

الجمهورية الجزائرية الديمقراطية الشعبية  
République Algérienne Démocratique et Populaire  
وزارة التعليم العالي والبحث العلمي  
Ministère de l'Enseignement Supérieur  
Et de la Recherche Scientifique  
المدرسة الوطنية العليا للتكنولوجيا المتقدمة  
Ecole nationale supérieure de technologie avancée  
قسم الهندسة الصناعية والصيانة  
Département Génie Industriel et Maintenance

Mémoire de fin d'étude en vue de l'obtention du diplôme de :  
**Ingénieur d'État**

Filière: **Génie Industriel**  
Spécialité: **Management et Ingénierie de la Maintenance Industrielle**

Thème

---

**Diagnostic et la classification des défauts  
dans les machines tournantes industrielles  
par les réseaux de neurones Artificiels  
Application : machine Asynchrone**

---

Réalisé par  
**Bouzid Amel**  
**Latreche Brahim**

Présenté devant les membres de jury:

Nom et prénom	Grade	Qualité
Mr REZGUI WAIL	MCA	Président
Mr HOUARI FOUAD	MCA	Examinateur
Mr Meradi Samir	MCA	Encadreur
Mr Amrane Ahmed	MCB	Co-encadreur
Mr Harzelli Imadeddine	Doctorant	Invité

# *Remerciements*

Nous tenons à exprimer nos sincères remerciements à toutes les personnes qui ont  
directement ou  
indirectement contribué à la réussite de notre travail.

Nous sommes profondément reconnaissants envers nos superviseurs, **M. Meradi Samir**  
et **M. Amrani Ahmed** , pour leur supervision et leurs précieux conseils pendant notre  
travail. De plus, nous tenons à remercier tous les employés de Sonelgaz à Biskra pour  
leur chaleureux accueil et leur soutien tout au long de notre stage. Nous souhaitons  
exprimer notre gratitude particulière à **M. Harzelli Imadeddine** , qui nous a soutenus  
dans la réalisation de ce travail.

Nous ne pouvons pas non plus oublier les membres du corps professoral de ENST, dont  
les enseignements ont été d'une grande valeur pour nous.

Enfin, nous tenons à remercier le comité d'évaluation de notre mémoire pour l'intérêt  
qu'il a porté à notre travail.

# *Dédicaces*

Si le début du chemin était difficile, sa fin est atteindre un rêve. Si le départ était une larme, sa fin est un sourire. Chaque début nécessite une fin. Et voilà les années ont passé et le rêve est en train de se réaliser. Merci Allah de m'avoir donné le courage pour accomplir cette tâche.

Je dédie ce travail à celui qui m'a élevé et s'est battu pour moi, à celui qui a éclairé mon chemin. Je prie Allah d'allonger sa vie et que ses paroles restent des étoiles qui guideront mon chemin aujourd'hui, demain et toujours. **mon cher père**

Et à celle qui a veillé et été avec moi dans mes pires moments, merci de m'avoir donné la force pour accomplir ce chemin. Et voici le jour que tu attendais, ta fille est enfin diplômée. **ma chère mère**

A mes chers frères, et mon bras droit dans la vie, kamel , abdelkader, hamida, islam et ma chère sœur allaa que dieu les protège.

A la chère famille Bouzid.

Ainsi qu'à mon cher mari qui m'a accompagné tout au long de ce travail et m'a soutenu en tout jusqu'à ce que mon rêve devienne réalité et sa famille,

A mes amis, et à tous qui ont été à mes côtés, à tous mes chers enseignants qui n'ont jamais hésité de m'aider. Je vous présente ce travail et j'espère qu'elle obtiendra votre satisfaction

*BOUZID Amel.*

# *Dédicaces*

Aujourd'hui, je voudrais prendre le temps de vous remercier du fond du cœur pour votre présence, votre soutien et votre amour tout au long de mon parcours d'études. Vos encouragements inébranlables, votre bienveillance et votre soutien ont joué un rôle crucial dans ma réussite, et je ne saurais jamais assez exprimer ma gratitude envers vous tous.

À mes chers parents, vous êtes mes héros. Votre dévouement et vos sacrifices pour mon éducation ont été la pierre angulaire de ma réussite. Vous m'avez offert les meilleures opportunités et m'avez soutenu(e) dans chaque décision que j'ai prise. Votre amour inconditionnel, vos encouragements constants et vos précieux conseils m'ont guidé(e) tout au long de mon parcours éducatif. Je ne pourrais jamais vous remercier assez pour tout ce que vous avez fait pour moi. Vous êtes la source de ma détermination et de ma persévérance.

À mes grands-parents, même si vous n'êtes plus physiquement parmi nous, votre amour et votre influence ont façonné la personne que je suis aujourd'hui. Vos conseils avisés, votre sagesse et vos histoires m'ont inspiré tout au long de mon parcours. Je vous porte dans mon cœur et je suis profondément reconnaissant de l'héritage que vous avez laissé.

A ma famille, amis et collègues.

Pour ceux qui ont contribué ne serait-ce qu'une seule lettre dans ma vie scolaire... Je leur dédie mon travail à tous et je prie pour que Dieu l'accepte sincèrement.

*LATRECHE Brahim.*

# Table des matières

<b>Table des matières</b>	<b>i</b>
<b>Table des figures</b>	<b>vi</b>
<b>Liste des tableaux</b>	<b>ix</b>
<b>Liste des abréviations</b>	<b>x</b>
<b>Introduction générale</b>	<b>1</b>
<b>1 Etat de l’art sur le diagnostic avec l’apprentissage automatique et MDP- RN</b>	<b>3</b>
1.1 Introduction . . . . .	4
1.2 Concept et terminologie . . . . .	4
1.3 Maintenance Industrielle . . . . .	5
1.3.1 Le rôle de la maintenance . . . . .	5
1.3.2 Les objectifs de la maintenance . . . . .	5
1.3.3 Les différents types de la maintenance . . . . .	6
1.3.4 la maintenance corrective . . . . .	7
1.3.5 Maintenance préventive . . . . .	8
1.3.6 Maintenance prédictive . . . . .	8
1.3.7 Mise en œuvre la maintenance prédictive . . . . .	9
1.3.8 Les phases pratiques de la maintenance prédictive . . . . .	10
1.3.9 Les enjeux de la maintenance prédictive . . . . .	11
1.3.10 Les avantages et les inconvénients la maintenance prédictive . . . . .	12

1.4	Surveillance . . . . .	12
1.4.1	Définition du diagnostic industriel . . . . .	13
1.4.2	Les différentes étapes de diagnostic . . . . .	13
1.5	Méthodes de diagnostic . . . . .	15
1.5.1	Méthode à base de modèles . . . . .	15
1.5.2	Méthodes sans modèles . . . . .	17
1.6	Apprentissage automatique . . . . .	17
1.6.1	Domaines d'applications de l'apprentissage automatique . . . . .	18
1.6.2	Méthodes d'apprentissage automatique . . . . .	18
1.6.3	les critères de choix de la méthode à utiliser pour un diagnostic industriel : . . . . .	20
1.7	Le Réseaux de neurones . . . . .	20
1.7.1	Les différents types de réseaux neuronaux . . . . .	21
1.8	Conclusion . . . . .	21
<b>2</b>	<b>Modélisation en vue du diagnostic de la machine asynchrone</b>	<b>22</b>
2.1	Introduction . . . . .	23
2.2	Machine asynchrone . . . . .	23
2.3	Constitution des machines asynchrones . . . . .	23
2.3.1	Stator . . . . .	24
2.3.2	Rotor . . . . .	25
2.4	principe de fonctionnement d'une machine asynchrone . . . . .	25
2.5	Etude des différents défauts de la machine asynchrone . . . . .	26
2.5.1	Etude Statistique . . . . .	27
2.6	Modélisation de la machine asynchrone . . . . .	28
2.6.1	Hypothèse de travail . . . . .	28
2.6.2	La mise en équation du moteur asynchrone . . . . .	29
2.7	Transformation triphasée - biphasée . . . . .	31
2.7.1	Transformation de Clark . . . . .	31
2.7.2	Transformation de Concordia . . . . .	33
2.7.3	Transformation de Park . . . . .	33
2.7.4	Choix du référentiel . . . . .	37
2.8	Passage du modèle biphasé vers une représentation d'état . . . . .	39

2.8.1	Représentation d'état de la machine asynchrone . . . . .	39
2.8.2	Modèle du MAS sans défaut sous forme d'état dans le repère fixe ( $\alpha, \beta$ ) . . . . .	40
2.8.3	Modèle du MAS en tenant compte du défaut de court-circuit sta- torique . . . . .	40
2.9	Block diagramme pour le cas sain et en défaut . . . . .	42
2.9.1	Cas sans défaut . . . . .	42
2.9.2	Cas avec défaut . . . . .	42
2.10	Simulation de la machine asynchrone sans défaut et avec défaut statorique	42
2.10.1	cas d'une machine saine . . . . .	43
2.11	Cas d'un défaut de court-circuit entre spire . . . . .	45
2.12	Conclusion . . . . .	47
<b>3</b>	<b>Application des PDM-ANN en vue dans le diagnostic de La MAS</b>	<b>48</b>
3.1	Introduction : . . . . .	49
3.2	La classification : . . . . .	49
3.3	Approche basée sur les réseaux de neurones artificiels pour le diagnostic ,la détection et la classification des défauts : . . . . .	49
3.4	Avantages des RNA dans la classification des défauts : . . . . .	50
3.5	Avantages et implications de l'application de la classification des défauts : .	51
3.6	Application de classification des défauts dans la machine asynchrone in- dustrielle par la méthode de réseaux de neurones : . . . . .	52
3.7	Diagnostic et localisation des défauts statorique de la machine asynchrone :	52
3.7.1	Choix des variables d'entrées du $RN_{cc}$ . . . . .	52
3.7.2	Energie de la décomposition d'ondelette en présence d'un défaut statorique . . . . .	55
3.7.3	Etude de l'énergie de la décomposition d'ondelette en fonction de la charge . . . . .	57
3.7.4	Acquisition des données (base d'apprentissage) . . . . .	59
3.8	Résultats de l'apprentissage . . . . .	60
3.8.1	Résultats de RN pour la prédiction des défauts : . . . . .	60
3.9	Les résultats de classification de défaut par réseau de neurones : . . . . .	62

3.10 Prédiction pour la localisation et classification de défaut de la machine	
asynchrone . . . . .	64
3.10.1 Résultat de test par la méthode de régression : . . . . .	64
3.10.2 Résultat de test par la méthode de Classification : . . . . .	66
3.11 Les résultats des défauts de La machine asynchrone court-circuitée par la	
méthode de regression : . . . . .	67
3.12 Les résultats des défauts de court-circuit entre les spires de la machine	
asynchrone par la méthode de classification : . . . . .	68
3.13 interface graphique . . . . .	69
3.13.1 Description de l'application . . . . .	69
3.13.2 Modèle de la MAS : . . . . .	70
3.13.3 Détection et Classification : . . . . .	71
3.13.4 Contact us : . . . . .	75
3.13.5 Aide : . . . . .	75
3.14 Conclusion . . . . .	76
<b>Conclusion générale</b>	<b>77</b>
<b>Bibliographie</b>	<b>79</b>
<b>A Annexe A</b>	<b>85</b>
<b>B Annexe B</b>	<b>87</b>
<b>C Annexe C</b>	<b>88</b>
C.1 L'importance de la collecte de données dans la maintenance prédictive : . . . . .	89
C.2 Les différents types de sources de données . . . . .	90
C.3 La structure de réseau de neurones . . . . .	92
C.3.1 Neurones . . . . .	92
C.3.2 Couches . . . . .	93
C.3.3 Connexions et pondérations . . . . .	93
C.4 Les étapes principales pour l'algorithme de réseaux de neurones . . . . .	94
C.4.1 Initialisation des poids . . . . .	94
C.4.2 Propagation avant (Forward propagation) . . . . .	94
C.4.3 Calcul de la fonction de perte (Loss function) . . . . .	95

C.4.4	Rétropropagation (Backpropagation) . . . . .	96
C.4.5	Mise à jour des poids . . . . .	96
C.4.6	Répétition des étapes 2 à 5 . . . . .	96
C.4.7	Validation et test . . . . .	97
C.5	La relation entre la machine asynchrone de défaut court-circuitée et le réseau de neurones . . . . .	97

# Table des figures

1.1	Les objectifs de la maintenance . . . . .	6
1.2	Les types de maintenance industrielle. . . . .	7
1.3	Mise en œuvre de la maintenance prédictive [8] . . . . .	9
1.4	Suivi de l'évolution du défaut par la surveillance prédictive [14] . . . . .	10
1.5	Les avantages et les inconvénients de MDP . . . . .	12
1.6	Composantes de la surveillance industrielle . . . . .	13
1.7	les différentes étapes de processus de diagnostic [18] . . . . .	14
1.8	Les types de diagnostic [21] . . . . .	17
1.9	Apprentissage supervisé [25] . . . . .	18
1.10	Apprentissage non supervisé [25] . . . . .	19
1.11	Renforcement de l'apprentissage automatique [25] . . . . .	19
2.1	Constitution d'une machine asynchrone triphasée [32]. . . . .	24
2.2	Stator d'une machine asynchrone [37]. . . . .	24
2.3	Les types de rotor . . . . .	25
2.4	causes internes des défauts de la machine asynchrone . . . . .	27
2.5	causes externes des défauts de la machine asynchrone . . . . .	27
2.6	Répartition des pannes des machines asynchrones de faible et moyennes puissances . . . . .	28
2.7	Représentation de la MAS en régime quelconque [35]. . . . .	29
2.8	Passage d'une base triphasée (abc) à une base biphasée ( $\alpha, \beta$ ) et réciproquement [35]. . . . .	32
2.9	Passage du système $\alpha, \beta$ vers le système d,q . . . . .	33

2.10	Block diagramme pour le cas sain . . . . .	42
2.11	Block diagramme pour le cas défaut de court-circuit . . . . .	42
2.12	Vitesse électrique . . . . .	43
2.13	Couplé électromagnétique . . . . .	43
2.14	Courants statorique . . . . .	44
2.15	Zoom des courants statorique . . . . .	44
2.16	Courants statorique . . . . .	45
2.17	Zoom des courants statorique . . . . .	45
2.18	Vitesse électrique . . . . .	46
2.19	Couple électromagnétique . . . . .	46
3.1	Les variations de l'énergie dans la bande de fréquence (db40) . . . . .	55
3.2	Evolution de l'énergie stockée dans le niveau 7 en fonction des courts circuits entre spires sur les phases $a_s, b_s, c_s$ . . . . .	56
3.3	Phase a . . . . .	57
3.4	Phase b . . . . .	58
3.5	Phase c . . . . .	58
3.6	Architecture de RN par la méthode de regression . . . . .	60
3.7	Performance du $RN_{cc}$ . . . . .	61
3.8	Les sorties de l'apprentissage du $RN_{cc}$ . . . . .	61
3.9	Les erreurs de l'apprentissage du $RN_{cc}$ . . . . .	62
3.10	L'architecture de RN pour la classification . . . . .	63
3.11	Matrice de confusion pour les données d'entraînement . . . . .	63
3.12	Tests des sorties du $RN_{cc}$ en présence de défauts sur la phase $a_s$ . . . . .	65
3.13	Tests des sorties du $RN_{cc}$ en présence de défauts sur la phase $b_s$ . . . . .	65
3.14	Tests des sorties du $RN_{cc}$ en présence de défauts sur la phase $c_s$ . . . . .	66
3.15	Matrice de confusion pour les données d'entraînement . . . . .	67
3.16	la page principal de l'interface graphic . . . . .	70
3.17	le Modèle de la MAS . . . . .	70
3.18	Les paramètres de rotor . . . . .	71
3.19	Les paramètres de stator . . . . .	71
3.20	Les types de défauts de court-circuit . . . . .	72
3.21	Diagnostic . . . . .	72

3.22	MAS sans défaut . . . . .	73
3.23	Défaut CC sur la phase A . . . . .	73
3.24	Défaut CC sur la phase B . . . . .	74
3.25	Défaut CC sur la phase C . . . . .	74
3.26	Les contacts . . . . .	75
C.1	Les couches de réseau neurone [30] . . . . .	93
C.2	Les couches de réseau neurone [30] . . . . .	93
C.3	Propagation directe . . . . .	94
C.4	Un nœud qui reçoit trois entrées [30] . . . . .	95
C.5	La fonction d'activation [30] . . . . .	95
C.6	Le concept d'apprentissage supervisé [30] . . . . .	97
C.7	Schéma explicatif qui représente le lien entre MAS et RN . . . . .	98

# Liste des tableaux

- 3.1 les différentes bandes de fréquence obtenues . . . . . 54
- 3.2 Les résultats finals des sorties de la machine asynchrone . . . . . 68
- 3.3 Les résultats finals des sorties de la machine asynchrone . . . . . 69

# Liste des abréviations

MDP	Maintenance prédictive .
RN	Réseau de neurones.
CC	Court-circuit.
KPI	indicateurs clés de performance .
MAS	Machine asynchrone.

# Introduction générale

Les machines tournantes, en particulier les moteurs asynchrones, jouent un rôle crucial dans divers secteurs industriels, assurant le bon fonctionnement des opérations essentielles à la production et aux services. Cependant, en raison des conditions de travail rigoureuses et des environnements hostiles auxquels elles sont exposées, ces machines sont sujettes à des défauts et des pannes.

Il est donc crucial de détecter de manière précoce et précise ces défauts dans les machines tournantes, afin de minimiser les interruptions coûteuses de la production et de garantir la sécurité des travailleurs. Dans ce contexte, l'utilisation des réseaux de neurones artificiels (RNA) s'est avérée être une approche puissante pour le diagnostic et la classification des défauts dans les machines industrielles.

Les RNA sont des modèles de calcul inspirés du fonctionnement du cerveau humain. Grâce à leur capacité à apprendre à partir de données, à extraire des caractéristiques pertinentes et à prendre des décisions basées sur ces informations, les RNA sont particulièrement adaptés à la détection de défauts dans les machines tournantes, où des motifs complexes et subtils peuvent se manifester.

L'objectif de cette étude est d'explorer l'application spécifique des RNA dans le diagnostic et la classification des défauts des moteurs asynchrones. Ces moteurs sont largement utilisés en raison de leur simplicité, de leur robustesse et de leur coût abordable. Toutefois, ils sont sujets à une variété de défauts tels que des déséquilibres, des courts-circuits, des roulements défectueux, etc. Par conséquent, il est essentiel de développer des techniques de diagnostic efficaces pour identifier ces problèmes et mettre en place des mesures correctives appropriées.

## **Organisation du mémoire**

Le présent mémoire s'articule en quatre chapitres

### **Le premier chapitre**

Le premier chapitre de cette mémoire sera consacré à une revue de la littérature sur la maintenance industrielle et le diagnostic industriel. Nous couvrirons les concepts de base de la maintenance, y compris la maintenance prédictive, préventive et corrective, Nous explorerons également le domaine de l'apprentissage automatique, en nous concentrant sur les domaines et les méthodes de son utilisation et les réseaux de neurones artificiels et leurs types Ensuite, nous étudierons les machines tournantes.

### **Le deuxième chapitre**

Ce chapitre est consacré à la modélisation spécifique du diagnostic de la machine asynchrone. nous présentons les caractéristiques spécifiques de cette machine, les défauts courants auxquels elle est sujette, ainsi que les paramètres et les signaux de mesure utilisés dans le processus de diagnostic. nous décrivons ensuite comment les données sont collectées, prétraitées et utilisées pour entraîner le modèle PdM-RN spécifique à la machine asynchrone.

### **Le troisième et dernier chapitre**

Dans ce dernier chapitre, nous présentons les résultats et les performances obtenus à partir de l'application du modèle PdM-RN au diagnostic de la machine asynchrone. nous analysons les résultats de simulations, et discutons les avantages et les limites de cette approche, et proposons des perspectives d'amélioration et de développement futur.

Chapitre **1**

Etat de l'art sur le diagnostic avec  
l'apprentissage automatique et MDP-RN

## **1.1 Introduction**

Des années se sont écoulées depuis l'émergence de la première révolution industrielle, mais la maintenance était considérée comme une affaire secondaire pour les entreprises, c'est-à-dire maintenir les machines en état de marche jusqu'à ce que le dysfonctionnement apparaisse et que les machines s'arrêtent, car toute l'attention était portée sur le processus de production. Mais après les développements et les progrès technologiques actuels, le changement a été fait de l'état de réparation uniquement à la prédiction d'une panne avant qu'elle ne se produise, basée sur l'apprentissage automatique. Dans ce chapitre, nous avons introduit quelques termes et concepts sur la maintenance et l'apprentissage automatique.

## **1.2 Concept et terminologie**

### **\* Défaut**

Un défaut est tout écart entre la caractéristique observé sur le dispositif et la caractéristique de référence lorsque celui-ci est en dehors des spécifications [1].

### **\* Défaillance**

Selon la norme AFNOR 60010X une défaillance est l'altération ou la cessation de l'aptitude d'un ensemble à accomplir sa ou ses fonctions requises avec les performances définie dans les spécifications techniques [2].

### **\* La panne**

La panne est l'inaptitude d'un dispositif à accomplir une fonction requise. Dès l'apparition d'une défaillance, caractérisée par la cessation du dispositif à accomplir sa fonction, le dispositif sera déclaré en panne. Donc une panne résulte toujours d'une défaillance [2].

### **\* détection**

Pour détecter les erreurs du système, nous devons être capables de classer les conditions observables comme normales ou anormales. Cette classification n'est pas triviale en raison du manque d'information qui caractérise les situations anormales en général. Une

simplification communément admise consiste à considérer les situations anormales comme étant anormales [3].

## **1.3 Maintenance Industrielle**

Selon l'AFNOR, la maintenance vise à maintenir ou rétablir un bien dans un état spécifié afin qu'il puisse assurer un service déterminé. Cela englobe les vérifications fonctionnelles, l'entretien, la réparation ou le remplacement des équipements et infrastructures dans les installations industrielles, commerciales et résidentielles. La maintenance industrielle, également appelée maintenance d'usine, consiste en la mise en œuvre de processus visant à réduire les pannes, à augmenter le temps de disponibilité et à améliorer la fiabilité globale. Un plan de maintenance adéquat permet de réduire les coûts, d'optimiser la disponibilité des équipements et d'accroître la rentabilité. Il est préférable d'avoir un plan de maintenance préventive plutôt que de dépendre de sous-traitants pour des réparations après une panne, ce qui expose à des coûts élevés et à des risques de temps d'arrêt imprévus. Un plan de maintenance approprié permet d'identifier les tâches de maintenance préventive, ce qui permet d'économiser à long terme [5,6].

### **1.3.1 Le rôle de la maintenance**

Le rôle de la maintenance consiste à garantir la disponibilité opérationnelle des équipements afin de les mettre à la disposition de la production. Par le biais de ses actions, la maintenance gère les bénéfices cumulés tout au long de la durée de vie des équipements en vue de :

- La réduction des coûts de maintenance.
- L'accroissement de la durée rentable de vie des équipements.
- Réduction des accidents et des risques concernant la sécurité des hommes et de l'environnement [7].

### **1.3.2 Les objectifs de la maintenance**

les objectifs de la maintenance sont d'assurer la disponibilité, la sécurité, la durabilité, l'efficacité et la conformité des équipements et des systèmes, tout en minimisant les coûts et en optimisant les performances.

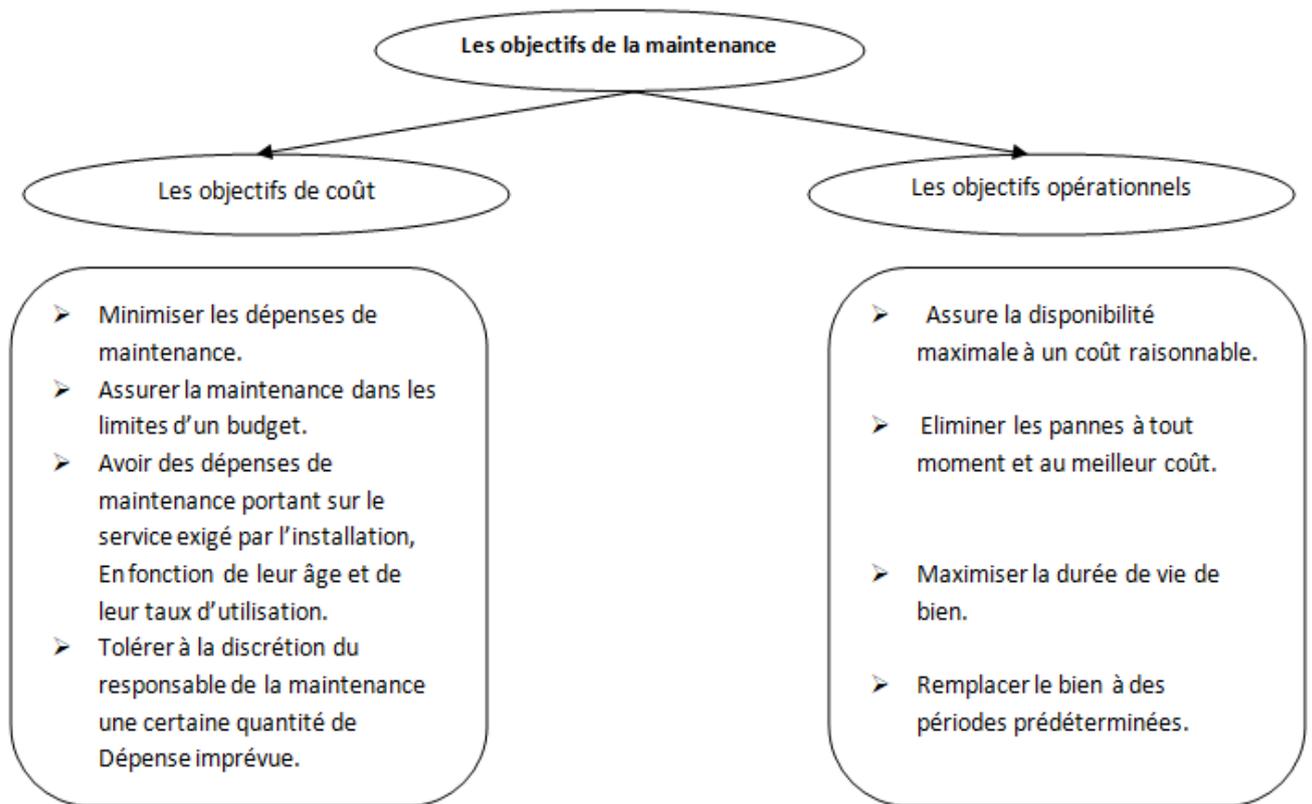


FIGURE 1.1 – Les objectifs de la maintenance

### 1.3.3 Les différents types de la maintenance

Il existe deux grands types de maintenance industrielle :

- La maintenance corrective, qui peut être palliative ou curative.
- La maintenance préventive, qui peut être systématique, conditionnelle ou prédictive.

Nous considérons aussi notamment la maintenance améliorative car nous en avons besoin dans notre travail, tout cela est illustré dans la figure I-2 :

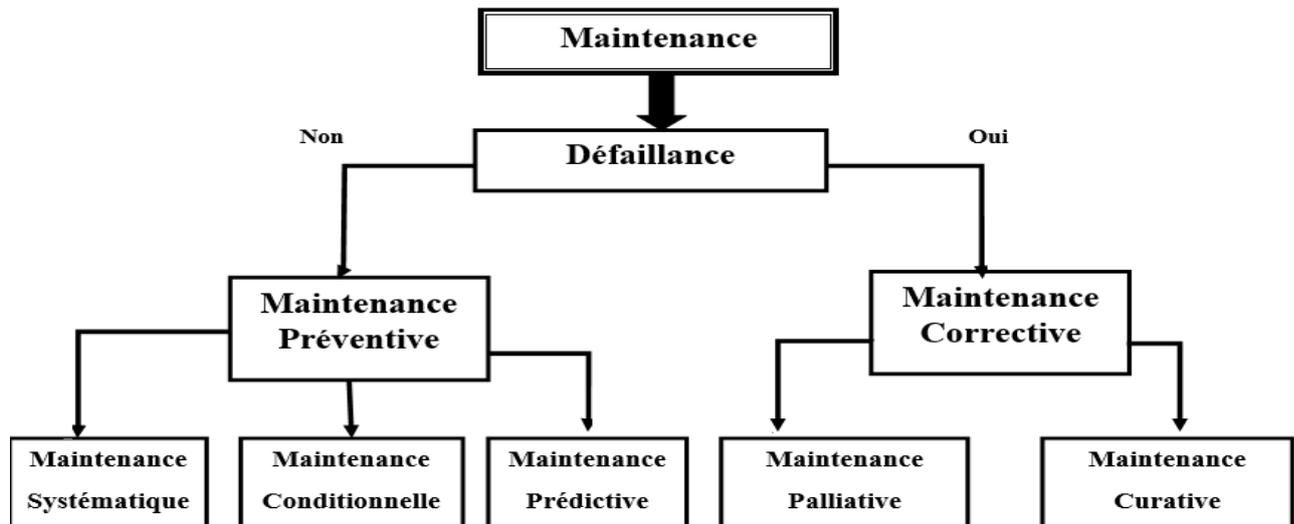


FIGURE 1.2 – Les types de maintenance industrielle.

### 1.3.4 la maintenance corrective

La norme SS-EN 13306 définit la maintenance corrective comme une série de travaux effectués après une panne ou la découverte d'un défaut évident. Différentes techniques de restauration peuvent être utilisées, mais une réparation minimale consiste simplement à remettre l'élément défaillant en état de fonctionnement sans amélioration. L'élément continuera à fonctionner avec la même probabilité d'échec qu'auparavant. En revanche, une réparation plus complète peut ramener l'élément à un état "comme neuf", réduisant ainsi le taux d'échec au niveau initial. Ces réparations plus approfondies sont considérées comme l'extrême de la réparation selon Høyland [9].

La maintenance corrective peut être divisée en deux typés de maintenance :

- **Maintenance palliative (dépannage) :**

Lorsqu'il s'agit d'une solution temporaire pour permettre à l'équipement de continuer à remplir partiellement ou complètement une fonction requise.

