 Maintenance Réactive (ou Corrective)..... | 17 |
| I.4.1.2 Maintenance Préventive | 18 |
| I.4.1.3 Maintenance Predictive | 18 |

| | | |
|--|---|----|
| I.4.1.4 | Maintenance Conditionnelle..... | 18 |
| I.5 | Grandeurs mesurables et signaux de défauts..... | 19 |
| I.6 | État de l’art de surveillance des défauts des machines électriques..... | 20 |
| I.6.1 | Méthodes basées sur un modèle..... | 20 |
| I.6.2 | Méthodes sans modèle | 21 |
| I.6.3 | Techniques de traitement de signal..... | 23 |
| I.6.3.1 | Analyse temporelle..... | 23 |
| I.6.3.2 | Analyse fréquentielle..... | 24 |
| I.6.3.2.1 | L’analyse spectrale | 24 |
| I.6.3.2.2 | L’analyse d’enveloppe..... | 24 |
| I.6.3.3 | Analyse temps-fréquence | 25 |
| I.6.3.3.1 | La Transformée de Fourier à Fenêtre Glissante (TFFG)..... | 25 |
| I.6.3.3.2 | Distribution de Wigner Ville | 25 |
| I.6.3.4 | Analyse temps-échelle..... | 26 |
| I.6.3.4.1 | La transformée en ondelettes continue | 26 |
| I.6.4 | Diagnostic orienté données | 27 |
| I.6.4.1 | Systèmes experts | 27 |
| I.6.4.2 | Reconnaissance de formes..... | 27 |
| I.6.5 | Méthodes par intelligence artificielle..... | 27 |
| I.7 | Conclusion..... | 27 |
| Chapitre II : Analyse de la texture..... | | 29 |
| II.1 | Introduction | 30 |
| II.2 | Définition de la texture..... | 30 |
| II.3 | Notion de textures | 31 |
| II.3.1 | Les familles de textures | 31 |
| II.3.2 | Perception visuelle de texture | 32 |
| II.4 | Les méthodes d’analyse de la texture..... | 33 |
| II.4.1 | Les méthodes empruntées au traitement du signal | 34 |
| II.4.2 | Les méthodes basées sur un modèle | 34 |
| II.4.3 | Les méthodes statistiques..... | 34 |
| II.4.3.1 | Les statistiques du premier ordre..... | 34 |
| II.4.3.2 | Les statistiques du deuxième ordre..... | 36 |
| II.4.3.2.1 | Matrice de cooccurrences | 36 |
| II.4.3.2.2 | Définition de la matrice de cooccurrence | 36 |

| | | |
|--|---|----|
| II.4.4 | Les méthodes basées sur une analyse des motifs..... | 39 |
| II.4.4.1 | Le spectre des textures..... | 39 |
| II.4.4.2 | Local binary pattern..... | 40 |
| II.4.4.2.1 | Invariance à la rotation..... | 43 |
| II.4.4.2.2 | Amélioration du motif de l'invariance à la rotation par le motif uniforme | 44 |
| II.4.4.2.3 | Local ternary pattern..... | 46 |
| II.5 | Classification et analyse de texture | 47 |
| II.5.1 | Classification K-NN..... | 47 |
| II.5.2 | Support vecteur machine SVM..... | 49 |
| II.5.3 | Les réseaux de neurones | 50 |
| II.6 | Conclusion..... | 52 |
| Chapitre III : Diagnostic des moteurs asynchrones par étude de l'histogramme LBP | | 54 |
| III.1 | Introduction | 55 |
| III.2 | Diagnostic des machines électriques par la méthode LBP | 55 |
| III.3 | Approche utilisée..... | 56 |
| III.3.1 | Génération des images à partir de signaux acoustiques..... | 57 |
| III.3.2 | Explications des principales étapes..... | 59 |
| III.3.3 | Prétraitement | 61 |
| III.3.3.1 | Filtrage des images..... | 61 |
| III.3.3.2 | Égalisation d'histogramme..... | 62 |
| III.4 | Fondements de l'histogramme LBP..... | 63 |
| III.4.1 | Evaluation de l'histogramme LBP | 64 |
| III.4.2 | Extraction des Caractéristiques via l'histogramme de LBP..... | 65 |
| III.5 | Conclusion..... | 68 |
| Chapitre IV : Diagnostic des machine asynchrones par application de la méthode LBP et GLCM | | 69 |
| IV.1 | Introduction | 70 |
| IV.2 | Utilisation de GLCM (Grey-Level Co-occurrence Matrix) dans le diagnostic des machines asynchrones | 70 |
| IV.3 | Analyse de la texture par LBP et GLCM | 71 |
| IV.3.1 | Combiner LBP _{1,8} et LBP1,8riu2 avec GLCM..... | 71 |
| IV.3.2 | Combinaison de GLCM avec la variante KLTP | 71 |
| IV.4 | Extraction des caractéristiques | 74 |
| IV.5 | Classification | 74 |
| IV.5.1 | Algorithme : Classification SVM "Un contre Tous" | 75 |

| | | |
|--------|--|----|
| IV.5.2 | Algorithme du classificateur KNN | 76 |
| IV.5.3 | Réseaux de neurones | 77 |
| IV.6 | Discussion des résultats | 77 |
| IV.7 | Conclusion..... | 82 |
| | Conclusion générale | 83 |
| | Conclusion Générale | 84 |
| | Bibliographique | 87 |
| | Résumé | 96 |

Liste des figures

Chapitre I

| | |
|--|----|
| Figure I.1 : Structure d'une machine asynchrone à cage d'écureuil..... | 6 |
| Figure I.2 : Stator d'une machine asynchrone..... | 7 |
| Figure I.3 : Rotor d'une machine asynchrone a cage..... | 8 |
| Figure I.4 : Défauts des machines selon leurs origines..... | 11 |
| Figure I.5 : Répartition des défauts des composants..... | 12 |
| Figure I.6 : Représentation des différents défauts statoriques..... | 13 |
| Figure I.7 : (a) Rupture d'anneaux ; (b) Ruptures de barres..... | 15 |
| Figure I.8 : Représentation d'un roulement à billes..... | 15 |
| Figure I.9 : Types d'excentricité : (a) statique ; (b) dynamique ; (c) mixte..... | 16 |

Chapitre II

| | |
|--|----|
| Figure II.1 : Les familles de textures : (a-d) textures déterministes, (e-h) textures observables, (i-l) textures stochastiques..... | 31 |
| Figure II.2 : Images contenant des textures de second ordre statistique identiques..... | 32 |
| Figure II.3 : Matrice de cooccurrence $P(1,0)$ de l'image Im ayant 4 niveaux de gris, pour une distance $d = 1$ et la direction $\theta = 0^\circ$ et $\theta = 180^\circ$ | 36 |
| Figure II.4 : Représentation du pixel central et de ces P voisins sur un rayon R | 39 |
| Figure II.5 : Génération du code LBP..... | 41 |
| Figure II.6 : Exemple du passage d'une image en niveaux de gris vers le plan LBP..... | 41 |
| Figure II.7 : Les 36 motifs binaires invariants à la rotation qui peuvent apparaître pour un voisinage de 3×3 . Les cercles noire et blanc correspondent au bit 0 et 1 respectivement..... | 42 |
| Figure II.8 : Différentes primitives de la texture détectées par $LBP_{P,R}$ | 43 |
| Figure II.9 : Illustration des motifs uniformes et non-uniformes..... | 44 |
| Figure II.10 : Les uniques codes $LBP_{P,R}^{riu2}$ qui peuvent exister pour différents U | 45 |
| Figure II.11 : Illustration du calcul de l'opérateur LTP [71]..... | 46 |
| Figure II.12 : Illustration de la méthode des k plus proches voisins (k -NN) avec $k = 5$ | 47 |
| Figure II.13 : Représentation de la marge maximale et des vecteurs supports qui lui sont liés..... | 48 |
| Figure II.1 : Modèle d'un neurone artificiel..... | 50 |

Chapitre III

| | |
|--|----|
| Figure III.1 : Moteur utilisé dans l'expérimentation..... | 55 |
| Figure III.2 : Types de défauts dans un moteur à induction utilisé dans l'expérience: (a) moteur sain; (b) moteur avec une barre cassée; (c) moteur avec deux barres cassées; (d) moteur avec trois barres cassées; (e) moteur avec défauts des roulements..... | 56 |
| Figure III.3: Conversion signal 1D à une image..... | 57 |
| Figure III.4 : Exemples de conversion de signaux 1D en images 2D en niveau de gris : (a) moteur sain, (b) une barre rotorique cassée, (c) deux barres rotorique cassées, (d) trois barres rotorique cassées et (e) défauts de roulement..... | 57 |
| Figure III.5 : fonctionnement du filtre médian..... | 61 |
| Figure III.6 : (a) Image original(b) Image avec égalisation d'histogramme..... | 62 |
| Figure III.7 : Histogramme LBP des images de signaux acoustiques avec défaut..... | 66 |

Chapitre IV

| | |
|--|----|
| Figure IV.1 : Image d'un signal défectueux soumise au filtre de Kirsh..... | 71 |
| Figure IV.2 : Processus de génération des images KLTP _l et KLTP _u | 72 |
| Figure IV.3 : Schéma de la méthodologie suivie..... | 72 |
| Figure IV.4 : Génération du code LBP..... | 73 |
| Figure IV.5 : Distribution des cinq classes..... | 77 |

Liste des tableaux

| | |
|---|----|
| Tableau I.1 Avantages et inconvénients des stratégies de maintenance..... | 19 |
| Tableau I.2 Hiérarchie des approches de diagnostic sans modèle..... | 21 |
| Tableau II.1 Quelques caractéristiques du premier ordre..... | 34 |
| Tableau II.2 Caractéristiques d'Haralick calculé à partir de la GLCM..... | 37 |
| Tableau II.3 Les fonctions d'activations utilisées dans les ANN..... | 51 |
| Tableau III.1 Caractéristiques des moteurs à induction utilisés dans la configuration expérimentale..... | 56 |
| Tableau IV.1 Présente les résultats de la classification..... | 77 |
| Tableau IV.2 Comparaison de notre méthode avec les méthodes utilisées dans la littérature | 7 |

Liste des acronymes

| | |
|-------------------|---|
| ACP | Analyse en Composantes Principales |
| AI | Approches par Intelligence Artificielle |
| ANN | Artificial Neural Network (Réseau de neurones artificiels) |
| ASM | Second moment angulaire |
| BLDC | BrushLess DC (à courant continu sans balais) |
| CNN | Réseaux de convolutifs |
| 2D | Bidimensionnel(le) (signaux ou images) |
| DWT | Discrete Wavelet Transform (Transformée en ondelettes discrète) |
| EEIC'23 | Electrical Engineering International Conference |
| EPRI | Electric Power Research Institute |
| FT | Transformée de Fourier |
| GLBP | Gray-Level Binary Patterns (nouvelle approche bidimensionnelle, combinaison de LBP et GLCM) |
| GLCM | Gray-Level Co-occurrence Matrix (Matrice de cooccurrence des niveaux de gris ou Matrice de dépendance spatiale des niveaux de gris) |
| GNS map | GNS map |
| HLBP1,8 | Histogramme LBP1,8 |
| IDM | Inverse Difference Moment (Homogénéité) |
| IEEE-IAS | IEEE Industry Application Society |
| K-NN / KNN | K-nearest neighbor / K-Nearest Neighbour (Méthode des k plus proches voisins) |
| KLTP | Kirsch Local Ternary Patern |
| KLTPi | Code supérieur KLTP |
| KLTPu | Code inférieur KLTP |
| LBP | Local Binary Pattern (Motifs binaires locaux) |
| LBPR,P | Code Local Binary Pattern (avec rayon R et P voisins) |
| LTP | Local ternary pattern (Motif ternaire local) |
| MA | Machines Asynchrones |
| MACE | Machine Asynchrone à Cage d'Écureuil |
| MARB | Moteurs Asynchrones à Rotor Bobiné |
| MCA | Maître de Conférences A (Grade/rang) |
| MCC | Machines à courant continu |
| MCSA | Analyse de la signature du courant du moteur |
| MCSVM | Multi-Class Support Vector Machine (classificateur SVM multiclasse) |
| MLP | Perceptron Multicouches |
| MPP | Moteurs Pas à Pas |
| MSAP | Machines Synchrones à Aimants Permanents |
| NCA | Neighbourhood Component Analysis |
| OAA | One Against All (Un contre Tous) |

| | |
|------------------------------------|---|
| RBF | Radial Basis Function (Fonction gaussienne à base radiale) |
| RdF | Reconnaissance de formes |
| RMS | Root Mean Square (Valeur efficace ou moyenne quadratique) |
| SMOFS-22- Multiexpanded | SMOFS-22-Multiexpanded |
| SVM | Support Vecteur Machine (Support Vector Machine) |
| SVMOVA | Support Vector Machine One Versus All |
| TF | Transformée de Fourier |
| TFFG | Transformée de Fourier à Fenêtre Glissante |
| TOC | Transformée en ondelettes continue |
| U | Mesure du nombre de transitions binaires (entre les valeurs 0 et 1) |
| WD | Distribution de Wigner-Ville |
| WT | Transformée en Ondelettes |
| X(f) | Contenu spectral d'énergie |

Introduction générale

Introduction générale

L'industrie d'aujourd'hui s'appuie fortement sur des machines utilisant des moteurs à induction, de sorte qu'une défaillance soudaine de ces machines entraînerait des dommages coûteux. On trouve dans la littérature, différents points de vue sur la catégorisation des défauts des moteurs à induction. Les défauts internes sont généralement classés en fonction de leur origine (électrique ou mécanique) ou de leur point d'émergence (stator ou rotor) [1]. Le pourcentage de répartition des défauts dans le moteur à induction est de 45 % dans les roulements, de 35 % dans le stator, de 10 % dans le rotor et de 10 % dans les autres catégories [2]. La détection précoce de ces défauts est cruciale pour garantir la sécurité de l'équipement et éviter les arrêts de production. Ces dernières années, de nombreux travaux de recherche ont été consacrés à cette question afin de résoudre ces problèmes, qui peuvent être classés en trois catégories principales en ce qui concerne le processus de diagnostic : basé sur un modèle, sur un signal et sur des données. L'approche du traitement du signal est un élément particulièrement important parmi eux [3].

De nombreuses recherches ont été menées sur la base de méthodes d'analyse du signal, telles que l'analyse des transformées de Fourier (FT) et la transformée en ondelettes (WT) [4]. Récemment, le traitement des signaux bidimensionnels (2D) a été appliqué dans diverses recherches sur le diagnostic des défauts. Le signal temporel unidimensionnel est d'abord converti en une image bidimensionnelle en niveaux de gris, puis les textures caractéristiques sont extraites à l'aide de différentes méthodes d'analyse des textures. Dans [5], l'auteur a utilisé le filtre de Gabor sur une image segmentée pour un modèle de diagnostic de défaut bidimensionnel des moteurs à induction. H Zhang et al. ont proposé une détection des défauts basée sur un opérateur de motifs binaires locaux multi-échelles et un algorithme d'optimisation amélioré basé sur l'apprentissage [6]. Shahriar et al. ont utilisé un diagnostic des défauts des moteurs à induction à l'aide d'une analyse de texture basée sur des motifs binaires locaux [3].

L'identification des défauts des machines peut être effectuée à l'aide de différentes méthodologies, notamment l'analyse de la signature des vibrations, les signaux de température, les signaux d'émission acoustique, les signaux de courant et la fréquence du champ magnétique ... ,[7]. Les signaux de vibration, de courant et de tension ont été utilisés dans la recherche pour faciliter la mesure des signaux et les systèmes de contrôle à faible coût. Cependant, un signal acoustique peut augmenter la précision du diagnostic par rapport aux

signaux de vibration en évitant les interférences de bruit avec un spectre à haute fréquence [5]. L Gao et al. ont proposé une étude et une application du test d'émission acoustique pour le diagnostic des défauts des engrenages à faible vitesse des poids lourds [8]. Mohd Sufian Othman et al [9] ont présenté une étude utilisant la surveillance des vibrations et des signaux d'émission acoustique pour la détection des défauts des roulements de moteurs à induction. Glowacz et al [10] ont présenté une méthode de détection des défauts utilisant des signaux acoustiques sur les moteurs à courant continu. Dans un autre travail, Glowacz et al [11] ont proposé une méthode de diagnostic des moteurs à induction triphasés à l'aide d'images thermiques. En outre, Glowacz [12] a proposé un diagnostic de défaut d'un moteur à induction monophasé basé sur des signaux acoustiques. O Yaman a présenté une méthode de classification automatisée des défauts basée sur l'analyse des motifs binaires en utilisant la méthode LBP (Local Binary Pattern) sur des moteurs à induction [13].

Notre approche consiste à appliquer l'analyse des signaux d'émission acoustique pour détecter les défauts du rotor et des roulements, en utilisant une nouvelle approche bidimensionnelle appelée GLBP qui utilise à la fois les méthodes LBP et GLCM. La méthode des motifs binaires locaux est utilisée pour analyser les données des signaux acoustiques car il s'agit d'une méthode d'analyse de texture efficace qui résiste aux changements monotones de niveaux de gris et à la rotation de l'image, de plus l'identification de ces motifs présente une faible difficulté de calcul [3]. L'extraction des caractéristiques est effectuée par la matrice de cooccurrence, qui comprend l'énergie (second moment angulaire), la corrélation, l'homogénéité, la moyenne et l'entropie. La méthode GLCM est utilisée pour faciliter l'extraction des caractéristiques et réduire la taille du vecteur de caractéristiques en utilisant seulement cinq caractéristiques au lieu d'utiliser l'histogramme LBP comme vecteur de caractéristiques qui nécessite d'autres traitements pour réduire sa taille et extraire des caractéristiques significatives. Le vecteur de caractéristiques est ensuite utilisé comme entrée dans les techniques d'intelligence artificielle, dans notre cas les algorithmes MCSVM multi classe, K-NN (K-voisinage le plus proche) et ANN (réseau de neurones artificiels).

Dans ce contexte le document est repartit sur quatre chapitre comme suit :

Le premier chapitre comporte les principaux types de machines électriques, à savoir les machines synchrones, asynchrones et à courant continu, en mettant en lumière leurs caractéristiques distinctives et leurs domaines d'application. Nous aborderons également les défauts les plus courants susceptibles de survenir dans ces machines, leurs causes principales,

ainsi que les méthodes de diagnostic employées pour détecter ces anomalies et garantir un fonctionnement optimal.

Le deuxième chapitre présente une définition de l'analyse de la texture et explore les différents types existants. Il aborde également les principales méthodes d'analyse de texture, notamment les approches basées sur les motifs locaux binaires (LBP) et ces variantes LBP uniforme et LTP (local ternary pattern), ainsi que les matrices de co-occurrence des niveaux de gris (GLCM), qui constituent le fondement de notre stratégie de diagnostic pour les machines asynchrones. Ce chapitre joue un rôle clé en fournissant les bases théoriques nécessaires à la compréhension de notre démarche.

Le troisième chapitre inclut une section dédiée aux étapes de l'expérimentation, comprenant les éléments suivants : le type de défauts étudiés, une illustration de la forme du signal acoustique enregistré, ainsi que la méthode utilisée pour convertir ce signal en une représentation bidimensionnelle. Ce chapitre présente également l'histogramme LBP et propose une comparaison entre l'histogramme LBP des images des défauts (une barre cassée, deux barres cassées, trois barres cassées, et défauts de roulement) et l'histogramme LBP d'un moteur en bon état.

Le quatrième chapitre présente l'approche de diagnostic des défauts dans les machines asynchrones en combinant deux méthodes de traitement d'images : LBP et GLCM. Il inclut également une présentation des résultats obtenus, suivie d'une discussion sur les performances des méthodes utilisées en association avec différents classificateurs, à savoir le SVMOVA (Support Vector Machine One Versus All), le KNN (K-Nearest Neighbour) et les réseaux de neurones artificiels (ANN, Artificial Neural Network).

La thèse se conclut par une synthèse générale des travaux réalisés, mettant en évidence les principales contributions apportées. Elle propose également des perspectives de recherche envisageables pour prolonger ces travaux. Enfin, elle comprend une bibliographie regroupant l'ensemble des références utilisées.

Chapitre I : Généralités sur les machines électriques

I.1 Introduction

Les machines électriques jouent un rôle essentiel dans tous les domaines industriels. Ils trouvent leur utilité dans une multitude d'applications industrielles. Dans le secteur manufacturier, ils alimentent des machines-outils, des convoyeurs et des équipements de levage. Dans le domaine de l'automatisation, ils sont utilisés pour piloter des robots industriels et des systèmes de contrôle. De plus, les moteurs électriques sont essentiels dans les secteurs du transport, propulsant des véhicules électriques, des trains et des avions.

Les machines électriques sont soumises durant leurs marches à de fortes sollicitations, ceci peut causer des défaillances qui influencent le bon fonctionnement d'un processus industriel pouvant provoquer l'arrêt total du système. Les machines asynchrones (MA) sont en ce moment les machines les plus courantes en raison de leur prix abordable, de leur processus de fabrication simple, de leur fiabilité et de leur solidité [14].

Dans ce chapitre, nous allons aborder trois types de machines électriques (synchrone asynchrone et à courant continu), puis nous allons voir les différents défauts qui peuvent apparaître dans ces machines et leurs causes, ainsi que les méthodes de diagnostics utilisées.

I.2 Les différents types de machines électriques

De nombreux types de machines électriques existent, des machines à courant continu des machines synchrones, et des machines asynchrone etc. Les machines électriques comportent toutes un circuit magnétique, généralement constitué de matériaux ferromagnétiques, divisé en deux éléments principaux : le stator, partie fixe, et le rotor, partie mobile. Un enroulement, le plus souvent réalisé en cuivre, permet de transférer et de distribuer l'énergie électrique en générant un champ magnétique au sein du circuit.

I.2.1 Machines à courant continu (MCC) à rotor bobiné

Ces machines ont pour caractéristique Une architecture de commande électronique peu complexe et d'un dé fluxage aisé. Malgré cela leurs nombreux inconvénients : faible puissance massique, il n'est pas facile de diminuer la température d'un induit tournant, exigeance l'utilisation d'un collecteur mécanique ce qui pour conséquence une diminution de la longévité fonctionnelle (Une détérioration résultant des frottements mécaniques à vitesse élevé ainsi que des arcs électriques générés lors du basculement du courant entre les segments du collecteur) [15].

I.2.2 Les machines synchrones à aimants permanents

Les machines synchrones à aimants permanents sont une catégorie de machines synchrones où l'excitation du circuit magnétique est réalisée à l'aide d'aimants permanents. Selon les courants qui traversent les phases statoriques, il est possible de citer les machines synchrones à aimants permanents (MSAP) pour des courants sinusoïdaux et les machines à courant continu (MCC), à courant continu sans balais (ou en anglais BrushLess DC (BLDC)) et les moteurs pas à pas (MPP) pour des courants non sinusoïdaux. Malgré leur bon rendement les machines synchrones se distinguent par un coût d'acquisition relativement important ainsi qu'une complexité notable de l'électronique de commande et de puissance [16].

I.2.3 La machine asynchrone

La machine asynchrone est la plus couramment utilisée dans l'industrie. Elle équipe plus de 50% des installations industrielles à travers le monde [17] : pompes, ventilation, traction ferroviaire..., car elle présente de nombreux avantages tels que sa puissance massique, sa robustesse, sa facilité de mise en œuvre, son faible coût, etc...La machine asynchrone, souvent nommée moteur à induction comprend un stator et un Rotor. Sa structure est représentée dans la figure I.1.




Figure I.1 : Structure d'une machine asynchrone à cage d'écureuil [18].

I.2.3.1 Le stator

Il est composé d'un circuit magnétique composé d'un ensemble de tôles ferromagnétiques fines empilées. Ce circuit est équipé d'une couronne composée d'une série de dents et d'encoches, généralement orientée vers l'intérieur du stator (pour une machine à rotor externe, la couronne est orientée vers l'extérieur). Une culasse, composante du circuit magnétique, se trouve à l'opposé de cette couronne et reboucle le flux magnétique. Le bobinage en cuivre est introduit entre les dents, dans les encoches, il est constitué de trois phases différentes. Le couplage des trois phases, généralement en forme d'étoile ou de triangle, permet d'alimenter le moteur à partir de trois fils. La figure I.2 montre un stator de machine asynchrone triphasée de la société SEW Usocom [19].



Figure I.2: Stator d'une machine asynchrone [19].

I.2.3.2 Le rotor

Les anneaux de court-circuit du rotor à cage permettent la fermeture des circuits électriques, assurant ainsi la circulation des courants induits entre les barres rotoriques insérées dans les encoches. La répartition régulière de ces barres conductrices forme le circuit du rotor. Le circuit magnétique de cette cage est composé de disques en tôles entassés sur l'arbre de la machine, similaire à celui du moteur à rotor bobiné [20].

La figure I.3 présente une image de rotor à cage de la société SEW Usocom [19].



Figure I.3: Rotor d'une machine asynchrone a cage [19].

Il existe des moteurs à cage d'écureuil et des moteurs à rotor bobiné. Le moteur asynchrone à cage d'écureuil se distingue par une conception plus simple que celle du moteur à rotor bobiné, ce qui en fait une solution plus économique en termes de coût de fabrication. Par ailleurs, sa structure robuste lui confère une excellente fiabilité en exploitation. Ces avantages expliquent pourquoi il représente la majorité des moteurs asynchrones utilisés dans les applications industrielles actuelles [21].

