

الجمهورية الجزائرية الديمقراطية الشعبية

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR
ET DE LA RECHERCHE SCIENTIFIQUE



UNIVERSITE MOHAMED SEDDIK BENYAHIA JIJEL

Faculté des sciences et de la technologie

Département d'Electrotechnique

N° :...../2024

MEMOIRE DE MASTER

DOMAINE : Sciences et Technologies

FILIERE: Elecromécanique

SPECIALITE : Elecromécanique

Thème

**Application des méthodes d'intelligence artificielle dans le
contrôle non destructif par méthodes électromagnétiques.**

Présenté Par : Chenib Tamer

Encadré Par : Chelabi mohamed

Hafsi Khedidja

Date de soutenance : 30/06/2024

Jury de Soutenance

Président : Sedira Dounia

MCA

Univ MSB jijel

Encadreur : Chelabi Mohamed

MAB

Univ MSB jijel

Examineur : Bourahla Kheireddine

MAB

Univ MSB jijel

Promotion : 2023 /2024

Remerciement

Le grand remerciement revient à Allah qui nous a donné la force et le courage à réaliser et terminer ce modeste travail.

Nous tenons à remercier vivement notre encadrant Mr. Chelabi Mohamed pour nous avoir encadrés, encouragés et conseillés durant la période du mémoire.

Nous remercions vivement tous nos familles et nos amis sans exception, ainsi que toutes les personnes qui, de près ou de loin, ont contribué à la réalisation de ce travail.

Dédicace

À nos chers parents, pour leur amour, leur patience et leur soutien inconditionnel tout au long de nos vies et de nos études. Nous sommes si chanceux d'avoir des parents aussi merveilleux.

Nous tenons également à remercier nos frères et sœurs pour leur soutien et leur encouragement tout au long de nos études. Leur amitié et leur amour nous ont aidés à surmonter toutes les difficultés que nous avons rencontrées.

Nous dédions également ce mémoire à toutes les personnes qui nous ont aidés dans sa réalisation

Table de matière

Contents

Liste des figures

Liste des tableaux

Introduction générale.....

CHAPITRE I LE CONTROLE NON DESTRUCTIF CND PAR LES METHODES ELECTROMAGNETIQUES

| | |
|---|-----------|
| INTRODUCTION..... | 3 |
| I.1 QU'EST-CE QUE LE CONTROLE NON DESTRUCTIF CND | 3 |
| I.2 DOMAINE D'APPLICATION DU CND | 4 |
| I.3 METHODES ELECTROMAGNETIQUES DE CONTROLE NON DESTRUCTIF..... | 4 |
| <i>I.3.1 Méthodes magnétiques</i> | <i>5</i> |
| I.3.1.1 Mesures de flux de fuite | 5 |
| I.3.1.2 Mesures par effet barkhausen..... | 5 |
| <i>I.3.2 Méthodes électromagnétiques basses fréquences</i> | <i>6</i> |
| I.3.2.1 Évolution des contrôles par courant de foucault..... | 6 |
| I.3.2.2 Méthode ACFM | 7 |
| <i>I.3.3 Méthodes électromagnétiques hautes et très hautes fréquences</i> | <i>8</i> |
| I.3.3.1 Diélectrométrie | 8 |
| I.3.3.2 Micro-ondes | 8 |
| I.4 CND PAR COURANT DE FOUCAULT CND-CF..... | 9 |
| <i>I.4.1 Principe du contrôle par CF</i> | <i>9</i> |
| <i>I.4.2 Effet de peau</i> | <i>10</i> |
| <i>I.4.3 Différences modes d'excitations</i> | <i>11</i> |
| I.4.3.1 Alimentation mono fréquence | 11 |
| I.4.3.2 Alimentation multi fréquentielle | 11 |
| I.4.3.3 Alimentation par des courants pulsés..... | 12 |
| <i>I.4.4 Types de capteurs à CF.....</i> | <i>12</i> |
| I.4.4.1 Capteurs à bobine absolue..... | 12 |
| I.4.4.2 Capteurs différentiels..... | 13 |
| I.4.4.3 Capteurs à multi-éléments | 13 |
| I.4.4.4 Capteurs à enroulement bobiné..... | 13 |
| I.4.4.5 Capteurs rotatifs | 13 |
| <i>I.4.5 Objectifs des CND-CF.....</i> | <i>14</i> |
| <i>I.4.6 Avantages et limites de la technique.....</i> | <i>14</i> |
| I.4.6.1 Avantages de la technique des courants de Foucault | 14 |
| I.4.6.2 Limites de la technique des courants de Foucault | 15 |
| CONCLUSION | 15 |