- **Maintenance curative (réparation) :**

Lorsque l'équipement est définitivement réparé et remis dans son état d'origine ou dans un état lui permettant de remplir sa fonction [10].

### **1.3.5 Maintenance préventive**

La maintenance préventive est définie comme : La maintenance préventive peut être divisée en deux types : la maintenance planifiée et la maintenance conditionnelle. La maintenance programmée est planifiée et organisée sans activités de surveillance. La planification peut être basée sur le temps d'utilisation, le nombre de fois qu'un article est utilisé. Par exemple, le nombre de kilomètres parcourus par l'élément en fonction des données fournies. L'entretien périodique est préférable pour les articles qui présentent une détérioration au fil du temps ou une usure caractéristique et qui peuvent être entretenus à un moment fiable pour éviter les pannes [11].

- **Maintenance préventive systématique**

C'est le type de maintenance préventive le plus courant. Il s'agit d'interventions effectuées systématiquement sur la base d'une période de temps fixe ou sur la base d'une périodicité d'utilisation (durée de fonctionnement, nombre de mouvements effectués...). Il répond souvent aux spécifications ou aux recommandations du fabricant de l'équipement concerné mais peut être ajusté par l'utilisateur en fonction de son expérience. Si on prend l'exemple d'un véhicule, une vidange tous les ans ou tous les 10 000 kilomètres est considérée comme un entretien systématique [12].

- **Maintenance préventive conditionnelle**

Ces interventions sont basées sur une condition qui peut être mesurée. Elle est donc réalisée en fonction de relevés ou de mesures, ou de contrôles (réalisés par un technicien ou à l'aide de capteurs) donnant des informations sur l'état de dégradation des équipements : analyse vibratoire, niveau d'huile, thermographie infrarouge, etc. Des indicateurs pertinents sont définis pour anticiper les pannes. Revenons à l'exemple de la voiture : le changement des plaquettes de frein lorsque le voyant correspondant s'allume est une intervention de maintenance préventive conditionnelle [12].

### **1.3.6 Maintenance prédictive**

Il s'agit d'une forme de maintenance conditionnelle réalisée sur la base de prévisions extrapolées à partir de l'analyse et de l'évaluation des paramètres de dégradation d'un

bien. Selon l'AFNOR, la maintenance préventive est : « Maintenance exécutée à des intervalles prédéterminés ou selon des critères prescrits et destinée à réduire la probabilité de défaillance ou la dégradation du fonctionnement d'un bien ». Elle repose sur l'anticipation du franchissement d'un seuil prédéfini qui renseigne sur l'état de dégradation de l'équipement avant qu'un dysfonctionnement ou une panne ne se produise [13].

### 1.3.7 Mise en œuvre la maintenance prédictive

Auparavant, les systèmes experts étaient utilisés pour prédire les erreurs en se basant sur des règles programmées, imitant ainsi le processus de décision des experts humains. Toutefois, avec l'avènement du Machine Learning, la maintenance prédictive a adopté de nouveaux algorithmes. Ces algorithmes utilisent des données collectées, telles que des images issues de l'analyse vibratoire, sonore, ultrasonore, des analyses de courant ou de thermographie infrarouge. Ces données contiennent des informations sur les problèmes potentiels et les pannes, appelés étiquettes, qui sont le résultat des prédictions [8].

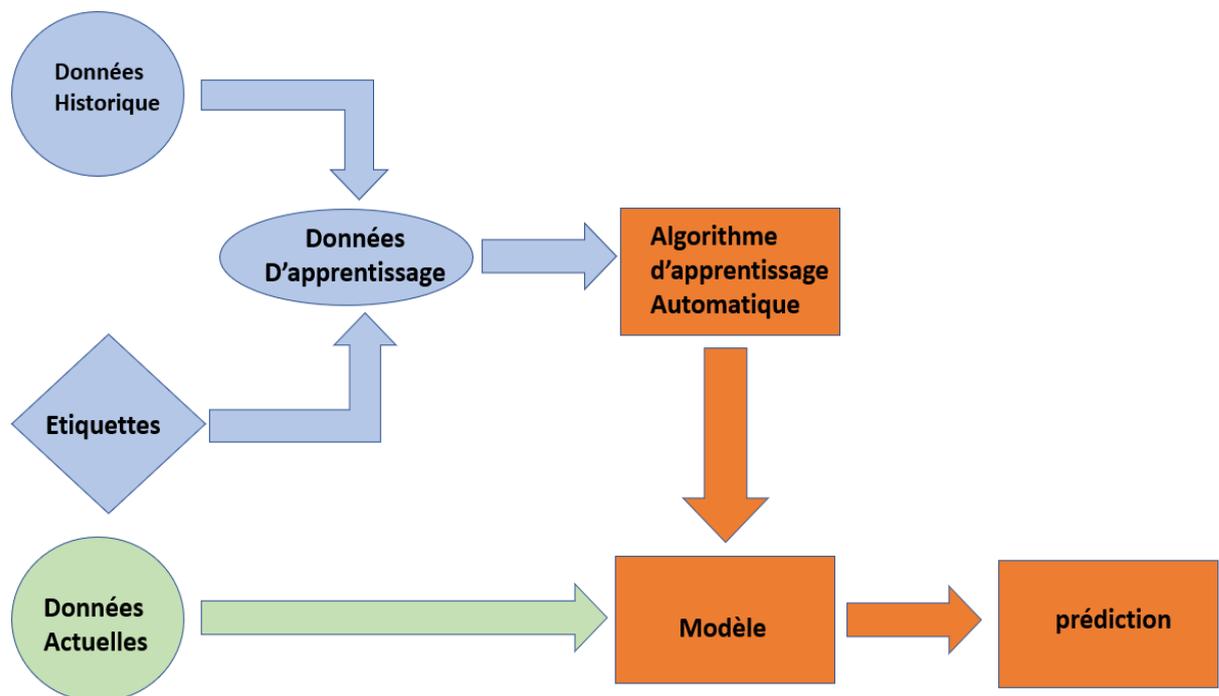


FIGURE 1.3 – Mise en œuvre de la maintenance prédictive [8]

Les algorithmes d'apprentissage pouvant être utilisés pour la maintenance prédictive se répartissent généralement en deux catégories [8] :

- Par exemple, les algorithmes de régression où la prédiction est un nombre indiquant la durée de vie utile restante d'une pièce ou d'un système.

C'est-à-dire combien de temps un composant ou un système continue de fonctionner avant que la prochaine panne ne se produise [8].

- Un algorithme de classification qui peut être utilisé spécifiquement pour prédire la cause la plus probable de défaillance de l'appareil [8].

### 1.3.8 Les phases pratiques de la maintenance prédictive

La maintenance prédictive inclut la capacité d'identifier rapidement les anomalies sans démonter la machine, d'éviter les pannes et de programmer les réparations le plus tard possible en fonction des besoins de production . Cette caractéristique fait de cette dernière une technique efficace qui permet des gains de productivité importants. En d'autres termes, les interventions ne sont réalisées que lorsque cela est nécessaire, d'abord avec diagnostic, puis avec remédiation prévue [14]. La pratique de la maintenance prédictive comporte 2 phases :

- La détection du défaut qui se développe → analyse du signal .
  - L'établissement d'un diagnostic → diagnostique machine .

#### 1.3.8.1 La détection du défaut qui se développe

Lors de la mise en service de chaque appareil, d'importantes caractéristiques de base de l'appareil sont enregistrées, notamment la signature vibratoire (paramètre intéressant des machines tournantes) et divers paramètres de fonctionnement (température, usure, puissance, etc.). Ou la signature sert de référence pour comparer et suivre les occurrences ultérieures de l'erreur [14].

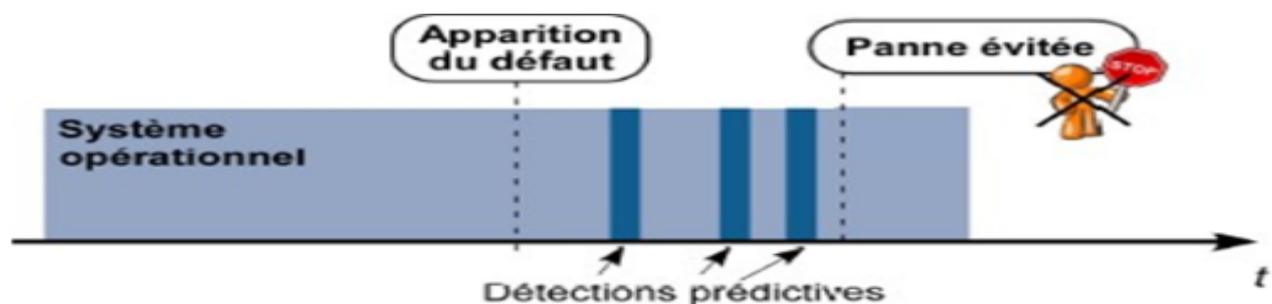


FIGURE 1.4 – Suivi de l'évolution du défaut par la surveillance prédictive [14]

### **1.3.8.2 L'établissement d'un diagnostic**

Dès qu'une anomalie est détectée par les outils caractéristiques, au sens d'analyse paramètres, un diagnostic concernant l'origine et la gravité du défaut constatée sera établi.

### **1.3.9 Les enjeux de la maintenance prédictive**

- **Exécution de la maintenance prédictive**

Le passage d'une technologie plus ancienne à la technologie la plus récente peut être un processus complexe et nécessite des investissements importants. De plus, la transition d'une technologie à une autre peut prendre du temps, ce qui constitue un autre défi majeur. En tant que collecte de données à partir de bases de données. Cela inclut des fonctionnalités telles que les alertes et les notifications, les indicateurs de performance clés (KPI) des actifs et la définition d'algorithmes pour déterminer les anomalies. C'est donc l'un des plus grands défis de la maintenance prédictive [5].

- **Équipe hautement qualifiée**

Pour mettre en œuvre efficacement la maintenance prédictive, les équipes de maintenance doivent être compétentes, formées et informées. Cependant, la formation et le développement des compétences des employés est un processus qui prend du temps. Vous devez également savoir comment fonctionne le logiciel. Donc, tout trier peut-être un long processus [5].

- **Sécurité**

La gestion des données a toujours été un grand défi pour les entreprises. Lorsqu'il s'agit de maintenance préventive, il est fondamental de garder les données et les informations sur les actifs hors de vue des assemblages externes.

Les administrateurs doivent également s'assurer que les agences extérieures n'exercent pas un contrôle indu sur les logiciels de maintenance prédictive. Plus important encore, aucune donnée n'a été divulguée car cela pourrait avoir un impact sur l'entreprise [5].

### 1.3.10 Les avantages et les inconvénients la maintenance prédictive

Par rapport à la maintenance préventive, on a :

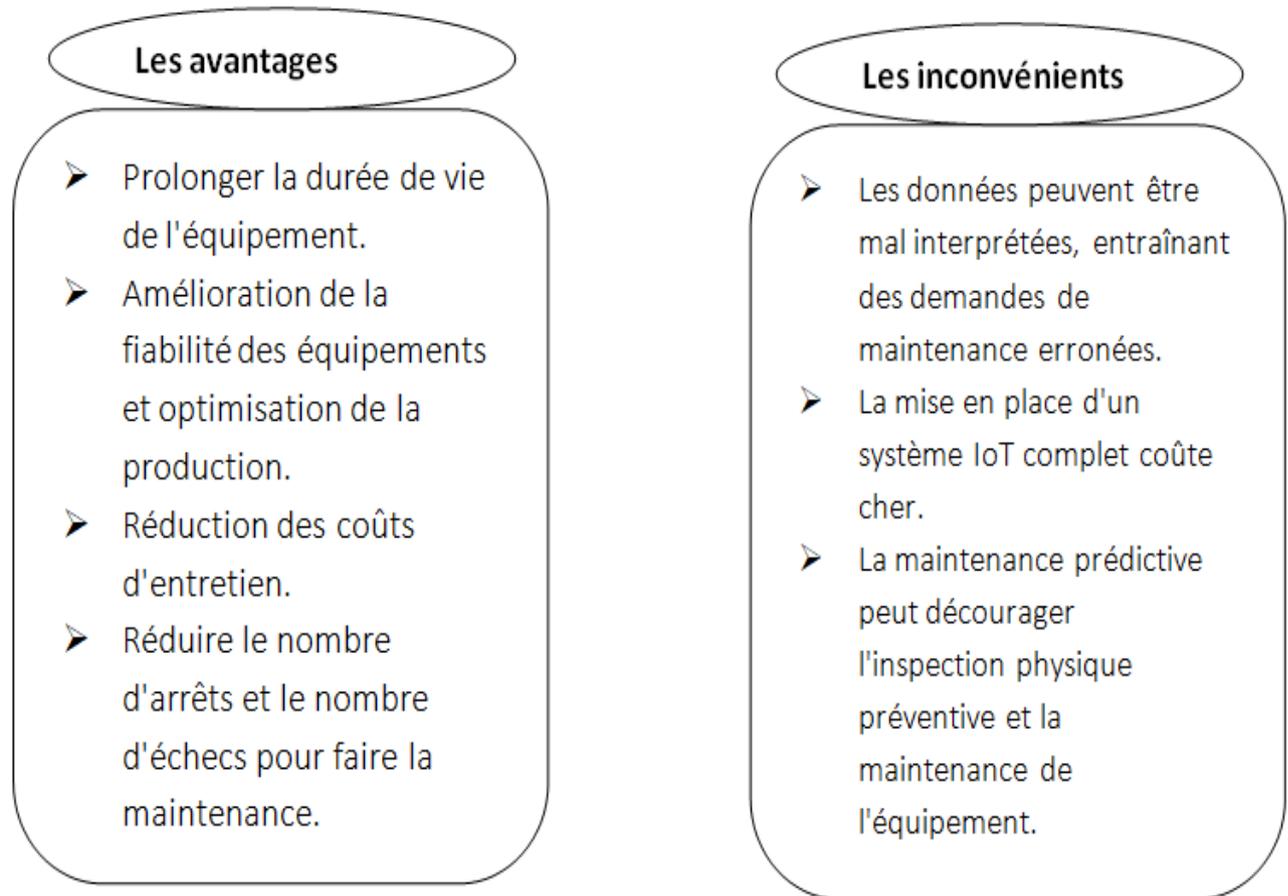


FIGURE 1.5 – Les avantages et les inconvénients de MDP

## 1.4 Surveillance

La surveillance est un dispositif passif, informationnel, qui analyse l'état du système et fournit des indicateurs. La surveillance consiste notamment à détecter et classer les défaillances en observant l'évolution du système, puis à les diagnostiquer en localisant les éléments défaillants et en identifiant les causes premières [16]. Voir la Figure suivante :

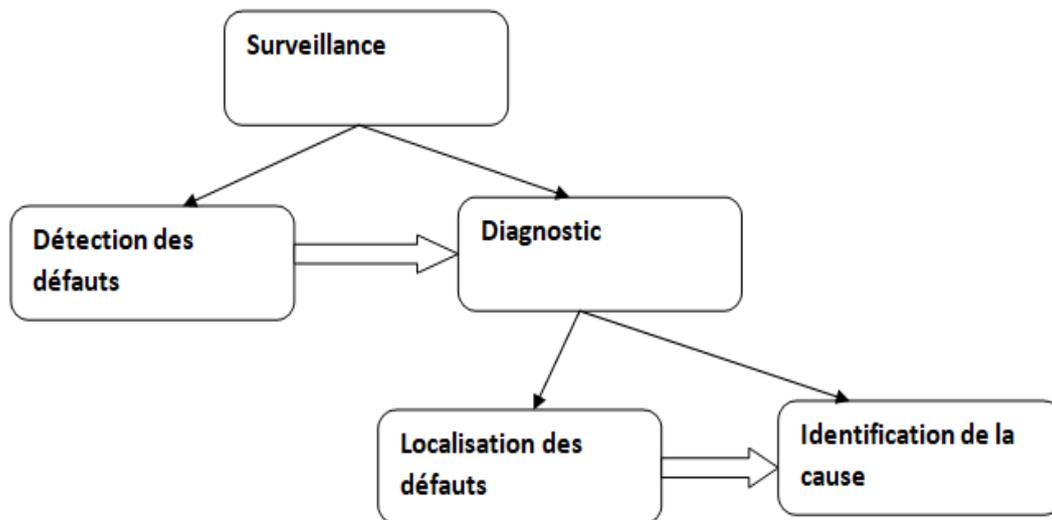


FIGURE 1.6 – Composantes de la surveillance industrielle

### 1.4.1 Définition du diagnostic industriel

Le diagnostic consiste en un ensemble d'actions visant à évaluer un procédé ou un système afin d'identifier la cause sous-jacente d'une défaillance, d'une panne ou d'un problème. Il implique un raisonnement basé sur les symptômes observés, les contrôles effectués et les tests réalisés. L'objectif est de comprendre les raisons qui ont conduit à l'incident ou à l'anomalie, en utilisant des techniques d'observation, d'analyse et de raisonnement.

Selon AFNOR : « Le diagnostic est l'identification de la cause probable de la (ou les) défaillance(s) à l'aide d'un raisonnement logique fondé sur un ensemble d'informations provenant d'une inspection, d'un contrôle, ou d'un test » [NF X60-010].

- Observer les symptômes de la défaillance.
- Identifier les causes de la défaillance à l'aide d'un raisonnement logique fondé sur des observations [17].

### 1.4.2 Les différentes étapes de diagnostic

L'exécution du diagnostic nécessite un certain nombre d'étapes consécutives

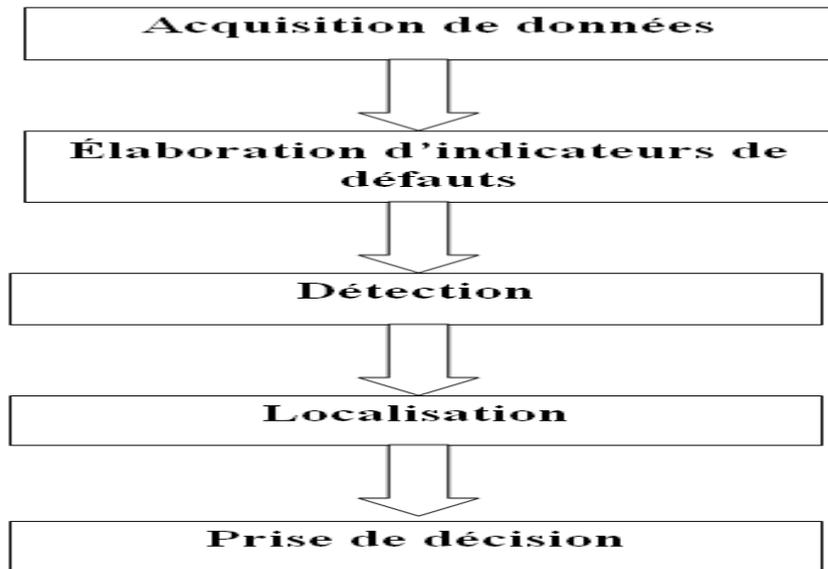


FIGURE 1.7 – les différentes étapes de processus de diagnostic [18]

### ●Acquisition de données

Les procédures de diagnostic nécessitent la disponibilité d'informations sur le comportement du système surveillé. Ces informations sont collectées lors de la phase de collecte des données suivant la vérification. Dans cette étape, diverses variables de processus sont mesurées à l'aide de capteurs appropriés. [18]

### ●Élaboration d'indicateurs de défauts

A partir des mesures et observations faites par les opérateurs responsables du système, il est important de construire des indicateurs permettant de mettre en évidence les défauts du système. Dans les diagnostics, les indicateurs de défauts sont communément appelés résidus ou symptômes [18].

### ●Détection

Cette étape est destinée à aider à déterminer si le système est dans un état de fonctionnement normal. Déterminer si un défaut existe ne suffit pas pour vérifier l'invalidité du résidu. En effet, en pratique, la grandeur mesurée est toujours superposée par du bruit, et le système surveillé est toujours brouillé. Cette étape est donc principalement réalisée à l'aide de tests statistiques ou, plus simplement, par seuillage [18].

## ●Localisation

Le but est d'identifier les défauts à partir de résidus statistiquement non nuls, c'est-à-dire d'identifier les éléments défectueux. La procédure de localisation nécessite l'utilisation d'un ensemble (ou vecteur) de résidus. Cela nécessite des propriétés qui caractérisent de manière unique chaque défaut. Vous pouvez utiliser deux méthodes pour cela [18] :

- Construction de résidus structurés.
- Construction de résidus directionnels.

## ●Prise de décision

Il est important de décider quoi faire pour maintenir les performances souhaitées du système surveillé. Cette décision, éventuellement sous le contrôle d'un opérateur humain, doit pouvoir déclencher les actions correctives nécessaires au retour de la centrale en fonctionnement normal. En résumé, quelle que soit la méthode utilisée, la procédure de diagnostic comprend deux étapes principales : l'étape de génération de résidus et l'étape d'évaluation des résidus [18].

## 1.5 Méthodes de diagnostic

Les méthodes de diagnostic des défauts employées dans le domaine industriel sont diverses et variées. Elles sont fondées sur le principe général de comparer les données observées lors du fonctionnement du système avec les connaissances accumulées sur son comportement normal ainsi que sur ses comportements de défaillance. En d'autres termes, ces méthodes cherchent à identifier les écarts ou les anomalies entre les observations réelles et les modèles de référence établis pour déterminer si un défaut est présent [19]. Il ya deux principales méthodes de diagnostic :

- Méthodes à base de modèle.
- Méthodes sans modèle.

### 1.5.1 Méthode à base de modèles

L'approche de diagnostic basée sur le contrôle se fonde sur une connaissance approfondie du système spécifique. Cette approche consiste à obtenir, analyser et comparer les données collectées avec le fonctionnement réel du système afin de détecter d'éventuels

défauts. Cela se fait à l'aide d'un modèle, qu'il soit quantitatif ou qualitatif, qui permet de représenter le comportement normal du système. En comparant les données observées avec ce modèle, on peut identifier les écarts ou les anomalies qui pourraient indiquer la présence d'un défaut [20].

### **Méthodes à base de modèle quantitatif**

Au fil des années, plusieurs approches de détection de défaillances ont été développées à partir de modèles mathématiques construits sur les lois fondamentales du système. Ces modèles utilisent des relations mathématiques pour décrire les interactions entre les entrées et les sorties du système. Différentes techniques, telles que les méthodes statistiques et l'apprentissage automatique, ont été utilisées pour exploiter ces modèles et détecter les défaillances. L'objectif est d'identifier les écarts entre les prédictions du modèle et les observations réelles afin de diagnostiquer les problèmes et prendre des décisions appropriées. Ces approches ont permis d'améliorer la détection et le diagnostic des défaillances, en exploitant les connaissances intégrées dans les modèles mathématiques pour une maintenance plus efficace [21]. Les techniques les plus utilisées pour la génération des résidus, à partir des modèles analytiques sont :

- Espace de parité.
- Estimations d'états.
- Estimations paramétrique.

### **Méthodes à base de modèle qualitatif**

Des techniques basées sur des modèles qualitatifs permettent de représenter le comportement des processus. Un certain degré d'abstraction par modèle n'est plus mathématique genre iconique. Un modèle qualitatif doit représenter le système qualitativement. Les diagnostics continus, discrets et/ou hybrides peuvent détecter les écarts par rapport au comportement normal, localiser les erreurs et identifier leurs causes. Une abstraction qualitative du comportement continu peut être exprimée dans un modèle basé sur celui-ci. Événement discret (SED). De nombreuses approches sont mises en œuvre à l'aide d'outils tels que : Observation partielle ou complète d'automates, d'équations logiques ou de réseaux de Petri (RP) Flux de traitement [21].

## 1.5.2 Méthodes sans modèles

Les techniques de détection et de diagnostic de modèles non référencés sont utilisées pour les systèmes pour lesquels il est difficile d'obtenir un modèle comportemental. Elles reposent sur l'utilisation de données issues de systèmes et de données issues de l'expertise humaine (intelligence artificielle, reconnaissance de formes, systèmes experts ou à base de connaissances). il y a quelques choses à ce sujet technologie diagnostique. La taxonomie de ces méthodes est bien illustrée dans la figure [21].

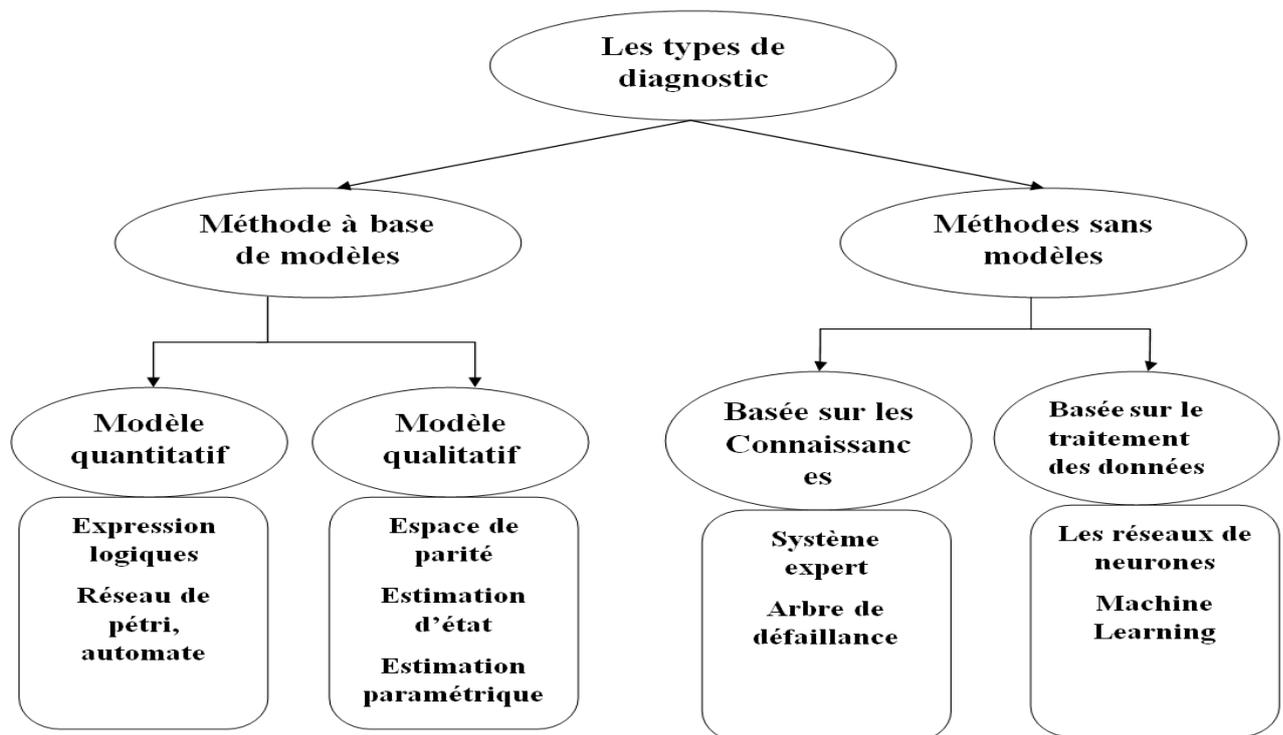


FIGURE 1.8 – Les types de diagnostic [21]

## 1.6 Apprentissage automatique

C'est La capacité d'apprendre et de s'adapter à partir d'expériences passées est une caractéristique essentielle des organismes supérieurs. Apprendre des choses de base telles que reconnaître des voix et des visages familiers, comprendre ce qui se dit, marcher et parler est essentiel pour les personnes dans les premiers stades de la vie [22].

L'apprentissage automatique est une tentative de comprendre et de reproduire cette capacité d'apprentissage dans des systèmes artificiels. Très grossièrement, nous partons

d'un grand nombre d'exemples (données correspondant à "l'expérience passée") et concevons un algorithme dont les propriétés peuvent être assimilées pour que ce que nous apprenons ainsi puisse être appliqué dans le futur. [22]

### 1.6.1 Domaines d'applications de l'apprentissage automatique

L'apprentissage automatique influence un large éventail d'activités humaines et est particulièrement bien adapté aux problèmes de prise de décision automatisée par exemple [23] :

- 1. Créer un diagnostic médical à partir de la description clinique du patient.
- 2. Pour répondre aux demandes de prêt bancaire en fonction de votre situation personnelle.
- 3. Déclenchez des processus d'alarme en fonction des signaux reçus des capteurs.
- 4. La reconnaissance de formes.

### 1.6.2 Méthodes d'apprentissage automatique

Les classificateurs d'apprentissage automatique appartiennent à trois catégories principales.

#### 1.6.1. Apprentissage automatique supervisé

Dans l'apprentissage supervisé, un humain aide l'algorithme à apprendre et un scientifique des données agit comme un guide, indiquant à l'algorithme les résultats à trouver. Il en va de même lorsque l'on apprend aux enfants à identifier et à stocker les fruits dans leur mémoire. Dans l'apprentissage supervisé, l'algorithme apprend à partir d'ensembles de données déjà identifiés et le résultat est prédéfini. [24]



FIGURE 1.9 – Apprentissage supervisé [25]

### 1.6.2. Apprentissage automatique non supervisé

Dans l'apprentissage non supervisé, les machines n'ont besoin d'aucune aide pour apprendre. L'apprentissage non supervisé est une approche plus autonome dans laquelle les ordinateurs apprennent à reconnaître des processus et des modèles complexes sans supervision, une formation basée sur des données non étiquetées qui ne contiennent aucun résultat spécifique. [24]



FIGURE 1.10 – Apprentissage non supervisé [25]

### 1.6.3. Renforcement de l'apprentissage automatique

L'apprentissage par renforcement est une industrie complètement différente. Un système d'apprentissage, appelé agent dans ce contexte, peut observer son environnement, sélectionner et effectuer des actions, et finalement recevoir une récompense ou une punition (récompense négative). Les machines peuvent apprendre par elles-mêmes les meilleures stratégies connues sous le nom de lignes directrices pour gagner plusieurs récompenses au fil du temps. Une stratégie définit les actions qu'un agent doit entreprendre dans certaines situations. [25]



FIGURE 1.11 – Renforcement de l'apprentissage automatique [25]

### **1.6.3 les critères de choix de la méthode à utiliser pour un diagnostic industriel :**

Incapacité à sélectionner la meilleure méthode de diagnostic pour un système industriel particulier. Cela ne peut se faire qu'après avoir fait l'inventaire de vos besoins et des connaissances disponibles. Le but de la taxonomie est de structurer les processus nécessaires au maintien d'une méthode. Le plus performant, techniquement et économiquement. Les critères à prendre en compte avant de choisir une méthode de diagnostic sont :

- La nature de la cause du manque de localisation.
- Connaissance des symptômes associés aux troubles causés par des causes.
- Apprenez à mesurer les symptômes. Familiarisez-vous avec les moyens de traiter les symptômes.
- Connaissance des mécanismes physiques entre cause et effet.
- Liste des retours d'expérience.