En résumé, la machine asynchrone en particulier à cage d'écureuil jouit d'une prédominance dans l'industrie actuelle. Par conséquent notre choix de travail c'est basé sur les moteur asynchrone à cage d'écureuil.

I.2.3.3 Principe de fonctionnement de la machine asynchrone

Reposant totalement sur les principes de l'induction électromagnétique, la machine asynchrone peut être assimilée à un transformateur à champ tournant : le stator joue le rôle de l'enroulement primaire, tandis que le rotor, généralement en court-circuit, agit comme l'enroulement secondaire.

Le principe de fonctionnement de la machine asynchrone repose sur l'interaction électromagnétique entre le champ magnétique tournant, généré par l'alimentation triphasée de l'enroulement statorique, et les courants induits dans le rotor, résultant du glissement entre le champ tournant et les conducteurs du rotor qu'il traverse.

Lorsque le rotor tourne à une vitesse N_s différente de la vitesse synchrone, l'application de la loi de Faraday aux conducteurs du rotor met en évidence l'apparition d'une force électromotrice (f.é.m.) induite, due à la variation du flux magnétique traversant ces conducteurs qui, en étant court-circuitée sur les enroulements, génère un courant dont l'intensité est limitée par l'impédance de celui-ci. Les forces exercées sur les brins du rotor

sont générées par l'interaction entre ce courant et le champ glissant, et le moment par rapport à l'axe de rotation représente le couple de la machine. Lorsque le champ est sinusoïdal, sa vitesse de rotation est [20]:

$$N_s = \frac{f}{p} \text{ En tr/s, ou } N_s = \frac{60f}{p} \text{ tr/min}$$

Où f : est la fréquence d'alimentation.

p : représente le nombre de paires de pôles.

L'interaction électromagnétique entre le champ tournant statorique (de vitesse n_1) et le rotor (de vitesse n) ne peut avoir lieu que si une différence existe entre ces deux vitesses. En effet, si $n=n_1$, le champ magnétique devient stationnaire par rapport au rotor, ce qui empêche toute variation de flux à travers les conducteurs rotorique, et par conséquent, aucune force électromotrice (f.é.m.) ni courant induit ne sont générés.

$$g = \frac{n_1 - n}{n_1}$$

g est le glissement de la machine asynchrone [20].

Malgré sa solidité, la machine asynchrone peut être confrontée à des problèmes électriques ou mécaniques. Ainsi, à cause des répercussions significatives et onéreuses que peut entraîner l'émergence d'un défaut sur les processus industriels, Le diagnostic des défauts a fait l'objet d'un intérêt grandissant au cours des trois dernières décennies [18].

I.3 Défauts des machines électriques tournantes

Ce paragraphe présente une typologie des défauts susceptibles d'affecter les machines électriques, en détaillant leurs origines ainsi que leur classification.

Un défaut dans la machine électrique désigne tout événement ou altération susceptible d'induire un fonctionnement anormal ou dégradé de la machine électrique et qui peut provoquer son endommagement à court ou long terme [20]. Les causes de défaillances dans les machines tournantes électriques peuvent avoir plusieurs origines. Tel que : a conception initiale, les tolérances de fabrication, les erreurs lors de l'assemblage, des conditions d'installation inadéquates, un environnement de fonctionnement défavorable, la nature de la charge appliquée, ainsi que l'irrégularité ou l'insuffisance des opérations de maintenance [22].

I.3.1 Terminologie dans le diagnostic

Diagnostic : consiste en l'analyse des symptômes et des manifestations observables d'un dysfonctionnement, en vue de déterminer la nature du défaut ou de la défaillance, sa localisation, son type ainsi que son degré de sévérité.

Fonction : action normale ou caractéristique d'une machine ou du système dont elle fait partie.

La défaillance : se définit comme la perte de l'aptitude d'un composant ou d'un système à accomplir la fonction pour laquelle il a été conçu. Contrairement au défaut, qui correspond à un état, la défaillance est un événement

Un défaut : correspond à un état de dégradation ou de dysfonctionnement partiel d'un composant ou d'un assemblage d'une machine, susceptible de compromettre son bon fonctionnement et de conduire à une défaillance. Un défaut peut être présent sans entraîner immédiatement une défaillance, et peut également résulter d'une défaillance antérieure.

Maintenabilité : c'est l'aptitude d'un système, ou d'un de ses sous-ensembles, à être maintenu ou restauré dans un état permettant l'exécution de ses fonctions opérationnelles, à l'aide de procédures, de moyens et dans des délais compatibles avec les exigences techniques et économiques..

Performance : La performance d'une machine est définie comme l'expression mesurable de son comportement opérationnel. Elle se caractérise par un ensemble de paramètres physiques ou fonctionnels (puissance, rendement, débit, vitesse, etc.), obtenus par mesure ou calcul, permettant d'évaluer son efficacité globale dans un contexte d'utilisation donné [23].

I.3.2 Classification des défauts selon leurs origines

Les défauts des moteurs à induction peuvent être classés en défaut internes, externes. La classification des défauts internes s'effectue généralement en fonction de leur cause première (électrique ou mécanique) ou de leur point d'émergence (stator ou rotor) [1]. Ces principales défaillances sont dues à des causes variées qui sont associées à la conception, la fabrication ou l'emploi.

Dans le but de donner une répartition des défaillances plusieurs études ont été effectuées, de nombreuses recherches ont été menées. Dans la figure I.4, nous illustrons les études de «

IEEE Industry Application Society » (IEEE–IAS), celles de « Electric Power Research Institute » (EPRI), les recherches de Thorsen et celles du groupe allemand « Allianz ». La disparité de puissance entre les machines étudiées dans chaque étude explique la différence de valeurs obtenues.

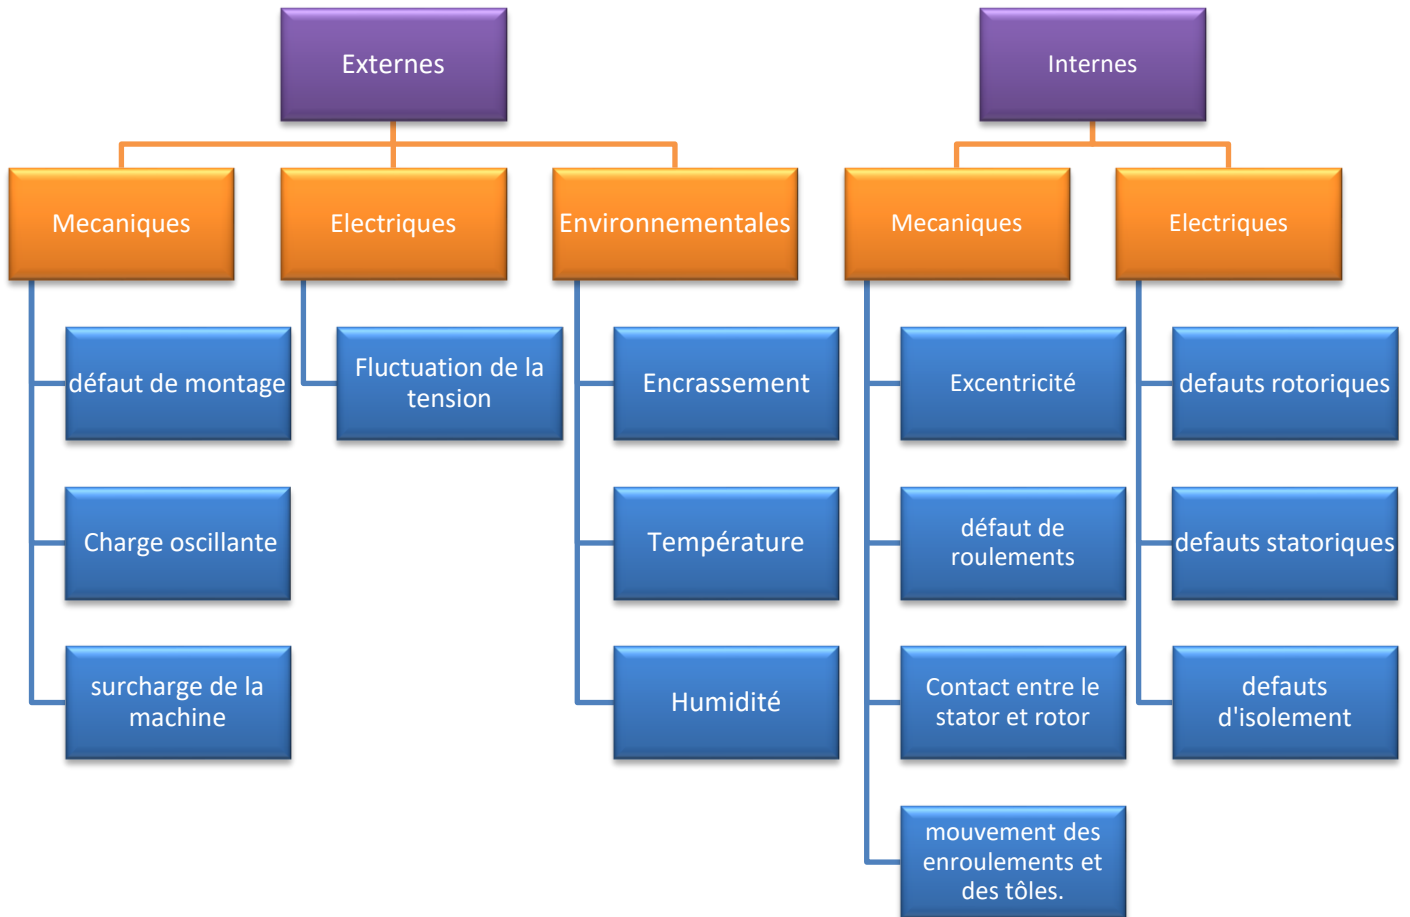


Figure I.4 : Défauts des machines selon leurs origines.

Dans les moteurs à basse et moyenne tension (jusqu'à 4 kV) les défauts de roulement ont un taux de 50% par rapport aux défaillances totale, tandis que dans les moteurs à haute tension (au-delà de 4 kV), les défauts liés à l'isolation de l'enroulement du stator représentent plus de 50%. Les études de *IEEE – IAS*, de *EPRI* et de Thorsen sont basées sur les machines à induction de taille moyenne alors que celle d'*Allianz* est spécifique aux machines de tailles moyenne à grande tailles [24].

Plus de 80 % des défauts observés sont des défauts de stator et de roulement comme le montre la figure I.5. Les défauts de stator sont moins fréquents dans les machines à faible puissance. Tandis que les défauts de roulement et de rotor sont plus courants dans les machines à haute vitesse. Par conséquent, dans les machines asynchrones, le maillon faible est constitué par les roulements et les isolants [25].

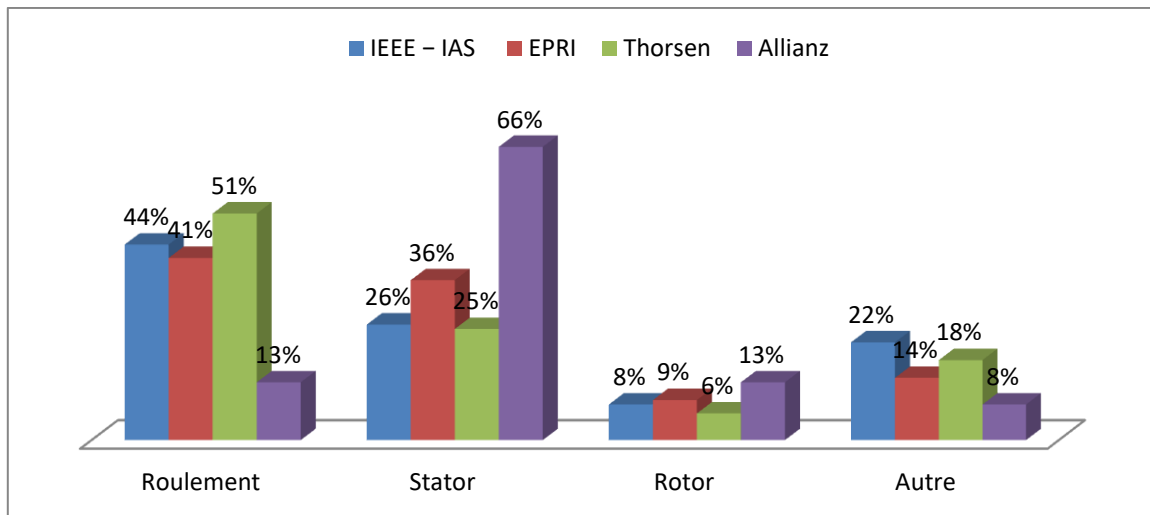


Figure I.5 : Répartition des défauts des composants.

I.3.3 Type des défauts

Les machines électriques peuvent être confrontées à différents types de défauts: des défauts électriques, des défauts mécaniques ou deux défauts peuvent survenir simultanément. Les paragraphes qui suivent présentent une brève description des défauts électriques et mécaniques les plus fréquents.

I.3.3.1 Défaillances électriques

Un dysfonctionnement électrique au niveau du stator peut s'avérer grave car cela entraîne une augmentation de la contrainte sur l'isolation du bobinage, ce qui peut à long terme causer des dommages au bobinage, voire entraîner une rupture de l'isolation avec la masse [14].

I.3.3.1.1 Court-circuit entre spires

Le court-circuit entre spire survient souvent au niveau des têtes de bobines ou dans les encoches. Ce défaut engendre une diminution du nombre de spires effectives de l'enroulement, Il provoque également une hausse des courants statoriques dans la phase concernée. Sur les autres phases cela cause une petite variation dans l'amplitude, il augmente aussi les courants dans le circuit rotorique. Dans le cas des machines asynchrones, l'augmentation de la température causée par le court-circuit peut entraîner la propagation du défaut à d'autres spires [22].

Ce défaut est causé par : surtension, température excessive, vibration, humidité.

I.3.3.1.2 Court-circuit entre bobine

Les répercussions de ce défaut sur le système sont difficiles à analyser. Cela est due au fait qu'il peut survenir à n'importe quel endroit du bobinage, et ces effets diffèrent selon le point d'émergence [14].

I.3.3.1.3 Court-circuit entre phases

Un court-circuit entre phases provoque un arrêt net de la machine. Des courants très élevés sont induit lorsqu'un court-circuit entre phase ce produit ce qui conduit à la fusion des conducteurs d'alimentation et/ou à la disjonction par les protections. Cela a pour conséquence l'arrêt total de la machine. Les courts circuits entre phases peuvent être causé par haute température, alimentation déséquilibrée, défaut d'installation [24].

I.3.3.1.4 Court-circuit phase-neutre

Un court-circuit entre une phase et le neutre ou entre une phase et la terre (par le biais de la carcasse) peut causer des dommages permanents à l'enroulement du stator et au circuit magnétique de la machine [14].




Figure I.6 : Représentation des différents défauts statoriques [14].

I.3.3.1.5 Défauts d'isolant dans un enroulement

Des courts-circuits peuvent survenir lorsque les isolants dans les enroulements se dégradent. Effectivement, les diverses pertes (joule, fer, mécanique, etc.) provoquent des phénomènes thermiques qui se manifestent par une hausse de la température des différents éléments du moteur. Cependant, les matériaux d'isolation présentent des contraintes thermiques, électriques et mécaniques. Ainsi, si l'environnement de travail d'un matériau d'isolation dépasse l'une de ces limites, il se dégrade prématurément ou rapidement, jusqu'à ce qu'il se brise complètement [24].

Les diverses origines de ce genre de défaut incluent [26]:

- Mauvaise qualité de l'isolant à la fabrication.
- La limite du matériau d'isolation est dépassée par la tension de l'enroulement.
- Vibrations mécaniques.
- L'enroulement présente un courant élevé en raison d'un court-circuit, d'un défaut du convertisseur ou d'une surcharge. Cela provoque une augmentation de la température qui entraîne une détérioration prématurée du matériau isolant.
- Vieillesse naturelle des isolants.
- température et humidité extrême.

I.3.3.1.6 Défauts rotoriques

Les défauts affectant le rotor proviennent principalement de contraintes thermiques, électromagnétiques, mécaniques résiduelles, dynamiques ou environnementales. Dans les moteurs asynchrones à cage d'écureuil, les défaillances les plus fréquentes concernent la rupture de barres de rotor ou de segments de l'anneau de court-circuit. En ce qui concerne les moteurs asynchrones à rotor bobiné (MARB), l'échauffement excessif peut altérer l'isolant, conduisant à des courts-circuits entre les enroulements. Par ailleurs, des phénomènes d'excentricité — qu'ils soient statiques ou dynamiques — peuvent survenir dans les deux types de machines, compromettant ainsi leur bon fonctionnement [27].

- **Ruptures de barres :** La rupture de barres est l'un des défauts les plus fréquents dans la (MACE). Le défaut peut apparaître ou au niveau de l'encoche ou au niveau des extrémités là où les barres sont reliées aux anneaux de court-circuit. Il peut causer une réduction de la valeur moyenne du couple électromagnétique, accompagnée d'une augmentation des fluctuations d'amplitude des oscillations. Cela se traduit par une variation de la vitesse de rotation, pouvant engendrer un fonctionnement instable de la machine ainsi que des vibrations mécaniques importantes. Dans les cas les plus graves, les fragments de barres rompues peuvent entrer en contact avec le stator et endommager l'isolation statorique, compromettant ainsi la fiabilité de l'ensemble de la machine.
- **Ruptures d'anneaux :** Il est plus fréquent de rencontrer ce type de défaut que la rupture de barre pour la machine asynchrone à cage. Ce genre de défaut est complexe à repérer car il est souvent confondu avec la rupture de barre. Ils provoquent une perturbation dans la distribution des courants dans les barres rotoriques, ce qui entraîne une variation d'amplitude sur les courants statoriques. Ces signes de dysfonctionnement sont semblables à ceux causés par la rupture de barres [22].




Figure I.7 : (a) Rupture d'anneaux

(b) Ruptures de barres

I.3.3.2 Défaillances mécaniques

I.3.3.2.1 Défauts de roulements

Comme, il a été exposé, préalablement dans la figure I.5, ce défaut représente plus de 40% sur les machines à fortes puissances. Le roulement constitue l'interface mécanique entre le stator et le rotor. Il assure le guidage et le maintien de l'arbre de la machine, garantissant ainsi une rotation stable et centrée du rotor par rapport au stator.

Les causes des défaillances des roulements peuvent être des charges excessives, des ajustements trop serrés et une élévation de température excessive, de la corrosion, une défaillance du lubrifiant, un désalignement [27].

Ce type de défaut peut causer :

- des trous dans les gorges du roulement intérieur et extérieur,
- ondulation de la surface du roulement,
- des variations (oscillations) dans le couple de charge de la machine asynchrone.

Dans son état le plus grave ce défaut entraîne un blocage du rotor [27].





Figure I.8 : Représentation d'un roulement à billes

I.3.3.2.2 Défaut d'excentricité

On peut définir l'excentricité de la machine comme une inégalité dans l'espace entre le stator et le rotor. Il est courant d'observer un degré d'excentricité dans les machines électriques. Ce défaut existe dès la fabrication de la machine. Un décentrement du stator et du rotor ce produit pendant l'assemblage. Cela est souvent accentué lors du fonctionnement de la machine en raison de la détérioration de certains éléments (usure des roulements), des défauts d'alignement, de balourd, et de la détérioration d'un réducteur mécanique, etc. En revanche, la présence d'excentricité entraîne un déséquilibre dans les forces radiales qui s'exercent sur le rotor, ce qui entraîne un accroissement du phénomène, ce qui peut entraîner un frottement entre le stator et le rotor qui peut conduire à la destruction [22], [28].

On différencie trois types de défaut d'excentricité : statiques, dynamiques ou mixtes. Elles sont représentées dans la figure I.9.

- ❖ Excentricité statique : il est dû par un défaut d'alignement de l'axe de rotation du rotor par rapport à l'axe du stator. L'origine la plus courante est en général un défaut de centrage des flasques.
- ❖ Excentricité dynamique : Il s'agit d'un défaut apparaissant lorsque l'axe de rotation du rotor est décalé par rapport à son axe géométrique. Cette anomalie peut résulter d'une déformation du rotor, d'un désalignement du stator ou encore d'une dégradation des roulements à billes.
- ❖ Excentricité mixte : C'est la forme la plus courante d'excentricité. Elle résulte de la combinaison d'une excentricité statique (désaxage du rotor par rapport au stator) et d'une excentricité dynamique (variation de la position du rotor pendant sa rotation) [14].






Figure I.9: Types d'excentricité : (a) statique ; (b) dynamique ; (c) mixte.

I.4 Méthodes de diagnostics

Dans les défauts dans les machines électriques le diagnostic est crucial pour garantir leur performance optimale et leur fiabilité. Cette partie explore diverses méthodes utilisées pour identifier et diagnostiquer les anomalies au sein de ces systèmes. La détection précoce des défauts permet de prévenir des pannes coûteuses et des interruptions de service. Les méthodes de diagnostic sont variées et comprennent des approches traditionnelles basées sur des modèles ainsi que des techniques modernes utilisant l'intelligence artificielle et l'apprentissage automatique. En détaillant ces méthodes, cette partie offre un aperçu des outils disponibles pour la maintenance prédictive et la gestion efficace des machines électriques.

I.4.1 Stratégies de Maintenance

La stratégie de maintenance est essentielle pour assurer le fonctionnement optimal et la longévité des machines électriques. Dans le domaine de la détection des défauts des machines électriques, plusieurs stratégies de maintenance peuvent être mises en œuvre. Voici une description des principales stratégies de maintenance accompagnée de leurs sources académiques.

I.4.1.1 Maintenance Réactive (ou Corrective)

Cette stratégie consiste à intervenir uniquement lorsque la machine tombe en panne. Bien que cette approche puisse minimiser les coûts initiaux de maintenance, elle peut entraîner des temps d'arrêt imprévus et des réparations coûteuses [29].

Souvent appelée réparation ou restauration, cette forme de maintenance implique la réparation et le remplacement des éléments défectueux. Un de ses avantages majeurs réside dans le fait qu'elle ne requiert aucun financement dans les opérations de maintenance avant la survenue de la panne. Toutefois, ce genre d'entretien peut provoquer une diminution, voire l'arrêt de la production. Dans le cas des opérations de réparation, il existe différentes méthodes. En utilisant une méthode appelée "réparations minimales", l'élément défaillant est juste rétabli à son mode fonctionnel [30].

I.4.1.2 Maintenance Préventive

Cette stratégie repose sur des interventions planifiées basées sur le temps ou le cycle d'utilisation de la machine. Elle vise à prévenir les pannes en effectuant des tâches de maintenance régulières, indépendamment de l'état actuel de la machine [31].

La maintenance peut être programmée selon différents critères tels que le nombre d'heures de fonctionnement, le nombre de cycles d'utilisation, la distance parcourue ou encore des échéances calendaires prédéfinies. Ce type de maintenance est particulièrement adapté aux composants dont la dégradation est prévisible, permettant ainsi d'intervenir à un moment opportun afin de prévenir une défaillance du système [30].

I.4.1.3 Maintenance Predictive

Basée sur la surveillance en temps réel des conditions de la machine, cette stratégie utilise des données de capteurs pour prévoir les défaillances avant qu'elles ne se produisent. Elle permet d'optimiser les intervalles de maintenance et de réduire les temps d'arrêt [32]. Le suivi de ces signatures permet de détecter l'émergence de défaillances ainsi que l'apparition de défauts précoces susceptibles de compromettre la performance du système ou de ses composants, voire de provoquer un arrêt complet en cas d'évolution non maîtrisée.

I.4.1.4 Maintenance Conditionnelle

Cette stratégie combine la maintenance préventive et prédictive en utilisant des mesures régulières de la condition des machines pour déterminer les actions de maintenance nécessaires. Elle se base sur des indicateurs tels que les vibrations, la température et l'usure [30].

Tableau I.1. Avantages et inconvénients des stratégies de maintenance [30].

| Stratégie de maintenance | Avantage | Inconvénient |
|---------------------------------------|---|--|
| Maintenance corrective | <ul style="list-style-type: none"> -Matériels pas souvent entretenus -Pas de frais lié à la Maintenance. | <ul style="list-style-type: none"> -Probabilité accrue de défaillances -Temps d'arrêt de production important -Coût élevé lié au remplacement des pièces -Charge de travail supplémentaire pour la maintenance -Risque élevé en matière de sécurité |
| Maintenance préventive | <ul style="list-style-type: none"> -diminution de pannes Graves. -Gestion maîtrisée des frais de maintenance -Niveau de défaillances diminuées. | <ul style="list-style-type: none"> - Entretien des équipements même en l'absence de pannes -Probabilité accrue de détérioration des équipements durant la maintenance -Forte probabilité de pannes imprévue |
| Maintenance préventive conditionnelle | <ul style="list-style-type: none"> -Diminution de pannes Subites ou inattendus. -Pièces de rechange commandées en cas de besoin. -Maintenance réalisée si nécessaire. -Longévité prolongée. | <ul style="list-style-type: none"> Montants d'investissement élevés. |

I.5 Grandeurs mesurables et signaux de défauts

Les méthodes communes qui utilisent des données sensorielles et l'analyse des signatures électriques sont utiles pour évaluer l'état des machines électriques. L'analyse de la signature du courant du moteur (MCSA) est largement reconnue comme l'approche standard pour l'analyse des signatures dans le diagnostic des défaillances dans les machines électriques tournantes. Cette technique implique l'examen et l'interprétation de la signature du signal de courant afin d'identifier et de localiser les problèmes potentiels dans le système du moteur. Plusieurs stratégies de surveillance ont été employées pour détecter les défauts dans les machines électriques [26]. Quelques-unes de ces techniques sont présentées ci-dessous [33] :

- Analyse de la signature du courant d'alimentation;
 - Analyse des signatures vibratoire;
 - L'analyse des signatures de puissance instantanée ;
 - L'analyse des paramètres de surveillance de l'état tels que la température, les perturbations, la variation de la vitesse et le flux magnétique ;
- **Capteurs de surveillance de l'état :**
- Les capteurs de vibrations, tels que les accéléromètres et les sondes de proximité, sont couramment utilisés dans diverses applications ;
 - Les équipements de détection de température, y compris les thermocouples et les détecteurs de température à résistance ;
 - les détecteurs de courant, y compris les capteurs à effet Hall et les transformateurs de courant ;
 - les microphones et les capteurs à ultrasons, qui sont inclus dans la catégorie des capteurs acoustiques ;
 - Surveillance basée sur les niveaux d'émission.