CHAPITRE II MODELISATION ET SIMULATION D'UN CAPTEUR A COURANT DE FOUCAULT

| | |
|---|-----------|
| INTRODUCTION..... | 16 |
| II.1 PHENOMENES ELECTROMAGNETIQUES..... | 16 |
| <i>II.1.1 Lois classiques de l'électromagnétisme.....</i> | <i>17</i> |
| II.1.1.1 Equation de Maxwell..... | 17 |
| II.1.1.2 Relations du milieu | 18 |
| II.1.1.3 Relation de passage | 19 |
| II.1.1.4 Hypothèses simplificatrices..... | 20 |
| II.1.1.5 Différentes formulations du champ électromagnétique..... | 21 |
| II.2 METHODES DE TRAITEMENT ET DE RESOLUTION | 22 |
| <i>II.2.1 Méthodes analytiques</i> | <i>22</i> |
| <i>II.2.2 Méthodes numériques.....</i> | <i>23</i> |
| II.2.2.1 Méthode des différences finis..... | 23 |
| II.2.2.2 Méthode des volumes finis (MVF)..... | 23 |
| II.2.2.3 Méthode des éléments finis | 24 |
| <i>II.2.3 Résolution des EDP par la MEF.....</i> | <i>24</i> |
| II.2.3.1 Etapes de résolution par la MEF..... | 24 |
| II.3 MODELISATION PAR ELEMENTS FINIS SOUS COMSOL MULTI PHYSIQUE..... | 25 |
| <i>II.3.1 Description d'un capteur de référence JSAEM n° 2-5.....</i> | <i>25</i> |
| <i>II.3.2 Simulation de la réponse du capteur.....</i> | <i>26</i> |
| II.3.2.1 Choix de la formulation..... | 27 |
| II.3.2.2 Modélisation du capteur..... | 27 |
| II.3.2.3 Détermination de l'impédance du capteur | 28 |
| II.3.2.4 Maillage généré par COMSOL Multiphysique..... | 29 |
| CONCLUSION | 32 |
| CHAPITRE III L'APPLICATION D'IA AU CND PAR COURANT DE FOUCAULT | |
| INTRODUCTION..... | 34 |
| III.1 PRINCIPE D'IA..... | 34 |
| III.2 TYPES D'IA | 35 |
| <i>III.2.1 Intelligence artificielle étroite (ANI)</i> | <i>35</i> |
| <i>III.2.2 Intelligence artificielle générale (AGI).....</i> | <i>36</i> |
| <i>III.2.3 Super intelligence artificielle (ASI).....</i> | <i>37</i> |
| III.3 DIFFERENTES TECHNIQUES D'INTELLIGENCE ARTIFICIELLE | 37 |
| <i>III.3.1 Apprentissage automatique (Machine Learning).....</i> | <i>37</i> |
| III.3.1.1 Apprentissage non supervisé..... | 37 |
| III.3.1.2 Apprentissage supervisé | 38 |
| III.3.1.3 Apprentissage par renforcement | 38 |
| <i>III.3.2 Apprentissage profond (Deep Learning)</i> | <i>38</i> |
| III.3.2.1 Réseaux de neurones convolutionnels (CNN) : | 38 |
| III.3.2.2 Réseaux de neurones récurrents (RNN) : | 40 |
| <i>III.3.3 Traitement du langage naturel (NLP)</i> | <i>40</i> |
| III.4 RESEAUX DE NEURONES ARTIFICIELS | 40 |