## **1.7 Le Réseaux de neurones**

Un réseau de neurones est un système d'opérateurs non linéaires interconnectés qui reçoivent des signaux de l'extérieur via des entrées et fournissent des signaux de sortie. Ces réseaux de neurones sont des métaphores du traitement parallèle et distribué des structures cérébrales et de l'information, avec de multiples éléments de traitement appelés neurones. Chaque neurone fonctionne indépendamment de l'autre, faisant de l'ensemble un système parallèle hautement interconnecté. Les informations détenues par un réseau de neurones sont réparties entre tous ses composants et non stockées sous forme de symboles dans une partie de la mémoire. Les réseaux de neurones ne sont pas programmés pour effectuer des tâches spécifiques. Il est formé sur les données acquises grâce à un mécanisme d'apprentissage qui agit sur les composants du réseau pour effectuer la tâche souhaitée de manière optimale [26].

### **1.7.1 Les différents types de réseaux neuronaux**

#### **Réseaux de neurones Feedforward :**

Un réseau de neurones sans boucle (également appelé statique) est représenté sous la forme d'un graphe dont les nœuds sont des neurones. Les informations circulent de l'entrée à la sortie sans traçabilité. Ce type de réseau est utilisé pour effectuer une interpolation non linéaire, une modélisation de processus statique non linéaire ou des problèmes de classification de formation [27].

#### **Réseaux de neurones récurrents :**

Un réseau en boucle (récurrent) piloté par une ou plusieurs équations différentielles résulte de la composition des fonctions exécutées par chaque neurone et du délai associé à chaque connexion. Ces réseaux sont utilisés pour effectuer des tâches de modélisation de système dynamique et de contrôle de processus [28].

#### **Réseaux de neurones convolutifs :**

Un réseau de neurones convolutifs (CNN ou ConvNet - Convolution Neural Network) est un type spécifique de réseau de neurones à réaction multicouche couramment utilisé dans le traitement d'images et a été introduit par Fukushima en 1980 pour des tâches de reconnaissance de formes. Son architecture réseau s'inspire de la vision. Le cortex cérébral des animaux, popularisé dans la tâche de reconnaissance de caractères [29].

## **1.8 Conclusion**

Dans ce chapitre, nous avons parlé en général de la maintenance et de l'apprentissage automatique, et comment cela faisait partie du développement de la maintenance. Puisque dans la première partie nous avons parlé de la maintenance industrielle, ses types et objectifs, puis nous avons présenté quelques termes liés au diagnostic, ou dans la deuxième partie nous avons présenté une définition de l'apprentissage automatique et ses domaines d'utilisation et types. Nous avons également ajouté une définition des réseaux de neurones et de leurs types, et dans le deuxième chapitre, nous travaillerons sur un modèle de maintenance prédictive avec des réseaux de neurones .

# Chapitre 2

Modélisation en vue du diagnostic de la  
machine asynchrone

## 2.1 Introduction

Dans ce chapitre notre objectif est de présenter la machine asynchrone et ses composants et aussi de comprendre les différents types de défauts qui peuvent survenir dans une machine asynchrone et faire la modélisation de notre machine en état sain c'est-à-dire sans défaut et avec un défaut particulier (défaut statorique en court-circuit). Cela nous permet de faire plusieurs essais en changeons des paramètres pour pouvoir d'extraire les données nécessaires et faire notre diagnostic et classifier les défauts.

## 2.2 Machine asynchrone

La machine asynchrone, également appelée moteur asynchrone, est un type de moteur électrique qui fonctionne sur le principe de l'induction électromagnétique. Il se compose d'un stator fixe qui produit un champ magnétique rotatif et d'un rotor qui tourne légèrement plus lentement que le champ magnétique. Lorsque le rotor tourne, il crée un courant induit qui crée un autre champ magnétique qui produit le couple nécessaire pour faire tourner la machine. Les machines à induction sont couramment utilisées dans les applications industrielles pour convertir l'énergie électrique en énergie mécanique.

## 2.3 Constitution des machines asynchrones

Une machine asynchrone est constituée d'une partie fixe, le stator, et d'une partie tournante, le rotor. Contrairement aux machines synchrones ou à courant continu, seuls les bobinages du stator sont couplés à un réseau d'alimentation dont la tension (amplitude et fréquence) définit l'état magnétique de l'entrefer. L'enroulement du rotor est relié à lui-même. Les moteurs asynchrones n'ont ni enroulements d'excitation ni aimants permanents. Le flux rotorique nécessaire pour produire le couple électromagnétique est produit par induction [32].

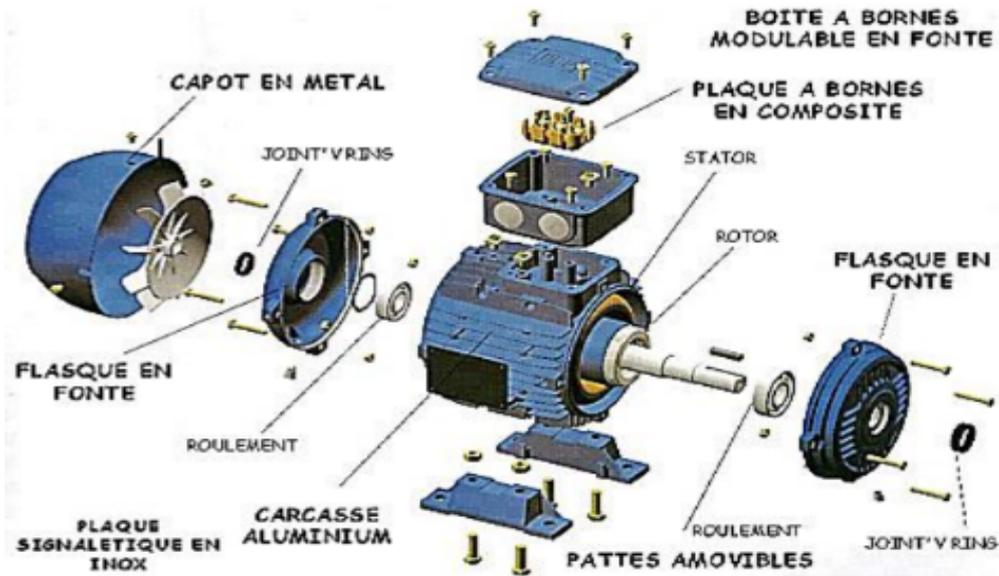


FIGURE 2.1 – Constitution d’une machine asynchrone triphasée [32].

### 2.3.1 Stator

Un circuit magnétique est un empilement de tôles d’acier sciées montrant les différentes fentes du stator, et les tôles sont généralement isolées avec une fine couche de vernis ou de silicate de sodium. L’enroulement du stator se compose de deux parties : les conducteurs encochés et les enroulements d’extrémité. Un conducteur fendu crée un champ magnétique dans l’entrefer qui provoque une conversion électromagnétique. Les bobines d’extrémité peuvent fermer le courant en organisant la circulation. Le but est de rendre la distribution de la force et du flux magnétomoteur dans l’entrefer la plus sinusoïdale possible afin de limiter les oscillations de couple électromagnétique [32].



FIGURE 2.2 – Stator d’une machine asynchrone [37].

### 2.3.2 Rotor

Le rotor présente quant à lui deux configurations dont le choix dépend de l'utilisation faite de la machine. Nous distinguons le rotor bobiné qui supporte un bobinage semblable à celui du stator où ces trois bobinages sont couplés en étoile et court-circuités sur eux même. La deuxième configuration qui est la plus usité dans l'industrie et qui est également celle utilisée au niveau des différents axes de recherche concernant la machine asynchrone est le rotor à cage d'écureuil. Les conducteurs des rotors à cage sont réalisés par coulage d'un alliage d'aluminium ou par des barres massives de cuivre préformées et frettés dans les tôles du rotor. On trouve deux types de rotor : bobiné ou à cage d'écureuil [32] .

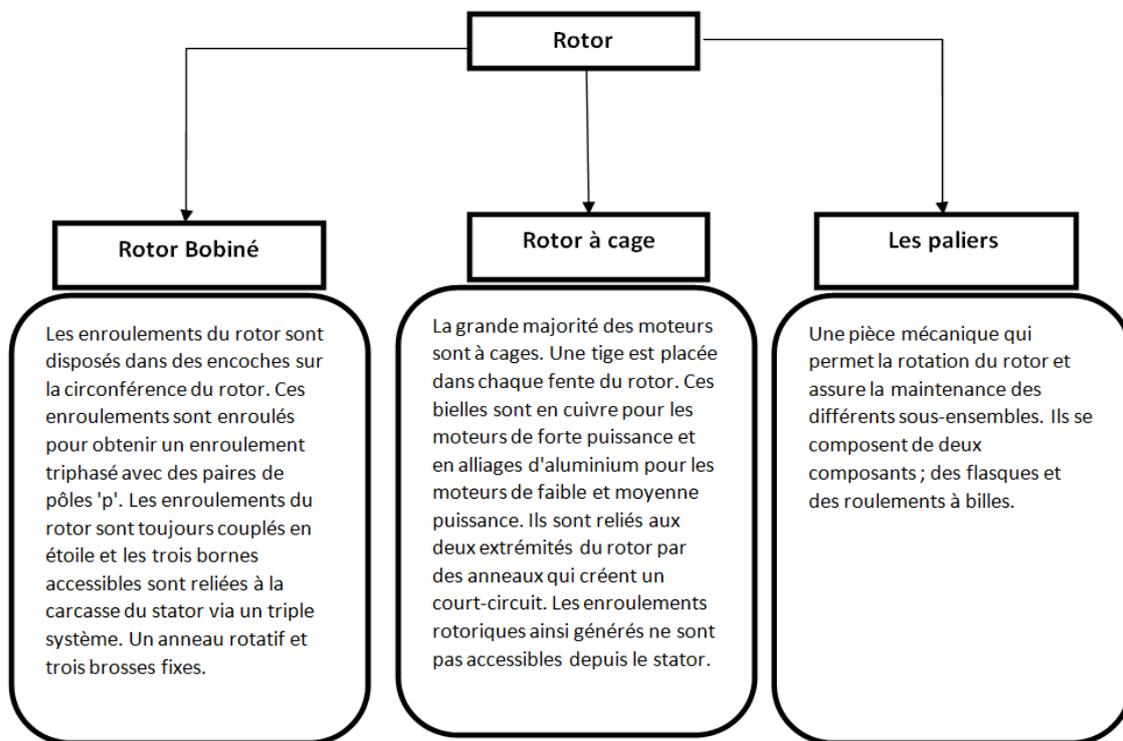


FIGURE 2.3 – Les types de rotor

## 2.4 principe de fonctionnement d'une machine asynchrone

Le fonctionnement d'une machine asynchrone est dû à l'interaction électromagnétique du champ magnétique tournant créé par les courants triphasés fournis depuis le réseau aux bobinages du stator et les courants induits dans les bobinages du rotor lorsque leurs

conducteurs sont déconnectés par principe. Champ tournant. Ainsi, le fonctionnement d'une machine asynchrone ressemble à celui d'un transformateur. Le stator correspond à

l'enroulement primaire et le rotor correspond à l'enroulement secondaire et peut tourner à une vitesse généralement donnée par le rapport :

$$n1 = \frac{f}{p} \quad (2.1)$$

$n1$  : vitesse de rotation tournant

$f$  : fréquence d'alimentation

$p$  : nombre pair de pole

L'interaction électromagnétique des deux parties d'une machine asynchrone (sans balai) n'est possible que si la vitesse du champ tournant ( $n1$ ) est différente de la vitesse du rotor ( $n$ ), c'est-à-dire  $n \neq n1$ .  $n1$ , lorsque le champ magnétique est stationnaire par rapport au rotor et qu'aucun courant n'est induit dans les enroulements du rotor. Le rapport

$$g = \frac{(n1 - n)}{n1} \quad (2.2)$$

$g$  : glissement d'une machine asynchrone.

## 2.5 Etude des différents défauts de la machine asynchrone

La machine asynchrone s'imposait par rapport à d'autre machine grâce à sa robustesse et son faible coût, elle peut parfois représenter différents types de défaillances, ces défaillances peuvent être soit d'origine électrique, soit d'origine mécanique pouvant touchés différents organes. Leurs causes sont très variées. Dans le but d'une présentation synthétique, ces défauts peuvent se classer en deux familles principales, les figures(2.4) et(2.6) regroupent ces causes [32].

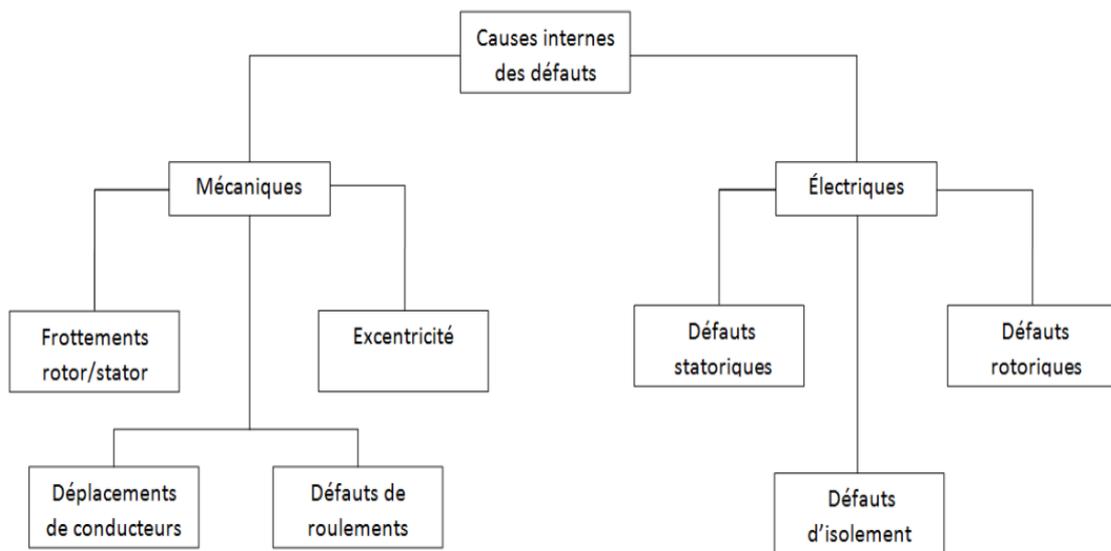


FIGURE 2.4 – causes internes des défauts de la machine asynchrone

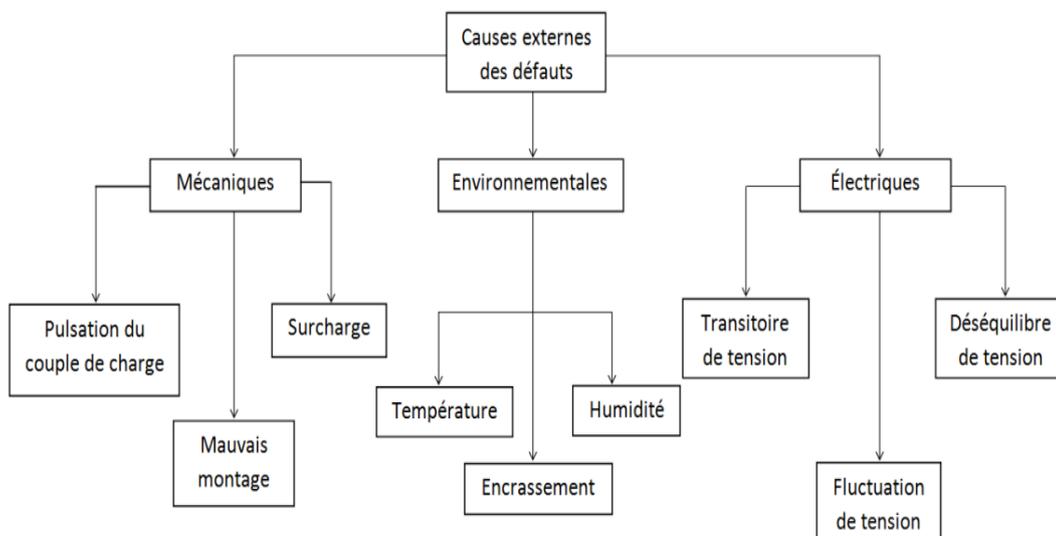


FIGURE 2.5 – causes externes des défauts de la machine asynchrone

### 2.5.1 Etude Statistique

Une étude statistique, effectuée par une compagnie allemande de systèmes industriels [49] sur les pannes des machines asynchrones de faible et moyenne puissance (50KW à 200KW) a donné les résultats suivants

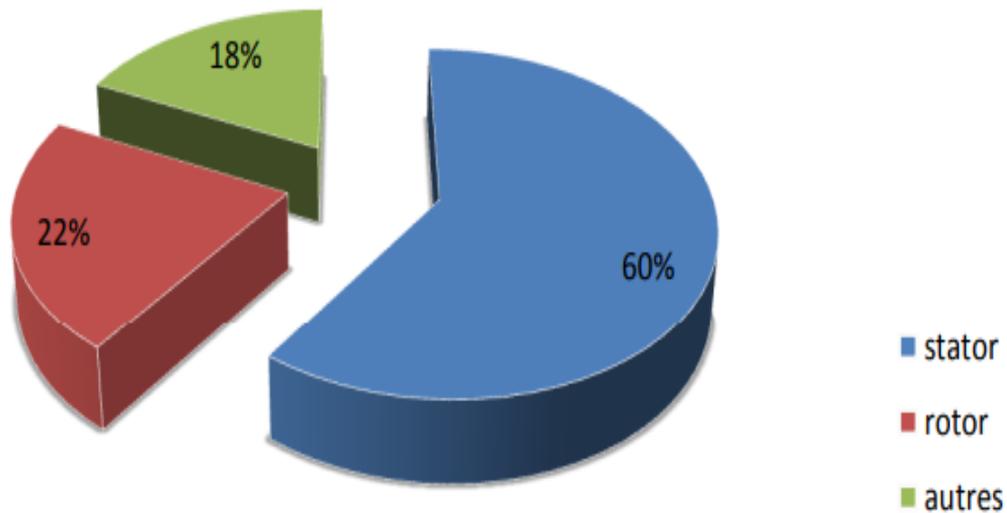


FIGURE 2.6 – Répartition des pannes des machines asynchrones de faible et moyennes puissances

## 2.6 Modélisation de la machine asynchrone

La modélisation est la description mathématique des processus techniques d'un système et constitue une étape essentielle de la recherche en électromécanique. Les phénomènes électromagnétiques dans les machines asynchrones sont généralement très complexes et difficiles à formuler mathématiquement. Les équations de la machine sont basées sur des outils mathématiques simplifiés représentés par les transformations de Clark, Concordia et Park [33].

### 2.6.1 Hypothèse de travail

La machine asynchrone considérée ci-dessous agit comme un moteur. La distribution et la configuration complexe des enroulements présentent des phénomènes tels que la saturation, l'hystérésis et les courants de Foucault difficiles à contrôler. Il faut alors ignorer les apparences et envisager certaines hypothèses simplificatrices pour aboutir à des résultats pleinement satisfaisants. Ses hypothèses sont :

- \* Symétrie parfaite.
- \* La densité de courant est uniforme à travers le conducteur.
- \* Les inductances propres constantes et les inductances mutuelles entre les deux en-

roulements sont des fonctions sinusoïdales de l'angle entre les axes magnétiques.

- \* Les flux sont additifs.
- \* Ignorer la saturation du circuit magnétique.
- \* Ignorer le phénomène d'hystérésis.
- \* Fil neutre non connecté (mode composite zéro).

## 2.6.2 La mise en équation du moteur asynchrone

Plusieurs expressions sont adoptées pour cette équation, selon les critères choisis pour identifier les enroulements du rotor et du stator. Le comportement d'une machine asynchrone peut être transformé en trois types d'équations [35] :

- \* Equations électriques
- \* Equations magnétiques
- \* Equations mécaniques

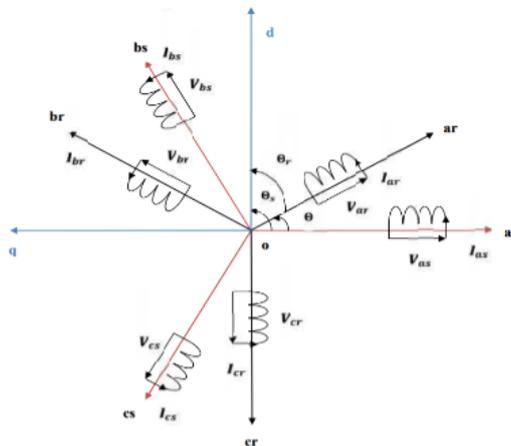


FIGURE 2.7 – Représentation de la MAS en régime quelconque [35].

- \* Equations électriques :

La loi de Faraday et la loi d'Ohm relie la tension aux bornes des enroulements à la somme du flux et du courant dans ces enroulements comme suit :

$$v = Ri + \frac{d\varphi}{dt} \quad (2.3)$$

En utilisant les hypothèses ci-dessus, les équations de tension de phase du stator et du rotor décrivant le comportement de la machine s'écrivent comme suit [35] :

$$\begin{cases} [V_{abcs}] = [R_s] \cdot [I_{abcs}] + \frac{d[\varphi_{abcs}]}{dt} \\ [V_{abcr}] = [R_r] \cdot [I_{abcr}] + \frac{d[\varphi_{abcr}]}{dt} \end{cases} \quad (2.4)$$

Les matrices de résistances au stator  $[R_s]$  et au rotor  $[R_r]$  sont données par [35] :

$$[R_s] = \begin{bmatrix} R_s & 0 & 0 \\ 0 & R_s & 0 \\ 0 & 0 & R_s \end{bmatrix}; [R_r] = \begin{bmatrix} R_r & 0 & 0 \\ 0 & R_r & 0 \\ 0 & 0 & R_r \end{bmatrix} \quad (2.5)$$

\* L'équation devient :

$$\begin{cases} \begin{bmatrix} V_{as} \\ V_{bs} \\ V_{cs} \\ V_{ar} \\ V_{br} \\ V_{cr} \end{bmatrix} = \begin{bmatrix} R_s & 0 & 0 \\ 0 & R_s & 0 \\ 0 & 0 & R_s \\ R_r & 0 & 0 \\ 0 & R_r & 0 \\ 0 & 0 & R_r \end{bmatrix} \cdot \begin{bmatrix} I_{as} \\ I_{bs} \\ I_{cs} \\ I_{ar} \\ I_{br} \\ I_{cr} \end{bmatrix} + \frac{d}{dt} \begin{bmatrix} \varphi_{as} \\ \varphi_{bs} \\ \varphi_{cs} \\ \varphi_{ar} \\ \varphi_{br} \\ \varphi_{cr} \end{bmatrix} \end{cases} \quad (2.6)$$

\* Equation magnétique :

Chaque flux interagit avec les courants dans toutes les phases, y compris lui-même (notion de flux réel/inductance) [35] :

L'équation de flux en fonction du courant est donnée par :

$$\begin{bmatrix} [\varphi_{is}] \\ [\varphi_{ir}] \end{bmatrix} = \begin{bmatrix} [L_{ss}] & [M_{sr}] \\ [M_{rs}] & [L_{rr}] \end{bmatrix} \cdot \begin{bmatrix} [I_{is}] \\ [I_{ir}] \end{bmatrix} \quad (2.7)$$

$\varphi_{is}$  et  $\varphi_{ir}$  des flux totalisés respectivement au stator et au rotor.

$$\begin{bmatrix} \varphi_{is} \\ \varphi_{ir} \end{bmatrix} = \begin{bmatrix} \varphi_{as} & \varphi_{bs} & \varphi_{cs} \\ \varphi_{ar} & \varphi_{br} & \varphi_{cr} \end{bmatrix}^t \quad (2.8)$$

Les matrices d'inductances au stator et au rotor sont données par :

$$\begin{cases} [L_{ss}] = \begin{bmatrix} l_s & M_s & M_s \\ M_s & l_s & M_s \\ M_s & M_s & l_s \end{bmatrix}; [L_{rr}] = \begin{bmatrix} l_r & M_r & M_r \\ M_r & l_r & M_r \\ M_r & M_r & l_r \end{bmatrix} \end{cases} \quad (2.9)$$

La matrice d'inductance mutuelle entre une phase du stator et une autre phase du rotor est donnée par :

$$[M_{sr}] = [M_{rs}] \cdot \begin{bmatrix} \cos\theta & \cos\left(\theta - \frac{4\pi}{3}\right) & \cos\left(\theta - \frac{2\pi}{3}\right) \\ \cos\left(\theta - \frac{2\pi}{3}\right) & \cos\theta & \cos\left(\theta - \frac{4\pi}{3}\right) \\ \cos\left(\theta - \frac{4\pi}{3}\right) & \cos\left(\theta - \frac{2\pi}{3}\right) & \cos\theta \end{bmatrix} \quad (2.10)$$

La matrice inductance mutuelle entre une phase rotorique et statorique sera donnée par :

$$[M_{sr}] = [M_{rs}]^T \quad (2.11)$$

\* Equation mécanique : Une fois qu'une machine asynchrone est chargée, son comportement est régi par les équations de base suivantes

$$C_{em} - Cr = J \frac{d}{dt} (\Omega r) + f.(\Omega r) \quad (2.12)$$

$$\Omega_r = \frac{\omega_r}{P} \quad (2.13)$$

## 2.7 Transformation triphasée - biphasée

L'objectif de cette conversion est de passer d'un système triphasé (abc) à un système diphasé ( $\alpha, \beta$ ). Il existe deux transformations principales. Transformation Clarke et Transformation Concordia. La transformée de Clarke préserve l'amplitude de la magnitude, mais pas la puissance ou le couple (doit être multipliée par un facteur de 3/2). D'autre part, la transformée de Concordia normalisée préserve la puissance mais pas l'amplitude [42].

### 2.7.1 Transformation de Clark

Le choix de la transformée non normalisée (Clark) est très pratique dans les commandes portant sur les grandeurs (d,q) que nous verrons plus loin. Passer par le facteur multiplicateur [35].

Cette figure permet de comprendre que le passage des coordonnées triphasées aux coordonnées biphasées consiste à projeter les coordonnées triphasées sur les axes  $\alpha$  et  $\beta$  [35] :

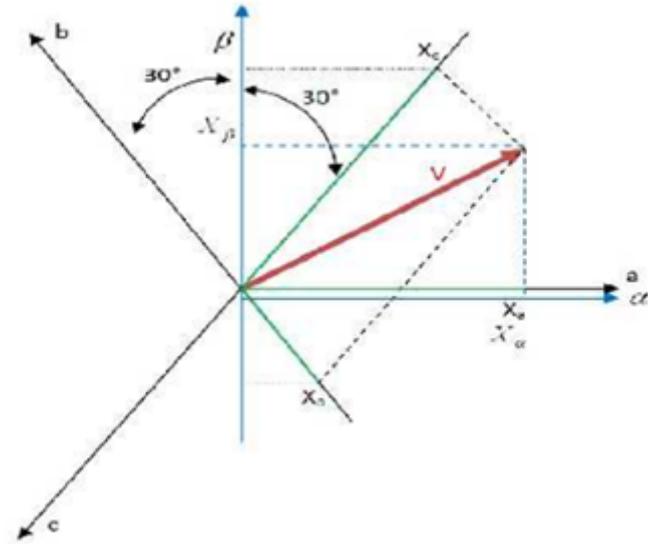


FIGURE 2.8 – Passage d'une base triphasée ( $abc$ ) à une base biphasée ( $\alpha, \beta$ ) et réciproquement [35].

$$[x_{\alpha\beta}] = [CL] \cdot [x_{abc}] \quad (2.14)$$

$x$  : représente les variables de la machine qui sont tensions, courants ou flux

$$\begin{bmatrix} x_{\alpha} \\ x_{\beta} \end{bmatrix} = \frac{2}{3} \begin{bmatrix} 1 & -\frac{1}{2} & -\frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \begin{bmatrix} x_a \\ x_b \\ x_c \end{bmatrix} \quad (2.15)$$

facteur  $2/3$  est arbitraire, mais choisi car il préserve l'amplitude du courant. Un système triphasé symétrique avec un courant sinusoïdal d'amplitude  $I_m$  produit un courant vectoriel d'amplitude  $I_m$  [35]

La transformée inverse est donnée par :

$$[x_{abc}] = [CL]^{-1} \cdot [x_{\alpha\beta}] \quad (2.16)$$

$$\begin{bmatrix} x_a \\ x_b \\ x_c \end{bmatrix} = \frac{2}{3} \begin{bmatrix} 1 & 0 \\ -\frac{1}{2} & \frac{\sqrt{3}}{2} \\ -\frac{1}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \begin{bmatrix} x_{\alpha} \\ x_{\beta} \end{bmatrix} \quad (2.17)$$

## 2.7.2 Transformation de Concordia

Les matrices de Clarke ne sont pas orthogonales, elles ne peuvent donc pas économiser de puissance instantanée. La transformée de Concordia notée [Co] est la matrice de Clarke orthogonalisée. Des composantes homopolaires sont introduites et tous les déséquilibres sont pris en compte.