I.6 État de l'art de surveillance des défauts des machines électriques

I.6.1 Méthodes basées sur un modèle

La méthode de diagnostic avec modèle est une approche qui utilise des modèles mathématiques ou physiques pour surveiller et évaluer l'état de fonctionnement des machines électriques. Cette approche consiste à comparer entre les données réelles mesurées sur la machine et les données simulées ou attendues fournies par le modèle. En détectant des écarts significatifs entre ces deux ensembles de données, il est possible de diagnostiquer des défauts ou des anomalies dans le fonctionnement de la machine [34], [35].

Un modèle de la machine est développé en utilisant des équations mathématiques basées sur les principes physiques qui régissent son fonctionnement. Ce modèle peut être linéaire ou non linéaire, selon la complexité de la machine. Des capteurs sont utilisés pour assembler des

données en temps réel sur les paramètres de la machine (courant, tension, vitesse, température, etc.). Les données mesurées sont comparées aux données générées par le modèle. Les écarts entre les mesures appelés aussi résidus et les prédictions du modèle sont analysés pour détecter des signes de défauts. Un seuil de tolérance est souvent défini pour déterminer quand un écart est suffisamment important pour être considéré comme un défaut.

Les avantages sont :

- **Précision** : La méthode permet une détection précoce des défauts grâce à la modélisation précise du fonctionnement normal de la machine.
- **Proactivité** : Elle permet une maintenance prédictive, réduisant ainsi les temps d'arrêt non planifiés.
- **Adaptabilité** : Les modèles peuvent être ajustés ou reconfigurés pour s'adapter à différents types de machines et de conditions de fonctionnement [36].

Inconvénients

- **Complexité** : Le développement de modèles précis peut être complexe et nécessite une connaissance approfondie de la machine et de ses principes de fonctionnement.
- **Coût** : L'implémentation de systèmes de diagnostic avec modèle peut être coûteuse en termes de matériel (capteurs) et de développement de logiciels [36].

I.6.2 Méthodes sans modèle

La méthode de diagnostic sans modèle est une méthode de détection des défauts qui ne repose pas sur un modèle mathématique ou physique préétabli du système surveillé. Au lieu de cela, elle utilise des données empiriques, historiques ou en temps réel, pour identifier des anomalies et des défaillances. Cette méthode exploite des techniques d'analyse de données, de statistiques, et d'intelligence artificielle pour surveiller les performances du système et détecter des comportements anormaux. Le tableau I.2 montre les différentes approches et leur hiérarchie [33].

Tableau I.2 : Hiérarchie des approches de diagnostic sans modèle

| Approche sans modèle | | |
|---|--|---|
| Techniques de traitement de signal | Méthodes statistiques | Méthodes à base de connaissances |
| Analyse temporelle Analyse fréquentielle Analyse temps fréquence Analyse temps-échelle | Test statistique Analyse en Composantes Principales (ACP) Reconnaissances de Formes (RdF) Support Vector Machines (SVM) | Réseaux de neurones Logique floue Logique neuro-floue |

Leur principale caractéristique est la dépendance aux données. En effet, la méthode repose sur des données de fonctionnement du système, souvent recueillies par des capteurs, plutôt que sur un modèle théorique [35].

Avantages

- Moins de modélisation : Élimine la nécessité de développer un modèle mathématique complexe du système.
- Adaptabilité : Peut s'adapter à des systèmes variés et complexes sans modifications majeures.
- Efficacité dans les systèmes où les modèles sont difficiles à obtenir : Utile lorsque les systèmes sont trop compliqués pour être modélisés avec précision ou lorsque les paramètres du modèle sont inconnus ou changent fréquemment.

Inconvénients

- Dépendance aux données : La performance de la méthode dépend fortement de la qualité et de la quantité des données disponibles.
- Nécessité d'un apprentissage préalable : Peut nécessiter une phase d'apprentissage ou d'entraînement avec des données de fonctionnement normal et de défaillance.

- Possibilité de faux positifs/négatifs : Peut produire des alertes incorrectes si les données d'entraînement ne couvrent pas tous les cas possibles ou si les anomalies sont rares [37].

I.6.3 Techniques de traitement de signal

Pour faire un diagnostic, divers signaux provenant de la machine sont examinés. L'analyse conjointe de l'évolution temporelle et du contenu spectral de ces signaux permet de détecter les anomalies qui entravent le bon fonctionnement de l'installation. Cette approche de surveillance requiert une connaissance approfondie des défauts potentiels et de leurs signatures caractéristiques [38].

I.6.3.1 Analyse temporelle

Cette analyse s'applique directement aux variations temporelles des grandeurs mesurables obtenues par les capteurs.

❖ Indicateurs scalaires

Cette technique, qui repose sur l'analyse des signaux temporels récoltés des capteurs et filtrés selon quelques gammes fréquentielles, permet d'extraire des indicateurs principalement statistiques. Ces indicateurs synthétisent l'information contenue dans le signal et génèrent un repère. Le suivi de ce repère fournit des informations plus ou moins précises sur l'état de fonctionnement de l'équipement.

Bien que l'utilisation de ces techniques offre une première évaluation basée sur les signaux, elle nécessite des investigations supplémentaires pour un diagnostic complet. Une grande variété d'indicateurs existe, chacun ayant des performances et une pertinence variables selon les types de défaillances à détecter. Ils en existent plusieurs, les plus couramment utilisés sont décrits ci-dessous [39] ;

- La valeur moyenne notée \bar{x} d'un signal sur une plage d'échantillons. Elle est définie par:

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (I.1)$$

Où x_i est la $i^{\text{ième}}$ donnée et N désigne nombre d'échantillon utilisés pour modéliser le signal.

- Le RMS (Root Mean Square), nommée aussi valeur efficace ou moyenne quadratique d'un signal, correspond à la racine carré du moment d'ordre deux. Elle permet de caractériser la dispersion des valeurs par rapport à la moyenne [39].

➤ Le facteur crête FC représente un indicateur plus précis. Grâce au suivi du facteur crête, il est possible de détecter plus précocement les défauts en étudiant le rapport entre la valeur maximale du module du signal (valeur crête) et sa valeur efficace [39].

➤ Le kurtosis, plus précisément utilisé pour détecter les défauts de roulements, est une valeur statistique qui permet d'étudier la forme d'une distribution, qu'elle soit « pointue » ou « plate », et d'observer ainsi l'aspect du signal. Dérivé du moment statistique d'ordre quatre, il est défini par la proportion de la valeur moyenne du signal élevé à la puissance 4 sur le carré de son énergie [40].

I.6.3.2 Analyse fréquentielle

L'analyse fréquentielle complète l'analyse temporelle du signal. En effet, un phénomène difficile à discerner dans le domaine temporel peut être étudié plus facilement dans le domaine fréquentiel, et inversement [41].

I.6.3.2.1 L'analyse spectrale

L'analyse spectrale est une technique utilisée pour examiner les composantes fréquentielles d'un signal. Elle consiste à décomposer un signal en ses différentes fréquences pour mieux comprendre sa structure et ses caractéristiques. Cette analyse permet d'identifier les amplitudes et les phases des différentes composantes sinusoïdales présentes dans le signal, facilitant ainsi l'étude de phénomènes périodiques ou la détection de signaux cachés dans le bruit.

Un signal temporel (t) est soumis à une analyse spectrale en utilisant la Transformée de Fourier (TF), définie par

$$X(f) = \int_{-\infty}^{+\infty} x(t)e^{-j2\pi ft} dt \quad (I.2)$$

Cette analyse implique une décomposition plus précise de l'énergie du signal analysé par bandes de fréquence par rapport à une analyse par la valeur RMS. Effectivement, la TF ou $X(f)$ offre la possibilité de calculer le contenu spectral d'énergie $|X(f)|^2$ ou de puissance du signal à une fréquence f [41] [42].

I.6.3.2.2 L'analyse d'enveloppe

L'analyse d'enveloppe est une méthode de traitement du signal utilisée pour extraire l'enveloppe d'un signal modulé, c'est-à-dire l'amplitude instantanée du signal en fonction du

temps. Cette approche est spécialement utile pour étudier les signaux de vibration dans le domaine du diagnostic des machines, ce qui permet de détecter des défauts mécaniques tels que les fissures dans les roulements ou les engrenages endommagés.

L'enveloppe extraite est analysée en fréquence pour identifier des composants harmoniques ou sous-harmoniques qui peuvent indiquer des défauts spécifiques [43], [44], [45].

I.6.3.3 Analyse temps-fréquence

L'analyse temps-fréquence est une technique avancée de traitement du signal utilisée pour examiner les caractéristiques fréquentielles des signaux qui varient au cours du temps. Les signaux issus des machines électriques, comme les vibrations ou les courants, sont souvent non stationnaires, ce qui signifie que leurs caractéristiques fréquentielles changent au cours du temps. L'analyse temps-fréquence permet de capturer ces variations temporelles, offrant ainsi une vue détaillée de l'évolution des signaux [46], [47].

I.6.3.3.1 La Transformée de Fourier à Fenêtre Glissante (TFFG)

L'analyse du spectre du signal temporel (t) dans une fenêtre (t) localisée dans le temps est la Transformée de Fourier à Fenêtre Glissante (TFFG), et déterminée par :

$$TFFG(t, f) = \int x(\tau) \times w^*(\tau - t) \times e^{-j2\pi f\tau} d\tau \quad (I.3)$$

La TFFG est le calcul de la Transformée de Fourier sur des segments courts et successifs d'un signal, ces segments étant définis par une fenêtre de temps glissante. Le signal continu est segmenté en intervalles courts en utilisant une fenêtre mobile (par exemple, une fenêtre de Hamming ou de Hanning). Pour chaque segment, la Transformée de Fourier est calculée pour obtenir le spectre de fréquences. Les spectres de fréquence successifs sont assemblés pour former un spectrogramme, qui représente l'évolution des fréquences en fonction du temps [45].

Les principaux inconvénients de la TFFG sont : la résolution temps-fréquence fixe, ainsi que la difficulté de satisfaire une bonne localisation simultanée en temps et en fréquence [41].

I.6.3.3.2 Distribution de Wigner Ville

La distribution de Wigner-Ville (WD) définie par l'équation (I.4), est une technique d'analyse temps-fréquence qui offre une représentation conjointe des domaines temporel et fréquentiel pour des signaux, permettant une analyse très détaillée des signaux non stationnaires.

$$WD(t, f) = \int_{-\infty}^{+\infty} x(\tau - \frac{t}{2}) \times x^* (\tau + \frac{t}{2}) \times e^{-j2\pi f\tau} d\tau \quad (I.4)$$

$x(t)$: Le signal temporel à analyser.

$x^*(t)$: Le conjugué complexe du signal $x(t)$.

t : Le temps.

f : La fréquence.

τ : Le paramètre de décalage temporel.

$e^{-j2\pi f\tau}$: Le noyau exponentiel complexe.

La WD est définie mathématiquement par une transformée bilinéaire du signal, ce qui signifie qu'elle considère les produits croisés du signal à différents instants temporels. Contrairement à la Transformée de Fourier à fenêtre glissante (TFFG), la WD n'utilise pas de fenêtre glissante et peut ainsi offrir une meilleure résolution en temps et en fréquence [46].

I.6.3.4 Analyse temps-échelle

I.6.3.4.1 La transformée en ondelettes continue

La transformée en ondelettes continue (TOC) est une méthode d'analyse de signaux qui réalise une décomposition d'un signal en une somme de fonctions d'ondelettes $\psi_{(a,b)}(t)$ translatées par a et dilatées par b dans le temps. Elle offre une manière de représenter un signal en termes de temps et de fréquence simultanément, ce qui est particulièrement utile pour analyser des signaux non stationnaires. Les coefficients en ondelettes (a) d'un signal (t) sont déterminés en le projetant sur les fonctions de base de l'ondelette (a) (t), exprimé par l'équation (I.5), tel que a et b sont des réels [42], [48].

$$TOC(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \psi^* (\frac{t-b}{a}) dt \quad (I.5)$$

- **Échelle (a)** : Contrôle la dilatation et la compression de l'ondelette. Des valeurs élevées de a correspondent à des ondes plus larges (basses fréquences), tandis que des valeurs faibles de a correspondent à des ondes plus étroites (hautes fréquences).
- **Translation (b)** : Déplace l'ondelette le long du signal. Il permet de localiser des caractéristiques temporelles spécifiques du signal.
- L'ondelette mère (t) est une fonction de base à partir de laquelle toutes les autres ondelettes sont générées par translation et dilatation [49].

I.6.4 Diagnostic orienté données

Les méthodes orientées données, sont principalement fondées sur la disponibilité des données de mesure. Les méthodes orientées données peuvent être [30] :

I.6.4.1 Systèmes experts

Les systèmes experts sont des outils capables de simuler les raisonnements d'un spécialiste dans un domaine spécifique. Ainsi, Les systèmes experts sont des programmes informatiques qui associent des connaissances formelles à des mécanismes de prise de décision. Ils sont en mesure de transmettre les connaissances dont ils disposent et d'offrir les arguments qui conduisent à la prise de décision. Il s'agit de systèmes avancés qui ont la capacité de communiquer avec l'utilisateur et de proposer des recommandations [50].

I.6.4.2 Reconnaissance de formes

La reconnaissance de formes (RdF) repose sur une classification des objets et des formes en les comparant à des forme-types. Une base de données est conçue pour chacune des formes-types en utilisant les mesures pour tout mode de fonctionnement. Le diagnostic par RdF consiste à trouver les limites entre les différentes classes afin d'attribuer un nouveau vecteur de forme à l'une d'entre elles [30].

I.6.5 Méthodes par intelligence artificielle

Les approches d'Intelligence Artificielle (IA) utilisent les connaissances heuristiques du domaine, ce qui englobe différentes techniques comme les réseaux de neurones, la logique floue ou une combinaison neuro-floue.

I.7 Conclusion

Ce chapitre a permis de présenter une vue d'ensemble des principaux types de machines électriques, ainsi que les différentes défaillances susceptibles d'affecter ces machines, leurs origines et leur classification. Ces défauts, qu'ils soient d'ordre électrique ou mécanique, peuvent avoir des impacts significatifs sur les processus industriels, justifiant ainsi l'importance de leur diagnostic et de leur maintenance. Nous avons donc abordé les principales méthodes de diagnostics utilisés.

Dans les chapitres suivants, nous présenterons notre approche de diagnostic des défauts dans les machines asynchrones, reposant sur l'analyse de la texture. Cette méthode innovante vise à exploiter les caractéristiques texturales pour identifier et différencier les états de fonctionnement des machines.

Chapitre II : Analyse de la texture

II.1 Introduction

L'analyse de la texture joue un rôle crucial dans de nombreux domaines de traitement d'images et de vision par ordinateur. La texture représente les variations spatiales dans l'intensité ou la couleur des pixels d'une image, permettant ainsi de caractériser la surface ou la structure d'objets. Les méthodes d'analyse de la texture, qu'elles soient statistiques, structurales ou spectrales, offrent des outils puissants pour l'extraction de caractéristiques, la segmentation d'images, et la reconnaissance de motifs. Elles sont utilisées dans divers domaines d'application tels que l'analyse de scènes et de vidéos, l'imagerie médicale, l'industrie etc. Pour cela plusieurs méthodes d'analyse de la texture existent. Ce chapitre explore les différentes approches d'analyse de la texture.

II.2 Définition de la texture

Il existe une variété de définition, on peut citer :

- Une zone d'une image est considérée comme présentant une texture stable lorsque les propriétés locales telles que les statistiques ou d'autres caractéristiques de la fonction image restent stables, peu variables ou présentent une périodicité approximative [51].
- La description d'une image présentant une texture régulière se fait en termes de nombre et des formes élémentaires de tonalité et leur disposition dans l'espace. Elle ne peut pas être étudiée sans avoir une vision du motif tonal élémentaire de base. Certains types de surfaces avec un gris flouté présentent une échelle telle que la texture est absente. Plus la résolution est élevée, plus la texture est fine, puis plus grossière [52].

Dans son travail, [53] propose une définition de la texture fondée sur la perception visuelle.

- Une texture correspond à une zone d'une image pour laquelle une fenêtre de dimensions minimales peut être définie, de telle manière qu'une observation au travers de cette fenêtre génère une perception visuelle inchangée, quelle que soit sa position dans la zone analysée.

Entre ces définitions, certaines se concentrent sur la perception, tandis que d'autres se concentrent davantage sur la stabilité des mesures statistiques à l'intérieur d'une région. La plupart de ces définitions restent insatisfaisantes, car elles proposent soit une description trop générale, donc peu précise, soit une formulation trop restrictive, incapable de couvrir la

diversité des situations observées. La notion de texture reste donc abstraite et difficile à cerner avec exactitude [54].

Toutefois, il est quasiment toujours possible de décrire une texture en utilisant un vocabulaire et des expressions descriptives, souvent en fonction du domaine concerné (comme les images médicales, les images naturelles, les matériaux, etc.), mais qui sont plus simples à comprendre et donc plus simples à manipuler [54].

II.3 Notion de textures

II.3.1 Les familles de textures

Plusieurs familles de textures sont fréquemment abordées dans la littérature, telles que les textures déterministes, les textures stochastiques et les textures observables [55]. Les textures déterministes se distinguent par la reproduction périodique d'un élément géométrique, aussi connu sous l'appellation de "texton". Il est donc possible de synthétiser ce type de textures à partir d'un élément dont on connaît la direction et la dimension.

Les textures stochastiques sont en revanche irrégulières. Ces dernières respectent certaines lois statistiques et peuvent être perçues de la même manière qu'une représentation d'un processus aléatoire à deux dimensions.

On peut définir une texture observable peut être considérée comme une combinaison d'une texture stochastique et d'une texture déterministe. Effectivement, dans ce genre de textures, on peut observer une redondance de motifs très semblables mais non similaires [55].

Le vocabulaire précédent n'est pas utilisé par certains auteurs qui privilégient les termes de textures structurées (macro-textures) ou de textures aléatoires (micro-textures). La particularité des textures structurées réside dans la redondance de primitives à intervalles réguliers. Les textures à périodicité parfaite (déterministes) et celles présentant des altérations mineures de leurs primitives (textures observables) sont parmi celles-ci. L'aspect des textures aléatoires (textures stochastique) est plus fin (sable, herbe, etc.). L'identification d'une primitive de base et d'une fréquence de répétition est difficile [56].

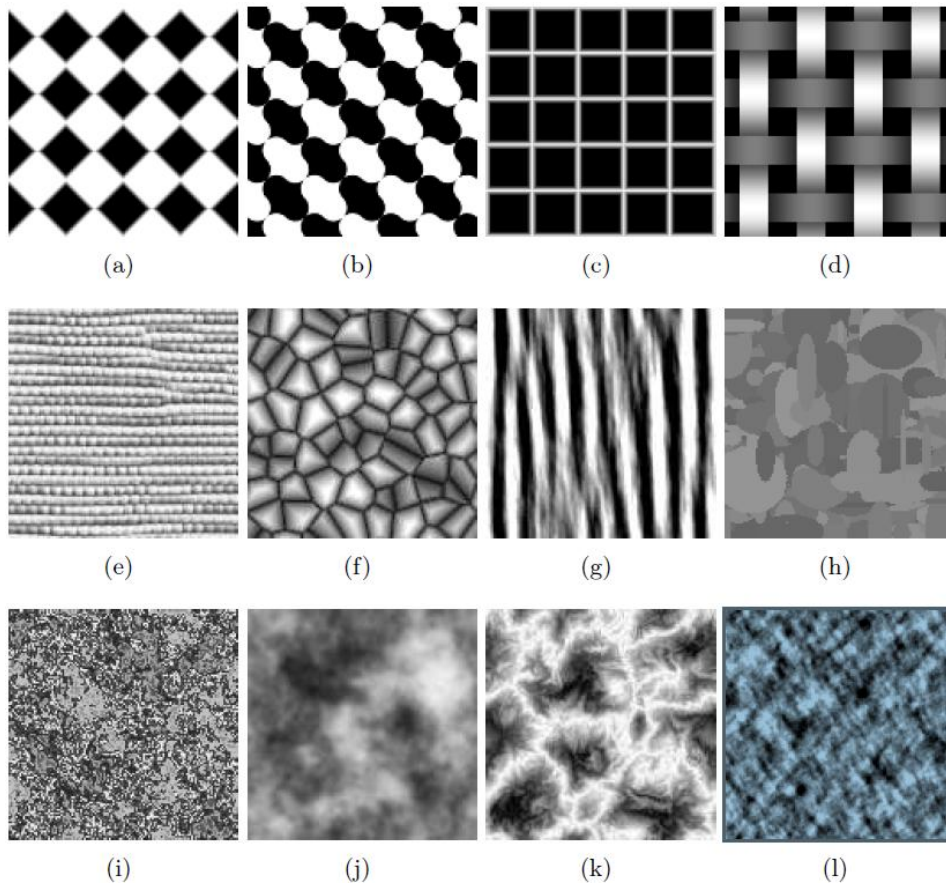


Figure II.1 : Les familles de textures : (a-d) textures déterministes, (e-h) textures observables, (i-l) textures stochastiques

II.3.2 Perception visuelle de texture

Les algorithmes de vision artificielle ou industrielle sont une succession d'approches développées pour pallier les insuffisances de la perception visuelle humaine à distinguer quelques motifs texturés. Plusieurs recherches ont permis de mettre en lumière la perception de la texture par l'œil humain. Par exemple, il est possible de mentionner les travaux psychovisuelles de Julesz [57], qui ont fourni des informations fiables sur la capacité du mécanisme perceptif de l'être humain à distinguer quelques variantes texturales. Ces recherches concernant la perception visuelle dans le domaine de la discrimination de texture ont été fondées sur les données statistiques spatiales des niveaux de gris de l'image. Selon Julesz, les statistiques spatiales du premier et du second ordre ont été définies de la manière suivante [58] :

Les statistiques de premier ordre représentent la probabilité d'observer un niveau de gris dans un emplacement aléatoire de l'image. On peut calculer ces statistiques en utilisant l'histogramme des intensités de pixels de l'image. La moyenne d'intensité d'une image est un exemple de statistiques de grande qualité.

Les statistiques de deuxième ordre désignent la probabilité d'occurrence d'une paire de niveaux de gris qui se manifestent aux bouts d'un segment dont la longueur est aléatoire situé dans l'image à un endroit et à une direction aléatoires [58].

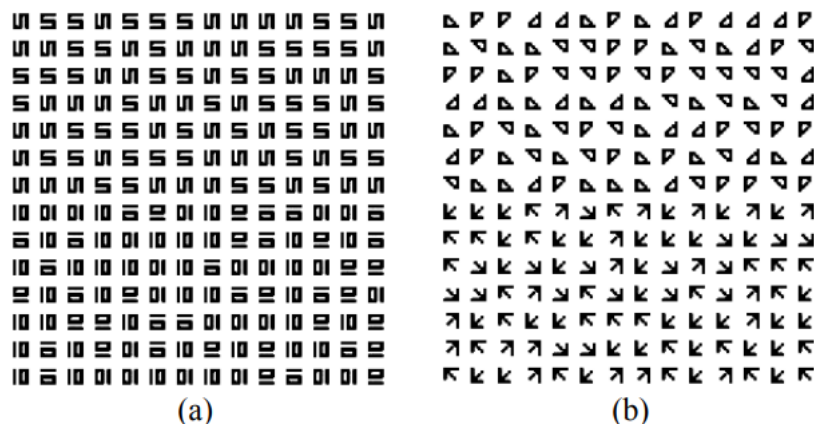


Figure II.2 : Images contenant des textures de second ordre statistique identiques.

Les textures de moitiés inférieures des images de la figure II.2 sont différents de ceux de moitiés supérieures. Dans la figure II.2 (a) les deux zones sont plus difficiles à distinguer par le système de perception humain. Tandis que dans la figure II.2 (b) Les deux zones peuvent être différenciées sans effort par la perception visuelle humaine [59].

II.4 Les méthodes d'analyse de la texture

L'analyse d'image est un instrument largement employé et en constante expansion dans divers secteurs tels que l'imagerie médicale, l'industrie, etc. L'étude de la texture est un ancien domaine de l'analyse d'image qui permet d'extraire des attributs distinctifs qui permettent de repérer des motifs distincts présents dans une image. Il existe plusieurs méthodes pour identifier et discriminer ces textures.