| | |
|--|----|
| <i>III.4.1 Neurone</i> | 41 |
| <i>III.4.2 Bases biologiques</i> | 41 |
| <i>III.4.3 Neurone artificiel</i> | 41 |
| <i>III.4.4 Types des réseaux de neurones</i> | 43 |
| III.4.4.1 Architecture de réseaux de neurones | 43 |
| III.4.4.2 Connexions de réseaux de neurones | 43 |
| III.4.4.3 Réseaux de neurones multicouches..... | 44 |
| <i>III.4.5 Réseaux de neurone et l'apprentissage profond</i> | 45 |
| III.4.5.1 Réseaux de neurones convolutifs (CNN) | 45 |
| III.4.5.2 Réseaux de neurones convolutifs profonds (DCNN) | 46 |
| III.4.5.3 Réseaux neuronaux récurrents (RNN) | 46 |
| III.4.5.4 Machines à états liquides (LSM) | 46 |
| III.4.5.5 Mémoire longue à court terme (LSTM) | 47 |
| III.4.5.6 Unités récurrentes fermées (GRU) | 47 |
| III.5 RESOLUTION DES PROBLEMES DIRECT ET INVERSE | 48 |
| <i>III.5.1 Inversion itérative</i> | 49 |
| <i>III.5.2 Inversion directe</i> | 49 |
| III.5 APPLICATIONS DES RESEAUX DE NEURONES AU CND PAR CF | 50 |
| <i>III.5.1 Créations de la base de données</i> | 50 |
| <i>III.5.2 Conditionnement des données</i> | 51 |
| III.5.2.1 Normalisation | 51 |
| III.5.2.2 Centrage..... | 51 |
| <i>III.5.3 Inversion par réseau de neurones</i> | 53 |
| III.5.3.1 Apprentissage | 53 |
| III.5.3.2 Validation..... | 53 |
| <i>III.5.4 Application sur les données de simulation</i> | 53 |
| CONCLUSION | 57 |
| Conclusion générale..... | 59 |

Liste des figures

Chapitre I Le contrôle non destructif CND par les méthodes électromagnétiques

| | |
|--|----|
| Figure I.1 Méthode de contrôle par flux de fuite..... | 5 |
| Figure I.2 : Influence des sollicitations mécaniques sur le bruit Barkhausen..... | 6 |
| Figure I.3 : Le CND par CF..... | 7 |
| Figure I.4 : Méthode ACFM..... | 7 |
| Figure I.5 : Principe de la détection par courants de Foucault..... | 9 |
| Figure I.6 : Détection d'un défaut avec une sonde encerclant différentielle..... | 10 |
| Figure I.7 : Répartition des courants Foucault..... | 10 |
| Figure I.8 : Multi-capteurs à CF..... | 13 |

Chapitre II Modélisation et simulation d'un capteur à courant de foucault

| | |
|---|----|
| Figure II.1 : Problème type on électrotechnique. | 17 |
| Figure II.2 : interface entre deux milieux..... | 19 |
| Figure II.3 : Problème général magnétostatique..... | 21 |
| Figure II.4 : Problème général magnétodynamique..... | 22 |
| Figure II.5 : Structure du system JSAEM..... | 26 |
| Figure II. 6 : Bobine réelle et son modèle simplifié..... | 27 |
| Figure II.7 : Orientation de la bobine pour la définition de J_0 | 28 |
| Figure II.8 : La Géométrie et le maillage du système..... | 29 |
| Figure II.9 : Zoom de la répartition des courants induits..... | 30 |
| Figure II.10 : Etapes de calcul de l'impédance du système..... | 31 |
| Figure II.11 : Variation de l'impédance du système..... | 31 |
| Figure II.12 : Variation de l'impédance du système du thèse de Chelabi | 32 |