Le choix de la transformation normalisée (Concordia) est souvent utilisé pour des raisons de symétrie. Utilisez la transformation Concordia lors de la modélisation du MAS. Cela permet d'écrire [35] :

$$\begin{bmatrix} x_\alpha \\ x_\beta \end{bmatrix} = [C_0] \begin{bmatrix} x_a \\ x_b \\ x_c \end{bmatrix} = \sqrt{\frac{2}{3}} \begin{bmatrix} 1 & -\frac{1}{2} & -\frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \begin{bmatrix} x_a \\ x_b \\ x_c \end{bmatrix} \quad (2.18)$$

## 2.7.3 Transformation de Park

Une transformation Park consiste en une transformation triphasée en 2 phases suivie d'une rotation. Ceci permet le passage de la référence (abc) à la référence ( $\alpha \beta$ ) à la référence d,q. Le système de coordonnées ( $\alpha\beta$ ) est toujours fixe par rapport au système de coordonnées abc. D'autre part d,q; le système de coordonnées est mobile et forme un angle avec le système de coordonnées ( $\alpha\beta$ ) fixe. C'est ce qu'on appelle l'angle de Park ou l'angle de transformation du Park[35].

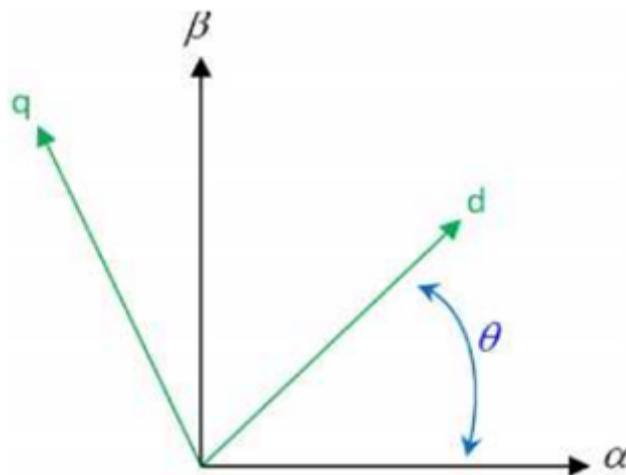


FIGURE 2.9 – Passage du système  $\alpha, \beta$  vers le système d,q

Pour simplifier ces équations, les critères de transformation de Park pour les quantités

de stator et de rotor doivent correspondre. Cela se fait en reliant les angles  $(\theta_s)$  et  $(\theta_r)$  par la relation [35] :

$$\theta_s = \theta_r + \theta$$

La matrice de Park est donnée par :

$$[P(\psi)] = \sqrt{\frac{2}{3}} \cdot \begin{bmatrix} \cos\psi & \cos(\psi - \frac{2\pi}{3}) & \cos(\psi - \frac{4\pi}{3}) \\ \sin\psi & \sin(\psi - \frac{2\pi}{3}) & \sin(\psi - \frac{4\pi}{3}) \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \quad (2.19)$$

Avec  $(\psi)$  est la position angulaire du système (d,q) par rapport au système d'axes réel (a,b,c). La matrice inverse du système est :

$$[P(\psi)]^{-1} = [P(\psi)]^t = \sqrt{\frac{2}{3}} \cdot \begin{bmatrix} \cos\psi & -\sin\psi & \frac{1}{\sqrt{2}} \\ \cos(\psi - \frac{2\pi}{3}) & -\sin(\psi - \frac{2\pi}{3}) & \frac{1}{\sqrt{2}} \\ \cos(\psi - \frac{4\pi}{3}) & -\sin(\psi - \frac{4\pi}{3}) & \frac{1}{\sqrt{2}} \end{bmatrix} \quad (2.20)$$

\* Equations électriques :

L'équation électrique peut s'écrire généralement sous la forme suivante :

$$[V_{abc}] = [R] \cdot [I_{abc}] + \frac{d[\varphi_{abc}]}{dt} \quad (2.21)$$

En appliquant la transformation inverse de Park  $[P(\psi)]^{-1}$

on obtient :

$$[P(\psi)]^{-1} \cdot [V_{dq0}] = [R] \cdot [P(\psi)]^{-1} \cdot [I_{dq0}] + \frac{d}{dt} \left\{ [P(\psi)]^{-1} \cdot [\varphi_{dq0}] \right\} \quad (2.22)$$

En multipliant l'équation par la transformée de Park, on obtient :

$$[V_{dq0}] = [R] \cdot [I_{dq0}] + \frac{d[\varphi_{dq0}]}{dt} + [P(\psi)] \cdot \left\{ \frac{d[P(\psi)]^{-1}}{dt} \right\} \cdot [\varphi_{dq0}] \quad (2.23)$$

On peut écrire :

$$P(\psi) \cdot \frac{d[P(\psi)]^{-1}}{dt} = \begin{bmatrix} 0 & -1 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \cdot \frac{d\psi}{dt} \quad (2.24)$$

Donc notre équation pourra s'écrire comme suit :

$$[V_{dq0}] = [R] \cdot [I_{dq0}] + \frac{d[\varphi_{dq0}]}{dt} + \begin{bmatrix} 0 & -1 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \cdot \frac{d\psi}{dt} \cdot [I_{dq0}] \quad (2.25)$$

Par conséquent, les tensions du stator et du rotor peuvent être exprimées comme :

$$\left\{ \begin{array}{l} \begin{bmatrix} V_{ds} \\ V_{qs} \end{bmatrix} = \frac{d}{dt} \begin{bmatrix} \varphi_{ds} \\ \varphi_{qs} \end{bmatrix} + \begin{bmatrix} 0 & -\frac{d\theta_s}{dt} \\ \frac{d\theta_s}{dt} & 0 \end{bmatrix} \cdot \begin{bmatrix} \varphi_{ds} \\ \varphi_{qs} \end{bmatrix} + \begin{bmatrix} R_s & 0 \\ 0 & R_s \end{bmatrix} \cdot \begin{bmatrix} I_{ds} \\ I_{qs} \end{bmatrix} \\ \begin{bmatrix} V_{dr} \\ V_{qr} \end{bmatrix} = \frac{d}{dt} \begin{bmatrix} \varphi_{dr} \\ \varphi_{qr} \end{bmatrix} + \begin{bmatrix} 0 & -\frac{d\theta_r}{dt} \\ \frac{d\theta_r}{dt} & 0 \end{bmatrix} \cdot \begin{bmatrix} \varphi_{dr} \\ \varphi_{qr} \end{bmatrix} + \begin{bmatrix} R_r & 0 \\ 0 & R_r \end{bmatrix} \cdot \begin{bmatrix} I_{dr} \\ I_{qr} \end{bmatrix} \end{array} \right. \quad (2.26)$$

Les pulsations des grandeurs statoriques et rotoriques sont données respectivement par :

$$\begin{cases} \frac{d\theta_s}{dt} = \omega_s \\ \frac{d\theta_r}{dt} = \omega_r \end{cases} \quad (2.27)$$

Ainsi, nous avons un système d'équations qui décrivent la tension du stator et du rotor en fonction du flux, du courant et de la pulsation du stator et du rotor[35] :

$$\begin{cases} V_{ds} = R_s \cdot I_{ds} - \omega_s \cdot \varphi_{qs} + \frac{d\varphi_{ds}}{dx} \\ V_{qs} = R_s \cdot I_{qs} - \omega_s \cdot \varphi_{ds} + \frac{d\varphi_{qs}}{dx} \\ V_{dr} = R_r \cdot I_{dr} - \omega_r \cdot \varphi_{qr} + \frac{d\varphi_{dr}}{dx} \\ V_{qr} = R_r \cdot I_{qr} - \omega_r \cdot \varphi_{dr} + \frac{d\varphi_{qr}}{dx} \end{cases} \quad (2.28)$$

\* Equations magnétiques : L'expression du flux dans l'axe (d,q) s'écrit généralement comme suit :

$$[\varphi_{dq0}] = [P(\psi)] \cdot [\varphi_{abc}] \quad (2.29)$$

En développant l'équation (3.31), nous arrivons au système matriciel des flux dans le stator et le rotor [35].

$$\begin{cases} [\varphi_{s(dq0)}] = [P(\theta_s)] \cdot \left\{ [L_{ss}] \cdot [P(\theta_s)]^{-1} \cdot [I_{s(dq0)}] + [M_{sr}] \cdot [P(\theta_r)]^{-1} \cdot [I_{r(dq0)}] \right\} \\ [\varphi_{r(dq0)}] = [P(\theta_r)] \cdot \left\{ [L_{rr}] \cdot [P(\theta_r)]^{-1} \cdot [I_{r(dq0)}] + [M_{sr}] \cdot [P(\theta_s)]^{-1} \cdot [I_{s(dq0)}] \right\} \end{cases} \quad (2.30)$$

Le système matriciel obtenu après développement de l'équation (3.32) est :

$$\begin{bmatrix} \varphi_{ds} \\ \varphi_{qs} \\ \varphi_{0s} \\ \varphi_{dr} \\ \varphi_{qr} \\ \varphi_{0r} \end{bmatrix} = \begin{bmatrix} (l_s - M_s) & 0 & 0 & \frac{3}{2}M_0 & 0 & 0 \\ 0 & (l_s - M_s) & 0 & 0 & \frac{3}{2}M_0 & 0 \\ 0 & 0 & (l_s + 2M_s) & 0 & 0 & 0 \\ \frac{3}{2}M_0 & 0 & 0 & (l_s - M_r) & 0 & 0 \\ 0 & \frac{3}{2}M_0 & 0 & 0 & (l_r - M_r) & 0 \\ 0 & 0 & 0 & 0 & 0 & (l_r + 2M_r) \end{bmatrix} \quad (2.31)$$

On pose :

$$\begin{cases} L_s = l_s - M_s \\ L_r = l_r - M_r \\ L_m = \frac{3}{2}M_{sr} \\ L_{0s} = l_s + 2M_s \\ L_{0r} = l_r + 2M_r \end{cases} \quad (2.32)$$

Dans la manière habituelle d'alimenter la structure des enroulements du stator et du rotor, la somme des courants du stator et du rotor est nulle, donc la composante homopolaire d'indice (o) est nulle.[35]

Dans ces conditions, le flux magnétique d'un système d'arbre diphasique est défini en fonction de trois paramètres  $L_s, L_r, L_m$ . Ainsi, l'expression du flux peut s'écrire :

$$\begin{cases} \varphi_{ds} = L_s \cdot I_{ds} + L_m \cdot I_{dr} \\ \varphi_{dr} = L_m \cdot I_{ds} + L_r \cdot I_{dr} \\ \varphi_{qs} = L_s \cdot I_{qs} + L_m \cdot I_{qr} \\ \varphi_{qr} = L_m \cdot I_{qs} + L_r \cdot I_{qr} \end{cases} \quad (2.33)$$

Les expressions des contraintes du stator et du rotor pour le système d'arbres (d,q) sont obtenues en substituant les expressions de flux dans l'équation (3.30) : [35]

$$\begin{cases} V_{ds} = R_s \cdot I_{ds} - \omega_s \cdot L_s \cdot I_{qs} - \omega_s \cdot L_m \cdot I_{qr} + L_m \cdot \frac{dI_{dr}}{dt} + L_s \cdot \frac{dI_{ds}}{dt} \\ V_{qs} = R_s \cdot I_{qs} + \omega_s \cdot L_s \cdot I_{ds} + \omega_s \cdot L_m \cdot I_{dr} + L_m \cdot \frac{dI_{qr}}{dt} + L_s \cdot \frac{dI_{qs}}{dt} \\ V_{dr} = R_r \cdot I_{dr} - \omega_r \cdot L_r \cdot I_{qr} - \omega_r \cdot L_m \cdot I_{qs} + L_m \cdot \frac{dI_{ds}}{dt} + L_s \cdot \frac{dI_{dr}}{dt} \\ V_{qr} = R_r \cdot I_{qr} + \omega_r \cdot L_r \cdot I_{dr} + \omega_r \cdot L_m \cdot I_{ds} + L_m \cdot \frac{dI_{qs}}{dt} + L_s \cdot \frac{dI_{qr}}{dt} \end{cases} \quad (2.34)$$

La machine étant un rotor à cage d'écuréuil, les paramètres du rotor apparaissant dans le système d'équations ne peuvent pas être mesurés. Pour surmonter cette limitation, nous devons changer les variables afin de pouvoir supprimer les différentes inductances mutuelles. [35] On pose donc :

$$\begin{aligned} I_{dr} &= \left(\frac{L_m}{L_r}\right) \cdot I'_{dr} \\ I_{qr} &= \left(\frac{L_m}{L_r}\right) \cdot I'_{qr} \\ \sigma &= 1 - \left(\frac{L_m^2}{L_s \cdot L_r}\right) \\ T_r &= \left(\frac{L_r}{R_r}\right) \end{aligned} \quad \text{Et } \sigma = 1 - \left(\frac{L_m^2}{L_s \cdot L_r}\right) \implies L_m^2 = (1 - \sigma) \cdot L_s \cdot L_r \quad (2.35)$$

Le rotor de la machine asynchrone est court-circuité ( $V_{dr} = V_{qr} = 0$ ), et en appliquant les changements de variables précédemment proposés, par les quatre paramètres électriques  $R_s, L_s, \theta, T_r$  On obtient une machine qui peut être caractérisé, les contraintes stator et rotor dans le système d'arbres (d,q) s'écrivent [35] :

$$\begin{cases} V_{ds} = R_s \cdot I_{ds} + L_s \cdot \frac{dI_{ds}}{dt} - \omega_s \cdot L_s \cdot I_{qs} + (1 - \sigma) \cdot L_s \cdot \frac{dI'_{dr}}{dt} - (1 - \sigma) \cdot \omega_s \cdot L_s \cdot I'_{qr} \\ V_{qs} = R_s \cdot I_{qs} + \omega_s \cdot L_s \cdot I_{ds} + L_s \cdot \frac{dI_{qs}}{dt} + (1 - \sigma) \cdot \omega_s \cdot L_s \cdot I'_{dr} + (1 - \sigma) \cdot L_s \cdot \frac{dI'_{qr}}{dt} \\ 0 = \frac{dI_{ds}}{dt} - \omega_r \cdot I_{qs} + \frac{1}{T_r} \cdot I'_{dr} + \left(\frac{dI'_{dr}}{dt}\right) - \omega_r \cdot I'_{qr} \\ 0 = \frac{dI_{qs}}{dt} + \omega_r \cdot I_{ds} + \frac{1}{T_r} \cdot I'_{qr} + \left(\frac{dI'_{qr}}{dt}\right) + \omega_r \cdot I'_{dr} \end{cases} \quad (2.36)$$

## 2.7.4 Choix du référentiel

Le problème à l'étude nécessite un choix judicieux du référentiel utilisé. Cependant, en choisissant un référentiel particulier pour (d,q) nous pouvons encore simplifier les équations pour les tensions stator et rotor. En fait, il existe trois référentiels possibles [35] :

### 2.7.4.1 Référentiel lié au stator

Noté que  $(\alpha, \beta)$  il est utilisé pour l'étude des grandes variations de la vitesse de rotation.

$$\frac{d\theta_s}{dt} = 0 \longrightarrow \frac{d\theta}{dt} = \omega_r, \text{ et } \psi = 0$$

Le système (3.32) devient

$$\left\{ \begin{array}{l} V_{\alpha s} = R_s \cdot I_{\alpha s} + \frac{d\varphi_{\alpha s}}{dt} \\ V_{\beta s} = R_s \cdot I_{\beta s} + \frac{d\varphi_{\beta s}}{dt} \\ V_{\alpha r} = R_r \cdot I_{\alpha r} - \omega_r \cdot \varphi_{\beta r} + \frac{d\varphi_{\alpha r}}{dt} \\ V_{\beta r} = R_r \cdot I_{\beta r} - \omega_r \cdot \varphi_{\alpha r} + \frac{d\varphi_{\beta r}}{dt} \end{array} \right. \quad (2.37)$$

#### 2.7.4.2 Référentiel lié au rotor

Noté que (x,y) Il est utilisé lorsque l'on considère la vitesse de rotation constante.

$$\frac{d\theta_r}{dt} = 0 \implies \frac{d\theta_s}{dt} = \omega, \text{ et } \psi = \theta_r \quad (2.38)$$

Le système devient

$$\left\{ \begin{array}{l} V_{xs} = R_s \cdot I_{xs} - \omega_s \cdot \varphi_{ys} + \frac{d\varphi_{xs}}{dt} \\ V_{ys} = R_s \cdot I_{ys} + \omega_s \cdot \varphi_{xs} + \frac{d\varphi_{ys}}{dt} \\ V_{xr} = R_r \cdot I_{xr} + \frac{d\varphi_{xr}}{dt} \\ V_{yr} = R_r \cdot I_{yr} + \frac{d\varphi_{yr}}{dt} \end{array} \right. \quad (2.39)$$

#### 2.7.4.3 Référentiel lié au champ tournant

il tourne à la vitesse de synchronisme, ce référentiel est utilisé lorsque la variation de la fréquence d'alimentation de la machine est petit [35].

$$\begin{aligned} \frac{d\theta}{dt} = \frac{d\theta_s}{dt} - \frac{d\theta_r}{dt} \implies \omega = \omega_s - \omega_r \implies g\omega_s = \omega_s - \omega \implies \omega_r = \frac{d\theta_r}{dt} = g\omega_s \\ \psi = \theta_s \end{aligned} \quad (2.40)$$

Le système(3.32) devient :

$$\left\{ \begin{array}{l} V_{ds} = R_s \cdot I_{ds} - \omega_s \cdot \varphi_{qs} + \frac{d\varphi_{ds}}{dt} \\ V_{qs} = R_s \cdot I_{qs} + \omega_s \cdot \varphi_{ds} + \frac{d\varphi_{qs}}{dt} \\ V_{dr} = R_r \cdot I_{dr} - \omega_r \cdot \varphi_{qr} + \frac{d\varphi_{dr}}{dt} \\ V_{qr} = R_r \cdot I_{qr} + \omega_r \cdot \varphi_{dr} + \frac{d\varphi_{qr}}{dt} \end{array} \right. \quad (2.41)$$

En appliquant la transformation de Park, les grandeurs physiques (flux, courant, tension) deviennent continues plutôt qu'alternatives. La description de l'état magnétique d'une machine à courant alternatif dans le cadre de référence (d,q) donne un modèle électromagnétique unifié qui s'applique à toutes les machines standard. Machine à aimant permanent et machine à réductance [35].

## 2.8 Passage du modèle biphasé vers une représentation d'état

Le contrôle des machines électriques est considéré comme le croisement de deux disciplines : le génie électrique, qui fournit des applications et des lois physiques dérivées des lois et des conversions d'énergie des circuits électriques et magnétiques, et l'auto-ingénierie, qui fournit des méthodes générales à partir des équations d'état. Peut faire. Utilisé pour définir les algorithmes de contrôle.

### 2.8.1 Représentation d'état de la machine asynchrone

Les représentations d'état permettent de modéliser des systèmes dynamiques sous forme matricielle à l'aide de variables d'état (cas linéaires). Cette représentation permet une description plus détaillée du système. Les variables d'état sont des variables physiques continues du système et doivent être indépendantes les unes des autres. Connaître toutes les variables d'état à un instant donné ( $t$ ) devrait nous permettre de calculer toutes les valeurs du système à un instant donné ( $t+dt$ ) La représentation d'état la plus courante pour les systèmes linéaires est :

$$X'(t) = A(t).X(t) + B(t).U(t)$$

$$Y(t) = C(t).X(t) + D(t).U(t)$$

X : vecteur qui représente les variables d'état

Y : vecteur qui représente les mesures

U : vecteur qui représente les commandes

A : matrice de dynamique

B : matrice de commande

C : matrice d'observation

D : matrice d'action directe

Nous pouvons généraliser la formule par :  $X' = f(X, Y)$

$Y = D(X, Y)$

Nos variables sont :  $I_{s\alpha}, I_{s\beta}, \varphi_{r\alpha}, \varphi_{r\beta}$  Comme variable d'état  $V_{s\alpha}, V_{s\beta}, \omega_s$  Comme grandeurs de commande .

### 2.8.2 Modèle du MAS sans défaut sous forme d'état dans le repère fixe ( $\alpha, \beta$ )

On peut adopter le modèle suivant obtenu après le développement mathématique et passant par l'écriture complexe des flux et des courants

$$\begin{aligned}
\frac{d}{dt} I_{s\alpha} &= -a_1 I_{s\alpha} + a_2 \varphi_{r\alpha} + a_3 W \cdot \varphi_{r\beta} + b V_{s\alpha} \\
\frac{d}{dt} I_{s\beta} &= -a_1 I_{s\beta} - a_3 W \cdot \varphi_{r\alpha} + a_2 \varphi_{r\beta} + b V_{s\beta} \\
\frac{d}{dt} \varphi_{r\alpha} &= a_4 I_{s\alpha} - a_5 \varphi_{r\alpha} + a_6 W \cdot \varphi_{r\beta} \\
\frac{d}{dt} \varphi_{r\beta} &= a_7 (\varphi_{r\alpha} \cdot I_{s\beta} - \varphi_{r\beta} \cdot I_{s\alpha}) - \frac{C_r}{J}
\end{aligned} \tag{2.42}$$

Avec :

$$\begin{aligned}
T_s &= \frac{L_s}{R_s}, T_r = \frac{L_r}{R_r}, \sigma = 1 - \frac{M^2}{L_r \cdot L_s}, \omega = PW, a_1 = \frac{R_s}{\sigma \cdot L_s} + \frac{1}{T_r} \left( \frac{1 - \sigma}{\sigma} \right), a_2 = \frac{K}{T_r} \\
a_3 &= KP, a_4 = \frac{M}{T_r}, a_5 = \frac{1}{T_r}, a_6 = P, a_7 = \frac{PM}{JL_r}, a_8 = \frac{C_r}{J}, b = \frac{1}{\sigma \cdot L_s}, K = \frac{M}{\sigma \cdot L_s \cdot L_r}
\end{aligned} \tag{2.43}$$

$$\tag{2.44}$$

Nous pouvons ainsi représenter le système sous la forme d'une représentation d'état définie dans le repère fixe :

$$\frac{d}{dt} \begin{bmatrix} I_{s\alpha} \\ I_{s\beta} \\ \varphi_{r\alpha} \\ \varphi_{r\beta} \end{bmatrix} = \begin{bmatrix} -a_1 & 0 & a_2 & a_3 \omega \\ 0 & -a_1 & -a_3 \omega & a_2 \\ a_4 & 0 & -a_5 & -\omega \\ 0 & a_4 & \omega & -a_5 \end{bmatrix} \cdot \begin{bmatrix} I_{s\alpha} \\ I_{s\beta} \\ \varphi_{r\alpha} \\ \varphi_{r\beta} \end{bmatrix} + \begin{bmatrix} b & 0 \\ 0 & b \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} V_{s\alpha} \\ V_{s\beta} \end{bmatrix} \tag{2.45}$$

Le couple électromagnétique donné dans le repère fixe ( $\alpha, \beta$ ) par la relation suivante :

$$C_{em} = \frac{PM}{L_r} (\varphi_{r\alpha} \cdot I_{s\beta} - \varphi_{r\beta} \cdot I_{s\alpha}) \tag{2.46}$$

### 2.8.3 Modèle du MAS en tenant compte du défaut de court-circuit statorique

L'équation d'état d'une machine asynchrone considérant le défaut de court-circuit statorique entre enroulements est obtenue en assemblant le vecteur d'état formé à partir du courant statorique et du flux rotorique avec l'entrée et la sortie formées respectivement

par la tension et le courant statorique Vous obtenez Par conséquent, le modèle d'état d'une machine asynchrone peut être décrit par le système d'équations non linéaires suivant

$$X'(t) = A(t).X(t) + B(t).U(t)$$

$$Y(t) = C(t).X(t) + D(t).U(t) \quad (2.47)$$

Tel que l'équation de  $X'(t)$  reste comme le modèle précédent dans (3.45) et

$$D = \sum_{q=1}^3 \frac{2}{3} \frac{\eta_{ccq}}{R_s} P(-\theta) Q(\theta_{ccq}) P(\theta)$$

ou :

$$P(\theta) = \begin{bmatrix} \cos(\theta) & \cos\left(\theta + \frac{\pi}{2}\right) \\ \sin(\theta) & \sin\left(\theta + \frac{\pi}{2}\right) \end{bmatrix}$$

$$Q(\theta_{ccq}) = \begin{bmatrix} \cos(\theta_{ccq})^2 & \cos(\theta_{ccq}) \sin(\theta_{ccq}) \\ \cos(\theta_{ccq}) \sin(\theta_{ccq}) & \sin(\theta_{ccq})^2 \end{bmatrix}$$

Avec :  $P(\theta)$  : matrice de rotation d'angle  $\theta$ .

$Q(\theta_{ccq})$  : matrice situant l'angle du bobinage en court-circuit.

$$\eta_{ccq} = \frac{n_{ccq}}{N_s} = \frac{\text{Nombre de spires en court - circuit}}{\text{Nombre de spires sur une phase saine}}$$

Et aussi la matrice  $C$  qui est égale

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

## 2.9 Block diagramme pour le cas sain et en défaut

### 2.9.1 Cas sans défaut

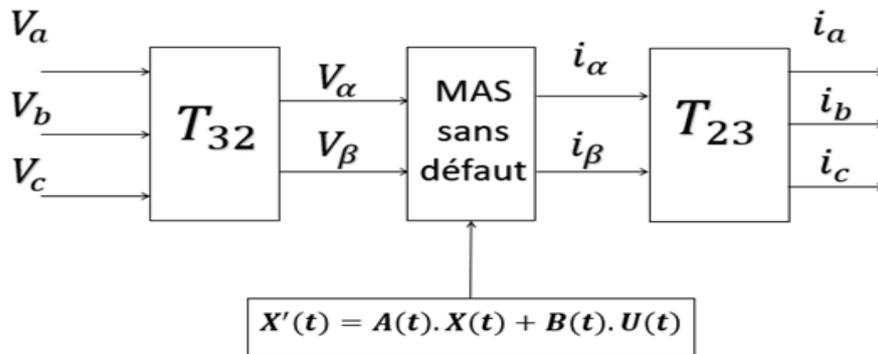


FIGURE 2.10 – Block diagramme pour le cas sain

### 2.9.2 Cas avec défaut

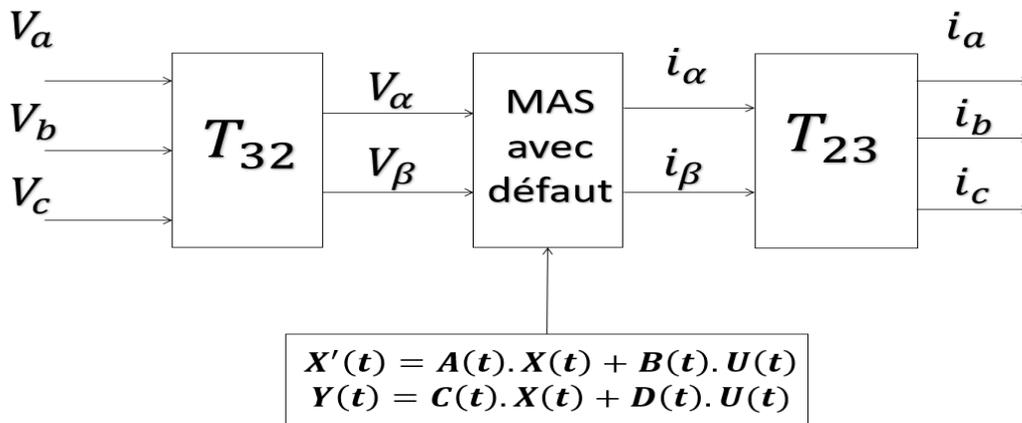


FIGURE 2.11 – Block diagramme pour le cas défaut de court-circuit

## 2.10 Simulation de la machine asynchrone sans défaut et avec défaut statorique

Une fois le modèle de la machine asynchrone créé, l'aspect simulation peut être géré sous l'environnement Matlab/Simulink, qui offre la possibilité de surveiller le compor-

tement du moteur dans différents états défectueux. Les paramètres de simulation de la machine asynchrone sont présentés à l'annexe A.

### 2.10.1 cas d'une machine saine

On a fait la simulation de la machine asynchrone à l'état sain dans un premier temps pour un démarrage à vide sous une alimentation triphasé nominale et équilibrée. A l'instant  $t=0.7$  seconde on applique la charge sur la machine et sa valeur nominal et 6 Nm.

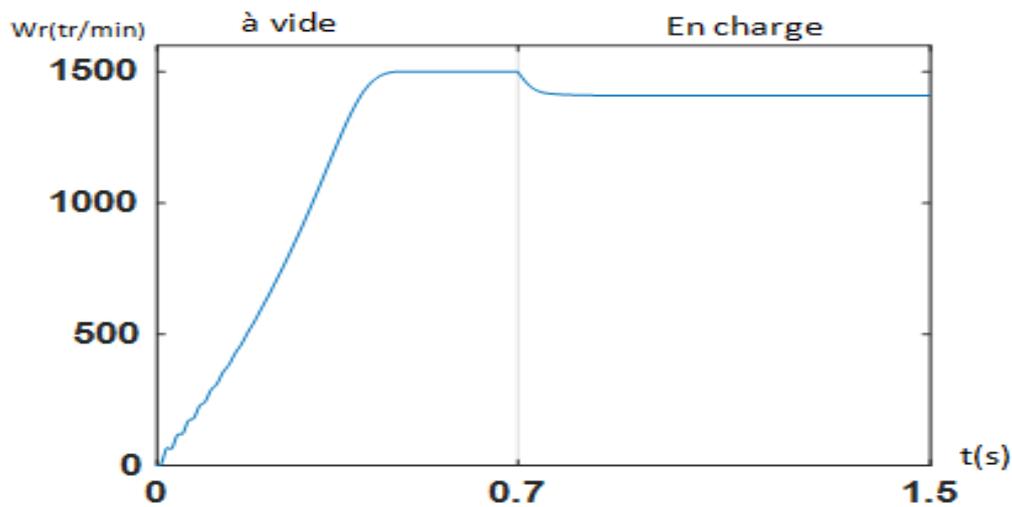


FIGURE 2.12 – Vitesse électrique

On note que la vitesse de rotation de la machine asynchrone atteint la valeur nominale et diminue un peu au moment où on applique la charge sur la machine.