II.4.1 Les méthodes empruntées au traitement du signal

Ces techniques, fréquemment employées dans le domaine du traitement du signal, permettent d'étudier une texture en repérant les diverses fréquences qui la constituent. En général, ces techniques utilisent des outils ou des techniques de traitement de signal. La transformée de Fourier, les filtres de Gabor et les ondelettes sont parmi celles-ci [60].

On définit généralement la transformation linéaire d'une image f comme le résultat de sa corrélation avec une fonction Φ_λ [60].

$$\int_{-\infty}^{+\infty} f(x, y) \overline{\Phi}(x, y) dx dy \quad (\text{II.1})$$

Avec λ un ensemble de paramètres propre à Φ .

II.4.2 Les méthodes basées sur un modèle

Ces approches interprètent la texture comme le résultat d'un processus aléatoire stationnaire. Elles reposent sur l'identification d'un cadre statistique permettant de caractériser ou de synthétiser une texture. Parmi les approches les plus courantes figurent les modèles autorégressifs (AR), les représentations fractales, ainsi que les modèles fondés sur les chaînes de Markov [60].

II.4.3 Les méthodes statistiques

Les approches statistiques s'appuient fréquemment sur niveaux de gris des pixels. Elles visent à analyser les interactions entre un pixel central et son environnement immédiat. La complexité de l'analyse dépend du rang de la méthode, déterminé par le nombre de pixels considérés dans l'estimation des caractéristiques [60].

II.4.3.1 Les statistiques du premier ordre

Les statistiques du premier ordre permettent d'estimer les probabilités d'apparition d'une valeur d'intensité à une position aléatoire dans l'image, à partir de la distribution des niveaux de gris [60].

Tableau II.1 : Quelques caractéristiques du premier ordre [54]:

| Statistiques du premier ordre | Description |
|-------------------------------|---|
| Les moments d'ordre k | $\mu_k = \sum_n n^k p(n)$ |
| les moments centrés d'ordre k | $\tilde{\mu}_k = \sum_n (n - \mu_1)^k p(n);$ Avec μ_1 : la moyenne des niveaux de gris |
| La variance | σ^2 |
| Le biais | $\frac{\tilde{\mu}_3}{\sigma^3}$ |
| L'aplatissement | $\frac{\tilde{\mu}_4}{\sigma^4} - 3$ |
| L'énergie | $\sum_n p(n) ^2$ |
| L'entropie | $- \sum_n p(n) \log p(n)$ |
| Le contraste | $\frac{\max(n) - \min(n)}{\max(n) + \min(n)}$ |
| Le coefficient de variation | $\frac{\mu}{\sigma}$ |
| La dynamique | $\max(n) - \min(n)$ |

$p(n)$ désigne la densité de probabilité estimée pour la valeur de gris n issue de l'histogramme de l'image.

Les histogrammes d'image représentent des statistiques de premier ordre qui décrivent la répartition des niveaux de gris dans l'image à analyser. Si les intensités de pixels sont codées sur 8 bits, l'histogramme de l'image comportera 256 cellules, chacune contenant le nombre de pixels de l'image caractérisé par le niveau d'intensité à analyser [58].

II.4.3.2 Les statistiques du deuxième ordre

Évaluent la probabilité d'apparition simultanée de deux intensités de gris séparées par une distance et une direction spécifiques [60].

II.4.3.2.1 Matrice de cooccurrences

En 1973 Haralick a introduit la matrice de cooccurrence, également nommée matrice de dépendance spatiale des niveaux de gris (GLCM), afin de quantifier les propriétés texturales d'une image à partir de mesures statistiques de second ordre. Cette matrice évalue le nombre de répétition de paires de pixels présentant des niveaux de gris spécifiques, selon une orientation donnée θ et une distance fixe d . Elle constitue l'un des outils les plus utilisés et les plus reconnus dans les travaux de caractérisation de texture [61].

Haralick suggère une démarche en deux phases pour l'extraction des descripteurs texturaux : la première consiste à générer la matrice de cooccurrence (GLCM), tandis que la seconde vise à extraire les attributs texturaux à partir de cette matrice. Cette méthode est largement adoptée dans le domaine de l'analyse d'images, notamment en imagerie médicale [62].

II.4.3.2.2 Définition de la matrice de cooccurrence

La matrice de cooccurrence exprime la probabilité d'observer un couple de pixels, de niveaux de gris i et j , séparés par une distance d et situés selon une direction donnée θ , notée généralement par $P_{d,\theta}(i,j)$. L'élément (i,j) de $P_{d,\theta}$ est la fréquence d'apparition du couple de niveaux de gris i et j espacés d'une distance $d=(d_x,d_y)$ et une orientation θ . La matrice de cooccurrence d'une image I de taille $N_x \times N_y$ est une matrice carrée de taille $N_g \times N_g$ tel que N_g est le nombre de niveaux de gris dans l'image [62].

$$P_{d,\theta}(i, j) = \#\{(r, s): I(r, s) = i, I(r + dx, v + dy) = j\} \quad (\text{II.2})$$

$I(r, s)$ correspond à la valeur de gris du pixel situé en (r, s) dans l'image I , et $\#$ la fonction cardinale.

La normalisation de la matrice de cooccurrence consiste à diviser chacun de ses éléments par le total des paires de niveaux de gris. Les angles de directions θ les plus communément utilisées sont, 0^0 , 45^0 , 90^0 , 135^0 ainsi que leurs symétriques [62].

La construction de cette matrice avec huit niveaux de gris, une distance entre pixel égal à un et zéros degrés pour la direction est illustrée dans la figure II.3.

Dans cet exemple, la valeur de l'élément (1,2) dans la GLCM est de 1, car cette cooccurrence ne se produit qu'une seule fois dans I_m .

| | | | | |
|------------------|---|---|---|---|
| I _m = | 1 | 4 | 2 | 3 |
| | 3 | 1 | 4 | 2 |
| | 3 | 2 | 1 | 3 |
| | 1 | 3 | 4 | 1 |

| | | | | | |
|-------------------------|---------------------------------|---|---|---|---|
| P(1,0°) et P(1,180°) | N _i , N _j | 1 | 2 | 3 | 4 |
| | 1 | 0 | 1 | 3 | 3 |
| | 2 | 1 | 0 | 2 | 2 |
| | 3 | 3 | 2 | 0 | 1 |
| | 4 | 3 | 2 | 1 | 0 |

Figure II.3 Matrice de cooccurrence P(1,0) de l'image I_m avec 4 niveaux de gris, pour $d = 1$ et $\theta = 0^\circ$, $\theta = 180^\circ$. Le 2^{ème} tableau indique la matrice de cooccurrence.

- **Caractéristiques d'Haralick**

À partir de la matrice de cooccurrence, quatorze descripteurs texturaux ont été définis par Haralick [52]. On retrouve notamment : le contraste, l'énergie (second moment angulaire), la corrélation et l'homogénéité.

Contraste : Évalue les différences de niveaux de gris entre un pixel et ses voisins [63].

Energie : second moment angulaire (ASM), il reflète la régularité du contenu de l'image. Lorsqu'une image présente une intensité constante, l'énergie prend la valeur 1 [64].

Corrélation : Elle exprime la dépendance linéaire entre les intensités des niveaux de gris au sein de la matrice de cooccurrence, illustrant le lien entre un pixel et son voisin. Une valeur

proche de 0 indique une absence de corrélation, tandis qu'un résultat proche de 1 traduit une corrélation parfaite [63].

Homogénéité (Inverse Difference Moment (IDM)): évalue la similarité de la distribution des valeurs de la matrice de cooccurrence avec la diagonale.

Entropie : Le concept vient de la thermodynamique, il se réfère à la quantité d'énergie qui est perdue en permanence sous forme de chaleur chaque fois qu'une réaction ou une transformation physique se produit. L'entropie ne peut être récupérée pour effectuer un travail utile. De ce fait, le terme peut être compris comme la quantité de chaos ou de désordre qui ne peuvent être corrigés [64].

Variance : C'est une mesure de l'étalement des valeurs autour de la moyenne des combinaisons de pixels de référence et de pixels voisins [64].

Le Tableau II.2 donne quelques caractéristiques d'Haralick avec leurs formoles ;

Tableau II.2 Caractéristiques d'Haralick calculé à partir de la GLCM

| Characteristics | Formules |
|-----------------|--|
| contraste | $\sum_{i,j} i - j ^2 P_{d,\theta}(i, j)$ |
| Energie | $\sum_{i,j} P_{d,\theta}^2(i, j)$ |
| Correlation | $\frac{\sum_{i,j}(i, j)P_{d,\theta}(i, j) - \mu_x\mu_y}{\sigma_x\sigma_y}$ |
| Moyenne | $\mu_x = \sum_{i,j} i P_{d,\theta}(i, j)$ $\mu_y = \sum_{i,j} j P_{d,\theta}(i, j)$ |
| Variances | $\sigma_x^2 = \sum_{i,j} (i - \mu)^2 P_{d,\theta}(i, j)$ $\sigma_y^2 = \sum_{i,j} (j - \mu)^2 P_{d,\theta}(i, j)$ |

| | |
|---------------------|--|
| Déviatiion standard | $\sigma_x = \sqrt{\sum_{i,j} (i - \mu)^2 P_{d,\theta}(i,j)}$ |
| | $\sigma_y = \sqrt{\sum_{i,j} (j - \mu)^2 P_{d,\theta}(i,j)}$ |
| Homogénéité | $\sum_{i,j} \frac{P_{d,\theta}(i,j)}{1 + i - j}$ |
| Entropie | $\sum_{i,j} -P_{d,\theta}(i,j) \log_2(P_{d,\theta}(i,j))$ |

La matrice GLCM est un outil puissant pour l'analyse de texture, mais son efficacité dépend de la nature des images traitées, des choix de paramètres, et de la gestion des compromis entre précision et complexité computationnelle.

II.4.4 Les méthodes basées sur une analyse des motifs

II.4.4.1 Le spectre des textures

En 1990, Wang et He ont présenté une approche de caractérisation de la texture basée sur le spectre textural de l'image. Cette méthode repose sur la séparation de l'image en un ensemble d'unités de texture, chacune constituée de n éléments prenant des valeurs discrètes (0, 1 ou 2). Dans le cas d'un voisinage de type 3×3, c'est-à-dire avec 8 voisins, cette configuration permet de générer jusqu'à 3⁸ = 6561 combinaisons d'unités de texture différentes [65].

Dans la méthode proposée par Wang et He en 1990, pour fenêtre de pixels de taille 3×3, on considère un ensemble d'intensités $V = V_0, V_1, \dots, V_8$ avec V_0 l'intensité du pixel central et V_1, \dots, V_8 celles des pixels adjacents. Les unités de texture associées sont regroupées dans l'ensemble $TU = E_1, E_2, \dots, E_8$ [65].

$$E_i = \begin{cases} 0 & \text{si } V_i < V_0 \\ 1 & \text{si } V_i = V_0 \\ 2 & \text{si } V_i > V_0 \end{cases} \quad i = 1, \dots, 8 \quad (\text{II.3})$$

Un identifiant unique est ensuite attribué à chaque unité de texture, en utilisant la formule suivante :

$$N_{TU} = \sum_{i=1}^8 E_i 3^{i-1} \quad (\text{II.4})$$

Avec N_{TU} le label de l'unité de textures et E_i l'élément i de l'unité de textures.

Cette méthode est améliorée en générant un nombre d'unités de textures plus restreint. Pour un voisinage de 8 pixels, il est possible d'obtenir $2^8=256$ unités de textures différentes contre 6561 pour la méthode du spectre de textures [60].

II.4.4.2 Local binary pattern

C'est une méthode qui est considérée comme une approche qui unifie les traditionnelles méthodes structurelles et statistiques. Ojala a introduit cette méthode en 1996, en s'appuyant sur les recherches de Wang et He (1990) portant sur l'analyse du spectre de texture [65]. L'atout majeur de l'opérateur LBP est sa robustesse face aux changements de luminosité et aux rotations. Par ailleurs, cette méthode se distingue par sa faible complexité computationnelle, ce qui permet l'analyse d'images 2D en temps réel [66]. Cette méthode a démontré son efficacité dans plusieurs applications avancées, notamment en détection et reconnaissance faciale, ainsi que dans divers contextes industriels, où une analyse texturale robuste est requise.

L'opérateur LBP (Local Binary Pattern) attribue à chaque pixel un code binaire basé sur les intensités de ses pixels voisins. La valeur du pixel central sert de référence pour binariser son voisinage : chaque pixel adjacent est comparé à cette valeur afin de générer un motif binaire. Ce motif est ensuite pondéré selon la position des pixels, puis converti en une valeur décimale représentant le code LBP associé [67].

Le voisinage est défini selon une disposition circulaire autour d'un pixel central, en fonction de deux paramètres : le rayon R , représentant la distance entre le pixel central et ses adjacents, et le nombre de points échantillonnés P sur le périmètre du cercle. Cette configuration est illustrée dans la figure II.4 [67].




Figure II.4: Illustration du pixel central et de ces P voisins sur un rayon R

Soit une texture $T=(g_c, g_0, \dots, g_{p-1})$, ou g_c représente le niveau de gris du pixel central et g_p celui de ses voisins, avec $p=0, \dots, P-1$. Si le pixel central g_c est situé aux coordonnées (x_c, y_c) , alors les coordonnées de g_p sont déterminées par $(x_c + R\sin(2\pi p/P), (y_c - R\cos(2\pi p/P))$ [66].

Comme dans la méthode LBP classique, le pixel central n'est pas utilisé pour la caractérisation des textures. En effet, indépendamment du voisinage g_p , ce pixel décrit uniquement une intensité lumineuse ce qui n'est pas forcément utile [68]. Ce qui nous permet d'écrire T sous la forme :

$$T=(g_0, \dots, g_{p-1}) \quad (\text{II.5})$$

On procède ensuite à la soustraction du niveau de gris du pixel central g_c à celui de chacun de ses voisins g_p ($p=0, \dots, P-1$) donnant [66]:

$$T=(g_0-g_c, \dots, g_{p-1}-g_c) \quad (\text{II.6})$$

La soustraction $g_p - g_c$ reste inchangée face aux variations de luminance globale, ce qui confère à cette opération une invariance aux transformations d'échelle d'intensité [66]. En s'intéressant uniquement au signe de cette différence plutôt qu'à sa valeur absolue, on obtient la fonction suivante :

$$T=(s(g_0-g_c), \dots, s(g_{p-1}-g_c)) \quad (\text{II.7})$$

Avec :

$$s(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases} \quad (\text{II.8})$$

En assignant un facteur de poids 2^p pour chaque signe $s(g_p - g_c)$ on obtient l'expression de $LBP_{P,R}$ suivante [59]:

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) \cdot 2^p \quad (\text{II.9})$$

La Figure II.5 illustre un exemple de calcul du code LBP pour un voisinage de 3x3. La Figure II.6 montre une image dans le plan LBP.

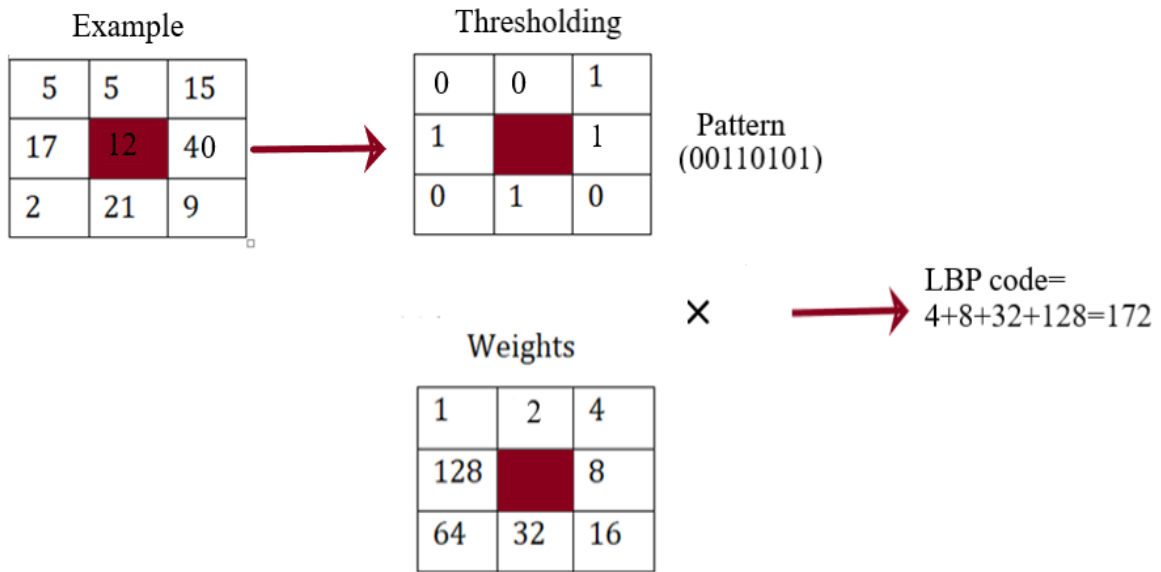


Figure II.5: Génération du code LBP.



Image original



Image LBP

Figure II.6 : Exemple du passage d'une image en niveaux de gris vers le plan LBP

Dans le but d'en améliorer les performances, notamment en renforçant son invariance à la rotation, diverses variantes de cette méthode ont été développées. Par ailleurs, le schéma de voisinage n'est plus restreint à huit pixels : il peut être étendu à 12, 16 voire 32 voisins, selon le rayon choisi [67].

II.4.4.2.1 Invariance à la rotation

Quand une image subit une rotation, la valeur de niveau de gris des pixels voisins g_p se déplace le long du périmètre du cercle centré sur g_c , ce qui engendre des motifs différents et des codes $LBP_{P,R}$ distincts. Afin de garantir l'invariance à la rotation, chaque code binaire généré doit être ramené à une position de référence, ce qui permet d'associer un code unique à toutes les rotations possibles d'un même motif [69]. Cette modification peut être déterminée comme suit :

$$LBP_{P,R}^i = \min\{ROR(LBP_{P,R}, i)\} \quad (II.10)$$

Avec $i=1, \dots, P-1$ et $ROR(x, i)$ présentant une rotation circulaire vers la droite du code binaire x , effectuée i fois. Le code $LBP_{P,R}$ est défini comme la plus petite valeur obtenue parmi toutes les rotations possibles du motif binaire initial. Cette méthode permet de réduire le nombre des motifs à 36 motifs différents au lieu de 2^p comme le montre la figure II.7. Néanmoins, cet opérateur n'a pas permis d'obtenir une séparation efficace des textures. Cette limitation s'explique principalement par la forte disparité dans la fréquence d'apparition des 36 motifs possibles, certains étant rarement observés, ce qui les rend statistiquement peu fiables [67].




Figure II.7 : Les 36 motifs binaires invariants à la rotation qui peuvent apparaitre pour un voisinage de 3x3. Les cercles noire et blanc correspondent au bit 0 et 1 respectivement.

II.4.4.2.2 Amélioration du motif de l'invariance à la rotation par le motif uniforme

Il existe des motifs binaires locaux présentent des propriétés essentielles dans la description de la texture, représentant parfois jusqu'à 90 % des occurrences totales dans une image texturée et démontrant une robustesse notable au bruit. Ces motifs, dits uniformes, se caractérisent par un nombre de passage (de 0 à 1 ou de 1 à 0) n'excédant pas deux. Ces structures régulières servent de représentations typiques pour diverses microstructures, telles que les zones uniformément sombres (motif 0), claires (motif 8), ou encore les contours et arêtes (motifs entre 1 et 7), comme illustré dans la figure II.8 [66]."




Figure II.8: Différentes primitives de la texture détecter par $LBP_{P,R}$.

Définition du nombre de transition U

Avant de présenter l'opérateur $LBP_{(P,R)}$, il convient de définir la mesure U , qui mesure le nombre de transitions binaires entre les valeurs 0 et 1 (et inversement) dans un motif binaire, en tenant compte de leur disposition spatiale. Comme illustré dans la figure II.9, si la valeur de U est inférieure ou égale à 2, le motif est qualifié d'uniforme. Dans le cas contraire, il est considéré comme non uniforme [67].

Donnant l'exemple du motif suivant (11100111) on compte un nombre de passage de 0 à 1 et de 1 à 0 est égal à 2 qui représente également la valeur de U , ce motif est donc considéré comme uniforme. Si on prend l'exemple du motif suivant (00101000) le nombre de transition dans ce cas est égal à 4 donc U a la même valeur, on constate que U est supérieur à 2, ce motif est donc un motif non-uniforme [67].

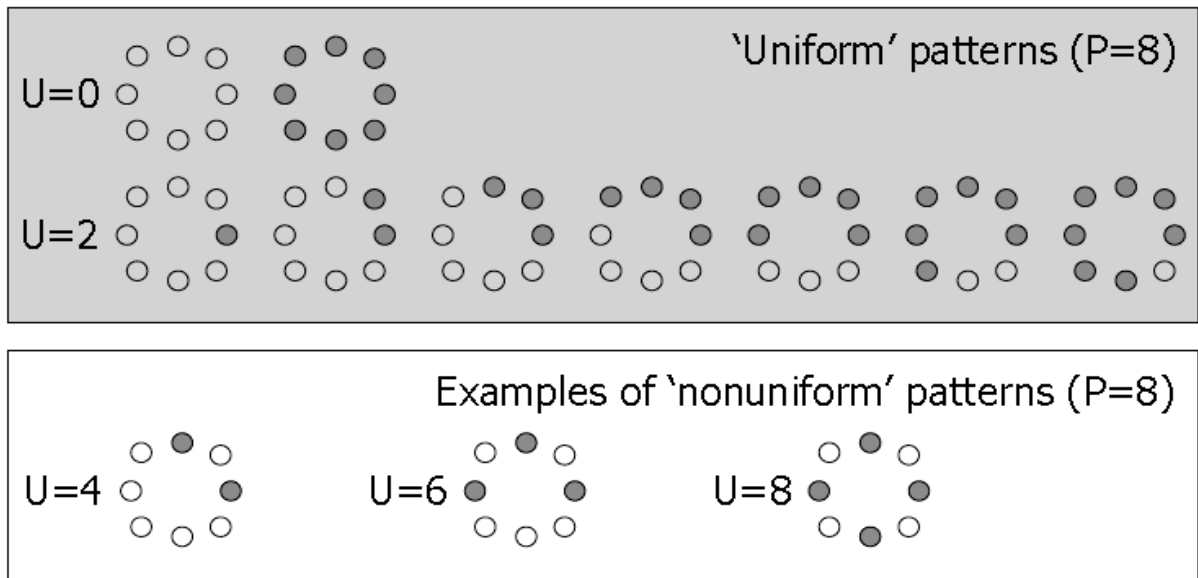


Figure II.9 : Illustration des motifs uniformes et non-uniformes.

Calcul du code $LBP_{P,R}^{riu2}$

$$LBP_{P,R}^{riu2} = \begin{cases} \sum_{p=0}^{P-1} s(g_p - g_c) & \text{si } U(LBP_{P,R}) \leq 2 \\ P + 1 & \text{sinon} \end{cases} \quad (\text{II.11})$$

Avec :

$$U(LBP_{P,R}) = |s(g_{P-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^{P-1} |s(g_p - g_c) - s(g_{p-1} - g_c)| \quad (\text{II.12})$$

Dans un voisinage circulaire comportant P voisins, il est possible d'identifier $P+1$ motifs binaires dits uniformes. Chacun de ces motifs est associé à une valeur distincte de l'opérateur $LBP_{P,R}^{riu2}$ dont les valeurs s'échelonnent de 0 jusqu'à P [67].

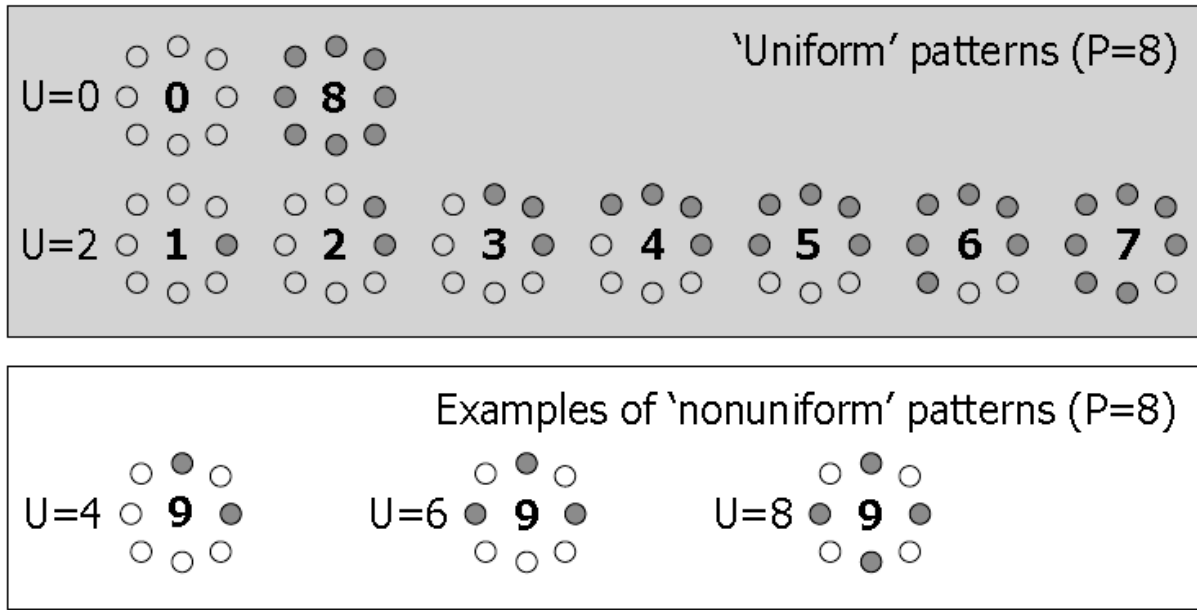


Figure II.10 : Les uniques codes $LBP_{P,R}^{riu2}$ qui peuvent exister pour différents U.