Chapitre III L'application d'IA au CND par courant de foucault

| | |
|--|----|
| Figure III.1 : Représentation schématique d'un neurone biologique. | 41 |
| Figure III.2 : Représentation d'un neurone artificiel..... | 43 |
| Figure III.3 : Connexions directes..... | 44 |
| Figure III.4 : Connexions récurrentes..... | 44 |
| Figure III.5 : Connexions partielles..... | 44 |
| Figure III.6 : Connexions totales..... | 44 |
| Figure III.7 : Réseau de neurones multicouches..... | 45 |
| Figure III.8 : un exemple d'unit GRU..... | 48 |
| Figure III.9 : Problème direct /problème inverse..... | 48 |

| | |
|---|----|
| Figure III.10 : Schéma du processus itératif d'inversion..... | 49 |
| Figure III.11 : Schéma du processus d'inversion directe utilisant l'inverse du modèle direct..... | 50 |
| Figure III.12 : Schéma du processus d'inversion directe basé sur un modèle d'inverse..... | 50 |
| Figure III.13 : Répartition de la base de données dans l'espace de variation..... | 51 |
| Figure III.14 : Procédure d'inversion par réseau de neurones..... | 53 |
| Figure III .15 : Évolution de l'erreur d'apprentissage pour le modèle MLP destiné à prédire les profondeurs..... | 55 |
| Figure III .16 : Évolution de l'erreur d'apprentissage pour le modèle MLP destiné à prédire les largeurs..... | 55 |
| Figure III.17 : Profil de la longueur sur la base de validation obtenu par le modèle MLP..... | 57 |
| Figure III.18 : Profil de la longueur sur la base de validation obtenu par le modèle MLP..... | 57 |

Liste des tableaux

Chapitre II Modélisation et simulation d'un capteur à courant de foucault

Tableau II.1 : caractéristiques de la sonde et de la plaque métallique..... 26

Chapitre III L'application d'IA au CND par courant de foucault

Tableau III.1: Résumé les performances des modèles MLP..... 56

Introduction générale

Introduction générale

L'intelligence artificielle (IA) révolutionne de nombreux secteurs industriels, y compris le contrôle non destructif (CND). Ce dernier est crucial pour l'inspection et la maintenance des structures et des matériaux, car il permet de détecter des défauts sans endommager les objets examinés. Parmi les différentes techniques de CND, les méthodes électromagnétiques sont particulièrement prisées en raison de leur efficacité à identifier des anomalies dans les matériaux conducteurs.

Les méthodes électromagnétiques de CND utilisent des champs magnétiques pour détecter des défauts tels que des fissures, des inclusions ou des variations de conductivité. Cependant, l'interprétation des données obtenues à partir de ces techniques peut être complexe et nécessite souvent des compétences spécialisées.

L'IA révolutionne le CND électromagnétique : diagnostics plus précis, analyses plus rapides et moindre expertise requise. Les algorithmes intelligents apprennent à partir de données complexes pour automatiser l'analyse et fiabiliser les résultats, rendant le CND plus accessible et performant. Il est possible d'améliorer la précision des diagnostics, de réduire le temps d'analyse et de minimiser la dépendance aux experts humains.

L'intégration de l'IA dans les techniques de CND électromagnétiques présente de nombreux avantages. Elle permet d'automatiser le processus de détection des défauts, d'augmenter la fiabilité des inspections et de fournir des diagnostics plus rapides. De plus, l'utilisation de l'IA facilite la gestion et l'analyse des vastes quantités de données générées lors des inspections, améliorant ainsi l'efficacité globale du processus.

Dans le cadre de ce mémoire de Master, l'objectif principal était de développer des modèles d'inversion directe, également appelés modèles comportementaux paramétriques. Ces modèles, construits à partir de bases de données issues de simulations numériques, permettent une caractérisation précise des défauts dans les pièces métalliques. Pour une meilleure compréhension du travail, le mémoire est organisé en trois chapitres principaux.