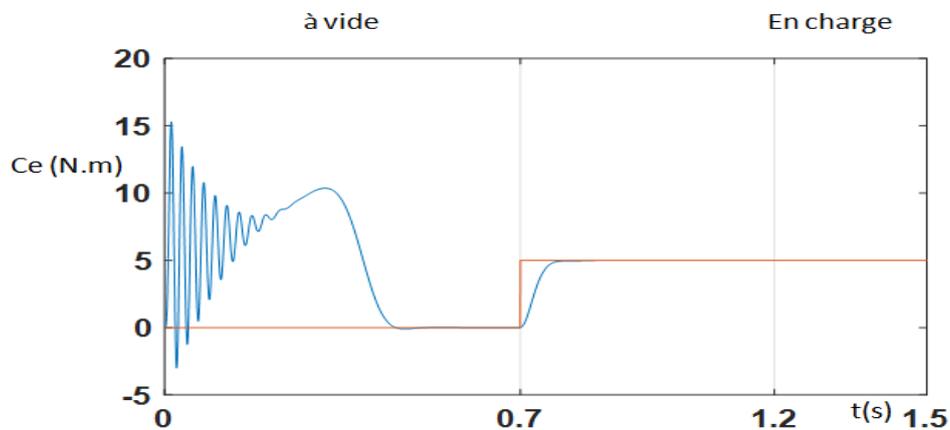


FIGURE 2.13 – Couplé électromagnétique

Le couple tend vers la valeur du couple de charge à l'instant  $t=0.7$  seconde

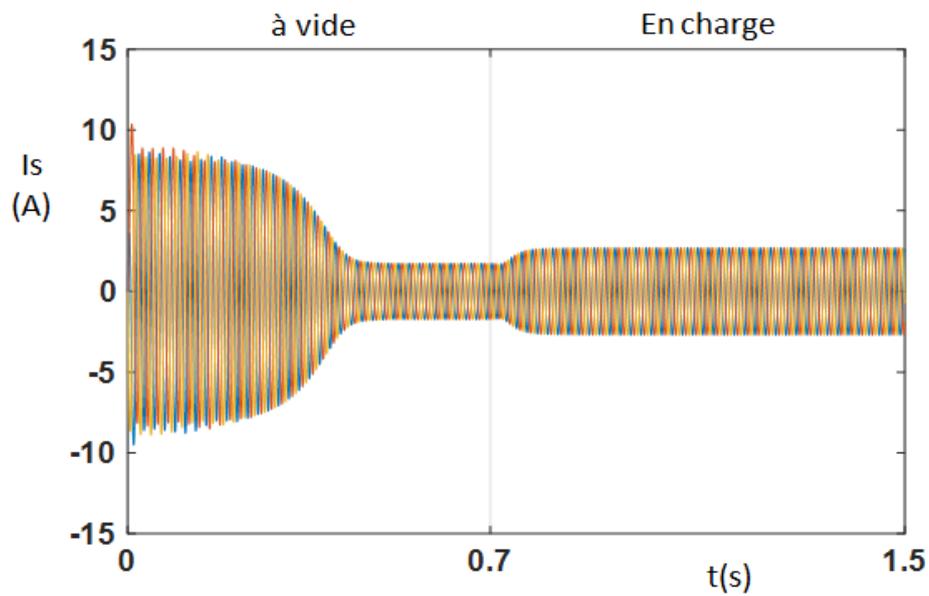


FIGURE 2.14 – Courants statorique

Cette figure illustre l'évolution des courants statorique de la machine, on constate que les trois courants de ligne sont bien équilibrés,

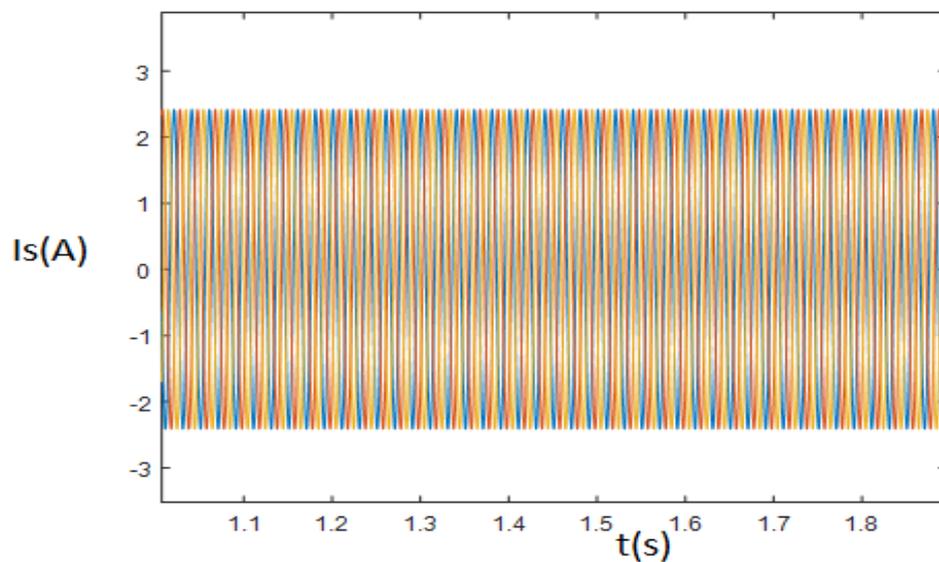


FIGURE 2.15 – Zoom des courants statorique

## 2.11 Cas d'un défaut de court-circuit entre spire

La simulation numérique est réalisée avec la machine fonctionnant en régime établi afin de bien voir le comportement exact de la machine par rapport à le défaut appliquée (Défaut de court-circuit entre spires de 10 sur la phase as de la machine asynchrone à charge moyenne, alimentée directement par le réseau).

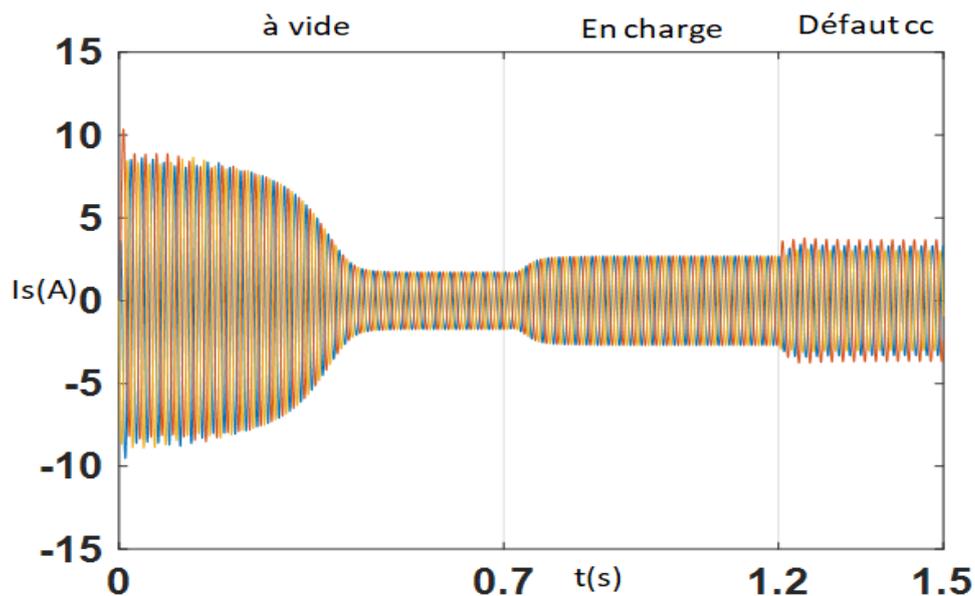


FIGURE 2.16 – Courants statorique

La figure montre à quoi ressemblent les trois courants d'une machine asynchrone lorsque le défaut statorique est appliqué sachant que le nombre de spires de chaque phase est de 160 spires.

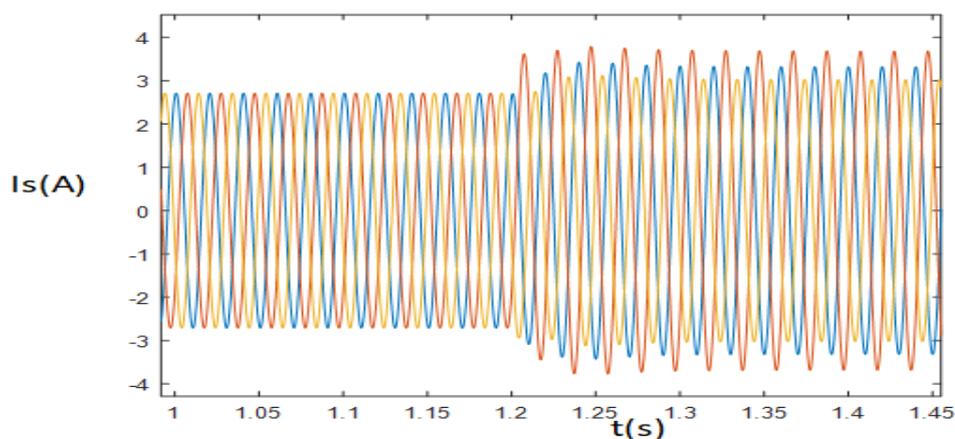


FIGURE 2.17 – Zoom des courants statorique

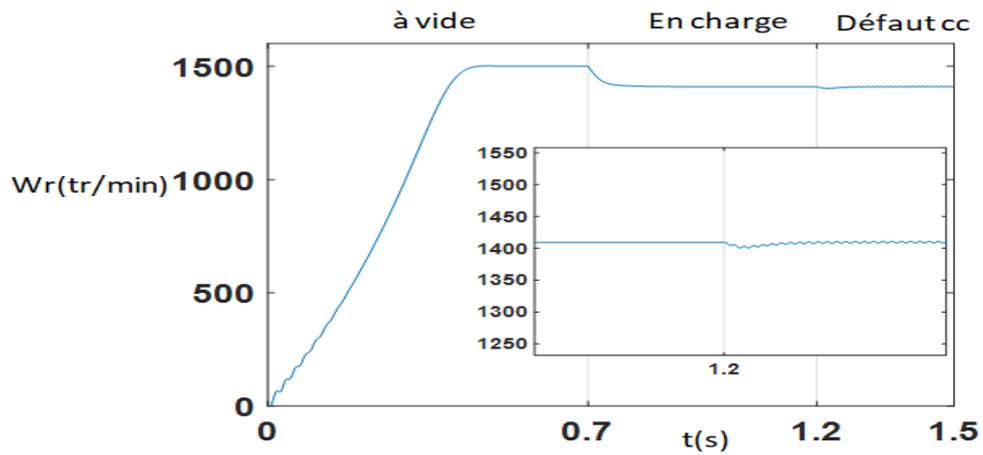


FIGURE 2.18 – Vitesse électrique

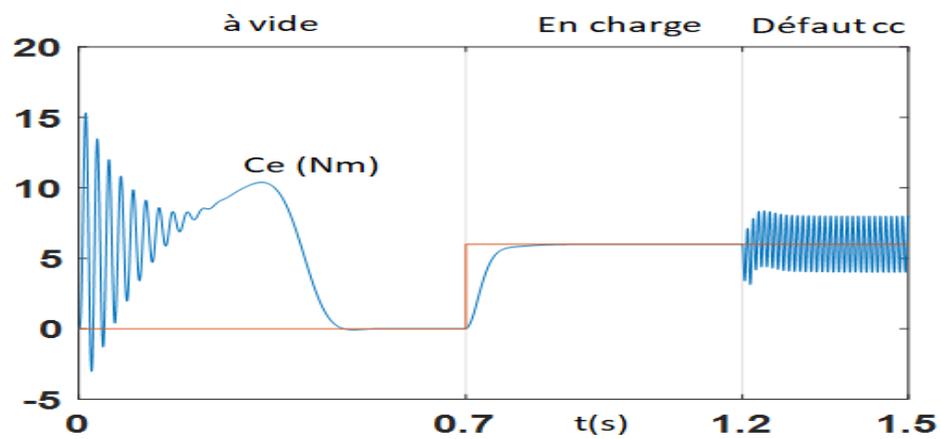


FIGURE 2.19 – Couple électromagnétique

Les figures ( 18 et 19 ) montrent la présence d'ondulations importantes dans les courbes de vitesse et de couple électromagnétiques, ce qui signifie de fortes vibrations mécaniques.

## 2.12 Conclusion

Dans ce chapitre, nous avons pu connaître les défauts communs les plus importants, et nous avons besoin d'équations mathématiques, car c'est le seul moyen qui nous aide à créer un modèle de la machine asynchrone dans Simlink /Matlab, qui simule la réalité. et aussi nous permet de voir son comportement et sa réaction lorsqu'il est sous l'influence de la charge et le défaut de court-circuit. Nous nous sommes concentrés sur la modélisation de défauts statoriques, notamment les défauts de court-circuit, car ils représentent plus de 60 des défauts d'une machine asynchrone par rapport à un rotor. Et il est considéré la cause racine pour apparaître les autres défauts. Nous avons pu réduire et simplifier le nombre d'équations dans le modèle grâce à une transformation de 3 phases à 2 phases appliquée aux enroulements du stator et du rotor.

# Chapitre 3

Application des PDM-ANN en vue dans le diagnostic de La MAS

### **3.1 Introduction :**

Dans ce chapitre, nous appliquerons la méthode des réseaux neuronaux pour détecter, localiser et classifier les défauts statoriques de court-circuit dans les machines asynchrones. Pour bien maîtriser ces défauts, il est nécessaire de fournir au réseau de neurones des données d'entrée et de sortie afin de construire un modèle efficace. Une fois que nous aurons injecté les données indéfinies, nous obtiendrons des résultats de prédiction, nous permettant de déterminer à quelle classe appartient le défaut (phase a, phase b ou phase c). Ensuite, nous comparerons les résultats du modèle avec les résultats attendus pour évaluer sa performance.

### **3.2 La classification :**

la classification est un processus d'attribution de classes ou de catégories à des données ou des objets en fonction de leurs caractéristiques. Dans le domaine spécifique de l'analyse des défauts statoriques de court-circuit, la classification permet de déterminer sur quelle phase chaque défaut s'est produit, ce qui facilite l'adoption de mesures correctives spécifiques. Les réseaux neuronaux sont une méthode couramment utilisée pour entraîner des modèles de classification afin de reconnaître les schémas et les caractéristiques associés à chaque classe de défaut.

### **3.3 Approche basée sur les réseaux de neurones artificiels pour le diagnostic ,la détection et la classification des défauts :**

L'utilisation des réseaux de neurones artificiels pour le diagnostic, la détection et la classification des défauts dans les machines asynchrones est une méthode prometteuse et efficace. Les réseaux de neurones sont capables d'apprendre à partir de grandes quantités de données et de détecter des schémas complexes, ce qui les rend particulièrement adaptés pour diagnostiquer les défauts de la machine asynchrone.

Dans cette approche, un modèle de réseau de neurones est entraîné à partir de données d'entrée représentant les caractéristiques mesurées de la machine, telles que les vibrations,

les courants et les températures. Le modèle apprend à associer ces caractéristiques à des défauts spécifiques, ce qui lui permet de détecter et de classer automatiquement les défauts lorsqu'il est confronté à de nouvelles données non étiquetées.

L'un des avantages clés de cette approche est sa capacité à détecter les défauts précocement, ce qui permet d'intervenir rapidement pour éviter des dommages supplémentaires et réduire les temps d'arrêt. De plus, les réseaux de neurones artificiels peuvent traiter efficacement des données complexes et hétérogènes provenant de différentes sources de surveillance de la machine, ce qui les rend polyvalents pour le diagnostic des défauts.

Il est important de noter que l'efficacité de cette approche dépend de la disponibilité de données de haute qualité et en quantité suffisante pour entraîner le modèle. De plus, une expertise en modélisation et en gestion des données est nécessaire pour obtenir des résultats précis et fiables. Malgré ces défis, l'utilisation des réseaux de neurones artificiels offre un potentiel significatif pour améliorer le diagnostic et la détection des défauts dans les machines asynchrones, ce qui contribue à une maintenance préventive efficace et à une meilleure performance globale de la machine.

### 3.4 Avantages des RNA dans la classification des défauts :

Les réseaux de neurones artificiels (RNA) offrent de nombreux avantages dans la classification des défauts des machines tournantes industrielles :

- **Extraction de caractéristiques complexes :**

Les RNA sont capables d'apprendre des caractéristiques pertinentes à partir de données brutes, ce qui les rend adaptés à l'analyse de signaux complexes tels que les mesures de vibration, les signaux électriques, et plus encore. Ils peuvent détecter des motifs non évidents pour les humains et les utiliser pour la classification des défauts.

- **Adaptabilité aux nouvelles données :**

Les RNA sont flexibles et peuvent s'adapter à de nouvelles données, améliorant ainsi leurs performances à mesure que de nouvelles informations deviennent disponibles. Cela

permet une mise à jour continue du modèle de classification des défauts, ce qui est essentiel dans un environnement industriel en constante évolution.

- **Gestion de données hétérogènes :**

Les RNA sont capables de traiter différents types de données provenant de sources de surveillance variées pour les machines tournantes. Ils peuvent intégrer des données provenant de multiples capteurs et les traiter de manière cohérente pour la classification des défauts. En somme, les RNA présentent des avantages significatifs dans la classification des défauts des machines tournantes industrielles. Leur capacité à extraire des caractéristiques complexes, à s'adapter aux nouvelles données et à gérer des données hétérogènes les rendent des outils puissants pour l'identification et la classification des défauts dans ces machines.

### **3.5 Avantages et implications de l'application de la classification des défauts :**

L'application de la classification des défauts dans la machine asynchrone offre de multiples avantages et a des implications importantes. En premier lieu, elle permet une détection précoce des défauts, ce qui permet d'entreprendre des actions de maintenance préventive avant que les problèmes ne s'aggravent et ne perturbent la production. Cela se traduit par une réduction des coûts de maintenance, des temps d'arrêt et des interruptions de production. De plus, l'utilisation de modèles de classification basés sur des réseaux de neurones artificiels assure une analyse précise et fiable des données, même dans des situations complexes et changeantes.

Il est toutefois essentiel de souligner que l'application de la classification des défauts requiert une collecte de données appropriée et de haute qualité, ainsi qu'une expertise en matière de modélisation et de gestion des données. La mise en place d'un système de surveillance en temps réel et l'intégration du modèle de classification peuvent également présenter des défis techniques et organisationnels. Néanmoins, les avantages potentiels en termes de maintenance prédictive et d'optimisation des performances de la machine asynchrone justifient pleinement ces efforts.

## 3.6 Application de classification des défauts dans la machine asynchrone industrielle par la méthode de réseaux de neurones :

L'application des réseaux de neurones pour la classification, le diagnostic et la détection défauts dans une machine asynchrone industrielle met en évidence l'importance de la classification des défauts. Elle souligne l'importance du diagnostic précoce des défauts et met en évidence les conséquences des défauts non détectés. Les réseaux de neurones artificiels sont présentés comme une solution prometteuse en raison de leur capacité à apprendre à partir de grandes quantités de données et à détecter des schémas complexes. Les avantages potentiels de cette approche comprennent la détection précoce des défauts, la réduction des temps d'arrêt et des coûts de maintenance, ainsi que l'amélioration globale de la fiabilité et de la performance de la machine.

## 3.7 Diagnostic et localisation des défauts statorique de la machine asynchrone :

### 3.7.1 Choix des variables d'entrées du $RN_{cc}$

Afin d'assurer le succès de l'application d'une méthode de diagnostic de défaut basée sur des réseaux de neurones, il est essentiel de disposer d'une richesse appropriée de données disponibles qui servent de données d'entrée pour chaque défaut. Les entrées des réseaux de neurones doivent être des indicateurs significatifs du défaut détecté. Pour sélectionner l'indicateur approprié, il est recommandé de trouver les paramètres qui fournissent le plus d'informations sur l'état du système [44].

Le défaut de court-circuit dans les trois phases du stator est évident, et les résultats de l'expérience menée dans nos travaux ont montré que les meilleures performances de diagnostic et la localisation de la phase défectueuse du court-circuit entre spires sont obtenues en utilisant comme un représentatif des paramètres du défaut d'énergie de décomposition en ondelettes D'après notre étude (B.Bessam, 2015), l'énergie de décomposition en ondelettes est un bon paramètre représentatif du défaut de discrimination de phase affecté par le défaut de court-circuit entre spires.

#### 4.1.1. Diagnostic à partir d'analyse par des ondelettes

Avant d'appliquer la transformée en ondelettes discrètes (TOD), nous devons d'abord déterminer le type d'ondelettes parent et le nombre de niveaux de décroissance

- **Choix du type de l'ondelette mère**

Les ondes Daubechies 40 (db40) sont souvent utilisées comme forme d'onde mère car cette fonction de mise à l'échelle réduira les interférences inévitables entre les bandes de fréquences [48].

- **Choix du nombre de niveaux de décomposition**

Le nombre approprié de niveaux de décroissance  $n_{ls}$  dépend de la fréquence d'échantillonnage  $f_e$  du signal à analyser. Pour toutes les approches de diagnostic basées sur la décomposition en ondelettes, le nombre de niveaux doit être choisi judicieusement pour permettre aux signaux de niveau supérieur (approximation et détail) de couvrir toute la gamme de fréquences le long de la configuration des composants en raison des changements de défauts au fur et à mesure que nous exploitons les systèmes. A partir du cas suivant, le nombre minimum de niveaux de décomposition nécessaires pour obtenir un signal approché ( $\alpha$ ) peut être calculé de telle sorte que la borne supérieure de sa bande de fréquence associée soit inférieure ou proche de la fréquence fondamentale [45] :

$$2^{-(n_{LS}+1)} f_e < f \quad (3.1)$$

En effet, le niveau de décomposition du signal d'approximation qui inclut les harmoniques autour du fondamental, est le nombre entier ( $n_{LS} + 2$ ) exprimé par [47] :

$$n_{ls} = \text{int}\left(\frac{\log\left(\frac{f_e}{f}\right)}{\log(2)}\right) \quad (3.2)$$

Donc pour une fréquence d'échantillonnage de  $f_e = 10H_z$ , la fréquence d'alimentation  $f = 50H_z$ , le nombre de décomposition est :

$$n_{LS} = \text{int}\left(\frac{\log\left(\frac{10^5}{50}\right)}{\log(2)}\right) + 2 = 9 \text{ niveau} \quad (3.3)$$

Une valeur de 9 ou plus pour  $n_{LS}$  fournit une bonne interprétation de ce phénomène. En effet, les modifications de ces signaux reflètent clairement les modifications harmoniques liées aux défauts dans les conditions transitoires.

Le processus de décomposition peut être répété, décomposant successivement des approximations successives de sorte que le signal est décomposé en de nombreuses composantes à haute résolution. C'est ce qu'on appelle un arbre de décomposition en ondelettes. Le processus d'analyse est itératif et peut théoriquement continuer indéfiniment. En pratique, la décomposition ne peut se poursuivre que jusqu'à ce que chaque détail individuel se compose d'un échantillon ou d'un pixel[46].

Le signal  $S'(S' = (S'_1, S'_1, S'_1))$  est un signal temporel discret qui est décomposé en ses versions approchées et détaillées en utilisant plusieurs analyses de résolution. Les premiers coefficients de décomposition sont a1 et d1, où a1 est la version approximative du signal d'origine S et d1 est la représentation détaillée du signal d'origine S'.

Pour décomposer un signal dans toute la gamme de fréquences, la décomposition par ondelettes peut être utilisée [46] :

$$f(d_j) \in [2^{-(j+1)} f_e, 2^{-j} f_e] \quad (3.4)$$

$$f(n_a) \in [0, 2^{-(n+1)} f_e] \quad (3.5)$$

Avec :

n : entier Natural

$d_j : (j \in [n; 1])$

Le tableau suivant indique les différentes bandes de fréquence obtenues par la décomposition en ondelettes discrète.

Niveau de l'ondelette	Bande de fréquence
Approximée 9	[0 9.765] HZ
Détail 9	[9.765 19.531] HZ
Détail 8	[19.531 39.062] HZ
Détail 7	[39.062 78.125] HZ
Détail 6	[78.125 156.25] HZ
Détail 5	[156.25 312.5] HZ

TABLE 3.1 – les différentes bandes de fréquence obtenues

Quand le défaut de court-circuit entre spires apparaît, l'information de défaut dans le signal du courant statorique est incluse dans chaque bande de fréquence résultante de la

décomposition en ondelettes. En calculant l'énergie associée à chaque niveau ou à chaque nœud de décomposition, on peut construire un outil de diagnostic très efficace. La valeur propre d'énergie de chaque bande de fréquence est définie par [43] :

$$E_j = \sum_{K=1}^{K=n} D_{j,K}^2 n$$

j : le niveau de décomposition.

Les valeurs propres d'énergie des niveaux de décroissance contiennent les informations des signaux générés par les capteurs du moteur asynchrone, et le suivi de ces valeurs peut être utilisé pour diagnostiquer les défauts de la machine et on peut également déterminer le degré de défaut. L'écart d'une valeur propre donnée indique la gravité du défaut.

### 3.7.2 Energie de la décomposition d'ondelette en présence d'un défaut statorique

La figure montre la variation d'énergie dans les gammes de fréquence de la décomposition en ondelettes multiniveaux pour le cas d'une machine sans défaut et avec un défaut de type court-circuit entre spires (5% en phase as, 5 % en phase b, 5% en CS- phase). Le calcul de l'énergie stockée à chaque niveau de décomposition confirme l'augmentation des signaux de détail et d'approximation, notamment au niveau 7

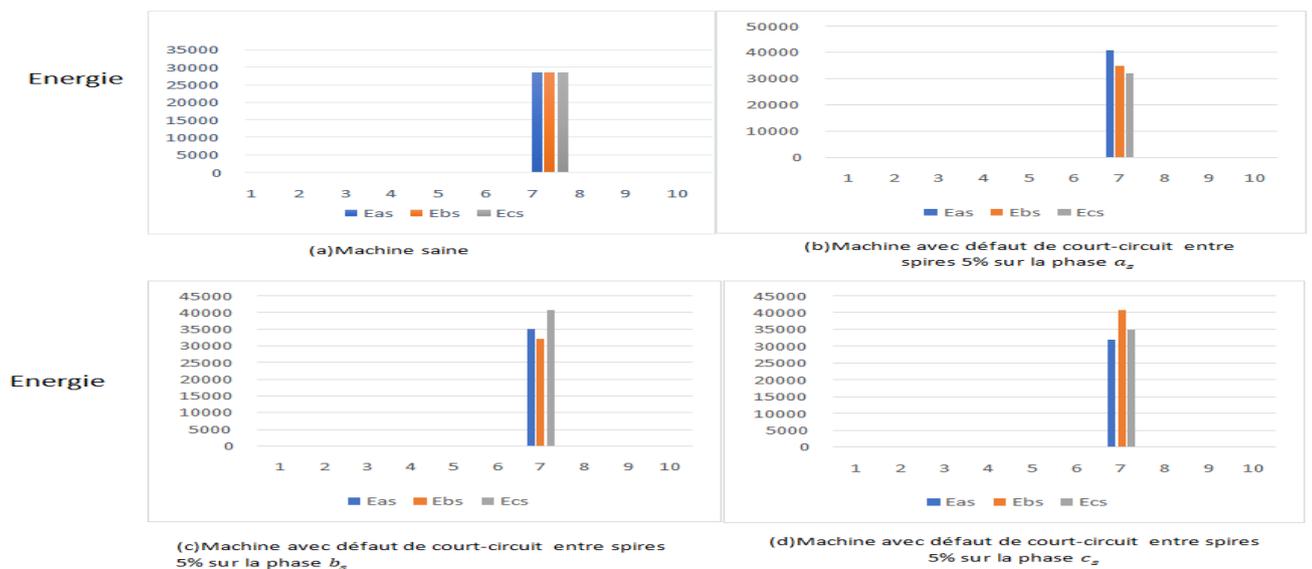


FIGURE 3.1 – Les variations de l'énergie dans la bande de fréquence (db40)

La figure suivante représente les caractéristiques d'énergie stockée à 7 niveaux ( $E_{as}$ ,  $E_{bs}$ ,  $E_{cs}$ ) des défauts dans les phases ( $a_s$ ,  $b_s$ ,  $c_s$ ) en fonction du nombre de courts-circuits entre spires ( $n$ ) de la charge moyenne.

**L'analyse de ces caractéristiques montre que :**

\* L'énergie stockée dans la phase de niveau 7 affectée par le défaut est la plus importante, d'autant plus que le nombre de spires en court-circuit augmente.

\* L'effet d'un défaut de court-circuit entre les spires d'une phase ne fait pas se croiser les énergies des autres phases, considérées comme saines.