II.4.4.2.3 Local ternary pattern

Tan et Triggs en 2010 ont modifié le code LBP pour en faire un code à trois valeurs appelé LTP, dans lequel les valeurs de gris dans la région de largeur $\pm t$ entourant g_c sont ramenées à zéro, les valeurs supérieures à (g_c+t) sont ramenées à +1, et les valeurs inférieures à (g_c-t) sont ramenées à -1, l'expression $s(x)$ est remplacée par une fonction à trois valeurs $s1(x)$, et le code LBP binaire est remplacé par un code LTP ternaire [70].

$$LTP_{P,R} = \sum_{p=0}^{P-1} s1(g_p - g_c) \cdot 2^p \quad (II.13)$$

$$s1(x) = \begin{cases} +1 & \text{si } x \geq g_c + t \\ 0 & \text{si } -t < x < t \\ -1 & \text{si } x \leq g_c - t \end{cases} \quad (II.14)$$

Où g_c , g_p , R et P sont définis précédemment. Le paramètre t est fixé de manière empirique, dans notre on prend cas $t=5$ [70].

Après l'étape de seuillage qui consiste à calculer la fonction $s1(\cdot)$, le motif supérieur et le motif inférieur sont créés et codés comme le montre la figure II.11. Le calcul est effectué séparément et les deux vecteurs de caractéristiques résultants sont combinés à la fin [71].

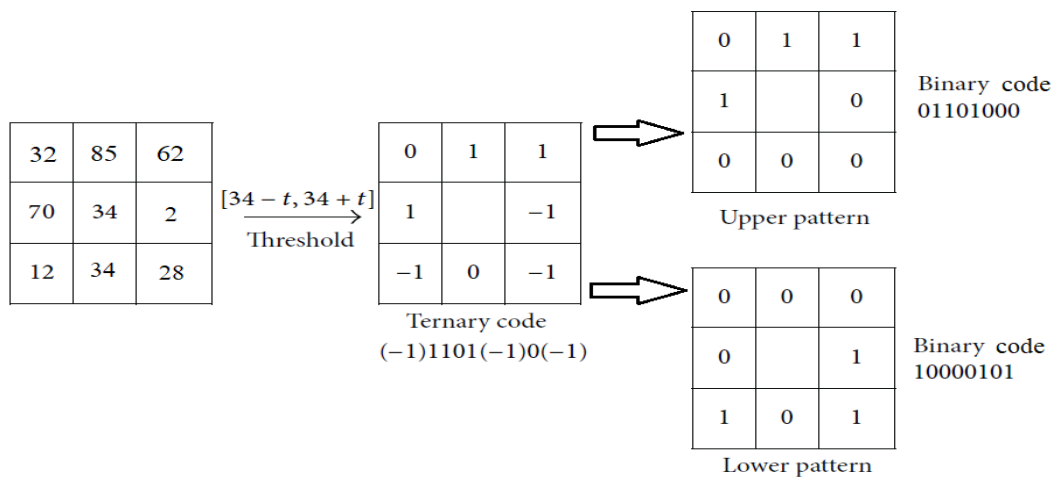


Figure II.11 : Illustration du calcul de l'opérateur LTP [71].

II.5 Classification et analyse de texture

La classification constitue une méthode visant à répartir un ensemble d'observations en plusieurs catégories, en rassemblant celles partageant des caractéristiques similaires au sein d'une même classe. Dans le cas de la classification d'images, les observations sont des images elles-mêmes, chacune étant représentée par un vecteur de caractéristique, notamment des descripteurs de texture [72].

II.5.1 Classification K-NN

La méthode des k plus proche voisin (k-NN) connus en anglais sous le nom K-nearest neighbor, est une méthode qui se distingue des approches classiques d'apprentissage supervisé par l'absence de phase de modélisation : les données d'apprentissage sont simplement mémorisées, sans construction préalable d'un modèle prédictif [72]. L'algorithme des k-NN) offre la possibilité de gérer des ensembles de données présentant une séparation non linéaire, grâce à son principe de classification basé sur la proximité dans l'espace des caractéristiques. L'avantage de cette approche réside dans sa simplicité et son efficacité. L'algorithme k-NN est l'un des plus simples algorithmes d'apprentissage artificiel.

La classification d'un échantillon de test repose sur le calcul de la distance entre celui-ci et l'ensemble des données d'apprentissage, puis d'effectuer un vote majoritaire parmi les k données les plus proches, chacune des données votant pour la classe à laquelle elle appartient.

Le seul paramètre qu'il est nécessaire de fixer est donc le nombre k de voisins à considérer pour prendre la décision [73], [74].

La distance euclidienne constitue la mesure de similarité la plus fréquemment employée dans l'algorithme k -NN, bien que d'autres métriques telles que les distances de Hamming ou de Mahalanobis puissent également être utilisées, en fonction de la nature des données. L'un des principaux avantages du classificateur k -NN réside dans l'absence de phase explicite d'apprentissage : chaque nouvel échantillon est comparé à l'ensemble des instances de la base d'apprentissage par le calcul des distances. Bien que simple à implémenter, cet algorithme présente l'inconvénient d'être long, notamment lors de la phase de classification, en raison du calcul systématique des distances entre l'échantillon à tester et l'ensemble des données disponibles [75].

La figure II.12 illustre le fonctionnement de l'algorithme k -NN pour le cas où $k=5$, dans un espace d'attributs bidimensionnel ($d=2$) et pour un problème de classification binaire. Pour déterminer la classe de l'image test, on identifie d'abord les cinq prototypes les plus proches, selon la métrique euclidienne. Ces prototypes correspondent aux points situés à l'intérieur d'un cercle centré sur la représentation de l'image test dans l'espace des caractéristiques. Parmi ces cinq voisins, trois appartiennent à la classe 2 et deux à la classe 1. Par conséquent, l'image test est classée dans la classe majoritaire, soit la classe 2."

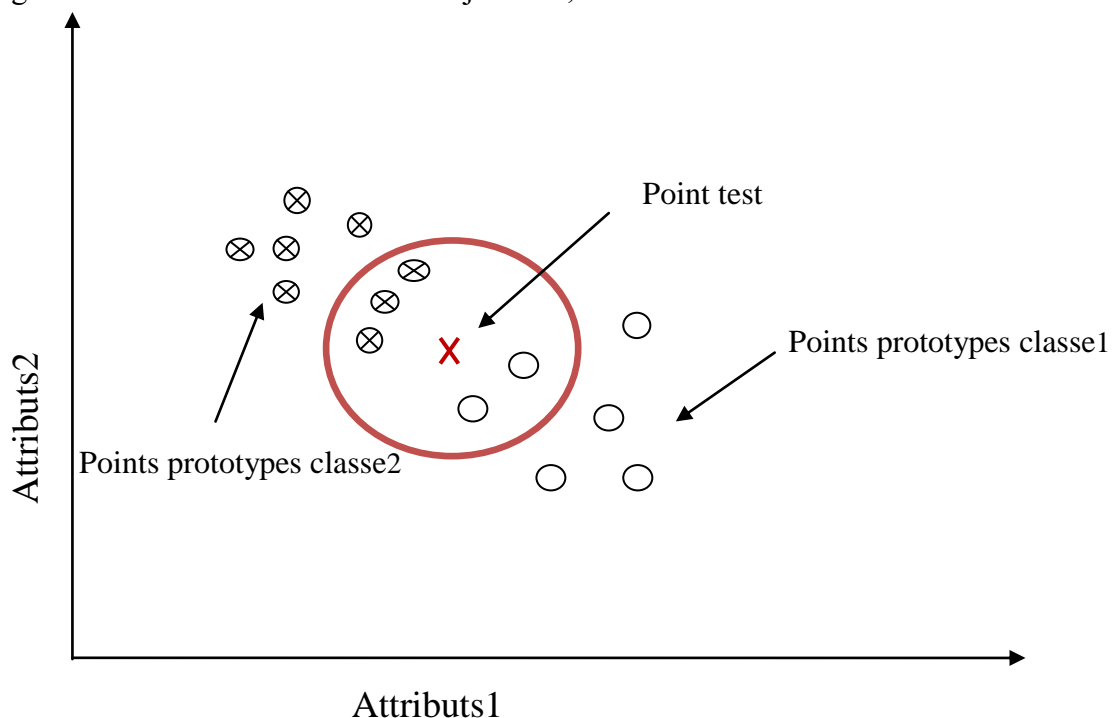


Figure II.12 : Illustration de la méthode des k plus proches voisins (k -NN) avec $k = 5$.

II.5.2 Support vecteur machine SVM

Vapnik a présenté cette méthode de classification de données en 1995 [76]. Elle a d'abord été définie pour un cas de discrimination à deux classes. Il s'agit, de façon très simple, de créer, dans l'espace des attributs, un hyperplan qui sépare les points représentatifs des prototypes de chaque classe. La méthode des séparateurs à vastes marges est basée sur deux concepts essentiels : la notion de marge maximale et la notion de noyau [77].

La frontière de séparation (l'hyperplan) et les points les plus proches de cette frontière sont séparés par la marge. On désigne ces points comme des vecteurs supports. Dans les SVM, on sélectionne la frontière de séparation comme celle qui permet de maximiser la marge [75].

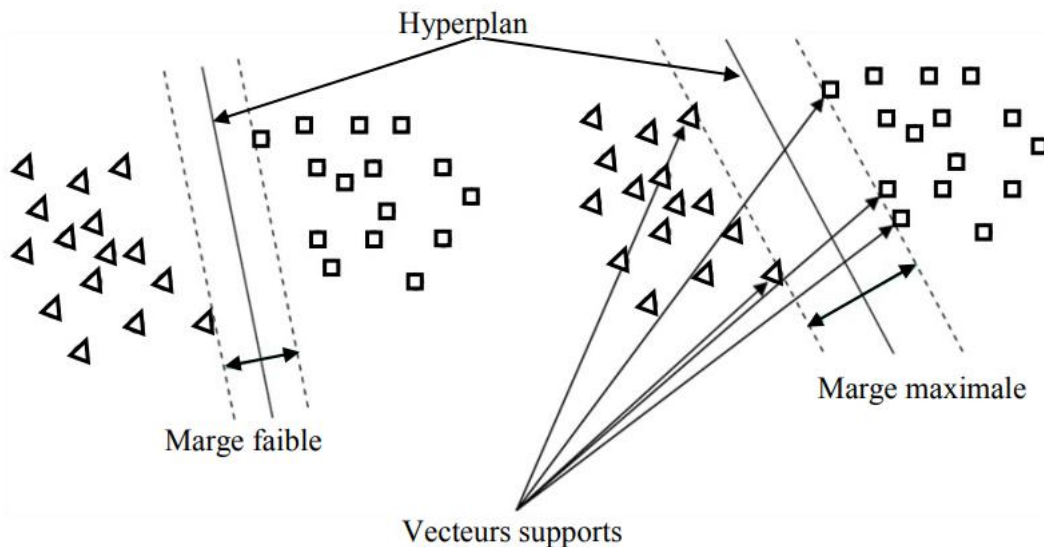


Figure II.13 : Représentation de la marge maximale et des vecteurs supports qui lui sont liés.

Les modèles des SVM comprennent des cas linéairement séparables et des cas non linéairement séparables comme le montre la figure II.13. Afin de surmonter les désavantages des cas non linéairement séparables, les SVM proposent de modifier l'espace des données. Le changement non linéaire des données peut donner la possibilité de séparer les exemples de manière linéaire dans un nouvel espace. La recherche de surfaces de décision non linéaires s'effectue par l'introduction d'une fonction noyau (kernel) dans le calcul du produit scalaire. Cette approche permet une transformation implicite des données vers un espace de caractéristiques (feature space) de dimension supérieure, dans lequel les données initialement non séparables deviennent linéairement séparables. Ce mécanisme est à la base du concept de

machine à noyau (kernel machine), fréquemment utilisé dans les méthodes d'apprentissage supervisé telles que les machines à vecteurs de support (SVM).

Il existe plusieurs familles de fonctions noyau paramétrables et il incombe à l'utilisateur de SVM de réaliser des tests afin de déterminer celle qui convient le mieux à son application. Les noyaux suivants peuvent être mentionnés : polynomial, gaussien, sigmoïde et laplacien [58].

Bien que les SVM soient initialement conçus pour des problèmes de classification binaire, plusieurs méthodes permettent de les adapter à la classification multi-classes.

L'approche un contre tous (one vs all) est la plus simple et la plus ancienne des méthodes de décomposition [76]. Elle consiste à utiliser pour un problème avec N classes, N classificateurs binaires sont construits. Chaque classificateur est entraîné pour distinguer une classe spécifique (la classe positive) de toutes les autres classes (les classes négatives). Lors de la classification d'un nouvel échantillon, chaque classificateur donne une étiquette ou une distance par rapport à l'hyperplan de séparation. La classe pour laquelle le classificateur donne l'étiquette la plus élevée ou la distance maximale est choisie comme classe prédite [78].

L'approche un contre un (one vs one) pour un problème de classification avec N classes, $N(N-1)/2$ classificateurs binaires sont construits, chaque classificateur étant entraîné pour distinguer entre une paire de classes. Chaque classificateur décide entre deux classes. Lors de la classification d'un nouvel échantillon, chaque classificateur vote pour une classe. La classe finale est déterminée par le vote majoritaire de tous les classificateurs binaires [79].

II.5.3 Les réseaux de neurones

Les réseaux de neurones ou artificial neural network ANN, conçus à partir du système nerveux biologique, ils sont constitués d'éléments simples appelés neurones, divisés en couches. C'est un système de traitement de l'information composé de l'interconnexion d'éléments de traitement simples appelés neurones. Chaque neurone est un élément de traitement autonome qui modifie ses données d'entrée à l'aide d'une fonction d'activation. Les valeurs de poids représentent les connexions entre les neurones et constituent la mémoire du réseau [80]. Un modèle simple de neurones est présenté dans la figure suivante.

L'entrée du neurone est représentée par $X=(x_1,x_2,\dots,x_n)$. Pour chaque entrée, il existe une valeur de poids $W=(w_1,w_2,\dots,w_n)$; b est le symbole de la valeur de biais du neurone qui permet d'ajouter de la flexibilité au réseau en le faisant varier lors de l'apprentissage.




Figure II.14 : Modèle d'un neurone artificiel.

Un neurone se compose principalement d'un intégrateur qui réalise la somme pondérée de ses entrées, le résultat s de cette somme est ensuite converti par une fonction de transfert f qui donne la sortie y du neurone [4]. L'expression de la sortie est donnée par l'équation (II.16).










$$s = \sum_{i=1}^n w_i x_i \pm b \quad (\text{II.15})$$

$$y = f(s) \quad (\text{II.16})$$

Plusieurs fonctions de transfert qui peuvent servir de fonction d'activation du neurone. Les fonctions les plus fréquemment employées pour activer sont les fonctions « seuil » (en anglais « hard limit »), « linéaire » et « sigmoïde » [81]. Le tableau II.3 montre les fonctions d'activation et leurs formules.

L'un des réseaux de neurones les plus répandus est le perceptron multicouches (MLP). Il est composé de différentes couches de neurones (une couche d'entrée, une couche de sortie et une ou plusieurs couches cachées) qui sont entièrement reliées entre elles. Le terme "couche d'entrée" désigne l'ensemble des neurones d'entrée, tandis que le terme "couche de sortie" désigne l'ensemble des neurones de sortie. On nomme couches cachées les couches intermédiaires qui ne sont pas en contact avec l'extérieur [81]

Tableau II.3 : Les fonctions d'activations utilisées dans les ANN [58]

| Nom de la fonction | Relation entrée/sortie | Icône |
|-----------------------------|--|---|
| Seuil | $y = 0$ si $s < 0$ $y = 1$ si $s \geq 0$ |  |
| Seuil symétrique | $y = -1$ si $s < 0$ $y = 1$ si $s \geq 0$ |  |
| Linéaire | $y = s$ |  |
| Linéaire saturée | $y = 0$ si $s \leq 0$ $y = s$ si $0 \leq s \leq 1$ $y = 1$ si $s \geq 1$ |  |
| Linéaire saturée symétrique | $y = -1$ si $s < -1$ $y = s$ si $-1 \leq s \leq 1$ $y = 1$ si $s > 1$ |  |
| Linéaire positive | $y = 0$ si $s \leq 0$ $y = s$ si $s \geq 0$ |  |
| Sigmoïde | $y = \frac{1}{1 + \exp^{-s}}$ |  |
| Tangente hyperbolique | $y = \frac{e^s - e^{-s}}{e^s + e^{-s}}$ |  |
| Compétitive | $y = 1$ si s maximum $y = 0$ autrement |  |

II.6 Conclusion

L'analyse de la texture est une composante essentielle du traitement d'images, offrant des techniques variées pour capturer et interpréter les motifs présents dans les données visuelles. Les méthodes statistiques, telles que la matrice de cooccurrence et les histogrammes, fournissent une quantification robuste des variations d'intensité, tandis que les approches basées sur les modèles, comme la méthode LBP, permettent de mieux comprendre les structures complexes. La combinaison de ces méthodes enrichit notre capacité à diagnostiquer et à classifier des objets dans diverses applications, de la reconnaissance de surfaces à la détection de défauts dans les machines électriques. Dans le prochain chapitre nous allons

discuter les résultats de notre approche qui consiste à combiner deux méthodes d'analyse de la texture qui sont la méthode GLCM et la méthode LBP tout en utilisant des outils de classification différents tel que K-NN, SVMOVA et AN.

Chapitre III : Diagnostic des moteurs asynchrones par étude de l'histogramme LBP

III.1 Introduction

Le diagnostic des moteurs asynchrones constitue un enjeu crucial pour garantir leur fiabilité et prévenir les pannes susceptibles de perturber les processus industriels. Parmi les différentes approches utilisées, les méthodes basées sur l'analyse des textures offrent des perspectives intéressantes en raison de leur capacité à extraire des informations significatives à partir de signaux transformés en image. Dans ce contexte, l'histogramme des motifs locaux binaires (LBP) est un outil intéressant pour la caractérisation et la discrimination des états de fonctionnement des machines.

Ce chapitre explore la méthodologie de diagnostic basée sur le descripteur LBP. À travers une série d'expérimentations, des émissions acoustiques de moteurs sains et défectueux ont été convertis en images pour extraire des caractéristiques texturales. Les variations observées dans les histogrammes LBP permettent de différencier les états de fonctionnement des moteurs.

III.2 Diagnostic des machines électriques par la méthode LBP

L'utilisation des images pour le diagnostic des machines électriques est une méthode de plus en plus populaire et efficace. En 2013 Shahriar et al démontrent que cette approche permet une détection précise et rapide des défauts. Les principales techniques impliquent l'analyse d'images dérivées de divers signaux, tels que les signaux acoustiques, thermographiques et vibratoires.

Le LBP est une méthode de description locale de la texture basée sur les relations entre un pixel central et ses voisins dans une petite région de l'image. Il fonctionne en comparant l'intensité de chaque pixel avec celle de ses voisins immédiats pour générer un motif binaire, appelé code LBP [68].

Il existe plusieurs travaux qui traitent de cette méthode pour le diagnostic des machines électriques. Shahriar et al. a utilisé des signaux vibratoires de machines à défauts de : roulement, rotor courbé et défaut d'excentricité. En utilisant la méthode LBP et l'SVM pour la classification [3]. O Yaman, dans son étude a utilisé des signaux acoustiques sur cinq machines avec différents défauts de roulement et de barres cassées. Son approche a comporté

l'utilisation de la méthode LBP avec la transformée en ondelettes discrète (Discrete Wavelet Transform DWT) [13].

III.3 Approche utilisée

Nous avons proposé dans cette étude un ensemble de données d'émissions acoustiques pour l'identification des défauts des moteurs à induction triphasés à cage d'écureuil. Le travail a été réalisé par le laboratoire de technologie informatique, Université Firat, Elazig en Turquie. Afin de recueillir des données sonores pour chaque type de défaut, le programme « Voice Recorder » a été installé sur un téléphone portable « LG G4'' brand de marque « LG G4' ». La fréquence d'échantillonnage est sélectionnée à 44 kHz dans le programme d'enregistrement sonore. En faisant fonctionner le moteur dans cinq conditions différentes, le microphone a été fixé à une distance de 10 cm pendant 330 s [13].

La détection des défauts a été effectuée sur cinq moteurs à induction pour chaque moteur un défaut différent a été créer à savoir, défaut d'une barre cassée, deux barres cassées, trois barres cassées et un défaut de roulement. Le cinquième moteur est gardé sain [13]. Le tableau III.1 présente les détails de la machine à induction utilisée pour l'expérimentation




Figure III.1 : Moteur utilisé dans l'expérimentation

La figure III.2 montre les images d'un moteur sain et de quatre défauts réalisés sur un moteur asynchrone à cage d'écureuil.




Figure III.2 : Types de défauts dans un moteur à induction utilisé dans l'expérience: (a) moteur sain; (b) moteur avec une barre cassée; (c) moteur avec deux barres cassées; (d) moteur avec trois barres cassées; (e) moteur avec défauts des roulements.

Tableau III.1 : Caractéristiques des moteurs à induction utilisés dans la configuration expérimentale.

| Description | Valeur |
|---------------------------|------------|
| Puissance active | 0.75 [kW] |
| Tension nominale | 380 [V] |
| Vitesse | 1380 [rpm] |
| Courant nominal | 2.2 [A] |
| Nombre de pôles | 4 |
| Nombre de barres de rotor | 22 |
| Fréquence nominale | 50 [Hz] |

III.3.1 Génération des images à partir de signaux acoustiques

Le processus de conversion des données est effectué pour générer des images en niveaux de gris à partir d'un signal acoustique 1D. Cette opération est réalisée avec un programme sur Matlab. Le signal acoustique est divisé en N fragments égaux, et chaque fragment est disposé comme la colonne d'une matrice 2D $M \times N$. L'amplitude d'un échantillon de chaque fragment est normalisée dans une plage de 0 à 255 pour devenir la valeur en niveaux de gris de cet échantillon. Ce processus est illustré dans la figure III.3. Le résultat de ce processus est une image d'une taille de 150×133 .

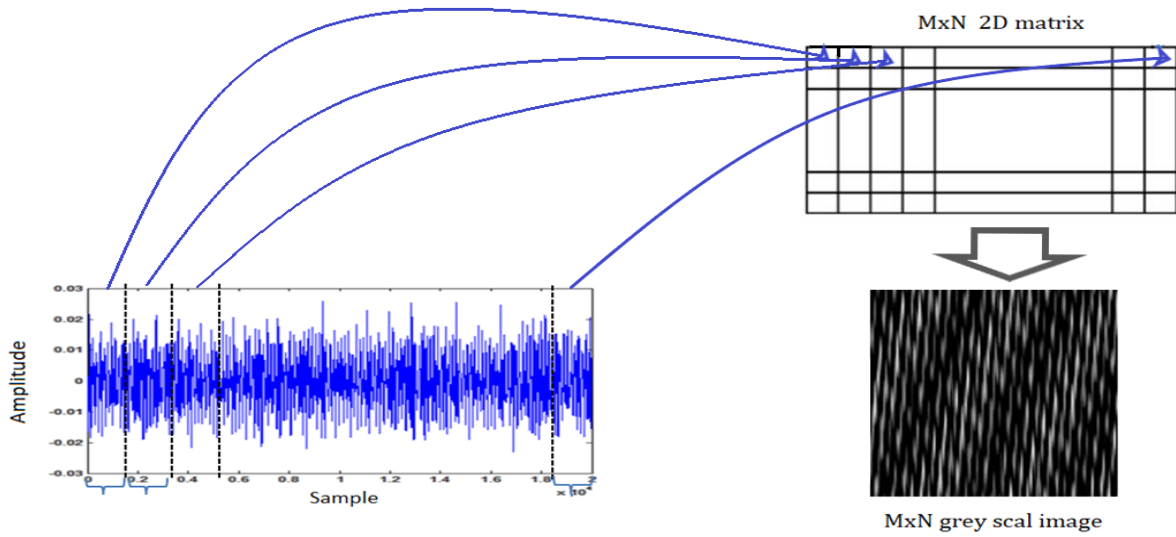


Figure III.3 : Conversion signal 1D à une image

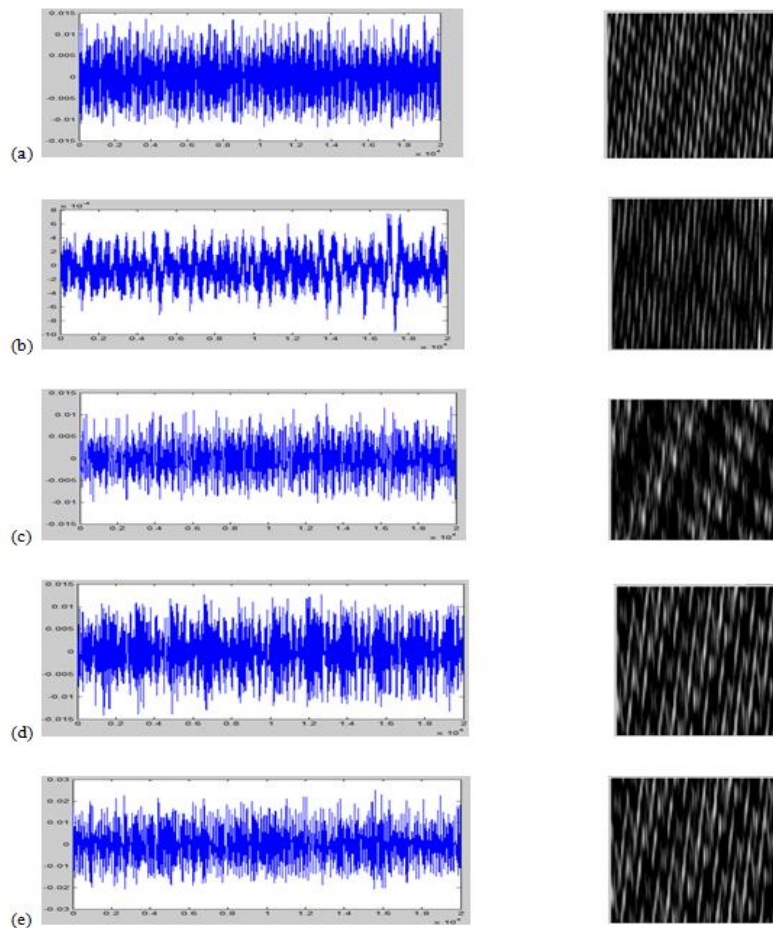


Figure III.4 : Exemples de conversion de signaux 1D en images 2D en niveau de gris : (a) moteur sain, (b) une barre rotorique cassée, (c) deux barres rotorique cassées, (d) trois barres rotorique cassées et (e) défauts de roulement.