Le premier chapitre de ce mémoire pose les bases solides pour la compréhension du CND par électromagnétisme. Il présente les différentes techniques utilisées, en expliquant les principes physiques qui les fondent. De plus, ce chapitre dresse un inventaire complet des capteurs magnétiques employés dans ce domaine, permettant au lecteur d'appréhender pleinement les outils mis en œuvre dans le cadre du CND électromagnétique.

Le deuxième chapitre de ce mémoire s'attaque aux bases théoriques du contrôle non destructif (CND) par électromagnétisme. Il débute par un rappel des lois fondamentales qui régissent les phénomènes électromagnétiques, à savoir les équations de Maxwell. À partir de ces équations, l'équation de la magnétostatique est formulée. Ensuite, le chapitre explore les différentes méthodes de résolution de ce type d'équations, en accordant une attention particulière à la méthode des éléments finis. Cette méthode est présentée avec sa formulation par les résidus pondérés, puis appliquée à la modélisation d'un capteur à courant de Foucault, illustrant ainsi son utilisation concrète dans le domaine du CND électromagnétique.

Le troisième chapitre de ce mémoire est structuré en deux parties distinctes. La première partie s'attache à présenter les concepts fondamentaux de l'intelligence artificielle (IA), en offrant une introduction claire et accessible à ce domaine en plein essor. La seconde partie explore l'application concrète de l'IA dans le contexte du CND électromagnétique. Plus précisément, elle met en œuvre un modèle d'apprentissage automatique de type MLP (Multilayer Perceptron) pour estimer les dimensions des défauts présents dans les pièces métalliques. Ce modèle est entraîné à partir de bases de données obtenues par une méthode directe, permettant ainsi une estimation précise des caractéristiques des défauts. Les résultats obtenus par ce modèle, ainsi que leur interprétation approfondie, font l'objet d'une présentation détaillée dans cette seconde partie.

Enfin, ce mémoire va être terminé par une conclusion générale qui englobera l'ensemble des travaux effectués, et par une liste adéquate de références bibliographiques.

Chapitre I

**Le contrôle non destructif CND par
les méthodes électromagnétiques**

Introduction

Le contrôle non destructif (CND) par les méthodes électromagnétiques est une technique essentielle dans l'industrie pour évaluer l'intégrité et la qualité des matériaux sans les endommager. Utilisant des principes électromagnétiques, ces méthodes permettent de détecter des défauts comme les fissures, les inclusions, et les variations de composition. Les techniques courantes incluent les courants de Foucault, l'induction magnétique et la radiographie électromagnétique. Les courants de Foucault, par exemple, exploitent l'induction de courants électriques dans le matériau pour révéler des discontinuités. L'induction magnétique, quant à elle, utilise des champs magnétiques pour identifier des défauts internes ou de surface. Ces méthodes sont particulièrement appréciées pour leur capacité à fournir des résultats rapides et précis, tout en étant non invasives et adaptables à une variété de matériaux et de formes. Elles sont cruciales pour assurer la sécurité, la fiabilité et la durabilité des structures dans des secteurs.

I.1 Qu'est-ce que le contrôle non destructif CND

Les contrôles non destructifs (CND) sont un ensemble de méthodes permettant de caractériser l'état d'intégrité d'une structure ou d'un matériau sans l'endommager. On l'appelle également contrôle non destructif (CND) ou évaluation non destructive. Les tests non destructifs sont utilisés dans l'industrie pour mesurer et garantir la cohérence et l'intégrité des pièces, évitant ainsi d'avoir à les démonter ou à les déplacer. Cette méthode est importante pour l'industrie car elle n'endommage pas les pièces et permet de détecter des défauts qui pourraient altérer la cohérence du produit, permettant ainsi d'économiser de l'argent.