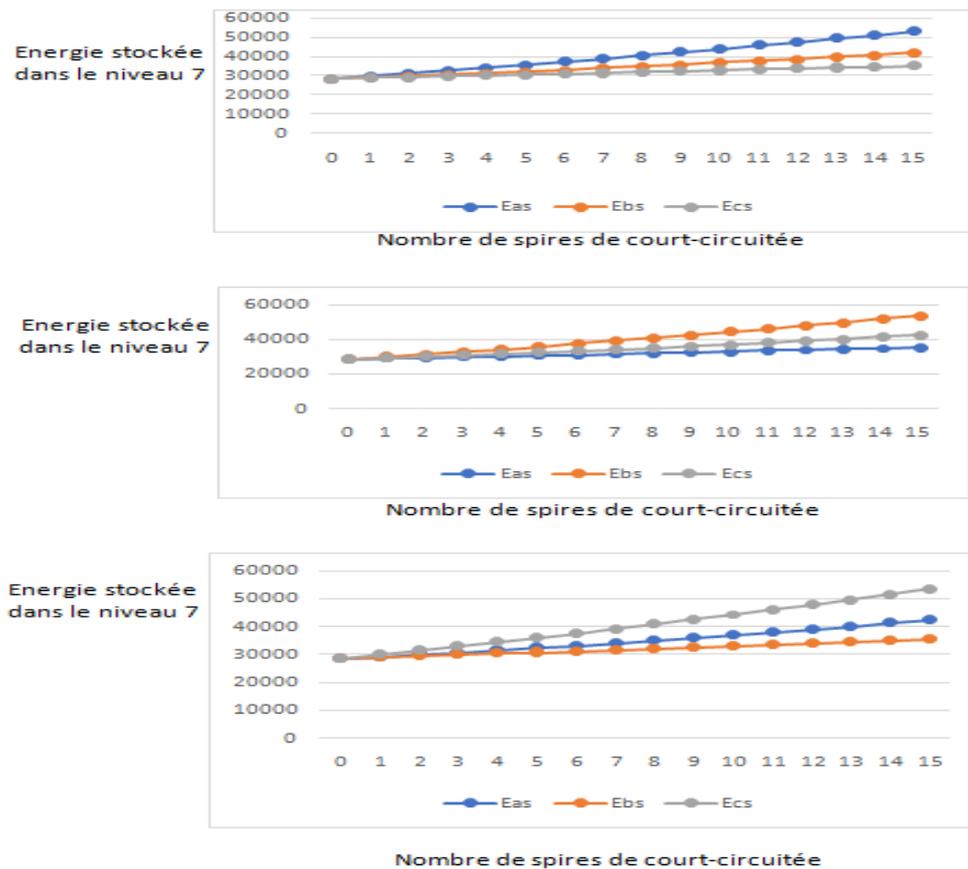


FIGURE 3.2 – Evolution de l'énergie stockée dans le niveau 7 en fonction des courts circuits entre spires sur les phases  $a_s$ ,  $b_s$ ,  $c_s$

### 3.7.3 Etude de l'énergie de la décomposition d'ondelette en fonction de la charge

L'analyse est effectuée en considérant une machine fonctionnant sous des charges variables, plus précisément deux charges, 50% et 100% de la charge nominale. En faisant varier la charge, on constate que l'énergie stockée dans la surface 7 est parfaitement discriminante.

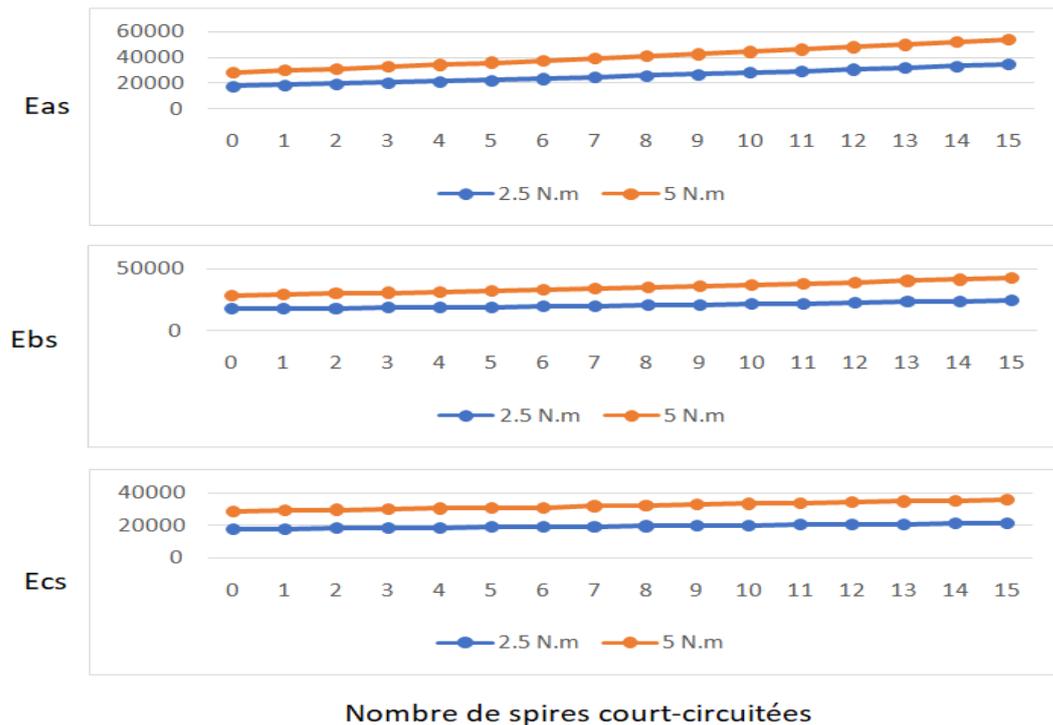


FIGURE 3.3 – Phase a

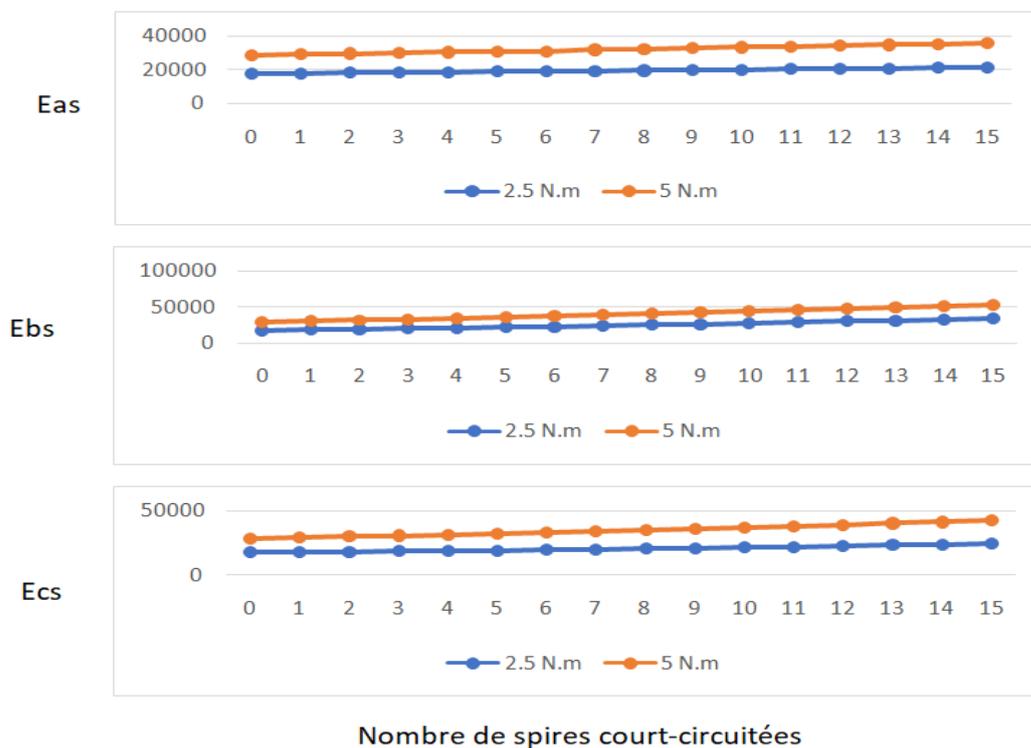


FIGURE 3.4 – Phase b

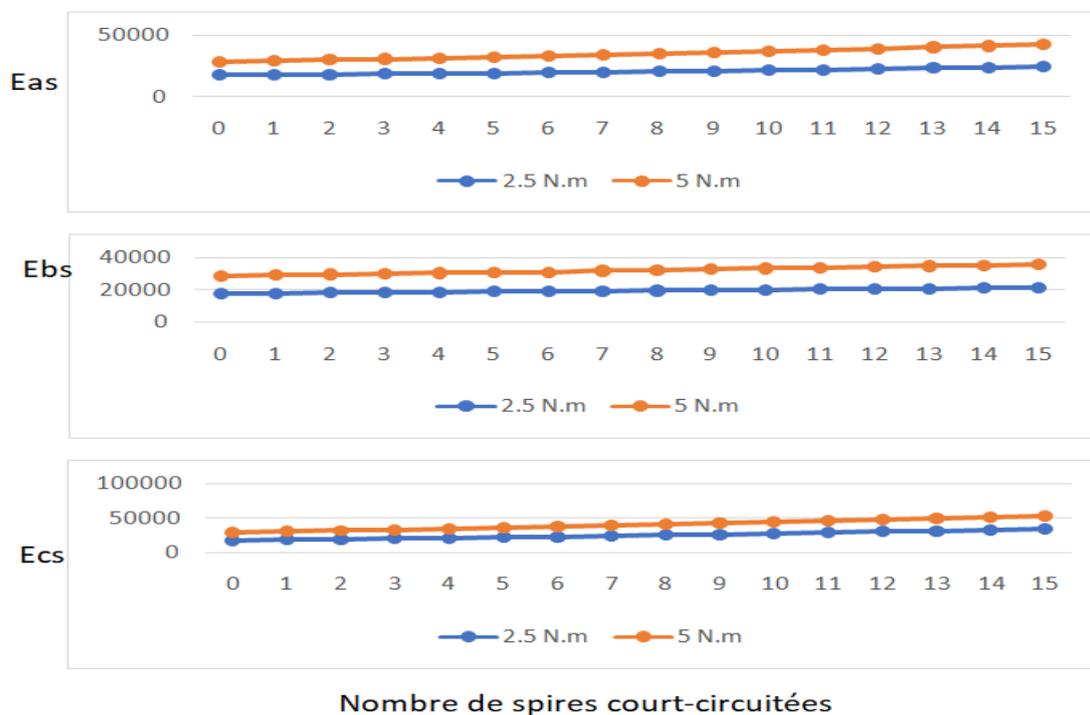


FIGURE 3.5 – Phase c

L'étude de l'énergie stockée dans le niveau 7 en fonction du défaut et de la charge

a montré que les trois valeurs simultanées. Il peut également être considéré comme une signature de défaut efficace pour diagnostiquer les défauts de stator de type court-circuit entre spires.

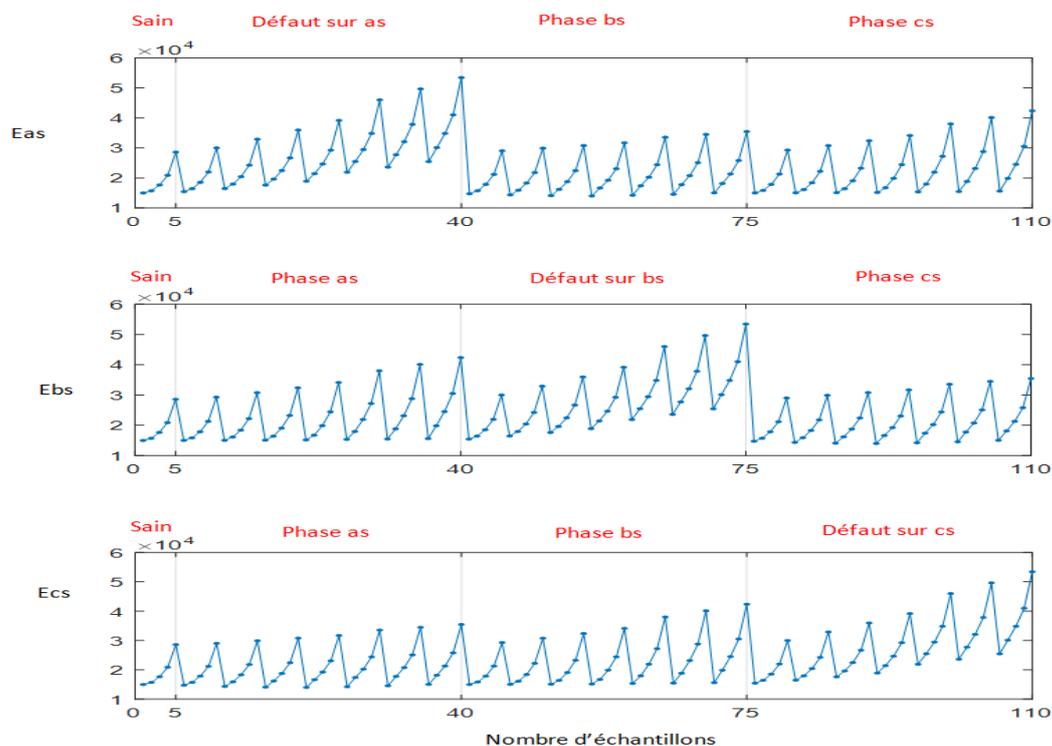
### 3.7.4 Acquisition des données (base d'apprentissage)

La procédure d'apprentissage du  $RN_{cc}$  pour la détection du défaut de court-circuit entre spires est formée en utilisant trois composantes ( $E_{as}$ ,  $E_{bs}$ ,  $E_{cs}$ ) comme illustré sur la figure suivante. Pour réaliser cette tâche on procède d'utiliser un algorithme d'apprentissage comme suit :

\* 5 échantillons sont utilisés pour un fonctionnement sain de la machine opérant pour diverses valeurs du couple de charge :  $Cr=0\%$ ,  $30\%$ ,  $50\%$ ,  $70\%$  et  $100\%$  de la charge nominale.

\* 35 échantillons pour chaque phase sont utilisés pour un fonctionnement avec défauts statorique de type court-circuit entre spires (1, 3, 5, 7, 11, 13 et 15 spires) respectivement sur les phases pour diverses valeurs du couple de charge :  $Cr = 0\%$ ,  $30\%$ ,  $50\%$ ,  $70\%$  et  $100\%$  de la charge nominale.

Cela signifie que pour chaque combinaison de défaut et de phase, il y a 35 échantillons disponibles, totalisant 105 échantillons pour les trois phases.



Les résultats souhaités pour les sorties du  $RN_{cc}$

\*(0 0 0) pour le cas de la MAS saine.

\*(1 0 0) pour le cas de la MAS avec défaut de court-circuit entre spires sur la phase  $a_s$ .

\*(0 1 0) pour le cas de la MAS avec défaut de court-circuit entre spires sur la phase  $b_s$ .

\*(0 0 1) pour le cas de la MAS avec défaut de court-circuit entre spires sur la phase  $c_s$ .

## 3.8 Résultats de l'apprentissage

### 3.8.1 Résultats de RN pour la prédiction des défauts :

Notre réseau de neurone que nous avons choisi contient de 3 neurones d'entrées, de 3 les couches cachées de 3 neurones et de 3 neurones de sorties. Les fonctions d'activation des neurones de la couche cachée sont des types de fonctions sigmoïdales et linéaires des neurones de la couche de sortie.

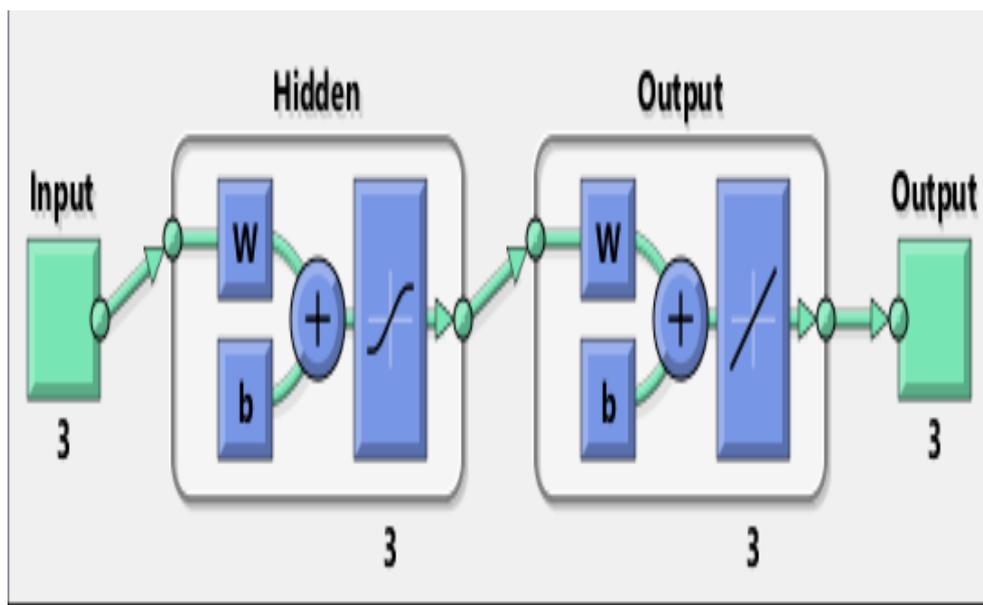
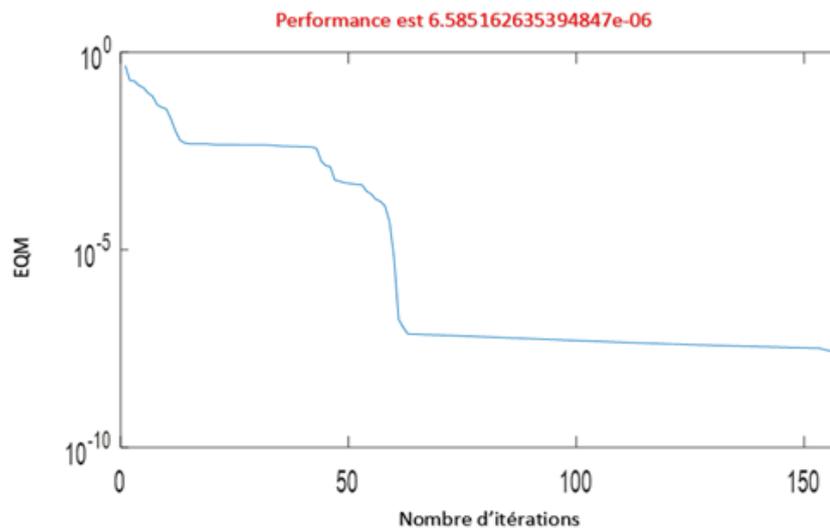
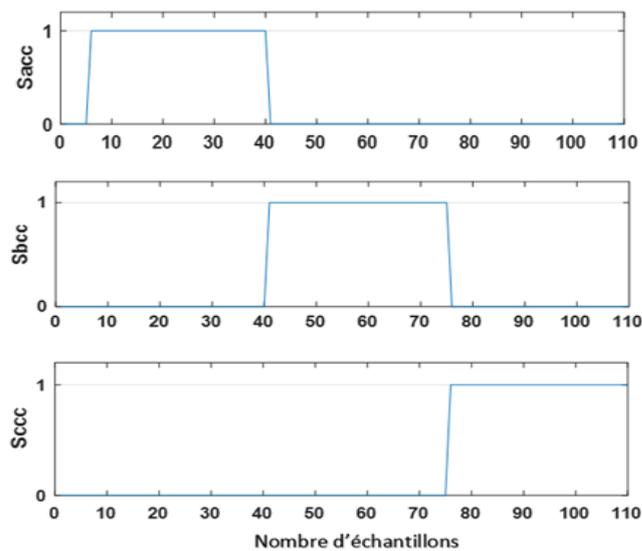


FIGURE 3.6 – Architecture de RN par la méthode de regression

L'algorithme utilisé pour l'apprentissage est de type rétropropagation du gradient.

FIGURE 3.7 – Performance du  $RN_{cc}$ 

Cette tendance représente la performance du réseau de neurones après 158 itérations, nous pouvons voir que notre modèle à chaque itération devient moins qu'avant pour atteindre le résultat plus précis. Ou en d'autres termes l'erreur quadratique moyenne (EQM) a atteint une valeur très faible  $6,585162635394847 \cdot 10^{-06}$

FIGURE 3.8 – Les sorties de l'apprentissage du  $RN_{cc}$

Après entraînement dans notre réseau de neurones, on constate que les valeurs attendues et les valeurs souhaitées sont proches les unes des autres

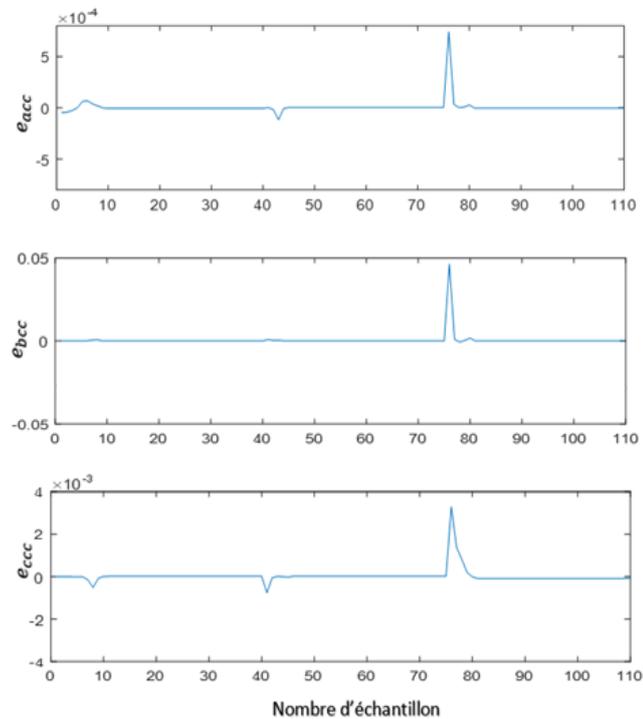


FIGURE 3.9 – Les erreurs de l'apprentissage du  $RN_{cc}$

Les images précédentes représentent les erreurs dans chaque phase, et le résultat de chaque phase c'est la preuve que notre  $RN_{cc}$  a fait le modèle adéquat à résultat souhaitée.

### 3.9 Les résultats de classification de défaut par réseau de neurones :

On a utilisé un autre algorithme de réseau de neurones qui nous permettons de faire la classification de défaut dans la partie training.

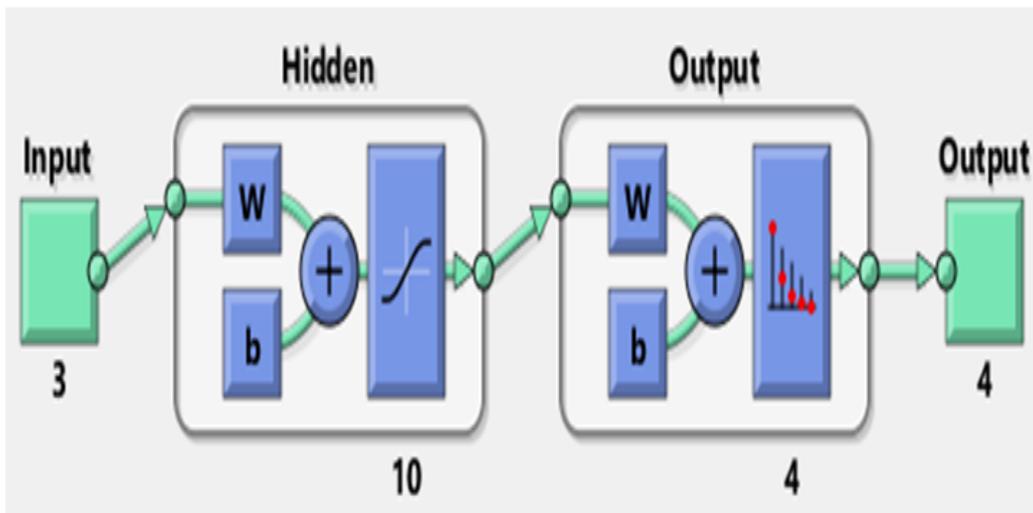


FIGURE 3.10 – L’architecture de RN pour la classification

L’architecture illustrée ci-dessus comprend une figure avec 3 paramètres d’entrée, une couche cachée unique comprenant 10 neurones, et 4 sorties correspondant à 4 cas attendus.

Après l’entraînement de ce modèle on a obtenu les résultats de l’apprentissage se forme matriciel pour le training, validation, classification et la somme entre eux.

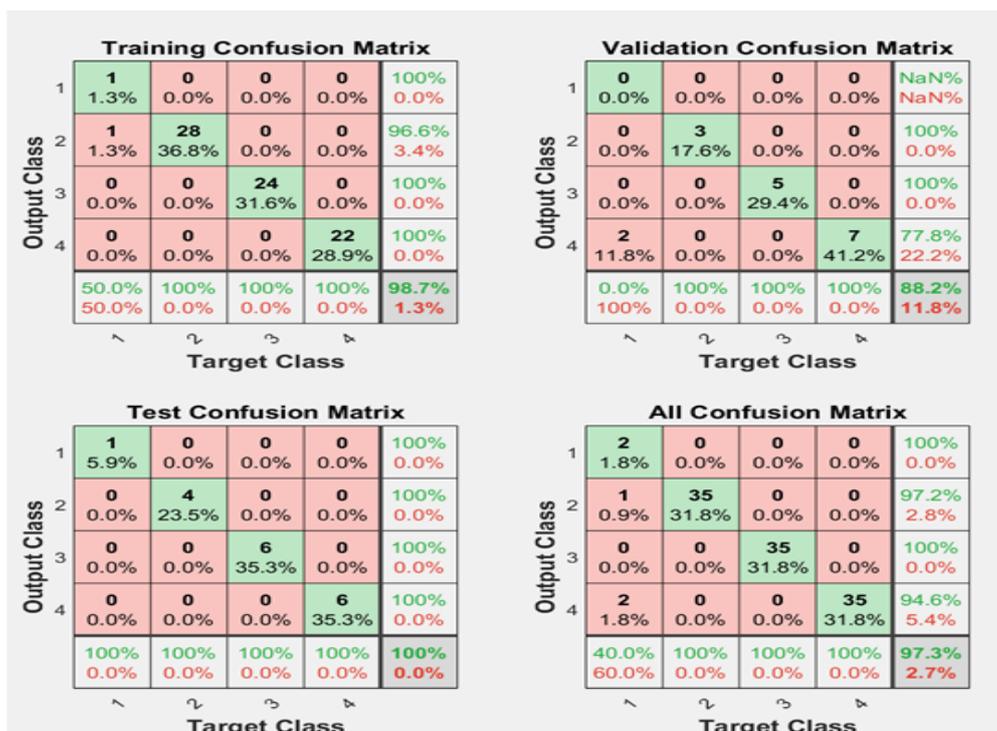


FIGURE 3.11 – Matrice de confusion pour les données d’entraînement

D'après faire les opérations pour évaluer la performance nous avons trouvé les résultats suivants, En utilisant la matrice de confusion suivante pour l'ensemble de données complet (entraînement + validation + test), Nous pouvons calculer différentes mesures de performance :

- Exactitude (Accuracy) : L'exactitude mesure la proportion de prédictions correctes parmi toutes les prédictions effectuées pour l'ensemble des classes.  $\text{Exactitude} = (2 + 35 + 35) / (2 + 0 + 0 + 1 + 35 + 0 + 2 + 0 + 35 + 0 + 2 + 0 + 35) = 0.935$

- Taux d'erreur (Error Rate) : Le taux d'erreur mesure la proportion de prédictions incorrectes parmi toutes les prédictions effectuées.  $\text{Taux d'erreur} = 1 - \text{Exactitude} = 1 - 0.935 = 0.065$  Les résultats obtenus démontrent que notre modèle a obtenu de bonnes performances en matière de classification des données. En effet, l'accuracy (exactitude) est très élevée, se rapprochant de la valeur 1, ce qui indique que la grande majorité des prédictions effectuées par le modèle étaient correctes par rapport aux étiquettes réelles des classes. De plus, l'erreur est faible, se rapprochant de la valeur 0, ce qui signifie que le modèle a commis très peu d'erreurs dans ses prédictions.

## 3.10 Prédiction pour la localisation et classification de défaut de la machine asynchrone

### 3.10.1 Résultat de test par la méthode de régression :

Nous avons pris la partie restante des données afin de faire la prédiction et émettre un jugement définitif sur le réseau de neurones, est-il capable de fournir des résultats satisfaisants et similaires à ce que nous attendons ou non.

Les données contiennent diverses charges de la machine asynchrone (Cr= 20%,40%, 60% et 80% de la charge nominale).

\* 4 échantillons pour un fonctionnement saine de la machine asynchrone.

\* 40 échantillons par phase sont utilisés pour le fonctionnement avec des défauts de court-circuit stator et le nombre de spires sélectionnés (2, 4, 8, 10, 12, 14, 16, 18, 20) respectivement pour les trois phases.