La figure III.4 montre les cinq signaux acoustiques issus des cinq moteurs utilisés dans l'expérimentation. A chaque signal est associée une image qui est le résultat de la conversion d'un signal 1D vers un signal 2D. On remarque que les textures de ces images sont différentes ce qui justifie l'utilisation des méthodes d'analyse de la texture LBP et GLCM.

III.3.2 Explications des principales étapes

- **Segmentation** : La division en segments de longueur fixe k permet de structurer le signal 1D en une matrice 2D.
- **Normalisation** : Adapter les valeurs à l'échelle 0-255 est nécessaire pour représenter les données sous forme d'image.
- **Conversion en uint8** : Cela permet de manipuler efficacement les données d'image dans MATLAB.

Algorithme : Conversion d'un signal acoustique en signal 2D

Étape 1 : Charger les données

1. Charger les données à partir d'un fichier .mat contenant les signaux acoustiques.

Entrée : Fichier *bearing_defects_near.mat*.

Sortie : Matrice M contenant les données du signal.

Étape 2 : Extraction du signal souhaité

2. Sélectionner une colonne spécifique du signal

3. **Entrée** : Matrice M .

Sortie : Vecteur S contenant le signal extrait.

Étape 3 : Division du signal en segments

3. Définir une longueur de segment k (ici $k=150$) et initialiser des variables :

- Une matrice I pour stocker les segments de signal.

- Un compteur it pour indexer les segments.

4. Découper le signal S en segments de longueur k :

- Parcourir S par pas de k .

- Pour chaque segment y , ajouter les données dans une colonne de I .

Entrée : Signal S , longueur k .

Sortie : Matrice I contenant les segments.

Étape 4 : Normalisation et conversion en image

5. Convertir la matrice I en une image 2D :

Normaliser les valeurs de I entre 0 et 255 :

Image= $I \times 255 / \max(\max(I))$

Convertir Image en format entier 8 bits (uint8).

Entrée : Matrice I.

Sortie : Image normalisée Image.

Étape 5 : Visualisation de l'image

6. Afficher l'image générée avec un outil d'inspection comme imtool.

Code Convertir Signal 1D vers 2D

ENTRÉES :

S : Signal 1D (vecteur)

k : Longueur des segments

SORTIES :

Image2D : Matrice 2D normalisée (image)

VARIABLES :

l : Longueur du signal

it : Compteur d'itérations

I : Matrice de segments

y : Segment extrait

maxVal : Valeur maximale dans la matrice

ImageNorm : Matrice normalisée

DÉBUT

l ← longueur(s) // Déterminer la taille du signal

```
it ← 0 // Initialiser le compteur
I ← MatriceVide(k, ⌊l / k⌋) // Initialiser la matrice des segments
POUR i ← 1 JUSQU'À (l - k) PAS k FAIRE
    it ← it + 1
    y ← s[i : (i + k - 1)] // Extraire un segment
    I[:, it] ← y // Stocker dans la colonne correspondante
FIN POUR
maxVal ← max(I) // Trouver le maximum
ImageNorm ← (I × 255) / maxVal // Normaliser les valeurs
Image2D ← uint8(ImageNorm) // Convertir en type entier
IMPRIMER Image2D // Visualiser l'image
FIN
```

III.3.3 Prétraitement

Le prétraitement est une étape importante dans le traitement d'image qui permet de préparer l'image pour l'analyse et l'extraction d'attributs qui vont permettre de discriminer les images à caractère défectueux.

III.3.3.1 Filtrage des images

Le filtre médian est couramment utilisé pour atténuer le bruit dans les images en supprimant les artefacts indésirables. Son principe repose sur un algorithme simple : chaque pixel de l'image est échangé par la valeur médiane des pixels situés dans son voisinage immédiat. Concrètement, pour chaque pixel P de l'image originale, on considère les valeurs des pixels dans une fenêtre locale de taille 3×3 centrée sur P, et on attribue à ce pixel la valeur médiane de ce groupe. Le résultat est une nouvelle image, de même taille, mais avec moins de bruit. Les pixels du voisinage sont triés par ordre croissant de leurs valeurs numériques. La valeur médiane correspond alors à celle du pixel situé au centre de la liste triée. Cette valeur est attribuée au pixel P dans l'image filtrée [82].

Par exemple, si l'on considère un ensemble de neuf pixels, et que le pixel central possède une valeur de 732, nettement différente de celles de ses voisins, cette valeur est jugée incohérente.

Le filtrage médian permettra alors de la remplacer par une valeur plus représentative du voisinage, réduisant ainsi le bruit local.

| | | | | |
|----|----|-----|----|----|
| 23 | 54 | 27 | 87 | 62 |
| 49 | 39 | 32 | 65 | 17 |
| 71 | 83 | 732 | 49 | 94 |
| 59 | 78 | 51 | 20 | 83 |
| 29 | 50 | 67 | 91 | 89 |
| 76 | 88 | 38 | 44 | 62 |

| | | | | | | | | |
|----|----|----|----|----|----|----|----|-----|
| 20 | 32 | 39 | 49 | 51 | 65 | 78 | 83 | 732 |
|----|----|----|----|----|----|----|----|-----|

Figure III.5 : fonctionnement du filtre médian

Le filtre médian examine les valeurs des pixels dans un voisinage de taille 3×3 autour du pixel central. Ces valeurs sont ensuite triées par ordre croissant. La valeur médiane c'est-à-dire celle située au centre de la liste triée est alors sélectionnée. Dans cet exemple, la valeur médiane est 51. Ainsi, la valeur aberrante du pixel central, initialement égale à 732, sera remplacée par 51, ce qui permet de réduire efficacement le bruit dans l'image.

III.3.3.2 Égalisation d'histogramme

L'égalisation d'histogramme est une technique utilisée dans le traitement d'images pour améliorer le contraste d'une image en répartissant les valeurs d'intensité les plus fréquentes. Essentiellement, elle ajuste l'histogramme de l'image de manière à ce que les valeurs d'intensité soient plus uniformément réparties, ce qui permet de mieux distinguer les caractéristiques de l'image [83].



Figure III.6 : (a) Image original
(b) Image avec égalisation d'histogramme

La méthode LBP s'appuie sur les détails de la texture d'une image. L'égalisation d'histogramme garantit que les variations subtiles de la texture, qui pourraient indiquer des défauts (par exemple, des défauts de roulement, des déséquilibres du rotor), sont amplifiées et plus facilement capturées par ces méthodes d'analyse de la texture.

III.4 Fondements de l'histogramme LBP

L'histogramme LBP (Local Binary Pattern) est un descripteur de texture largement utilisé dans le diagnostic en général et le diagnostic des machines électriques en particulier [64]. Il est basé sur la comparaison locale des niveaux de gris des pixels d'une image. Le code $LBP_{1,8}$ et $LBP_{1,8}^{riu2}$ attribue à chaque pixel de l'image une valeur binaire en fonction de la comparaison de son niveau de gris avec les niveaux de gris de ses voisins. Le choix des paramètres R et P sont fixés à 1 et 8. Cela correspond à la configuration classique introduite dans les travaux originaux de Ojala et al. [65], qui ont proposé le LBP comme descripteur de texture robuste et efficace. Cette configuration permet de capturer les motifs texturaux locaux dans un voisinage immédiat d'un pixel central, ce qui est souvent suffisant pour représenter les textures des images dans de nombreuses applications. Cette configuration est optimale pour un bon compromis entre richesse des informations texturales et simplicité de calcul.

Lorsque les images générées à partir des signaux acoustiques sont relativement petites, un rayon ($R=1$) permet de capturer les motifs locaux sans diluer les informations importantes. Les travaux de Pietikäinen et al. [66] montrent que des rayons plus grands sont mieux adaptés pour des images contenant des structures plus larges, mais ne sont pas nécessaires pour des textures fines ou des détails locaux.

Des études antérieures, comme celles de [4], [84], [85], ont également utilisé $R=1$, $P=8$ pour le diagnostic des défauts dans les moteurs électriques, notamment pour les roulements et les barres cassées. Ces paramètres ont démontré leur efficacité dans la capture des variations texturales caractéristiques des différents états de fonctionnement.

Après le calcul des codes $LBP_{1,8}$ et $LBP_{1,8}^{riu2}$, un histogramme est construit pour représenter la distribution spatiale des valeurs LBP dans l'image, ce qui permet de capturer les caractéristiques de texture locales.

Pour chaque pixel (x_c, y_c) , l'image d'entrée I de taille $M \times N$ ($x_c \in \{0, 1, 2, \dots, N-1\}$, $y_c \in \{0, 1, 2, \dots, M-1\}$) est représenté par un histogramme LBP H utilisant l'équation(III.1) et l'équation(III.2) L'histogramme résultant H est le descripteur LBP de cette image. Ainsi, chaque image est représentée par un histogramme LBP qui est ensuite utilisé comme vecteur de caractéristiques pour la classification :

$$H(k) = \sum_i \sum_j f(LBP_{P,R}(i,j), k), \quad k \in [0, K] \quad (III.1)$$

$$f(x, y) = \begin{cases} 1 & \text{si } x = y \\ 0 & \text{sinon} \end{cases} \quad (III.2)$$

Où K est la valeur maximale du motif LBP.

Ce descripteur est efficace, simple à calculer et présente une bonne discrimination des textures, ce qui en fait un outil populaire pour l'analyse d'image.

III.4.1 Evaluation de l'histogramme LBP

Avantages de l'histogramme LBP dans le diagnostic des moteurs asynchrones

- * **Simplicité et efficacité de calcul:** Le calcul des motifs locaux binaires et leur représentation sous forme d'histogrammes sont rapides et peu coûteux en termes de ressources. Cela rend la méthode adaptée à des applications en temps réel dans des environnements industriels.
- * **Robustesse aux variations d'intensité:** Les histogrammes LBP sont peu sensibles aux variations globales de l'éclairage ou de l'intensité des images, ce qui est crucial pour analyser des signaux acoustiques ou visuels soumis à des conditions changeantes.
- * **Bonne discrimination des défauts locaux:** Les LBP capturent efficacement les variations locales de texture, permettant de distinguer des états de défaut spécifiques,

comme les barres cassées ou les défauts de roulement, grâce à des différences significatives dans les motifs binaires.

- * **Flexibilité d'intégration avec des classificateurs** : Les histogrammes LBP peuvent être facilement intégrés dans des algorithmes de classification comme les SVM, KNN ou les réseaux de neurones, offrant une grande adaptabilité pour différentes tâches de diagnostic [65-68].

Inconvénients de l'histogramme LBP dans le diagnostic des moteurs asynchrones

- * **Sensibilité au bruit**: Les histogrammes LBP peuvent être influencés par le bruit présent dans les images, notamment dans les environnements industriels bruyants. Les variations aléatoires des pixels peuvent générer des motifs binaires erronés, affectant ainsi la qualité des descripteurs [66].
- * **Perte d'informations globales**: Les LBP se concentrent sur des motifs locaux, ce qui peut entraîner une perte d'informations sur les structures globales de l'image, essentielles pour certains types de défauts [67], [68].
- * **Incapacité à capturer les textures complexes** : Les LBP standard peuvent avoir des difficultés à représenter des textures complexes ou non uniformes, qui sont parfois caractéristiques de certains défauts [68].
- * **Dépendance à la résolution de l'image** : La méthode peut être affectée par la résolution des images générées à partir des signaux acoustiques. Une résolution trop faible peut réduire la qualité des descripteurs extraits [66].

III.4.2 Extraction des Caractéristiques via l'histogramme de LBP

Les histogrammes LBP sont souvent utilisés comme vecteurs de caractéristiques pour des algorithmes de classification, tels que les machines à vecteurs de support (SVM), les réseaux de neurones artificiels (ANN) et les k-plus proches voisins (KNN). Ces classificateurs sont entraînés sur des histogrammes LBP pour chaque type de défaut, permettant de détecter et d'identifier automatiquement les défauts dans les machines électriques.

Il existe plusieurs exemples qui ont utilisé la méthode des histogrammes LBP pour la détection des défauts de roulement dans les moteurs en utilisant des classificateurs SVM, en montrant que les LBP permettent une bonne classification des états de défauts dans des environnements bruités [13].

Shahriar et al [4] ont utilisé l'histogramme LBP comme vecteur de caractéristique sur des défauts de roulement et des défauts d'excentricités et de barre cassées en utilisant les SVM multi-classe SVM. On peut citer aussi les résultats de Cao et al [86] qui joignent leurs travaux sur le diagnostic des défauts de roulement, défauts de bague interne et défauts de bague externe en utilisant l'histogramme LBP.




Image LBP pour le défaut une barre cassée




Image LBP pour le défaut deux barres cassées




Image LBP pour le défaut trois barres cassées




Image LBP pour le de roulement




Image LBP pour un moteur sain

Histogramme $LBP_{1,8}$

histogramme $LBP_{1,8}^{riu2}$

Figure III.7 : Histogramme LBP des images de signaux acoustiques avec défaut.

Les résultats obtenus à partir des histogrammes $LBP_{1,8}$ et $LBP_{1,8}^{riu2}$ mettent en évidence la possibilité de distinguer un moteur en bon état de fonctionnement des moteurs présentant des défauts. En effet, pour chaque type de défaut étudié dans le cadre de cette expérimentation, des variations spécifiques dans l'amplitude de certains motifs ont été observées. Ces variations se manifestent par des différences significatives dans les amplitudes des motifs des histogrammes $LBP_{1,8}$ et $LBP_{1,8}^{riu2}$, lorsqu'on les compare à celles des motifs correspondants dans l'histogramme d'un moteur sain. Ces observations suggèrent que chaque défaut génère des signatures caractéristiques au niveau des motifs texturaux, ce qui peut permettre une discrimination efficace entre un moteur sain et un moteur défectueux, indépendamment de la nature du défaut. Cette capacité à différencier les états du moteur renforce l'intérêt de l'utilisation des descripteurs basés sur LBP pour le diagnostic des machines électriques.

III.5 Conclusion

Ce chapitre présente en détail les différentes étapes de notre méthodologie expérimentale, allant de l'acquisition des signaux acoustiques provenant de moteurs sains et défectueux à leur conversion en images. Les étapes de prétraitement des images, ainsi que l'analyse des textures via les histogrammes LBP, sont également abordées. Les résultats incluent une illustration des images générées et de leurs histogrammes LBP respectifs, mettant en évidence les différences caractéristiques entre les moteurs sains et défectueux.

Dans le prochain chapitre, nous détaillerons les performances des modèles de classification utilisés, notamment les SVM, KNN et réseaux de neurones, pour évaluer leur capacité à discriminer les différents états de fonctionnement des moteurs à partir des descripteurs LBP.

Chapitre IV : Diagnostic des machine asynchrones par application de la méthode LBP et GLCM

IV.1 Introduction

Traditionnellement, le diagnostic des machines asynchrones repose sur l'analyse de signaux électriques et vibratoires. Cependant, l'essor des technologies de traitement du signal et d'analyse d'image a ouvert de nouvelles perspectives pour améliorer la précision et la fiabilité des diagnostics. Dans ce contexte, l'utilisation des signaux acoustiques émis par les moteurs représente une approche innovante et prometteuse. En effet, les signaux acoustiques contiennent des informations précieuses sur l'état de santé de la machine, et leur analyse permet de détecter des anomalies spécifiques à des types de défauts particuliers.

Ce chapitre se concentre sur l'application des méthodes de traitement d'image GLCM (Gray-Level Co-occurrence Matrix) et LBP (Local Binary Patterns) pour le diagnostic des défauts des machines asynchrones à partir des signaux acoustiques. La méthode GLCM est utilisée pour extraire les caractéristiques texturales des images obtenues en convertissant les signaux acoustiques, tandis que la méthode LBP permet d'analyser ces caractéristiques pour en déduire des informations pertinentes sur l'état de la machine.

L'objectif de ce chapitre est de démontrer l'efficacité des méthodes GLCM et LBP dans l'identification des défauts des machines asynchrones, en comparant leurs performances avec différentes techniques de classification.

IV.2 Utilisation de GLCM (Grey-Level Co-occurrence Matrix) dans le diagnostic des machines asynchrones

La méthode GLCM est largement utilisée pour extraire des caractéristiques texturales à partir d'images. Elle quantifie les relations spatiales entre les pixels d'une image, permettant l'extraction de caractéristiques comme l'homogénéité, la variance et l'entropie [87]. Chaque caractéristique permet de décrire une spécificité et une particularité d'une image ce qui permet de discriminer une image d'une autre. Ces caractéristiques sont donc utilisées comme des descripteurs pour identifier les conditions normales ou défailantes des machines électriques. Elles sont ensuite exploitées dans des algorithmes de classification. Uddin J et al [88] ont utilisé des signaux acoustiques sur des défauts pour identifier des défauts de roulements. Les auteurs ont utilisé la matrice de cooccurrence pour extraire les caractéristiques contraste, énergie et homogénéité. Jang WC et al [89] propose une approche de la représentation bidimensionnelle (2D) des signaux de vibration pour la classification des défauts de

roulement d'un moteur à induction. Ils ont notamment utilisé la matrice de cooccurrence de niveau gris (GLCM) pour calculer différents descripteurs de texture tels que le contraste, la corrélation, l'énergie et l'homogénéité [89].

IV.3 Analyse de la texture par LBP et GLCM

L'intégration des méthodes LBP (Local Binary Pattern) et GLCM (Gray-Level Co-Occurrence Matrix) pour l'analyse de texture a été explorée avec succès dans plusieurs domaines du diagnostic médical. Par exemple, une étude sur la classification des tumeurs cérébrales a montré que la combinaison de ces deux méthodes améliore significativement la capacité discriminative des caractéristiques extraites, facilitant une classification plus précise des tumeurs [90]. De même, pour l'analyse des IRM cérébrales, l'approche combinée a permis d'extraire des caractéristiques locales et globales, atteignant une précision de 98% dans la différenciation des images normales et anormales [91]. De même, l'analyse des caractéristiques texturales du muscle droit fémoral basée sur LBP et GLCM a permis de différencier efficacement les patients atteints de sarcopénie, démontrant la robustesse de cette approche face aux variations des conditions d'acquisition des images [92]. Ces travaux soulignent le potentiel de cette combinaison pour capturer des informations texturales complexes et discriminatives et son utilisation pour le diagnostic des machines électriques.

IV.3.1 Combiner $LBP_{1,8}$ et $LBP_{1,8}^{riu2}$ avec GLCM

Les méthodes LBP et GLCM sont combinées pour extraire des caractéristiques de texture à l'aide d'images 2D obtenues par conversion du signal acoustique 1D. La méthode LBP est utilisée sur les images pour analyser la texture est générer une matrice du code $LBP_{1,8}$ et une autre pour la variante $LBP_{1,8}^{riu2}$. Par la suite la matrice de cooccurrence GLCM est utilisée pour extraire les caractéristiques texturales, à savoir l'énergie, la corrélation, l'homogénéité, la moyenne et l'entropie. La classification est effectuée par les classificateurs MCSVM multiclasse, un contre tous (One Against All) OAA, K-NN (K-voisins les plus proches) et ANN (réseaux de neurones artificiels).

IV.3.2 Combinaison de GLCM avec la variante KLTP

La même opération est répéter avec le motif ternaire local LTP, qui est appliqué avec le filtre de Kirsch pour donner un nouveau operateur KLTP (Kirsch Local Ternary Patern).

L'opérateur de Kirsch est un filtre de détection de contours linéaire utilisé en traitement d'image pour identifier les bords dans une image. Il fait partie des opérateurs de détection de contours basés sur les masques directionnels (3x3), qui est appliqué à chaque pixel d'une image pour calculer la valeur du gradient dans huit directions différentes (nord, nord-est, est, sud-est, sud, sud-ouest, ouest, et nord-ouest). Il calcule la différence de luminosité dans plusieurs directions pour accentuer les variations significatives (les contours). Ce filtre utilise un ensemble de masques convolutifs pour détecter les bords selon les huit directions principales [93].

$$\begin{array}{l}
 \text{Nord} = \begin{bmatrix} +5 & +5 & +5 \\ -3 & 0 & -3 \\ -3 & -3 & -3 \end{bmatrix} \\
 \text{SW} = \begin{bmatrix} -3 & -3 & -3 \\ +5 & 0 & -3 \\ +5 & +5 & -3 \end{bmatrix} \\
 \text{Est} = \begin{bmatrix} -3 & -3 & +5 \\ -3 & 0 & +5 \\ -3 & -3 & +5 \end{bmatrix} \\
 \text{NW} = \begin{bmatrix} +5 & +5 & -3 \\ +5 & 0 & -3 \\ -3 & -3 & -3 \end{bmatrix} \\
 \text{Sud} = \begin{bmatrix} -3 & -3 & -3 \\ -3 & 0 & -3 \\ +5 & +5 & +5 \end{bmatrix} \\
 \text{NE} = \begin{bmatrix} -3 & +5 & +5 \\ -3 & 0 & +5 \\ -3 & -3 & -3 \end{bmatrix} \\
 \text{West} = \begin{bmatrix} +5 & -3 & -3 \\ +5 & 0 & -3 \\ +5 & -3 & -3 \end{bmatrix} \\
 \text{SE} = \begin{bmatrix} -3 & -3 & -3 \\ -3 & 0 & +5 \\ -3 & +5 & +5 \end{bmatrix}
 \end{array}$$

L'opérateur KLTP est calculé en soumettant les images en niveaux de gris à un ensemble d'opérateurs de Kirsch à noyau, le pixel central ayant une valeur d'intensité de zéro. Deux matrices sont obtenues avec les codes supérieur KLTP_I et inférieur KLTP_u, qui sont utilisées par la matrice de cooccurrence pour extraire les mêmes caractéristiques, et les vecteurs résultants sont concaténés pour obtenir un seul vecteur caractéristique. La figure IV.1 montre le résultat de l'application du filtre de Kirsch sur une image représentant le défaut trois barres cassées.

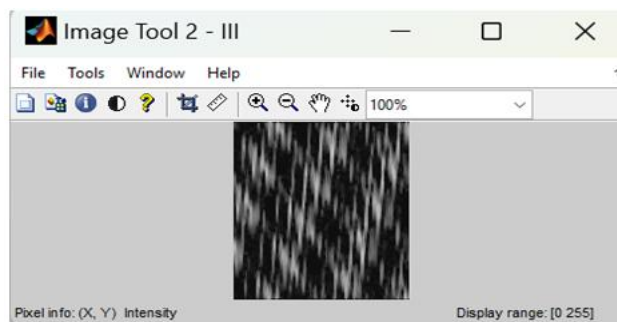


Image de trois barres cassées

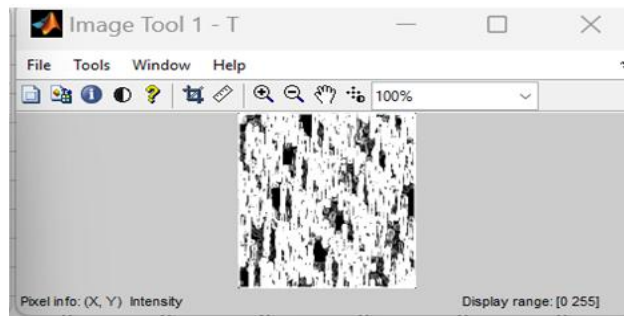


Image soumise au filtre de Kirsch

Figure IV.1 : Image d'un signal defectueux soumise au filtre de Kirsh.

Les images de la figure IV.2 représentent le résultat de calcul du code LTP après l'application du filtre de Kirsch.