Il existe plusieurs techniques de contrôle non destructif, mais cinq sont spécifiquement utilisées par l'industrie. Ces technologies sont la microscopie magnétique, la radiographie, les ultrasons, le ressuage et la thermographie infrarouge. Chacune de ces techniques présente ses propres avantages et inconvénients, et le choix de la technique dépend du type de défaut recherché et des caractéristiques de la pièce à inspecter [1].

Par conséquent, les tests non destructifs (CND) constituent une méthode importante dans l'industrie pour mesurer et garantir la cohérence et l'intégrité des pièces sans les endommager. Il existe une variété de techniques de contrôle non destructif, chacune ayant ses propres avantages et inconvénients, et le choix de la technique dépend du type de défauts recherchés et des caractéristiques de la pièce inspectée [1].

I.2 Domaine d'application du CND

La technologie des tests non destructifs est utilisée dans divers domaines industriels tels que l'aviation, l'aérospatiale, l'industrie pétrolière, les chemins de fer, l'énergie nucléaire, l'énergie et l'automobile. Les opérateurs utilisent ces évaluations non destructives pour mettre en évidence les défauts susceptibles d'altérer la conformité des produits, comme le non-respect des spécifications, les défauts de surface et les défauts internes. Ainsi, l'évaluation non destructive permet aux fabricants non seulement de s'assurer que les produits qu'ils vendent répondent aux exigences, mais également de contrôler l'usure du produit tout au long de son cycle de vie, garantissant ainsi la sécurité du produit tout au long de son utilisation [2].

Voici quelques-uns des principaux domaines d'application du CND :

- Industrie automobile : Le Contrôle Non Destructif (CND) est utilisé pour vérifier la qualité et la fiabilité des blocs moteurs.
- Industrie pétrolière : Le CND est utilisé pour inspecter les pipelines, les tubes, les barres, les soudures et les réservoirs, afin de détecter d'éventuels défauts et assurer la sécurité des installations.
- Industrie navale : Le CND est utilisé pour inspecter les coques de navires et garantir leur intégrité.
- Aéronautique : Le CND est utilisé pour inspecter les poutres, les ailes d'avion, les pièces moteurs, les trains d'atterrissage et d'autres composants critiques, afin d'assurer la sécurité des avions.
- Aérospatiale et armée : Le CND est utilisé pour inspecter les matériaux et les structures des engins spatiaux et des équipements militaires.
- Industrie de l'énergie : Le CND est utilisé pour inspecter les réacteurs, les chaudières, la tuyauterie, les turbines et d'autres composants critiques, afin de garantir la sécurité et la fiabilité des installations.
- Ferroviaire : Le CND est utilisé pour inspecter les essieux, les roues, les bogies et d'autres composants critiques, afin d'assurer la sécurité des trains.

I.3 Méthodes électromagnétiques de contrôle non destructif

Ces techniques exploitent les propriétés électromagnétiques des matériaux pour détecter et caractériser les défauts internes ou de surface. Parmi les méthodes les plus couramment utilisées, on retrouve les :

I.3.1 Méthodes magnétiques

Les contrôles non destructifs (CND) par les méthodes magnétiques sont essentiels pour l'inspection et l'évaluation de l'intégrité des matériaux ferromagnétiques, tels que l'acier et le fer. Les principales méthodes magnétiques utilisées sont :

I.3.1.1 Mesures de flux de fuite

Le contrôle magnétoscopique est une technique de contrôle non destructif utilisant un champ magnétique dont les valeurs sont spécifiques à chaque pièce. C'est l'une des techniques les plus anciennes (avec le ressuage) et permet de détecter les discontinuités de surface. Cependant, cette technique ne peut être utilisée que sur des matériaux ferromagnétiques (c'est-à-dire des matériaux sensibles aux aimants).

Les télescopes magnétiques ne peuvent détecter que les discontinuités ouvertes ou légèrement situées en dessous de la surface, telles que les fissures, les craquelures ou les cônes.




Figure I.1 Méthode de contrôle par flux de fuite [3].