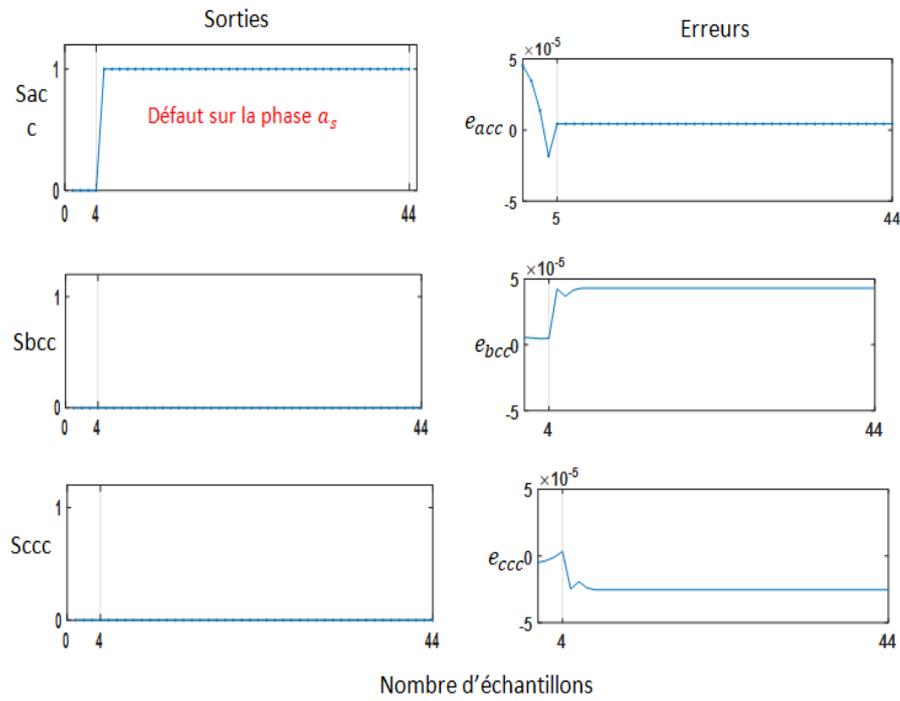


FIGURE 3.12 – Tests des sorties du  $RN_{cc}$  en présence de défauts sur la phase  $a_s$

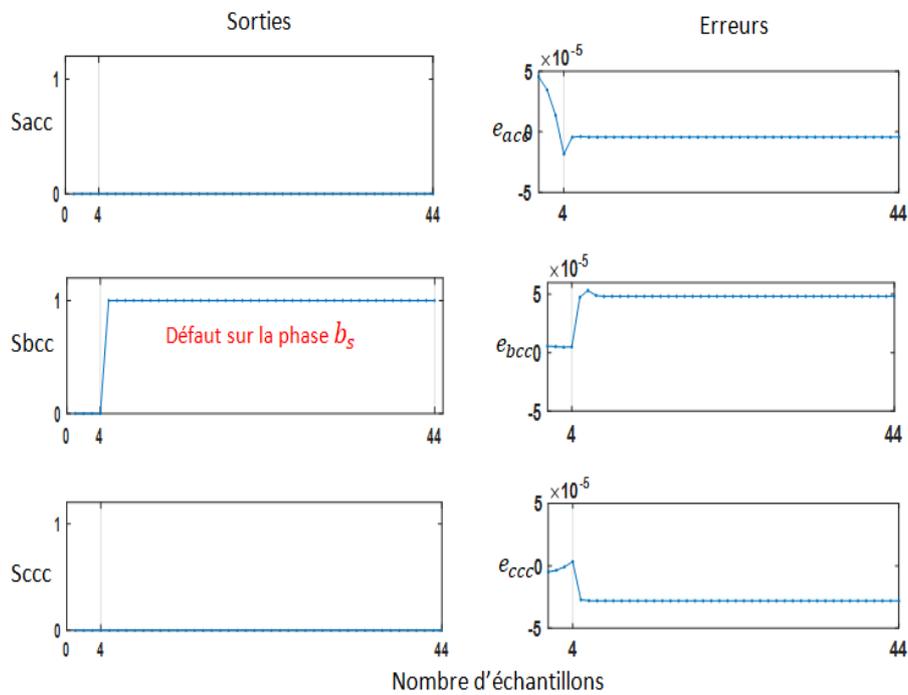


FIGURE 3.13 – Tests des sorties du  $RN_{cc}$  en présence de défauts sur la phase  $b_s$

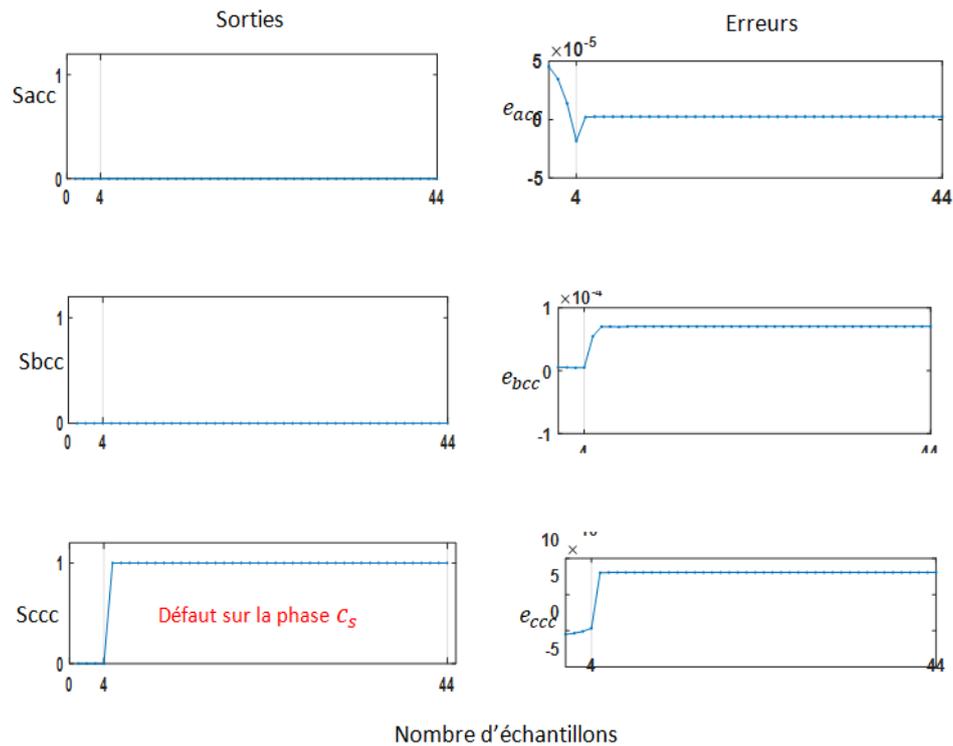


FIGURE 3.14 – Tests des sorties du  $RN_{cc}$  en présence de défauts sur la phase  $c_s$

D'après les figures on constate que les sorties du  $RN_{cc}$  indiquent les valeurs :

\*(0 0 0) pour le cas de la MAS saine.

\*(1 0 0) pour le cas de la MAS avec défaut de court-circuit entre spires sur la phase  $a_s$ .

\*(0 1 0) pour le cas de la MAS avec défaut de court-circuit entre spires sur la phase  $b_s$ .

\*(0 0 1) pour le cas de la MAS avec défaut de court-circuit entre spires sur la phase  $c_s$ .

Également les erreurs de sortie données par  $RN_{cc}$  sont considérées de l'ordre de  $10^{-4}$ ).

### 3.10.2 Résultat de test par la méthode de Classification :

On a aussi faire le test pour l'algorithme de classification pour savoir les performances de ce modèle sur la capacité d'apprentissage.

Output Class	1	2	3	4	
1	2 1.6%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	40 32.3%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	40 32.3%	0 0.0%	100% 0.0%
4	2 1.6%	0 0.0%	0 0.0%	40 32.3%	95.2% 4.8%
	50.0% 50.0%	100% 0.0%	100% 0.0%	100% 0.0%	98.4% 1.6%
	1	2	3	4	
	Target Class				

FIGURE 3.15 – Matrice de confusion pour les données d’entraînement

Matrice de confusion pour les données de test Nous pouvons calculer l’accuracy (exactitude) et le error rate (taux d’erreur) comme suit : • Exactitude =  $(2 + 40 + 40 + 40) / (2 + 0 + 0 + 0 + 40 + 0 + 2 + 0 + 40 + 0 + 2 + 0 + 40) = 0.975$ .

• Taux d’erreur =  $1 - \text{Exactitude} = 1 - 0.975 = 0.025$  L’accuracy (exactitude) de notre modèle lors du test est de 0.975, ce qui signifie que près de 97.5% des prédictions faites par notre modèle étaient correctes par rapport aux véritables étiquettes de classe. Le error rate (taux d’erreur) est de 0.025, ce qui indique que seulement environ 2.5% des prédictions étaient incorrectes.

Ces résultats démontrent une performance élevée de notre modèle lors du test, avec une précision élevée et un taux d’erreur relativement faible.

### 3.11 Les résultats des défauts de La machine asynchrone court-circuitée par la méthode de regression :

Stator	$S_{acc}$	$S_{bcc}$	$S_{ccc}$
Sain (Cr=40 %)	4,53445339380632 E-5 == 0	5,65069934232998E- 06 == 0	-4,93243391508358 E- 06 == 0
Sain (Cr=80%)	-1,83474093018443 E- 05 == 0	-4,99879220577926E- 06 == 0	-3,35373310689224E- 06 == 0
Défaut Phase $a_s$ (Cr = 40%) $n = 4$	1,00000431703242== 1	4,31864470612497 E- 05 == 0	-2,54546842314296 E- 05
Défaut Phase $a_s$ (Cr = 80%) $n = 4$	1,00000431703237==1	4,31931649017558 E- 05 == 0	-2,54614029520095 E- 05 == 0
Défaut Phase $b_s$ (Cr = 40%) $n = 10$	-4,30673455686925E- 06 ==0	1,00004820656583== 1	-2,81988072978745 E- 05 == 0
Défaut Phase $b_s$ (Cr = 80%) $n = 12$	-4,30673455686925E- 06 == 0	1,00004820656583== 1	-2,81988072978745 E- 05 == 0
Défaut Phase $c_s$ (Cr = 40%) $n = 16$	2,39665579487847E- 06 == 0	0,0000702947728569159 ==0	1,00008066489197== 1
Défaut Phase $c_s$ (Cr = 80%) $n = 18$	2,39665579487847E- 06 == 0	0,0000702947728569159 == 0	1,00008066489197== 1

TABLE 3.2 – Les résultats finals des sorties de la machine asynchrone

### 3.12 Les résultats des défauts de court-circuit entre les spires de la machine asynchrone par la méthode de classification :

Stator	S <sub>1</sub>	S <sub>2</sub>	S <sub>3</sub>	S <sub>4</sub>	output class
Sain (Cr=40 %)	1	0	0	0	1
Sain (Cr=80%)	1	0	0	0	1
Défaut Phase a <sub>s</sub> (Cr = 40%)n = 4	0	1	0	0	2
Défaut Phase a <sub>s</sub> (Cr = 80%)n = 4	0	1	0	0	2
Défaut Phase b <sub>s</sub> (Cr = 40%)n = 10	0	0	1	0	3
Défaut Phase b <sub>s</sub> (Cr = 80%)n = 12	0	0	1	0	3
Défaut Phase c <sub>s</sub> (Cr = 40%)n = 16	0	0	0	1	4
Défaut Phase c <sub>s</sub> (Cr = 80%)n = 18	0	0	0	1	4

TABLE 3.3 – Les résultats finals des sorties de la machine asynchrone

### 3.13 interface graphique

#### 3.13.1 Description de l'application

On a conçu cette application pour le but de détection et la classification de défaut cela permet à faciliter la tâche sur l'utilisateur et assurer la communication entre l'humain et la machine. et L'application utilisé c'est la APP designer sur Matlab. Voici la page principale qui représente dans la figure les différentes cases tel que (Model de la MAS, détection et classification, Aide, contactus).



FIGURE 3.16 – la page principal de l’interface graphiq

### 3.13.2 Modèle de la MAS :

Représente le schéma de la machine asynchrone et ses paramètres tel que les paramètres de stator et les paramètres de rotor.

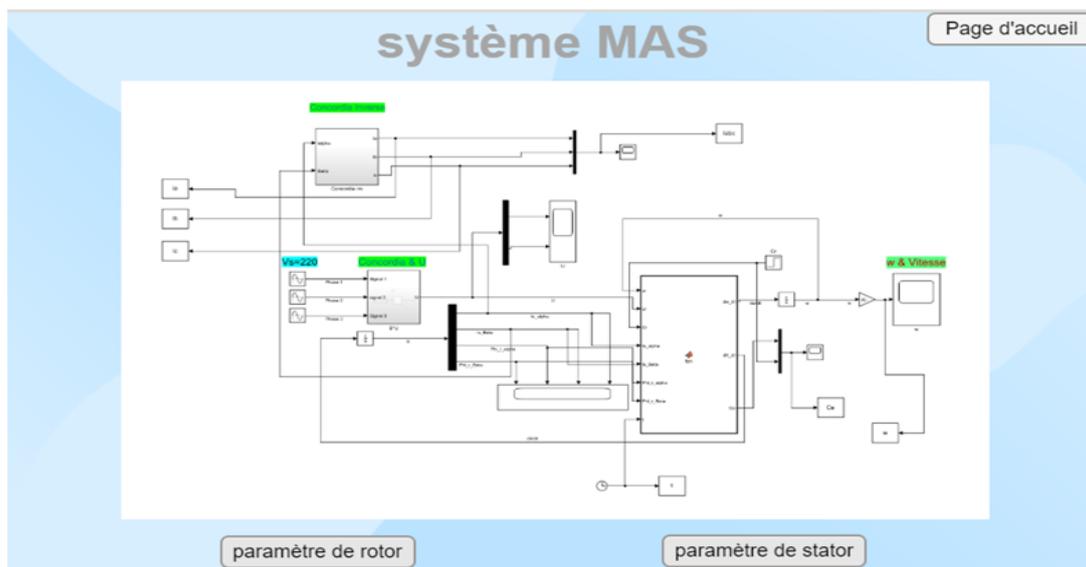


FIGURE 3.17 – le Modèle de la MAS

- Les paramètres de rotor :
- Les paramètres de stator :

Précédent Page d'accueil

Le rotor est la partie mobile d'une machine électrique. Il contient des conducteurs électriques et interagit avec le champ magnétique du stator. Cette interaction génère un couple électromagnétique qui fait tourner le rotor, produisant ainsi de l'énergie mécanique ou électrique.



**Paramètres rotoriques :**

- $R_r = 6.3 \Omega$  : Résistance rotorique
- $L_r = 0.4642 \text{ H}$  : Inductance rotorique
- $F = 0$  : Frottement visqueux
- $W_r = 157 \text{ rad/s}$  : Vitesse de rotation nominale
- $J = 0.02 \text{ kgm}^2$  : Moment d'inertie
- $C_{em} = 5 \text{ Nm}$  : Couple électromagnétique

FIGURE 3.18 – Les paramètres de rotor

Précédent Page d'accueil

Le stator est la partie fixe d'une machine électrique telle qu'un moteur ou un générateur. Il est composé d'un ensemble de bobines ou de conducteurs électriques disposés de manière stationnaire autour du rotor.



**Paramètres statoriques :**

- $R_s = 10 \Omega$  : Résistance statorique
- $L_s = 0.4612 \text{ H}$  : Inductance statorique
- $M = 0.4212 \text{ H}$  : Inductance mutuelle
- $F_s = 50 \text{ Hz}$  : Fréquence du réseau industriel
- 220/380V : Tension du réseau
- $P = 2$  : Paire de pôles
- $P_N = 0.75 \text{ kW}$  : Puissance nominale

FIGURE 3.19 – Les paramètres de stator

### 3.13.3 Détection et Classification :

Dans la première page il y a les différentes types de défauts tel que (sain, défaut sur la phase a, b, et c).

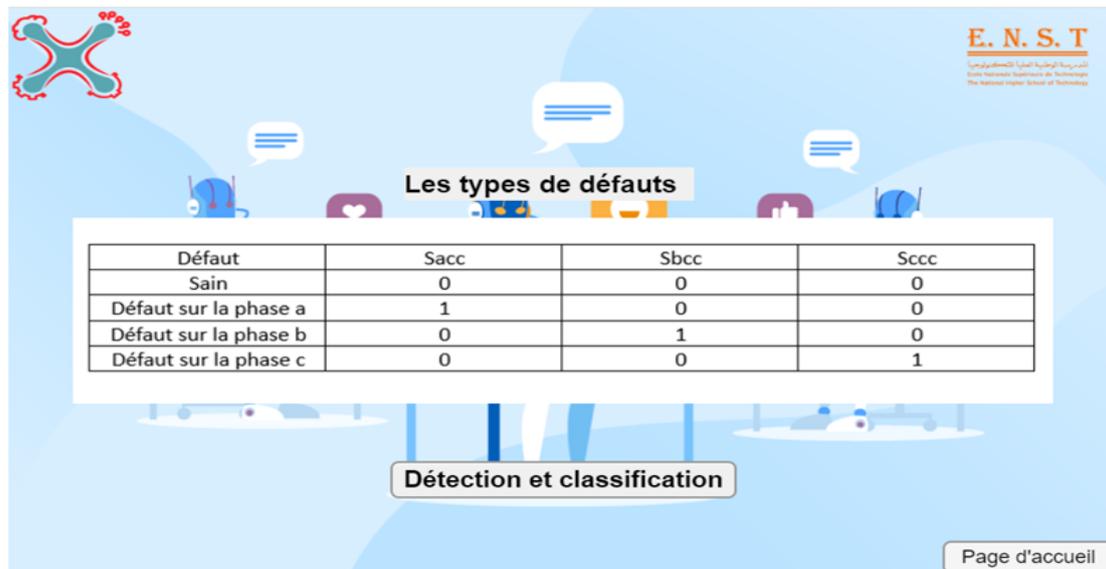


FIGURE 3.20 – Les types de défauts de court-circuit

Quand on a cliqué sur le bouton détection et classification il apparaît d'autre fenêtre qui nous permettons d'entrer les valeurs de l'énergie obtenues lors de l'exécution de notre modèle de la machine asynchrone programmé par le réseau de neurone artificiel. Voici

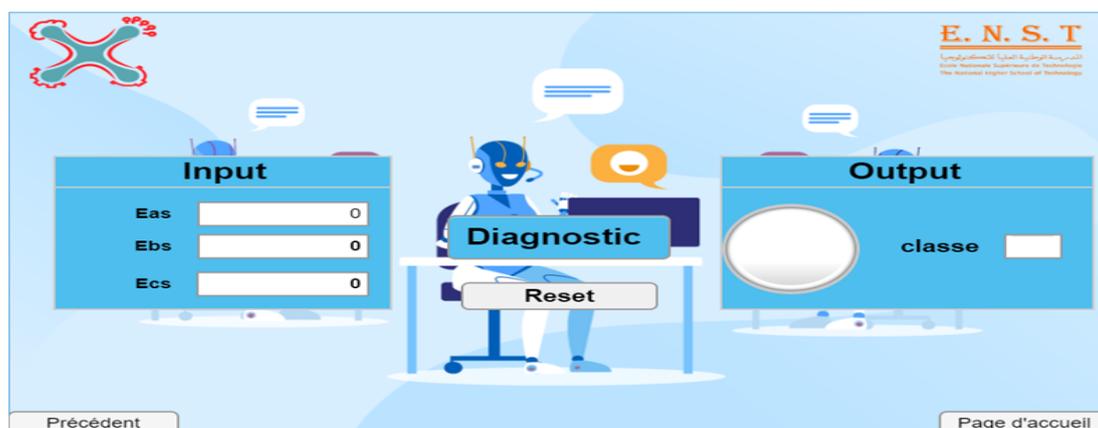


FIGURE 3.21 – Diagnostic

l'interface qui contient des cases des valeurs d'entres et l'output qui va apparaître par allumé la lampe que se soit vert ou bien rouge s'iln'y a pas le défaut la lampe allumée le colore vert et sinon il va allumer la colore rouge.

- Le cas sans défaut :

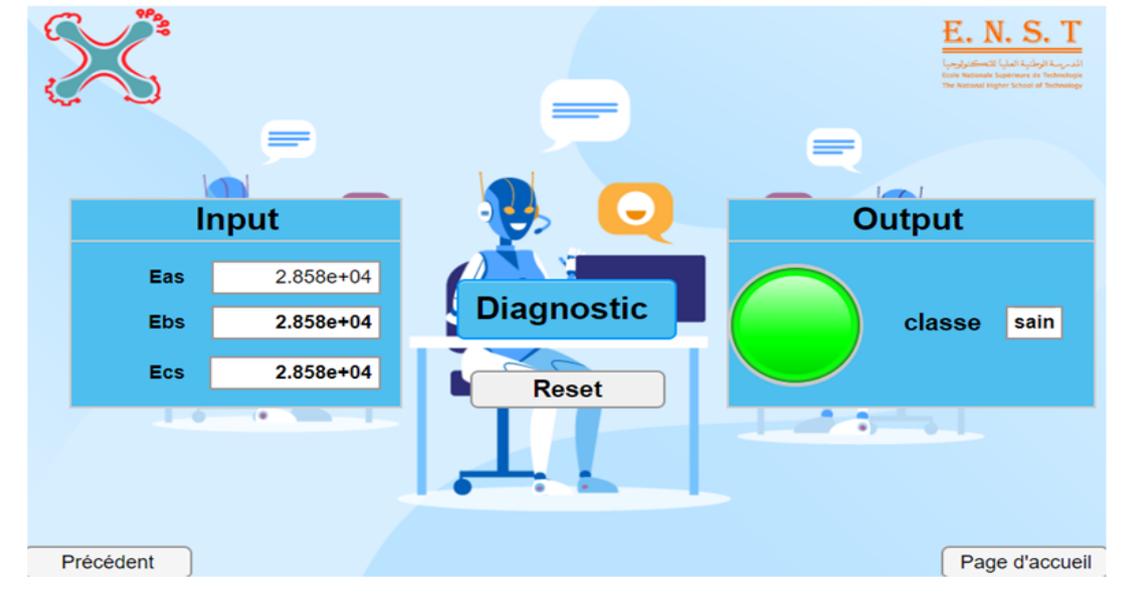


FIGURE 3.22 – MAS sans défaut

- Le défaut de court-circuit entre les spires dans la phase a :

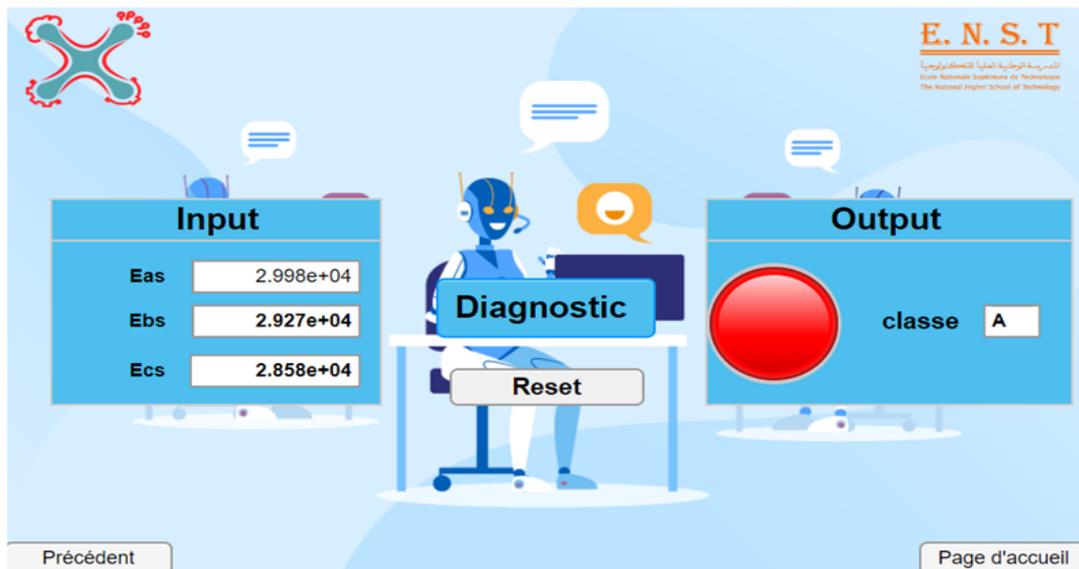


FIGURE 3.23 – Défaut CC sur la phase A

- Le défaut de court-circuit entre les spires dans la phase b :



FIGURE 3.24 – Défaut CC sur la phase B

- Le défaut de court-circuit entre les spires dans la phase c :

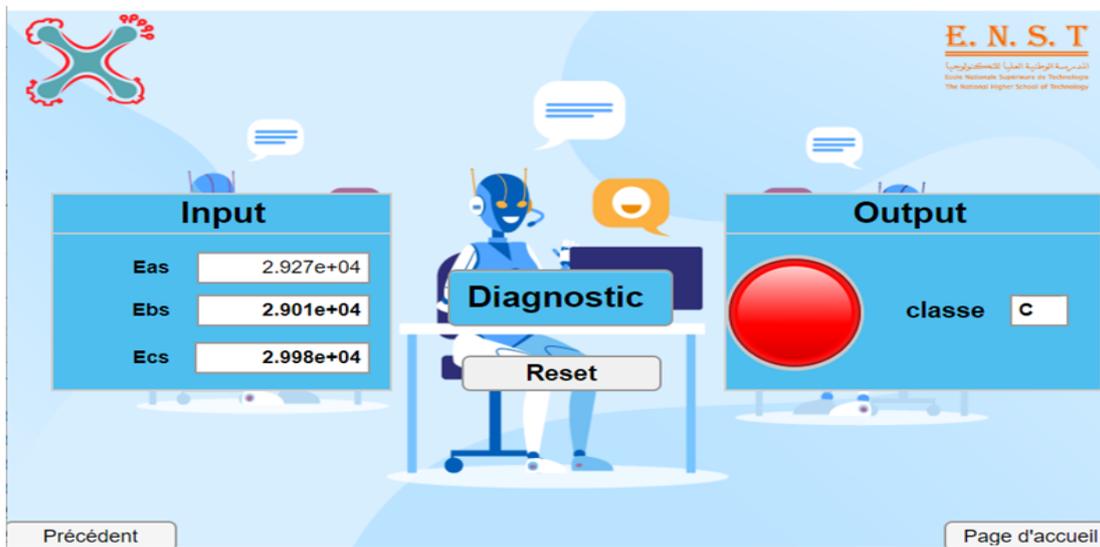


FIGURE 3.25 – Défaut CC sur la phase C

### 3.13.4 Contact us :

Cette fenêtre représente nos contacts s'il y a des problèmes ou vous trouvez des difficultés sur cette application.



FIGURE 3.26 – Les contacts

### 3.13.5 Aide :

Si vous cliquez sur ce bouton vous pouvez accéder à notre PDF (description de l'application) pour savoir plus de détail.

### **3.14 Conclusion**

les algorithmes de réseau de neurones utilisé dans cette étude s'est avéré efficace pour la détection et la classification des défauts statoriques de court-circuit entre les spires d'une machine asynchrone. Ces résultats sont encourageants pour l'application de cette approche dans le domaine de la maintenance prédictive des machines électriques, permettant une détection précoce des défauts et une réduction des temps d'arrêt non planifiés.

# Conclusion générale

Dans cette étude, nous avons exploré l'application des réseaux de neurones artificiels pour le diagnostic et la classification des défauts dans les machines tournantes industrielles, avec une attention particulière portée à la machine asynchrone. Nous avons réalisé la modélisation de la machine en tenant compte de son état sans défaut et de la présence d'un défaut de court-circuit entre les spires. En utilisant la décomposition en ondelettes, nous avons extrait les caractéristiques énergétiques des signaux, puis utilisé ces données pour entraîner un réseau de neurones en utilisant à la fois un algorithme de régression linéaire et une approche de classification.

Les résultats obtenus ont démontré l'efficacité de notre approche dans la prédiction des défauts de la machine asynchrone. Les réseaux de neurones artificiels ont permis d'atteindre une précision élevée dans la détection et la classification des différents défauts. Cette recherche ouvre des perspectives prometteuses pour améliorer le diagnostic des machines tournantes industrielles, en contribuant à une meilleure fiabilité et à une maintenance préventive plus efficace.

En conclusion, notre étude souligne l'importance des réseaux de neurones artificiels dans le domaine du diagnostic des machines tournantes. L'utilisation de ces algorithmes offre des avantages significatifs, tels qu'une plus grande précision de détection des défauts et une réduction des coûts de maintenance. Ces avancées contribuent à améliorer la disponibilité des machines, à optimiser les opérations industrielles et à garantir une production efficace et fiable.

pour cloturer, l'utilisation des réseaux de neurones artificiels dans le diagnostic des machines tournantes présente de nombreux avantages, tels qu'une plus grande précision de détection des défauts et une réduction des coûts de maintenance. Ces avancées contribuent

à améliorer la disponibilité des machines, à optimiser les opérations industrielles et à garantir une production efficace et fiable. L'avenir de cette recherche promet de nouvelles avancées dans le domaine, ouvrant la voie à des méthodes de diagnostic encore plus performantes et à une gestion proactive des machines tournantes industrielles.

# Bibliographie

[1] Mohammed, G. (2012). Diagnostic par reconnaissance des formes :Application à la machine asynchrone. Mémoire de Magister, Université Mouloud Mammeri De Tizi-Ouzou.

[2] Norme afnor. Terminologie de la maintenance. nfen, 13306 :x60–319

[3] BOUTICHE, H. (2015). modélisation et diagnostic d’un réducteur de vitesse à un seul étage par analyse cepstrale. UNIVERSIT2 M4HAMED BOUGARRA-Boumerdes .

[4] F. Castang, “ Synthèse robuste de filtres de diagnostic pour la surveillance à base de modèle des systèmes multivariables et incertains.” Thèse de doctorat, 2003. Bordeaux 1.

[5] Samir, M. (2007). Estimation des paramètres et des états de la machine asynchrone en vue de diagnostic des défauts rotoriques. Mémoire Magister en Electrotechnique UNIVERSITÉ MOHAMED KHIDER DE BISKRA 2007.

[6] Polotski, V., Kenne, JP. Gharbi, A. Optimal production and corrective maintenance in a failure-prone manufacturing system under variable demand. Flex Serv Manuf J 31, 894– 925 (2019).

[7] Hamdi, m., Hamia , a. (Juin 2022). Diagnostic des défauts du moteur asynchrone par analyse temporelle. Mémoire Master en Electrotechnique, Université Mohamed Khider de Biskra.

[8] Robert, M. (2020, Novembre 03). Intelligence artificielle : maintenance prédictive et brevets.

[9] Høyland, A. . (1994). System Reliability Theory – Models and Statistical Methods. USA :John Wiley Sons, Inc.

[10] course Les différents types de maintenance ,Chapitre II master 2 ,électromécanique. (s.d.).

[11] Starr, A. (1997). A Structured Approach to the Selection of Condition Based Maintenance. 5th International Conference on FACTORY 2000 – The Technology Exploitation Process, Cambridge, UK.

[12]Abed. (Mars 2002). Contribution à l’Etude et au Diagnostic de la Machine Asynchrone. Thèse de Doctorat,Université Henri Poincaré, Nancy-1, France.

[13]Polotski, V., Kenne, JP. Gharbi, A. Optimal production and corrective maintenance in a failure-prone manufacturing system under variable demand. Flex Serv Manuf J 31, 894– 925 (2019).

[14]St-Marseille M. and Lapointe J.B., La gestion des équipements vers l’entretien préventif, Association paritaire pour la santé et la sécurité du travail Secteur fabrication de produits en métal et de produits électriques, Bibliothèque nationale du Québec, 1997

[15]les start-up et les entreprises spécialisées

[16] Daniel Racoceanu Contribution à la surveillance des systèmes de production en utilisant les techniques de l’intelligence artificielle, habilitation à diriger des recherches, université de Données issues de capteurs Base de règles initiale (vide ou non) Base de données Apprentissage de réseau neuro-flou Test de réseau neuroflou Module d’adaptation Validati on SETIT2009 - 7 - Franche Comté de Besançon, 2006.