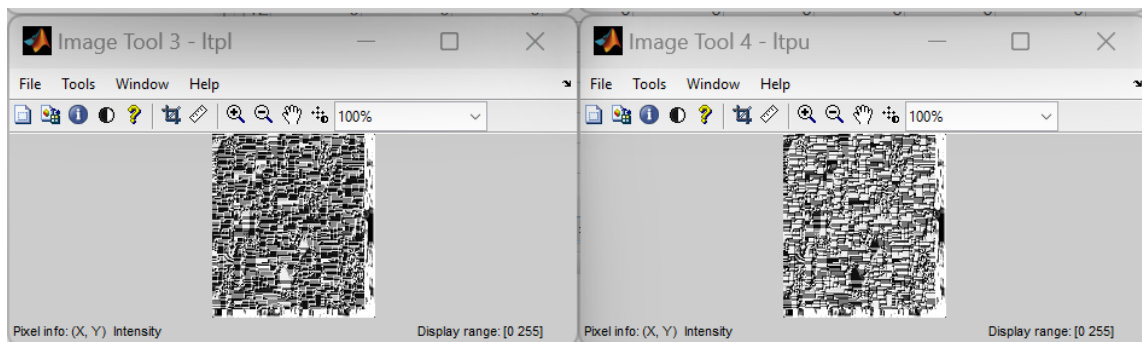


Image représentant l'operateur KLTPi

Image représentant l'operateur KLTPu

Figure IV.2 : Processus de génération des images KLTPi et KLTPu.

La figure IV.3 montre les étapes de notre approche :

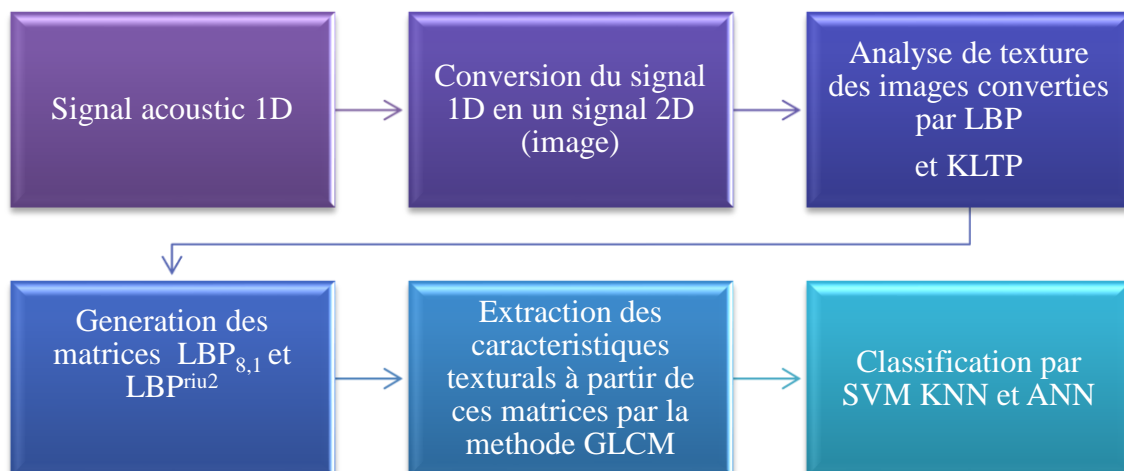


Figure IV.3 : Schéma de la méthodologie suivie.

Les méthodes telles que GLCM ou LBP s'appuient sur les détails de la texture d'une image. L'égalisation d'histogramme garantit que les variations subtiles de la texture, qui pourraient indiquer des défauts (par exemple, des défauts de roulement, des déséquilibres du rotor), sont amplifiées et plus facilement capturées par ces méthodes d'analyse de la texture.

IV.4 Extraction des caractéristiques

Les images en niveaux de gris obtenus après conversion pour les défauts donnés sont d'abord analysées en calculant le code LBP_{R,P}. La matrice LBP 2D est calculée pour le LBP basique et ces deux variantes LBP_{1,8}^{riu2} et KLTP_{1,8}, puis les cinq caractéristiques décrites auparavant sont extraites à l'aide de la méthode GLCM. Ainsi, un vecteur de caractéristiques est construit avec cinq caractéristiques et en utilisant 60 échantillons de chaque défaut ; nous obtenons donc une matrice de 300×5.

La figure IV.4 montre deux images la première est le résultat de conversion du signal acoustique 1D vers le signal 2D, la deuxième est l'image générée à partir du code LBP_{1,8}.

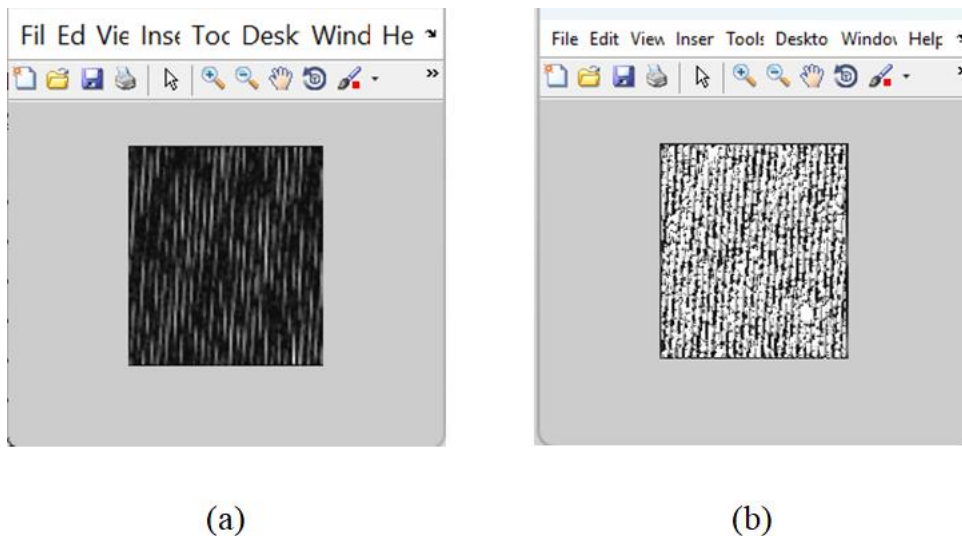


Figure IV.4 : Génération du code LBP

IV.5 Classification

La classification est réalisée à l'aide du classificateur SVM multiclasse (MCSVM). La fonction Kernel est utilisée en choisissant la fonction gaussienne à base radiale pour s'assurer que la classification n'est pas linéaire entre les différents défauts. En conséquence, un vecteur

de caractéristiques est construit en utilisant cinq caractéristiques et soixante échantillons pour chaque erreur, ce qui donne une matrice de 300x5.

En fonction du nombre de classes, des classificateurs SMOVA (SVM un contre tous) binaires sont construits. Chaque classificateur isole une classe des autres afin de réduire l'analyse à un problème à deux classes [94].

IV.5.1 Algorithme : Classification SVM "Un contre Tous"

1. Chargement des données

- Charger les caractéristiques texturales des images GLCM et leurs labels correspondants.
- Les données sont divisées en ensembles d'entraînement (X, Y) et de test (X_t, Y_t).

2. Exploration des données

- Visualiser les données d'entraînement dans un graphique 2D en utilisant deux caractéristiques texturales (énergie et corrélation).

3. Création des modèles SVM "Un contre Tous"

- Identifier les classes uniques dans les données d'entraînement.
- Pour chaque classe :
 - Créer des étiquettes binaires où la classe courante est positive et toutes les autres sont négatives.
 - Entraîner un modèle SVM avec une fonction noyau RBF (Gaussian Radial Basis Function).

4. Classification des données de test

- Créer une grille de points pour visualiser les régions de classification.
- Calculer les scores pour chaque modèle SVM sur les données de test et enregistrer les prédictions.

5. Évaluation des modèles

- Définir les étiquettes binaires pour chaque classe.
- Comparer les prédictions du modèle avec les étiquettes binaires réelles pour chaque classe.
- Calculer la précision (accuracy) pour chaque classe et la précision globale moyenne.

6. Affichage des résultats

- Afficher les précisions par classe et la précision globale.

IV.5.2 Algorithme du classificateur KNN

On a utilisé dans ce travail un classificateur KNN avec les paramètres suivant :

Distance Euclidienne Normalisée : Permet de prendre en compte les échelles différentes des caractéristiques en normalisant les données avant de calculer les distances.

Validation Croisée : Évalue la robustesse du modèle en simulant des ensembles d'entraînement et de test multiples.

KNN avec 3 Voisins : L'utilisation d'un petit nombre de voisins réduit le risque d'un sur-ajustement tout en capturant des informations locales pertinentes.

❖ Chargement des données

- Charger les données de caractéristiques
- Extraire les caractéristiques pour les utiliser comme entrée (x) et les labels (Y) comme sortie.

❖ Construction du modèle KNN

- Créer un modèle KNN en définissant :
 - Le nombre de voisins (NumNeighbors = 3).
 - La distance utilisée pour les calculs (Distance = seuclidean, distance euclidienne normalisée).

❖ Évaluation du modèle sur les données d'entraînement

- Calculer la perte de re-substitution en utilisant la fonction MATLAB (*resubLoss*), c'est-à-dire la fraction d'observations mal classées sur l'ensemble d'entraînement. Cette fonction évalue l'erreur de classification du modèle en utilisant les mêmes données qui ont servi à l'entraîner. Elle retourne une mesure de la perte.

❖ Validation croisée

- Effectuer une validation croisée avec $kfold = 7$ pour diviser les données en 7 sous-ensembles.
- Calculer la perte moyenne par pli de validation croisée avec la fonction MATLAB (*kfoldLoss*).

La fonction *kfoldLoss* évalue la performance d'un modèle en simulant son comportement sur de nouvelles données, contrairement à *resubLoss* qui utilise les données d'entraînement.

Elle fonctionne en :

- Divisant les données en k sous-ensembles (folds)
- Entraînant le modèle sur (k-1) folds ou parties et testant sur le fold restant, puis en répétant cela k fois.
- Calculant la moyenne des pertes obtenues sur chaque fold.

❖ Classification d'un nouvel échantillon

- Charger les caractéristiques du nouvel échantillon (new ou testlbp).
- Utiliser la fonction *knnsearch* pour :
 - Trouver les indices et distances des 3 voisins les plus proches dans les données d'entraînement.
- Classifier le nouvel échantillon en fonction de la majorité des classes des voisins les plus proches.

❖ Prédiction avec le modèle KNN

- Utiliser la fonction (*predict*) pour prédire directement les classes des nouveaux échantillons en appliquant le modèle KNN entraîné.

IV.5.3 Réseaux de neurones

Le réseau neurone artificiel est également utilisé dans ce travail à l'aide de (nctool) de MATLAB qui nous a permis de faire la classification pour classer le vecteur de caractéristiques. Il existe plusieurs types de réseaux neuronaux. Dans le cadre de cette étude, nous avons utilisé un réseau neuronal feed-forward avec rétro propagation. Le réseau se compose de deux couches : une couche de sortie avec cinq neurones de sortie et une couche cachée avec vingt neurones cachés. La fonction sigmoïdale active la couche cachée.

IV.6 Discussion des résultats

Le code $LBP_{1,8}$ et le motif uniforme $LBP_{1,8}^{riu2}$ ont été employés en utilisant un rayon (R) de 1 et 8 voisins dans les deux cas. Il a été démontré que la matrice de cooccurrence des niveaux de gris (GLCM) est une approche statistique utile pour extraire les caractéristiques des

images. Par conséquent, dans notre approche nous avons pu extraire cinq caractéristiques statistiques discriminantes déjà citées, à partir de $LBP_{1,8}$, $LBP_{1,8}^{riu2}$, LTP et KLTP de la matrice obtenue au cours du processus d'analyse des motifs. Le vecteur de caractéristiques de dimensions 300×5 , résultant de ce processus est utilisé comme entrée pour les classificateurs MCSVM, K-NN et ANN. L'ensemble de données a été divisé en 75 % comme données d'entraînements, comprenant 225 échantillons, et 25 % pour le test, comprenant 75 échantillons de test. Les classes à discriminer dans ce travail sont illustrées dans la figure suivante.

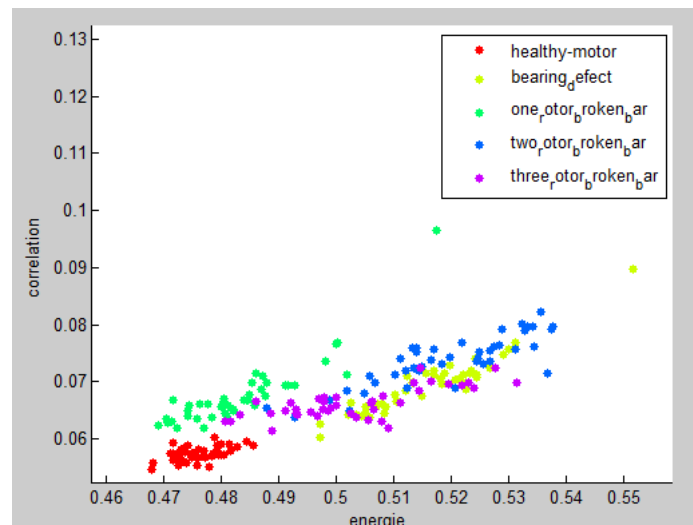


Figure IV.5 : Distribution des cinq classes

Les résultats obtenus dans cette études pour les méthodes $GLBP_{1,8}$, $GLBP_{1,8}^{riu2}$, $GLTP_{1,8}$, et $GKLP_{1,8}$ sont illustré dans le tableau suivant.

Les résultats obtenus à l'aide de l'histogramme $LBP_{1,8}$ ($HLBP_{1,8}$) sont également présentés dans le but de comparer la performance de notre méthode avec cette approche de référence. Cette comparaison d'élargir la portée de notre étude, mettant en évidence les différences de précision et de robustesse entre les deux approches.

Tableau IV.1 : Résultats de la classification.

| Feature extraction operator | MCSVM | K-NN | ANN |
|-----------------------------|--------|--------|-------|
| $HLBP_{1,8}$ | 86,33% | 82% | 97,3% |
| $GLBP_{1,8}$ | 100% | 97,33% | 100% |

| | | | |
|---------------------|--------|--------|-------|
| $GLBP_{1,8}^{riu2}$ | 98,33% | 86,66% | 97,8% |
| $GLTP_{1,8}$ | 94,66% | 92% | 98,3% |
| $GKLTP_{1,8}$ | 92% | 88,33% | 97,7% |

D'après le tableau IV.11 l'utilisation de la méthode $HLBP_{1,8}$ donne des résultats inférieure par rapport aux autres méthodes proposées ce qui peut être expliquer par le fait que Les LBP se concentrent sur des motifs locaux, ce qui peut entraîner une perte d'informations sur les structures globales de l'image, ce qui appuis la validité de notre approche de combiner cette méthode avec GLCM qui extrait des caractéristiques globales de l'image .

Les résultats obtenus dans ce travail montrent un taux de réussite parfait de 100% avec le $GLBP_{1,8}$ en utilisant les classificateurs MSVM et ANN et 97,3% avec les classificateurs K-NN. Ils ont montré une meilleure précision en utilisant MCSVM, avec 98,33% pour la méthode $GLBP_{1,8}^{riu2}$. Les motifs uniformes sont ceux où il y a au plus deux transitions entre 0 et 1 dans la séquence binaire. Ces motifs sont considéré plus « significatifs » et écarte les autres, ce qui diminue l'espace des caractéristiques. Cette réduction des motifs rend la méthode plus robuste et plus rapide, mais peut entraîner une perte de certains détails de la texture. Cette méthode est aussi conçue pour rendre le descripteur de caractéristiques LBP invariant par rapport aux rotations, ce qui signifie qu'elle traite les textures orientées différemment comme équivalentes. Bien que cela soit bénéfique dans certains contextes (par exemple, lorsque l'orientation de la texture est imprévisible), cela pourrait réduire le pouvoir de discrimination dans les cas où de légères modifications de la texture serai dues à des défauts.

La méthode $GLBP_{1,8}$, qui contient tous les motifs binaires locaux, offre une extraction de caractéristiques plus fine car il ne simplifie pas autant les motifs que le $GLBP_{1,8}^{riu2}$. Cette richesse supplémentaire dans les caractéristiques extraites lui confère un avantage en termes de précision, car il capture plus précisément les variations subtiles dans les textures liées aux défauts.

Pour les méthodes $GLTP_{1,8}$ et $GKLTP_{1,8}$ le résultat est inférieure au deux méthodes précédente. $GKLTP_{1,8}$ combine LTP (Local Ternary Pattern) avec le filtre de Kirsch, un filtre directionnel qui accentue les contours dans huit directions différentes. Bien que ce filtre puisse être efficace pour détecter les contours et les variations fortes dans certaines images, il

peut également amplifier le bruit ou ignorer des détails plus subtils dans les textures. Ces variations plus fines dans la texture sont essentielles pour l'identification de défauts dans les machines électriques. $GLTP_{1,8}$ et $GKLTP_{1,8}$ réduisent la précision en raison de la conversion des motifs en niveaux ternaires ou en filtrant trop agressivement certaines caractéristiques. Cela peut entraîner une perte de détails fins, essentiels pour un diagnostic précis.

Il est clair que le $GLBP_{1,8}$ est le choix optimal pour discriminer les moteurs à induction défectueux en raison de sa simplicité et parce qu'il contient plus d'informations discriminantes.

➤ Comparaison avec d'autres méthodes

Dans des travaux antérieurs [5] portant sur les mêmes données acoustiques, l'auteur a choisi d'utiliser conjointement la méthode des motifs binaires locaux (LBP) et la méthode de la Discrete Wavelet Transform (DWT), puis la méthode de (NCA) Neighbourhood Component Analysis a été appliquée pour sélectionner les caractéristiques les plus pertinentes. Notre approche a permis d'obtenir une meilleure précision dans la classification même en n'utilisant qu'une partie de cet ensemble de données. Notre méthodes $GLBP$ est simples à calculer et ne nécessitent pas d'autres méthodes pour réduire ou sélectionner les caractéristiques les plus significatives ; en effet, l'extraction des caractéristiques avec la méthode $GLCM$ nous permet de réduire le vecteur de caractéristiques en calculant seulement cinq caractéristiques discriminantes. Le tableau IV.2 présente les résultats obtenus par notre méthode par rapport à d'autres dans le même domaine.

Tableau IV.2: Comparaison de notre méthode avec les méthodes utilisées dans la littérature

| Authors and year | Type of signal | methods | Classifier | Fault type | accuracy % |
|-------------------------|----------------|---------|------------|--|------------|
| Shahriar et al 2013 [3] | Vibration | LBP | SVM | bowed rotor, broken R B bearing Rotor unbalance, (misalignment), phase unbalance | 100 |

| | | | | | |
|-------------------------------|----------------------|--|---------------------|--|-----------------------|
| Uddin J et al 2014 [25] | Acoustic emission | GLCM Gabor Filter GNS map | MCSVM | Bearing (inner, outer, and roller) | 100 88,06 90,06 |
| Uddin J et al 2016 [5] | Acoustic emission | Gabor Filter DWT | MCSVM | Bearing (inner, outer, and roller) | 97,22 |
| Glowacz A 2019 [12] | Acoustic emission | SMOFS-22- Multiexpand ed | NN classifier | Bearing, B Rotor Bar faulty ring | 94 97 89,3 |
| Kaplan et al 2020 [30] | vibration | LBP | ANN | bearing for image 70×70 | 100 100 |
| Jha RK et al 2020 [4] | Vibration | Semivariance Kurtosis, Shannon entropy. wave atom transform | ANN | bearings gears | 90.5 99.3 |
| Yaman O 2021 [13] | Acoustic Emission | LBP DWT | MCSVM KNN | Bearing | 99.86 99.93 |
| Our method | Acoustic Emission | LBP GLCM | KNN MCSVM ANN | Bearing | 97,33 100 100 |

IV.7 Conclusion

En résumé, ce chapitre présente une approche novatrice pour le diagnostic des défauts des machines asynchrones, en utilisant des signaux acoustiques et en combinant des techniques avancées de traitement d'image GLCM et LBP et des algorithmes de classification performants ANN et MCSVM. En effet la méthode GLBP a montré une grande efficacité pour discriminer les défauts de roulement et de barres cassées même en présence de bruits. Les attributs calculés à partir de la matrice GLCM (l'énergie, la corrélation, l'homogénéité, la moyenne et l'entropie) ont permis de réduire l'espace de caractéristique et de discriminer les différents défauts introduits. LBP est robuste aux changements d'intensité lumineuse, et particulièrement efficace pour capturer des textures fines, qui peuvent indiquer la présence de défauts ou d'usure dans les machines électriques. La combinaison de ces deux méthodes GLCM et LBP_{1,8} améliore l'extraction des caractéristiques de texture en exploitant les motifs spatiaux locaux (LBP) tout en capturant la distribution spatiale globale de ces motifs (GLCM). Les contributions de cette étude offrent des perspectives prometteuses pour l'amélioration des stratégies de maintenance prédictive et la gestion des équipements industriels.

Conclusion générale

Conclusion Générale

Notre travail explore l'application de techniques avancées d'analyse de texture pour le diagnostic des défauts dans les machines asynchrones à cage d'écureuil. Il met en évidence le potentiel des signaux d'émission acoustique comme source d'information riche pour la détection précoce des anomalies, offrant ainsi une alternative ou un complément aux méthodes traditionnelles basées sur les vibrations et les courants.

Nous proposons une nouvelle approche bidimensionnelle appelée GLBP, qui combine les méthodes LBP (Local Binary Pattern) et GLCM (Gray-Level Co-occurrence Matrix) pour l'analyse de texture.

L'approche GLBP tire parti des avantages des deux méthodes LBP et GLCM. Le code LBP est efficace pour capturer les motifs texturaux locaux et est invariant aux changements monotones de niveaux de gris et à la rotation de l'image. La matrice GLCM permet d'extraire des caractéristiques de texture telles que l'énergie, la corrélation, l'homogénéité, la moyenne et l'entropie, ce qui facilite l'extraction des caractéristiques et réduit la taille du vecteur de caractéristiques.

Notre thèse décrit une méthodologie expérimentale où les signaux acoustiques de moteurs sains et défectueux sont convertis en images. Ces images sont ensuite analysées à l'aide de la méthode GLBP, et les caractéristiques extraites sont utilisées comme entrées pour les algorithmes d'intelligence artificielle, tels que les MCSVM multi-classe, K-NN et ANN.

Les résultats expérimentaux démontrent l'efficacité de l'approche GLBP pour la détection des défauts de rotor et de roulements. La combinaison de LBP et GLCM permet d'obtenir des taux de classification élevés, surpassant les méthodes basées uniquement sur LBP.

Les principaux points forts de ce travail sont les suivants :

- Démonstration de la pertinence des signaux acoustiques pour le diagnostic des machines : Les résultats expérimentaux confirment que les signaux acoustiques, souvent négligés dans le passé, peuvent fournir des informations cruciales sur l'état de santé des machines asynchrones. Leur analyse permet de détecter des défauts spécifiques, ouvrant ainsi de nouvelles voies pour la surveillance et la maintenance prédictive.

- Introduction d'une nouvelle méthode d'analyse de texture : La méthode GLBP, fruit de la combinaison judicieuse de LBP et GLCM, se distingue par sa capacité à extraire des caractéristiques à la fois locales et globales, améliorant ainsi la précision du diagnostic. Sa robustesse face aux variations d'illumination et de rotation en fait un outil puissant pour l'analyse d'images complexes et bruitées.
- Validation expérimentale rigoureuse : La méthodologie expérimentale mise en œuvre repose sur un ensemble de données conséquent, comprenant des signaux acoustiques de moteurs sains et défectueux, soumis à différents types de défauts. L'utilisation de techniques de classification robustes, telles que les MCSVM, K-NN et ANN, permet de valider l'efficacité de l'approche GLBP et de démontrer sa supériorité par rapport aux méthodes basées uniquement sur LBP.

Les contributions de cette étude ouvrent des perspectives prometteuses pour l'amélioration des pratiques de maintenance dans l'industrie. La détection précoce des défauts grâce à l'analyse des signaux acoustiques et à la méthode GLBP permet d'anticiper les pannes, de réduire les coûts de maintenance et d'optimiser la disponibilité des équipements. En conclusion, ce document met en avant une approche intégrée et multidimensionnelle du diagnostic des défauts, combinant des techniques de traitement du signal, d'analyse de texture et d'intelligence artificielle. Cette stratégie représente une avancée significative dans le domaine de la maintenance prédictive, offrant des solutions prometteuses pour répondre aux exigences croissantes de l'industrie en termes de fiabilité, d'efficacité et de durabilité. Les perspectives futures incluent l'amélioration des algorithmes de classification et l'évaluation de la robustesse de ces méthodes dans des environnements industriels variés, avec des conditions de fonctionnement encore plus complexes.

L'originalité de cette thèse

Elle réside dans le développement d'une approche innovante pour le diagnostic des défauts des machines asynchrones, exploitant les signaux acoustiques et combinant des techniques avancées d'analyse de texture issues du traitement d'image, à savoir la matrice de cooccurrence des niveaux de gris (GLCM - Gray-Level Co-occurrence Matrix) et les motifs binaires locaux (LBP - Local Binary Patterns). Cette combinaison a conduit à la conception d'une nouvelle approche bidimensionnelle, baptisée GLBP (Gray-Level Binary Patterns), permettant une représentation optimisée des caractéristiques texturales des signaux acoustiques convertis en images.

L'un des aspects fondamentaux de cette contribution est la réduction efficace de l'espace de caractéristiques. Contrairement aux méthodes classiques qui génèrent des vecteurs de caractéristiques de grande dimension, la méthode GLCM permet d'extraire uniquement cinq caractéristiques discriminantes essentielles (énergie, corrélation, homogénéité, moyenne et entropie), minimisant ainsi la complexité computationnelle sans compromettre la précision du diagnostic.