La réalisation de tests non destructifs à l'aide d'un microscope magnétique est relativement simple. Il suffit de magnétiser la zone que l'on souhaite contrôler afin de créer une fuite de champ magnétique vers la discontinuité. Les fuites repoussent les particules ferromagnétiques vers les discontinuités, permettant ainsi de visualiser les défauts. [3]

I.3.1.2 Mesures par effet barkhausen

L'effet Barkhausen résulte d'une émission locale d'ondes électromagnétiques résultant de l'action d'un champ magnétique sur les cristaux d'un matériau. La technique Barkhausen repose

sur la microstructure magnétique et sa réorganisation, ce qui permet d'obtenir des informations précises sur l'état métallurgique du matériau et le niveau de contraintes résiduelles.

On peut mesurer les émissions Barkhausen à l'aide de sondes encerclées ou de sondes de côté composées de bobines plates placées à la surface de l'appareil. La courbe enveloppe du bruit Barkhausen est généralement tracée en fonction du champ appliqué et présente la forme d'un pic [4].

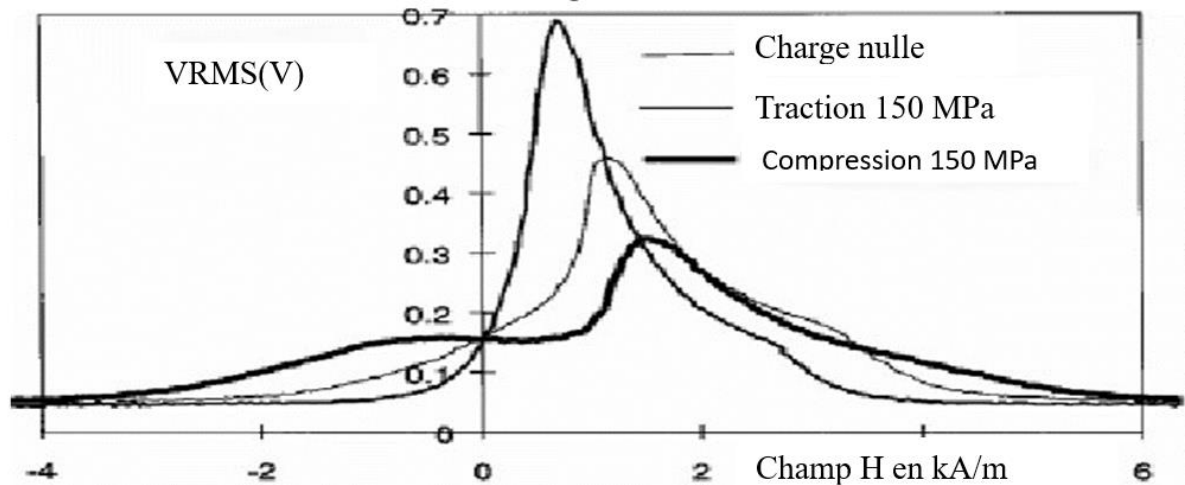


Figure I.2 : Influence des sollicitations mécaniques sur le bruit Barkhausen [4].

I.3.2 Méthodes électromagnétiques basses fréquences

I.3.2.1 Évolution des contrôles par courant de Foucault

Les contrôles par courants de Foucault (Eddy currents) sont une méthode non destructive largement utilisée pour l'inspection des matériaux conducteurs, notamment dans les secteurs de l'aéronautique, de l'automobile et du nucléaire. Cette technique repose sur l'induction de courants électriques dans le matériau à inspecter à l'aide d'un champ magnétique alternatif. Les variations de ces courants, causées par la présence de défauts ou de variations de propriétés matérielles, sont détectées et analysées pour évaluer l'intégrité de la pièce.

Un contrôle de cette nature est obtenu grâce à l'utilisation d'un champ magnétique capable de s'adapter aux contours d'un composant métallique. En cas de perturbations dues à des anomalies dans les courants induits à proximité, l'impédance observée aux bornes du capteur subira des modifications. En manipulant la fréquence du courant d'excitation et la configuration des bobines, diverses formes de contrôle peuvent être exécutées, notamment le contrôle à fréquence unique, multifréquence et en mode pulsé.