- [17] Sylvain PIECHOWIAK. Intelligence artificielle et diagnostic. 2003
- [18] Boulenger A, P. C. (2009). Surveillance des machines par analyse des vibrations . Dunod ,Paris.
- [19] M.Combacau , “ ”Commande et surveillance des systèmes à événements discrets complexes : applications aux ateliers flexibles”.Thèse de doctorat,1991. L’université Paul Sabatier de Toulouse.
- [20] R. Isermann et P. Balle, “ Trends in the Application of Model-Based Fault Detection and Diagnosis of Technical Processes”.Control Engineering Practice.Article 5(5),pp709-719, 1997 .
- [21] Samir Sekiou , “ Diagnostic des Défaillances des Systèmes Instrumentés de Sécurité : Simulation et Etude Expérimentale ”.Mémoire de Master,03/02/2013.Université El-Hadj Lakhdar-Batna.8
- [22] P.Vincent. (2003). Modèles à noyaux à structure locale. Thèse de Phd en informatique ,Université de Montréal.
- [23] Nadia, M. (2013). Apprentissage Incrémental et Machines à Vecteurs Supports. Mémoire Master ,Université HADJ LAKHDAR – BATNA.
- [24] Goodfellow, I. Y. (2016). Deep Learning. MIT Press.
- [25] Géron, A. (2017). Hands-On Machine Learning with Scikit-Learn and TensorFlow. USA.
- [26] V, F. B. (1996). Les réseaux de neurones artificiels. Presses Universitaire,Paris.
- [27]RIVALS, L. P. (2001). Modélisation, classification et commande par réseaux de neurones : principes fondamentaux, méthodologie de conception et illustrations indus-

rielles.

[28] NERRAND, P. R.-R. (2002). Neural Networks and Non-linear Adaptive Filtering : Unifying Concepts and New Algorithms, Neural Computation.

[29] Khaled, S. K. (2022). Segmentation D'Image Médicale Via Non supervisor Réseau de neurones convolutif. Mémoire Master ,UNIVERSITE MOHAMED BOUDIAF - M'SILA.

[30] Kim, P. (s.d.). MATLAB Deep Learning with Machine Learning, Neural Networks and Artificial Intelligence .

[31] ANNANE , A., MEZIANI , M. (2017). la détection des défauts d'enroulement de stator dans un moteur à induction en utilisant la logique floue. ENST Alger.

[32] Babaa, F. (2005). modélisation et diagnostic des machines Asynchrones :Application A La détection Des Défauts Statorique. Constantine.

[33] BAGHLI, L. (s.d.). Modélisation et commande de la machine asynchrone. Notes de cours modélisation, IUFM de Lorraine – UHP, France.

[34] Belhamdi, S. (2014). Diagnostic Des Défauts De La Machine Asynchrone Contrôlée Par Différentes Techniques De Commande.

[35] BENDALI , R., BENDIF, L. (2012). commande par mode glissant de la machine asynchrone . UNIVERSITÉ MOULOUD MAMMERI ,TIZI OUZOU.

[36] BESSAM, B. (2016). analyse et détection de défauts dans la machine asynchrone a base des techniques intelligentes. BISKRA.

[37] CHERMAT, B. (2012). Diagnostic des défauts de MAS par les méthodes paramétriques de traitement du signal. Mémoire de Master, Université Mohamed Khider Biskra.

[38] HARZELLI, I. (2020). Contrôle non linéaire de la machine asynchrone en vue du diagnostic des défauts en utilisant des techniques avancées. Biskra.

[39] Kamel, O. M. (s.d.). "Surveillance et diagnostic des défauts rotoriques de la machine à induction avec différents types d'alimentation", mémoire de thèse présenté pour obtenir le diplôme de Doctorat en sciences En Electrotechnique,.

[40] KERROUM, B. (2017). Etude et Diagnostic de mauvais branchement d'un moteur à induction. Mémoire de Master , Université Badji Mokhtar, Annaba.

[41] M. Blodt, P. G. (Apr. 2008). Models for Bearing Damage Detection in Induction Motors Using Stator Current Monitoring," IEEE Trans. Ind. Electron., vol. 55, no.4, pp. 1813–1822 .

[42] RETIF, J. (s.d.). Commande vectoriel des machines asynchrones et synchrone. Institut national des sciences appliquées de Lyon.

[43] A. Bouzida, O. T. (2011). Fault Diagnosis in Industrial Induction Machines Through Discrete Wavelet Transform. iIEEE Trans. Ind. Electron.,vol. 58,no.9,pp. 4385-4395.

[44] B.Bessam, A. (2015). Wavelet transform and neural network techniques for interturn short circuit diagnosis and location in induction motor. International Journal of System Assurance Engineering and Management.

[45]Besma, B. (2016). Analyse et détection des défauts dans la machine asynchrone à base des techniques intelligentes ,thèse Doctorat.Biskra.

[46] H.Talhaoui, A. (Sept.2014). Fast Fourier and discrete wavelet transforms applied to sensor less vector control induction motor for rotor bar faults diagnosis. ISA Transaction, Vol.53,pp.1639-1649.

[47] M.R.Guasp, J. (December 2008). A general approach for the transient detection of slip dependent fault components based on the discrete wavelet transform,IEEE Transactions on Industrial Electronics, Vol.55,N° 12.

[48] S.Bourdin. (14 juin 2015). Contribution au diagnostic des générateurs utilisés dans les systèmes éoliens . Thèse doctorat,Université de Hadj Lakhder ,Batna .

[49] Allianz, "Présentation des avaries. Machines électriques tournantes", cahier des préventions. CP2, 1988

Annexe **A**

Annexe A

# Paramètre de la Machine Asynchrone

$P_N = 0.75\text{KW}$  *Puissance nominale.*

$F_s = 50\text{HZ}$  *Frquence du rseau industrielle.*

$U = 220/380\text{V}$  *Tension du réseau.*

$W_r = 157\text{rad/s}$  *Vitesse de rotation nominale.*

$C_{em} = 5\text{Nm}$  *Couple lectromagntique.*

$R_s = 10$  *Rsistance statorique.*

$R_r = 6.3$  *Rsistance rotorique.*

$L_s = 0.4612\text{H}$  *Inductance statorique.*

$L_r = 0.4642\text{H}$  *Inductance rotorique.*

$M = 0.4212\text{H}$  *Inductance mutuelle.*

$J = 0.02\text{Kgm}^2$  *Moment d'inertie.*

$F = 0$  *Frottement visqueux.*

$P = 2$  *Paire de pole.*

Annexe **B**

Annexe B

Annexe **C**

Annexe C

# Le modèle de maintenance prédictive avec réseau de neurones

## C.1 L'importance de la collecte de données dans la maintenance prédictive :

La collecte de données revêt une importance cruciale dans la maintenance prédictive. Voici quelques raisons clés pour lesquelles la collecte de données est essentielle dans ce domaine :

- **Détection précoce des anomalies**

La collecte de données permet de surveiller en continu les performances des équipements et des machines. En enregistrant les données provenant de capteurs, de systèmes de surveillance et d'autres sources, il est possible de détecter les anomalies ou les variations par rapport aux conditions normales de fonctionnement. Cela permet d'identifier les problèmes potentiels avant qu'ils ne se transforment en pannes majeures.

- **Analyse et apprentissage automatique**

Les données collectées sont utilisées pour analyser les modèles, les tendances et les corrélations. Les techniques d'apprentissage automatique sont appliquées sur ces données pour découvrir des relations cachées et des informations précieuses. Ces modèles permettent de prédire les défaillances futures, d'estimer les temps de panne et de planifier les activités de maintenance de manière plus efficace.

- **Amélioration continue**

La collecte de données à long terme permet d'accumuler des informations précieuses sur les performances et la durée de vie des équipements. Cela permet d'identifier les facteurs qui affectent la fiabilité, l'efficacité et la durabilité des actifs. Ces informations peuvent ensuite être utilisées pour optimiser les processus de maintenance, améliorer la conception des équipements et prendre des décisions éclairées pour réduire les temps d'arrêt imprévus.

- **Optimisation des ressources**

En collectant des données sur les conditions de fonctionnement réelles des équipements, il est possible d'optimiser l'utilisation des ressources de maintenance. Les informations collectées aident à planifier les activités de maintenance de manière proactive, en se concentrant sur les équipements les plus critiques ou les plus susceptibles de connaître des défaillances. Cela permet d'économiser du temps et des coûts en évitant des réparations inutiles ou en réalisant des interventions plus rapides et plus efficaces.

- **Évolution vers l'industrie 4.0**

La collecte de données est un élément clé de la transformation numérique et de l'adoption de l'industrie 4.0. En tirant parti des technologies de l'Internet des objets (IoT), des capteurs intelligents et de l'analyse de données avancée, les entreprises peuvent collecter des données en temps réel, permettant une maintenance prédictive en temps réel. Cela favorise une gestion proactive des équipements, une réduction des temps d'arrêt non planifiés et une amélioration globale de la productivité.

La collecte de données joue un rôle fondamental dans la maintenance prédictive en fournissant les informations nécessaires pour détecter les anomalies, prédire les défaillances et optimiser les activités de maintenance. Elle permet d'améliorer l'efficacité opérationnelle, de réduire les coûts de maintenance et d'assurer la disponibilité et la fiabilité des actifs industriels.

## C.2 Les différents types de sources de données

Il existe différents types de sources de données utilisées en maintenance prédictive. Voici quelques-unes des sources de données couramment utilisées et les étapes de prétraitement.

tement associées :

- **Données des capteurs**

Les capteurs sont utilisés pour collecter des mesures physiques telles que la température, la pression, la vibration, le courant, etc. Ces données sont essentielles pour surveiller les performances des équipements. Avant de les utiliser dans les modèles prédictifs, il est souvent nécessaire de les prétraiter en supprimant les valeurs aberrantes, en normalisant les échelles, en comblant les données manquantes et en filtrant le bruit.

- **Données de maintenance**

Les données de maintenance comprennent les journaux d'activités de maintenance, les rapports d'intervention, les historiques de réparations, les temps d'arrêt, etc. Ces données fournissent des informations sur les activités de maintenance passées et les défaillances précédentes. Avant de les utiliser, il est important de les nettoyer, de les normaliser et de les organiser de manière appropriée pour faciliter leur analyse.

- **Données opérationnelles**

Les données opérationnelles incluent des informations sur les conditions de fonctionnement des équipements, telles que les paramètres de réglage, les modes de fonctionnement, les charges, etc. Ces données sont souvent utilisées pour contextualiser les mesures des capteurs. Avant de les utiliser, il peut être nécessaire de les prétraiter en éliminant les valeurs aberrantes, en normalisant les échelles et en effectuant des regroupements ou des agrégations si nécessaire.

- **Données textuelles**

Les données textuelles comprennent des informations provenant de rapports, de manuels, de courriels, de tickets de maintenance, etc. Ces données peuvent contenir des informations précieuses sur les défaillances, les symptômes, les causes racines, etc. Avant de les utiliser, il est souvent nécessaire de les nettoyer, de les filtrer, de les normaliser et de les convertir en une représentation numérique appropriée, telle que des vecteurs de mots.

### • Données contextuelles

Les données contextuelles incluent des informations sur les facteurs externes qui peuvent avoir un impact sur les performances des équipements, tels que les conditions météorologiques, les données économiques, les données de production, etc. Ces données peuvent être intégrées pour améliorer la précision des modèles prédictifs. Avant de les utiliser, il peut être nécessaire de les prétraiter de manière similaire aux autres types de données, en les nettoyant, en les normalisant et en les adaptant aux besoins spécifiques des modèles.

Le prétraitement des données est une étape essentielle dans la maintenance prédictive, car il permet de préparer les données brutes pour une analyse efficace et une utilisation dans les modèles prédictifs. Les techniques de prétraitement incluent le nettoyage des données, l'élimination des valeurs aberrantes, la normalisation des échelles, la gestion des données manquantes, la conversion des données non numériques en format numérique, etc. Un bon prétraitement des données permet d'améliorer la qualité des résultats et la performance des modèles prédictifs.

## C.3 La structure de réseau de neurones

Les réseaux de neurones sont des modèles informatiques conçus pour imiter la structure et le fonctionnement du cerveau humain. Ils sont constitués de nœuds interconnectés appelés neurones artificiels ou « neurones » qui travaillent ensemble pour traiter et analyser les données. La structure et le fonctionnement des réseaux de neurones peuvent être décrits comme suit :

### C.3.1 Neurones

les neurones sont les éléments constitutifs fondamentaux des réseaux de neurones. Chaque neurone reçoit des signaux d'entrée d'autres neurones ou de sources externes, effectue des calculs sur ces entrées et produit un signal de sortie. La sortie d'un neurone est déterminée en appliquant une fonction d'activation à la somme pondérée de ses entrées.

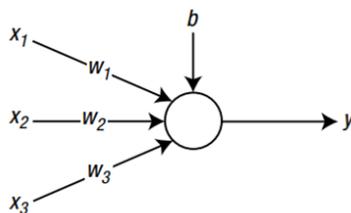


FIGURE C.1 – Les couches de réseau neurone [30]

### C.3.2 Couches

Les neurones sont organisés en couches au sein d'un réseau de neurones. Les trois principaux types de couches sont la couche d'entrée, les couches masquées et la couche de sortie. La couche d'entrée reçoit les données d'entrée brutes et les transmet aux neurones de la première couche cachée. Les couches cachées sont des couches intermédiaires qui effectuent des calculs et des transformations sur les données d'entrée. La couche de sortie produit le résultat final du réseau.

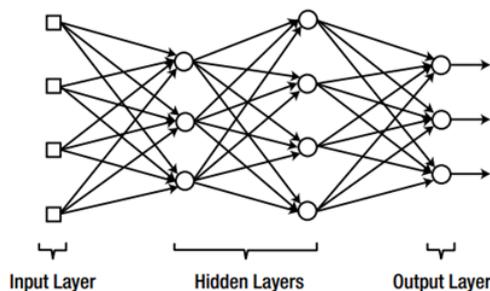


FIGURE C.2 – Les couches de réseau neurone [30]

### C.3.3 Connexions et pondérations

les neurones d'un réseau de neurones sont connectés aux neurones des couches adjacentes. Chaque connexion est associée à un poids, qui représente la force ou l'importance du signal transmis entre les neurones. Ces poids sont initialement attribués à des valeurs aléatoires et sont ajustés au cours du processus de formation du réseau pour optimiser ses performances.

## C.4 Les étapes principales pour l'algorithme de réseaux de neurones

Les étapes principales pour l'algorithme d'un réseau de neurones sont les suivantes :

### C.4.1 Initialisation des poids

Les poids initiaux du réseau de neurones sont généralement initialisés de manière aléatoire avec des valeurs proches de zéro. Les poids représentent les connexions entre les neurones et sont ajustés au cours de l'apprentissage.

### C.4.2 Propagation avant (Forward propagation)

Lors de la propagation avant, les données d'entrée sont transmises à travers le réseau couche par couche. Chaque neurone effectue une opération de calcul en utilisant les poids et les fonctions d'activation pour générer une sortie. Les sorties des neurones d'une couche deviennent les entrées de la couche suivante.

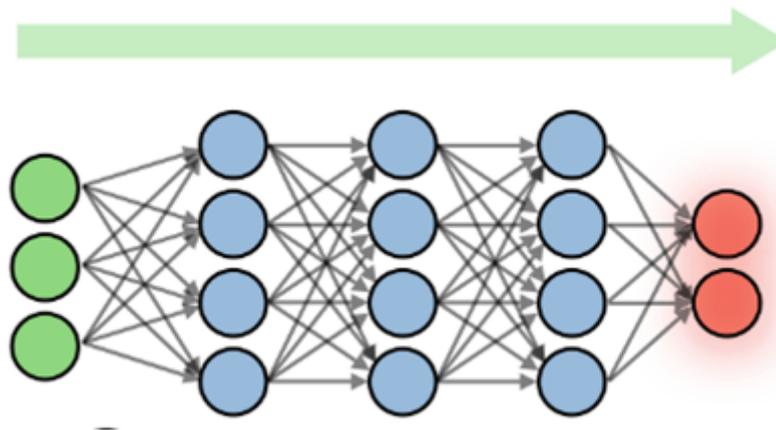


FIGURE C.3 – Propagation directe

Supposons que on a 3 entrées et une seule sortie comme présenter dans la figure suivante

Le calcul se fait par :

$$Z = w_1x_1 + w_2x_2 + w_3x_3 + b \quad (\text{C.1})$$

La fonction d'activation donné par la relation suivante [30] :

$$a(Z) = \frac{1}{1 + e^{-Z}} \quad (\text{C.2})$$

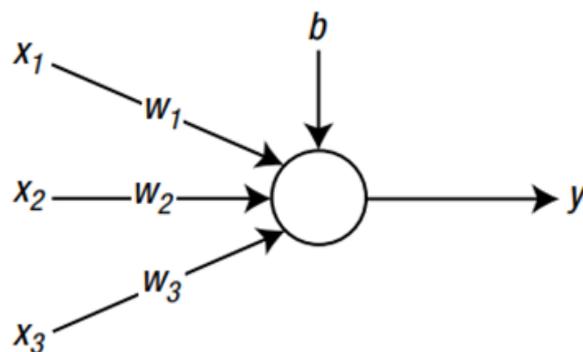


FIGURE C.4 – Un nœud qui reçoit trois entrées [30]

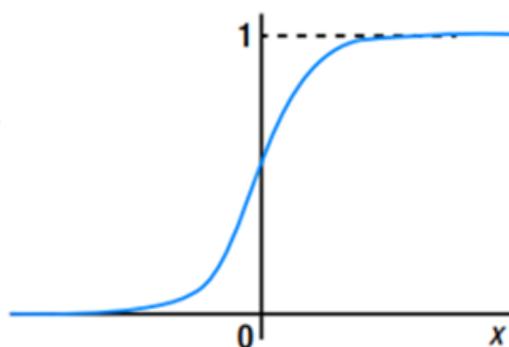


FIGURE C.5 – La fonction d'activation [30]

### C.4.3 Calcul de la fonction de perte (Loss function)

Une fois la propagation avant terminée, la fonction de perte est calculée pour mesurer la différence entre les sorties prédites du réseau et les valeurs réelles attendues. La fonction de perte détermine la performance du réseau et est utilisée pour ajuster les poids lors de l'apprentissage.

Equation de loss function :

$$\mathcal{L} = -\frac{1}{m} \sum_{i=0}^m y^i \log(a)^i + (1 - y^i) \log(1 - a^i) \quad (\text{C.3})$$

#### C.4.4 Rétropropagation (Backpropagation)

La rétropropagation est une étape clé dans l'apprentissage des réseaux de neurones. Elle consiste à calculer les gradients de la fonction de perte par rapport aux poids du réseau, en utilisant la règle de dérivation en chaîne. Ces gradients indiquent la direction dans laquelle les poids doivent être ajustés pour réduire l'erreur de prédiction.

L'équation est définie comme suit [30] :

$$w = w - \alpha \frac{\partial \mathcal{L}}{\partial w} \quad (\text{C.4})$$

$$b = b - \alpha \frac{\partial \mathcal{L}}{\partial b} \quad (\text{C.5})$$

#### C.4.5 Mise à jour des poids

Les poids du réseau sont mis à jour en utilisant un algorithme d'optimisation, tel que la descente de gradient, qui utilise les gradients calculés lors de la rétropropagation. L'objectif est de minimiser la fonction de perte en ajustant les poids de manière itérative.

L'équation représente la mise à jour de chaque itération [30] :

$$w_{i+1} = w_i + dw \quad (\text{C.6})$$

$$b_{i+1} = b_i + db \quad (\text{C.7})$$

#### C.4.6 Répétition des étapes 2 à 5

Les étapes de propagation avant, de calcul de la fonction de perte, de rétropropagation et de mise à jour des poids sont répétées pour chaque lot (batch) d'exemples d'apprentissage. Cela permet au réseau de s'ajuster progressivement aux données et d'améliorer ses performances.

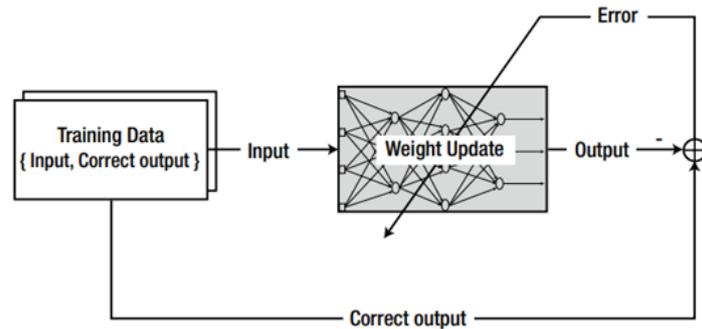


FIGURE C.6 – Le concept d'apprentissage supervisé [30]

### C.4.7 Validation et test

Une fois l'apprentissage terminé, le réseau est évalué sur des données de validation ou de test distinctes pour évaluer sa capacité à généraliser à de nouvelles données. Cela permet de mesurer la performance réelle du réseau et de prendre des décisions quant à son déploiement.

Ces étapes sont répétées jusqu'à ce que le réseau atteigne une performance satisfaisante ou jusqu'à ce qu'un critère d'arrêt spécifique soit atteint, comme le nombre maximal d'itérations ou l'amélioration de la performance ne dépasse pas un seuil prédéfini.

## C.5 La relation entre la machine asynchrone de défaut court-circuitée et le réseau de neurones

Dans notre schéma explicatif, nous décrivons un processus en plusieurs étapes pour la détection des défauts, en particulier les courts-circuits, dans une machine asynchrone. Voici une explication plus détaillée de chaque étape :

\* Dans la première étape, nous entrons les tensions triphasées dans la machine asynchrone et nous modélisons son comportement électrique. Cela signifie que nous appliquons les tensions électriques nécessaires pour alimenter la machine et nous créons un modèle mathématique qui représente le fonctionnement de la machine asynchrone. Notre modèle peut inclure des équations qui décrivent les relations entre les tensions, les courants et les autres paramètres électriques de la machine.

\* La deuxième étape implique la décomposition d'énergie par ondelette. L'ondelette

est une technique d'analyse de signal qui nous permet de diviser un signal en différentes composantes fréquentielles. En utilisant la décomposition par ondelette, nous extrayons les différentes énergies présentes dans les signaux électriques générés par la machine asynchrone. Cette étape nous permet de mettre en évidence les caractéristiques énergétiques spécifiques du signal.

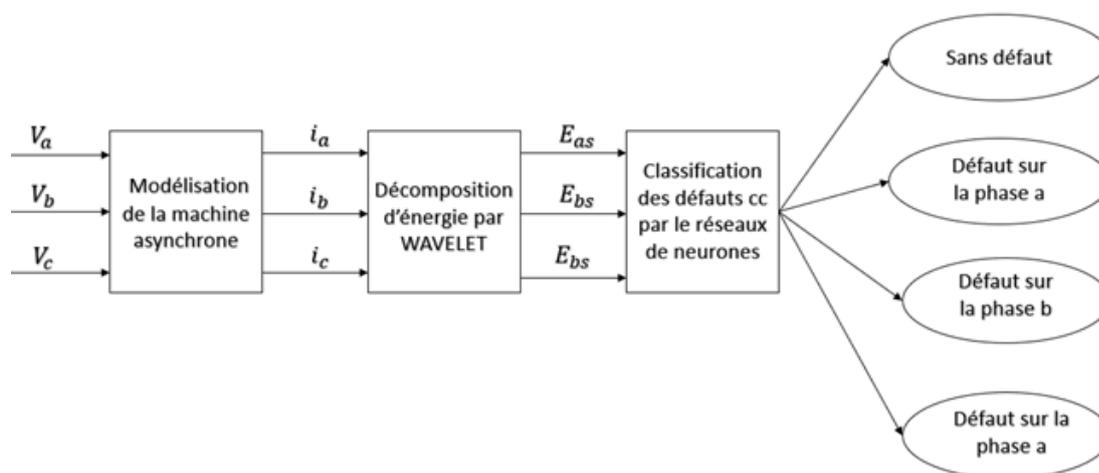


FIGURE C.7 – Schéma explicatif qui représente le lien entre MAS et RN

Dans la troisième étape, nous utilisons la méthode de classification par réseau de neurones. Les réseaux de neurones sont des modèles d'apprentissage automatique qui peuvent apprendre à reconnaître des patterns complexes dans les données. Nous entraînons un réseau de neurones en lui fournissant les énergies extraites à partir de la décomposition par ondelette comme entrée. Le réseau de neurones apprend à associer ces énergies à différents types de défauts, tels que les courts-circuits.

Notre objectif final à cette étape est d'identifier le type de défaut spécifique. Notre réseau de neurones, une fois correctement entraîné, peut prendre les énergies extraites en entrée et déterminer avec une certaine précision.

En résumé, notre schéma explicatif décrit le processus complet que nous suivons pour détecter les défauts, notamment les courts-circuits, dans une machine asynchrone. Il comprend les étapes d'entrée des tensions triphasées, de modélisation de la machine asynchrone, de décomposition d'énergie par ondelette et de classification par réseau de neurones pour identifier le type de défaut.

## ملخص

يشكل تشخيص وتصنيف العيوب في الآلات الدوارة الصناعية تحديًا كبيرًا لضمان أداءها السليم وتجنب الأعطال المكلفة. في هذه الدراسة، نركز على تطبيق الشبكات العصبية الاصطناعية لتشخيص العيوب في الآلات غير المتزامنة. شرعنا في تصميم الآلة غير المتزامنة، مع الأخذ في الاعتبار كلاً من حالتها الخالية من العيوب ووجود خطأ في دائرة قصيرة بين الملفات. باستخدام تحليل الموجات، قمنا بحساب طاقة الإشارات القادمة من الجهاز، مما يسمح لنا باستخراج الخصائص ذات الصلة. بعد ذلك، قمنا بخطوة استخراج البيانات مع التركيز بشكل خاص على خصائص الطاقة. تم استخدام هذه البيانات لتدريب شبكة عصبية، باستخدام خوارزمية الانحدار الخطي ونهج التصنيف. أظهرت النتائج التي تم الحصول عليها فعالية نهجنا في التنبؤ بعيوب الآلة غير المتزامنة. أتاح استخدام الشبكات العصبية الاصطناعية الحصول على دقة عالية في اكتشاف وتصنيف العيوب المختلفة. تمهد هذه الدراسة الطريق لوجهات نظر جديدة في مجال تشخيص الآلات الدوارة الصناعية. أثبتت الشبكات العصبية الاصطناعية أنها أدوات واعدة لتحسين الموثوقية والصيانة الوقائية للآلات، مما يساهم في زيادة الكفاءة التشغيلية وخفض التكاليف.

تهدف أطروحتنا في نهاية الدراسة إلى إجراء صيانة محسنة لنظام آضاغط . ٤ باز لشركة سيفيتال. لهذا، قمنا بنقل عنصر التحكم من نظام - القديم إلى صـمـنـس، باستخدام قـا عرتل للبرمجة. كان هدفنا من هذا الحل هو تحديث النظام وجعله أكثر آلية. من خلال تنفيذ حلنا ، نتوقع تحسين أداء الضاغط بشكل كبير ، مما سيضمن الإنتاج المستمر والموثوق داخل أعمال سيفيتال بمجرد بدء تشغيل البرنامج.

كلمات مفتاحية : تشخيص الآلات الدوارة، تصنيف العيوب، الشبكات العصبية الاصطناعية، الآلة غير المتزامنة، التحلل إلى موجات، الطاقة، الانحدار الخطي، التصنيف

## Abstract

Diagnosing and classifying faults in industrial rotating machines is a major challenge to ensure their smooth operation and avoid costly breakdowns. In this study, we focus on the application of artificial neural networks for fault diagnosis in asynchronous machines. We proceeded to model the asynchronous machine, taking into account both its fault-free state and the presence of a short-circuit fault between the turns. Using wavelet decomposition, we calculated the energy of the signals coming from the machine, enabling us to extract relevant characteristics. Next, we performed a data extraction step focusing specifically on the energy characteristics. These data were used to train a neural network, using

both a linear regression algorithm and a classification approach. The results obtained demonstrated the effectiveness of our approach in predicting asynchronous machine faults. The use of artificial neural networks enabled us to achieve high accuracy in the detection and classification of the various faults. This study opens up new perspectives in the field of industrial rotating machine diagnostics. Artificial neural networks are proving to be promising tools for improving machine reliability and preventive maintenance, thus contributing to greater operational efficiency and lower costs.

**Key words :** rotating machine diagnostics, fault classification, artificial neural networks, asynchronous machine, wavelet decomposition, energy, linear regression, classification . . .

## Résumé

Le diagnostic et la classification des défauts dans les machines tournantes industrielles constituent un enjeu majeur pour assurer leur bon fonctionnement et éviter des pannes coûteuses. Dans cette étude, nous nous concentrons sur l'application des réseaux de neurones artificiels pour le diagnostic des défauts dans les machines asynchrones. Nous avons procédé à la modélisation de la machine asynchrone, en tenant compte à la fois de son état sans défaut et de sa présence d'un défaut de court-circuit entre les spires. En utilisant la décomposition en ondelettes, nous avons calculé l'énergie des signaux provenant de la machine, permettant ainsi d'extraire des caractéristiques pertinentes. Ensuite, nous avons réalisé une étape d'extraction de données en se concentrant spécifiquement sur les caractéristiques énergétiques. Ces données ont été utilisées pour entraîner un réseau de neurones, en utilisant à la fois un algorithme de régression linéaire et une approche de classification. Les résultats obtenus ont démontré l'efficacité de notre approche dans la prédiction des défauts de la machine asynchrone. L'utilisation des réseaux de neurones artificiels a permis d'obtenir une précision élevée dans la détection et la classification des différents défauts. Cette étude ouvre la voie à de nouvelles perspectives dans le domaine du diagnostic des machines tournantes industrielles. Les réseaux de neurones artificiels se révèlent être des outils prometteurs pour améliorer la fiabilité et la maintenance préventive des machines, contribuant ainsi à une plus grande efficacité opérationnelle et à une réduction des coûts.

**Mots clés** : diagnostic des machines tournantes, classification des défauts, réseaux de neurones artificiels, machine asynchrone, décomposition en ondelettes, énergie, régression linéaire, classification...