L'approche GLBP a démontré une efficacité remarquable en termes de performance de classification. Les résultats expérimentaux indiquent un taux de classification parfait de 100 % avec les classificateurs MCSVM (Multi-Class Support Vector Machine) et ANN (Artificial Neural Network), et une précision de 97,3 % avec le classificateur K-NN (K-Nearest Neighbour). Ces performances attestent de la robustesse et de la fiabilité de la méthode proposée, même en présence de conditions bruitées ou de variations dans les signaux acoustiques.

Perspectives et développements futurs

Bien que les résultats obtenus soient encourageants, il reste encore des pistes à explorer pour améliorer et étendre l'approche GLBP. Parmi les perspectives envisageables, on peut citer:

- Exploration de nouveaux descripteurs de texture : L'étude d'autres méthodes d'analyse de texture, telles que les transformées en ondelettes, les fractales ou les champs de Markov, pourrait permettre d'extraire des informations complémentaires et d'améliorer la précision du diagnostic.
- Développement d'algorithmes de classification plus performants : L'exploration de nouveaux algorithmes de classification, tels que les réseaux de convolutifs (CNN), pourrait améliorer la précision et la robustesse du diagnostic. L'utilisation des algorithmes génétiques est aussi en perspective.
- Intégration dans des plateformes de maintenance prédictive : L'intégration de l'approche GLBP dans des plateformes de maintenance prédictive permettrait de déployer cette technologie à grande échelle et de faciliter sa mise en œuvre dans les environnements industriels.

Bibliographique

Bibliographie

- [1] Terron-Santiago C, Martinez-Roman J, Puche-Panadero R, Sapena-Bano A. A Review of Techniques Used for Induction Machine Fault Modelling. *Sensors*, 2021; 21(14):4855. <https://doi.org/10.3390/s21144855>.
- [2] Bindu S, Thomas V.V. Diagnoses of internal faults of three phase squirrel cage induction motor — A review. *International Conference on Advances in Energy Conversion Technologies (ICAECT)*, Manipal, India, 2014; pp. 48-54, doi:10.1109/ICAECT.2014.6757060.
- [3] Shahriar MR, Ahsan T, Chong U. Fault diagnosis of induction motors utilizing local binary pattern-based texture analysis. *EURASIP Journal on Image and Video Processing*, 2013; 2013:29. <https://doi.org/10.1186/1687-5281-2013-29>.
- [4] Jha RK, Swami P.D. Intelligent fault diagnosis of rolling bearing and gear system under fluctuating load conditions using image processing technique. *J Mech Sci Technol*, 2020; 34, 4107–4115. <https://doi.org/10.1007/s12206-020-0903-z>.
- [5] Uddin J, Islam R, Kim J, Kim C.H. A two-dimensional fault diagnosis model of induction motors using a gabor filter on segmented images. *International Journal of Control and Automation*, 2016; 9, 11-22. doi: 10.14257/ijca.2016.9.1.02.
- [6] Zhang H, He P, Yang X. Fault Detection Based on Multi-Scale Local Binary Patterns Operator and Improved Teaching-Learning-Based Optimization Algorithm. *Symmetry*, 2015; 7(4):1734-1750. <https://doi.org/10.3390/sym7041734>.
- [7] Wu G, Yan T, Yang G, Chai H, Cao C. A Review on Rolling Bearing Fault Signal Detection Methods Based on Different Sensors. *Sensors*, 2022; 22(21):8330. <https://doi.org/10.3390/s22218330>
- [8] Gao L, Zai F, Su S, Wang H, Chen P, Liu L. Study and Application of Acoustic Emission Testing in Fault Diagnosis of Low-Speed Heavy-Duty Gears. *Sensors*, 2011; 11(1):599-611. <https://doi.org/10.3390/s110100599>.
- [9] Othman MS, Nuawi, M, Mohamed R. Vibration and Acoustic Emission Signal Monitoring for Detection of Induction Motor Bearing Fault. *International Journal of Engineering Research & Technology*, 2015; 4. 924-929.

- [10] Glowacz A, Fault diagnostics of DC motor using acoustic signals and MSAF-RATIO30-EXPANDED, *Arch. Electr. Eng.*, 2016; 65, 733,744, <https://doi.org/10.1515/ae-2016-0051>.
- [11] Glowacz A, Glowacz Z. Diagnosis of the three-phase induction motor using thermal imaging, *Infrared Phys. Infrared Physics and Technology*, 2017; 81,7,16, <https://doi.org/10.1016/j.infrared.2016.12.003>.
- [12] Glowacz A. Fault diagnosis of single-phase induction motor based on acoustic signals, *Mechanical Systems and Signal Processing*, 2019; Volume 117, Pages 65-80,ISSN 0888-3270, <https://doi.org/10.1016/j.ymssp.2018.07.044>.
- [13] Yaman O, An automated faults classification method based on binary pattern and neighborhood component analysis using induction motor, *Measurement*, 2021; Volume 168, 108323, ISSN 0263-2241, <https://doi.org/10.1016/j.measurement.2020.108323>.
- [14] Irhoumah M. Diagnostic des machines électriques par fusion d'informations. Thèse doctorat, Université Lille Nord de France, 2019.
- [15] Nguimpi Langue L. Contribution au dimensionnement optimal d'une machine électrique sans aimant pour la propulsion de véhicules hybrides. Thèse de doctorat, Université de Technologie de Compiègne, 2018.
- [16] Kawthar Alameh. Contribution au diagnostic et a l'analyse de défauts d'une machine synchrone à aimants permanents. Automatique. Thèse de doctorat, Université Normandie, 2017.
- [17] Gréhan S. Contribution à l'étude de moteurs à flux transverse. Thèse de doctorat de l'INP Grenoble, décembre 2003.
- [18] Didier G. Modélisation et diagnostic de la machine asynchrone en présence de défaillances. Thèse de Doctorat, Université Henri Poincaré, Nancy-I, France, 2004.
- [19] Bernot A. Modélisation et optimisation d'une machine électrique homopolaire en poudre de fer. Ecole Doctorale STITS, Paris France, 2015.
- [20] Chahmi A. Identification paramétrique de la machine asynchrone dédiée au diagnostic. These doctorat Université des sciences et technologie d'Oran –MB, 2017.
- [21] Kerszenbaum L, C. F. Landy. The existence of large inter bar currents in the three phase squirrel cage motors with rotor-bar and en-ring faults' *IEEE Transactions on Power Apparatus Systems*, Vol. PAS-103, n°7, pp.1854-1862, July 1984.

- [22] Ceban A. Méthode Globale de Diagnostic des Machines Electriques, Université Lille de Nord de France, 2012.
- [23] International Organization for Standardization, 'ISO 13372:2012 - Condition monitoring and diagnostics of machines – Vocabulary'. ISO, 2012.
- [24] Haje Obeid N. Contribution à la détection des défauts statoriques des actionneurs à aimants permanents Application à la détection d'un défaut inter-spires intermittent et au suivi de vieillissement. Thèse doctorat Université de Lorraine, 2016.
- [25] Elbouchikhi. E, Amirat. Y, Feld. G, Benbouzid. M. Diagnostic et détection des défauts dans les machines asynchrones par des méthodes avancées de traitement du signal. 2018, 91. 43-55.
- [26] M. Ammar, Surveillance et Diagnostic des Défauts des Machines Electriques : Applications aux Moteurs Asynchrones. Thèse Université du 20 Août 1955-Skikda, 2012.
- [27] Fanjason Jacques Ramahaleomiarantsoa. Diagnostic des systèmes à énergies renouvelables de type éolien. Génie mécanique [physics.class-ph]. Université Pascal Paoli; Ecole supérieure polytechnique d'Antsiranana (Madagascar), 2013.
- [28] Ali Ibrahim. Contribution au diagnostic de machines électromécaniques : Exploitation des signaux électriques et de la vitesse instantanée. Traitement du signal et de l'image, Thèse doctorat université Jean Monnet - Saint-Etienne, 2009.
- [29] Moubray, J. Reliability-centered Maintenance. Industrial Press Inc, 1997.
- [30] Abdenour Soualhi. Du diagnostic au pronostic de pannes des entraînements électriques. Thèse doctorat Université Claude Bernard - Lyon I, 2013.
- [31] Jardine A. K. S., Tsang A. H. C. Maintenance, Replacement, and Reliability: Theory and Applications. CRC Press, 2013.
- [32] Lee J, Wu F, Zhao W, Ghaffari M, Liao L, Siegel. Prognostics and health management design for rotary machinery systems—Reviews, methodology and applications. Mechanical Systems and Signal Processing. 2014, 42(1-2), 314-334.
- [33] Antoni, J. Cyclostationarity by examples. Mechanical Systems and Signal Processing, 2009. 23(4), 987-1036.
- [34] Blanke M, Kinnaert M, Lunze J, Staroswiecki M. Diagnosis and Fault-Tolerant Control. Springer, 2016.
- [35] Isermann R. Fault-Diagnosis Systems: An Introduction from Fault Detection to Fault Tolerance. Springer, 2006.

- [36] Chen J, Patton R. J, Robust Model-Based. Fault Diagnosis for Dynamic Systems. Springer, 2012.
- [37] Sahraoui Mohamed. Etude Comparative des Méthodes de Diagnostic des Machines Asynchrones. Thèse université Biskra, 2010.
- [38] Djebala N. Ouelaa, Hamzaoui N. Detection of rolling bearing defects using discrete wavelet analysis. *Meccanica*, 43(3) :339–348, Novembre 2007. ISSN 0025-6455.
- [39] Boukar A, Hamzaoui N. Evaluation des indicateurs de surveillance par analyse vibratoire : Application aux engrenages et roulements. *International Journal of Innovation and Applied Studies*, 2019, Vol. 25 No. 2 Jan. pp. 800-808.
- [40] Razafindrazato G. M. R. Méthodes numériques pour la caractérisation vibratoire de structures complexes. Thèse Université Paris Est Créteil, 2010.
- [41] Hamou Mamar Z. Analyse Temps-Échelle et Reconnaissance des Formes pour le Diagnostic du Système de Guidage d'un Tramway sur Pneumatiques. Thèse doctorat, Université Blaise Pascal - Clermont II, 2008.
- [42] McFadden, P. D., Smith, J. D. Vibration monitoring of rolling element bearings by the high-frequency resonance technique—a review. *Tribology International*, 1984. 17(1), 3-10.
- [43] Antoni J. The spectral kurtosis: A useful tool for characterising non-stationary signals. *Mechanical Systems and Signal Processing*, 2006, 20(2), 282-307.
- [44] Cohen L. *Time-Frequency Analysis*. Prentice Hall, 1995.
- [45] Kawthar Alameh. Contribution au diagnostic et à l'analyse de défauts d'une machine syn- chrone à aimants permanents. Thèse Université de Normandie, 2017.
- [46] Staszewski W. J. et al. Wavelet based compression and feature selection for vibration analysis. *Journal of Sound and Vibration*, 1997, 203(3), 491-507.
- [47] Pietrzak P, Wolkiewicz M. Fault Diagnosis of PMSM Stator Winding Based on Continuous Wavelet Transform Analysis of Stator Phase Current Signal and Selected Artificial Intelligence Techniques. *Electronics* 2023, 12, 1543.
- [48] Kronland-Martinet R, Morlet J, Grossmann A. Wavelet transforms and time-frequency signal analysis. *Proceedings of the IEEE*, 1987. 84(4), 626-636.
- [49] Bouaissi I, Laib A, Rezig A, et al. Frequency bearing fault detection in non-stationary state operation of induction motors using hybrid approach based on wavelet transforms and pencil matrix. *Electr Eng*, 2024.

- [50] Haje Obeid N. Contribution à la détection des défauts statoriques des actionneurs à aimants permanents Application à la détection d'un défaut inter-spires intermittent et au suivi de vieillissement. Thèse doctorat Université de Lorraine, 2016.
- [51] Sklansky J. Image segmentation and feature extraction, *IEEE Transactions on Systems, Man, and Cybernetics*, 8:237–247, 1978.
- [52] Haralick R. M. Statistical and structural approaches to textures, *Proceedings of the IEEE*, 197967(5):786–804.
- [53] Unser M. Description statistique de la texture. Application à l'inspection automatique. Thèse de doctorat, EPFL, Lausanne, Suisse, 1984.
- [54] Paulhac L. Outils et méthodes d'analyse d'images 3D texturées : Application à la segmentation des images échographiques. Thèse de doctorat, École Doctorale Santé, Sciences, Technologies, Tours, 2009.
- [55] Gool L. J. V, Dewaele P, Oosterlinck A. Texture analysis anno 1983. *Computer Vision, Graphics, and Image Processing*, 1985. 29(3):336–357.
- [56] Unser M. Texture classification and segmentation using wavelet frames. *IEEE Transactions on Image Processing*, 1995. 4:1549–1560.
- [57] Julesz B. Experiments in the visual perception of texture. *Scientific American*, 1975. vol. 232, pp. 34-43,
- [58] Houam L. Contribution à l'analyse de textures de radiographies osseuses pour le diagnostic précoce de l'ostéoporose. Thèse doctorat Université d'Orléans; Université 08 mai 45 Guelma (Algérie), 2013.
- [59] Julesz B, Gilbert E. N, Victor J. D. Visual discrimination of textures with identical third-order statistics. *Biological Cybernetics*, 1978. vol. 31, pp. 137-140,
- [60] Tuceryan M, Jain A. K. Texture segmentation using voronoi polygons. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1990. 12:211–216.
- [61] Shanmugam K, Haralick R. M, Dinstein I. H. Textural features for image classification, *IEEE Transactions on Systems, Man and Cybernetics* 1973. 3, 610-621,
- [62] Shahbahrami A, Pham T. A. Bertels K. Parallel implementation of Gray Level Co-occurrence Matrices and Haralick texture features on cell architecture. Springer, 2011.
- [63] Pham T. A. Optimization of Texture Feature Extraction Algorithm, Delf University Of Technology, Holand, 2010.

- [64] Kaur D, Sandhu P. Human Skin Texture Analysis using Image Processing Techniques, International Journal of Science and Research (IJSR), India Online ISSN: 2319-7064, 2013.
- [65] Ojala T, Pietikainen M, Harwood D. A comparative study of texture measures with classification based on feature distributions. *Pattern Recognition*, 1996. 29(1):51–59,
- [66] Pietikäinen M, Hadid A, Zhao G, Ahonen T. *Computer Vision Using Local Binary Patterns*. Computational Imaging and Vision, Springer-Verlag London, 2011.
- [67] Ojala T, Pietikäinen M, Mäenpää T. A Generalized Local Binary Pattern Operator for Multiresolution Gray Scale and Rotation Invariant Texture Classification, Second International Conference on Advances in Pattern Recognition, Rio de Janeiro, Brazil, 2001. 397-406,
- [68] Ojala T, Pietikäinen M, Mäenpää T. Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns. *IEEE Transactions On Pattern Analysis and Machine Intelligence*, 2002. VOL. 24, NO. 7, July
- [69] Jaideva G. C, Andrew, C. K. *Digital Signal Processing Applications in Fundamentals of Wavelets. Theory, Algorithms, and Applications* Hoboken, New Jersey: John Wiley and Sons, Inc, 2011
- [70] Tan X, Triggs B. Enhanced Local Texture Feature Sets for Face Recognition Under Difficult Lighting Conditions. *IEEE Transactions on Image Processing*, 2010; volume. 19, iss. 6, pp. 1635–1650. ISSN 1941-0042. DOI: 10.1109/TIP.2010.2042645.
- [71] Taha H, Rassem, Bee Ee Khoo. Completed Local Ternary Pattern for Rotation Invariant Texture Classification. *The Scientific World Journal*, vol. 2014, Article ID 373254, 10 pages, 2014.
- [72] Mark S. N, Alberto S. A. *Feature extraction and image processing*. Newness, 2002.
- [73] Wannous H. *Classification multi vues de régions couleur application à l'évaluation 3D des plaies chroniques*. Thèse doctorat Université d'Orléans, 2008.
- [74] Zhang S. Challenges in KNN Classification, in *IEEE Transactions on Knowledge and Data Engineering*, Oct. 2022. vol. 34, no. 10, pp. 4663-4675, 1.
- [75] Chou K. C. A novel approach to predicting protein structural classes in a (20-1)-d amino acid composition space. *Proteins*, 1995. 21(4), 319–344
- [76] Vapnik V. *Consistency of Learning Processes. The Nature of Statistical Learning Theory*: Springer New York, 1995, pp. 33-64.

- [77] Rajpoot K. M, Rajpoot N. M. Wavelets and support vector machines for texture classification. Multitopic Conference, 2004. Proceedings of INMIC 2004. 8th International, 2004, pp. 328-333.
- [78] Awad M. Efficient Learning Machines American University of Beirut Rahul Khanna Intel In book, April 2015; (pp.39-66)
- [79] Guermeur Y. SVM Multiclasses, Théorie et Applications, 2007. Laboratoire Lorrain de Recherche en Informatique et ses Applications - UMR 7503. Université Henri Poincaré.
- [80] Jawadekar A, Paraskar S, Jadhav S, Dhole G. Artificial neural network-based induction motor fault classifier using continuous wavelet transform, Systems Science & Control Engineering. 2014; 2:1, 684-690, DOI: 10.1080/21642583.2014.956266.
- [81] Harsh Kukreja¹, Bharath N, Siddesh C S, Kuldeep S. An introduction to artificial neural network. International Journal of Advance Research and Innovative Ideas in Education. 2016; 1. 27-30.
- [82] Ohki M. et al. 3-D Digital Filters. Control Dyn. Syst, 1995.
- [83] Acharya and Ray. Image Processing: Principles and Applications. Wiley-Interscience 2005.
- [84] Garcia Freitas P, Da Eira L.P, Santos S.S, Farias M.C.Q.d. On the Application LBP Texture Descriptors and Its Variants for No-Reference Image Quality Assessment. J. Imaging, 2018, 4, 114.<https://doi.org/10.3390/jimaging4100114>.
- [85] Kohei Arai, Yeni Herdiyeni and Hiroshi Okumura. Comparison of 2D and 3D Local Binary Pattern in Lung Cancer Diagnosis. International Journal of Advanced Computer Science and Applications (IJACSA), 3(4), 2012.
- [86] Cao, Susheng, Xu, Feiyu, Ma Tianchi. Fault diagnosis of rolling bearing based on multiscale one-dimensional hybrid binary pattern. Measurement, 2021. 181. 109552. 10.1016/j.measurement.2021.109552.
- [87] Haralick, R. M., Shanmugam, K., & Dinstein, I. Textural features for image classification. IEEE Transactions on Systems, Man, and Cybernetics, 1973. SMC-3(6), 610-621.
- [88] Uddin J, Rashedul I, Jong-Myon K. Texture Feature Extraction Techniques for Fault Diagnosis of Induction Motor. 2014, Journal of Convergence Information Technology. 5. 15-20.

- [89] Jang WC, Kang M, Kim JM. Fault Classification of an Induction Motor Using Texture Features of Vibration Signals. In: Park, J., Zomaya, A., Jeong, HY., Obaidat, M. (eds) *Frontier and Innovation in Future Computing and Communications. Lecture Notes in Electrical Engineering*, vol 301. Springer, Dordrecht. 2014.
- [90] Dheepak G, J AC, Vaishali D. Brain tumor classification: a novel approach integrating GLCM, LBP and composite features. *Front Oncol.* 2024 Jan 30;13:1248452. doi: 10.3389/fonc.2023.1248452
- [91] Mohamed Wageh, Khalid M. Amin, Ashraf Zytoon, mina Ibrahim. Brain Tumor Detection Based on A Combination of GLCM and LBP Features with PCA and IG. *IJCI. International Journal of Computers and Information*, 10, 2, 2023, 43-53. doi: 10.21608/ijci.2023.205444.1107
- [92] Xinyi Tang BS, Yujia Yang MS, Li Huang MS, Li Qiu MD. The Application of Texture Feature Analysis of Rectus Femoris Based on Local Binary Pattern (LBP) Combined With Gray-Level Co-Occurrence Matrix (GLCM) in Sarcopenia. *Journal of Ultrasound in Medicine*, 2021, Volume41, Issue9, September 2022 Pages 2169-2179
- [93] Venmathi A.R, Ganesh E.N, Kumaratharan N. Kirsch Compass Kernel Edge Detection Algorithm for Micro Calcification Clusters in Mammograms, *Middle East Journal of Scientific Research*, 2016; 24. 1530-1535. DOI: 10.5829/idosi.mejsr.2016.24.04.23384.
- [94] Awad M. *Efficient Learning Machines* American University of Beirut Rahul Khanna Intel In book, April 2015 (pp.39-66) DOI:10.1007/978-1-4302-5990-9_3.

Résumé

Cette thèse propose une approche innovante pour le diagnostic des défauts des machines asynchrones en exploitant les signaux acoustiques et en combinant deux techniques avancées de traitement d'image : la matrice de cooccurrence des niveaux de gris (GLCM) et les motifs binaires locaux (LBP). Cette combinaison a conduit au développement d'une nouvelle approche bidimensionnelle, baptisée GLBP (Gray-Level Binary Patterns), permettant une extraction optimisée des caractéristiques texturales. L'utilisation de la méthode GLCM a permis de réduire l'espace de caractéristiques en sélectionnant uniquement cinq caractéristiques discriminantes, minimisant ainsi la complexité computationnelle.

Les performances de l'approche GLBP ont été évaluées à l'aide de trois classificateurs d'intelligence artificielle : MCSVM (Multi-Class Support Vector Machine), K-NN (K-Nearest Neighbour) et ANN (Artificial Neural Network). Les résultats montrent un taux de classification parfait de 100 % avec MCSVM et ANN, et de 97,3 % avec K-NN, démontrant ainsi la robustesse et la fiabilité de la méthodologie proposée.

Cette étude apporte une contribution significative en combinant des signaux acoustiques et des méthodes d'analyse de texture pour améliorer la précision du diagnostic des défauts dans les machines asynchrones.

Mots clés: Diagnostic des défauts, Méthodes de traitement du signal, Motifs Binaires Locaux, Matrice de Cooccurrence GLCM, Machine Asynchrone.

Abstract

This thesis presents an innovative approach for fault diagnosis in asynchronous machines by leveraging acoustic signals and combining two advanced image processing techniques: the Gray-Level Co-occurrence Matrix (GLCM) and Local Binary Patterns (LBP). This combination led to the development of a new two-dimensional approach called GLBP (Gray-Level Binary Patterns), optimizing the extraction of textural features. The use of the GLCM method helped reduce the feature space by selecting only five discriminative features, thereby minimizing computational complexity.

The performance of the GLBP approach was evaluated using three artificial intelligence classifiers: MCSVM (Multi-Class Support Vector Machine), K-NN (K-Nearest Neighbour), and ANN (Artificial Neural Network). The results show 100% classification accuracy with MCSVM and ANN, and 97.3% with K-NN, demonstrating the robustness and reliability of the proposed methodology.

This study makes a significant contribution by combining acoustic signals and texture analysis methods to enhance the accuracy of fault diagnosis in asynchronous machines. The obtained results open promising industrial applications in predictive maintenance and electrical equipment monitoring.

Keywords: Faults diagnosis, Signal processing approaches, Local Binary Pattern, Grey Co-occurrence Matrix, Induction machine.

ملخص

تقدم هذه الأطروحة نهجًا مبتكرًا لـ تشخيص الأعطال في المحركات غير المتزامنة باستخدام تحليل الإشارات الصوتية جنبًا إلى جنب مع تقنيات معالجة الصور. يعتمد هذا النهج على تحويل الإشارات الصوتية إلى صور ثنائية الأبعاد، يتبعها تحليل النسيج باستخدام (LBP) أنماط ثنائية محلية (و) (GLCM مصفوفة التواجد المشترك لمستوى الرمادي). (تم تقديم نهج جديد، GLBP، يجمع بين LBP و GLCM لاستخراج الميزات بشكل أكثر كفاءة. تشمل الأعطال التي تمت دراستها عيوب المحامل و كسور قضبان الدوار. المنهجية: يتم تحويل الإشارات الصوتية إلى صور، ثم تحليلها باستخدام LBP و GLCM لاستخراج ميزات النسيج. يجمع نهج GLBP بين نقاط قوة كلتا الطريقتين.

• الأعطال التي تمت دراستها : يركز البحث على عيوب المحامل، وكسور قضبان الدوار الفردية والمزدوجة والثلاثية.
• التصنيف: تُستخدم الميزات المستخرجة لتدريب المصنفات مثل MCSVM و K-NN و ANN، مما يدل على دقة عالية، خاصة مع نهج GLBP الذي يحقق 100٪ مع MCSVM و ANN. الأصالة: تكمن أصالة هذه الأطروحة في استخدام الإشارات الصوتية، والجمع بين طرق GLCM و LBP من خلال نهج GLBP، وتقليل مساحة الميزات عبر استخراج خمس ميزات مميزة. النتائج: أظهر نهج GLBP فعالية فائقة، متجاوزًا طرق تحليل النسيج التقليدية. تقدم النتائج آفاقًا لتحسين الصيانة التنبؤية وإدارة المعدات الصناعية.

الكلمات المفتاحية: تشخيص الأعطال، مناهج معالجة الإشارات، الأنماط الثنائية المحلية، مصفوفة التعايش لمستويات الرمادي، الآلة غير المتزامنة.