Figure I. 3 : Le CND par CF[5].

I.3.2.2 Méthode ACFM

La méthode ACFM (Alternating Current Field Measurement) repose sur la création d'un courant électrique alternatif uniforme qui est induit dans la peau du matériau à analyser. En présence d'un défaut, ce courant génère un champ magnétique qui sera perturbé et circulera autour des extrémités de celui-ci. Lorsqu'il y a un problème, la sonde, qui comprend de petits capteurs qui évaluent les perturbations du champ magnétique généré, envoie les informations au logiciel qui affiche alors des "pics" et un autre signal appelé "le tracé papillon ». L'examen du logiciel de ces tracés nous donne des informations précises sur la longueur et la profondeur du défaut [6].



Figure I.4: Méthode ACFM [6].

I.3.3 Méthodes électromagnétiques hautes et très hautes fréquences

I.3.3.1 Diélectrométrie

La diélectrométrie est une technique de Contrôle Non Destructif (CND) qui repose sur la mesure des propriétés diélectriques d'un matériau pour détecter des défauts ou des anomalies. Les propriétés diélectriques d'un matériau, telles que la permittivité électrique et la perte diélectrique, peuvent varier en fonction de la présence de défauts tels que des fissures, des inclusions ou des variations de composition. La diélectrométrie peut être réalisée de différentes manières, notamment en utilisant des capteurs capacitifs ou des sondes électromagnétiques. Dans les applications de CND, cette technique est souvent utilisée pour inspecter des matériaux isolants tels que les polymères, les composites et les céramiques. La diélectrométrie est une technique de CND qui exploite les variations des propriétés diélectriques des matériaux pour détecter des défauts internes ou des anomalies. Elle offre une alternative non destructive pour l'inspection de matériaux isolants, mais nécessite une attention particulière aux conditions environnementales et aux paramètres de mesure pour obtenir des résultats fiables [7].

I.3.3.2 Micro-ondes

L'interaction des micro-ondes avec les matériaux est définie par l'énergie électrique et magnétique emmagasinée et dissipée, en termes de polarisation, de magnétisation et de conduction. Les micro-ondes sont totalement réfléchies à la surface des matériaux conducteurs, permettant ainsi l'étude de leur surface externe.

Les micro-ondes sont partialement réfléchies et transmises dans les matériaux diélectriques comme les plastiques, les céramiques et les matières organiques. Cette interaction ne permet pas seulement la mesure d'épaisseur, de dimension, mais aussi le contrôle non destructif de l'intérieur et la détection du matériau, la détermination de ses caractéristiques d'anomalies.

Une onde électromagnétique se propageant dans un milieu diélectrique ne subit de réflexion et de transmission partielle, que si elle rencontre une variation d'impédance. D'autre part, chaque matériau est caractérisé par une impédance propre à lui. Dans ce cas-là l'onde électromagnétique est autant réfléchi qu'il existe de changement de milieu. Sa vitesse de propagation et son amplitude varient aussi avec le changement de milieu.

Une onde émise dans la direction d'une pièce à contrôler saine ne subit que deux réflexions, une au début de la pièce et une autre à la fin de la pièce, qui correspond aux deux discontinuités

majeures d'impédance. La présence d'une anomalie dans la matière va générer une ou plusieurs autres ondes réfléchies en plus des deux principales [8].

I.4 CND par courant de Foucault CND-CF

I.4.1 Principe du contrôle par CF

Le contrôle par courants de Foucault consiste à créer un champ magnétique dans une bobine que l'on déplace le long de la surface d'une pièce métallique. Tout défaut dans la pièce perturbera les lignes de courant induites, ce qui entraînera une modification du coefficient d'auto-induction, qui sera détectée.

En général, on utilise une méthode comparative dont le but est de mesurer la différence entre l'impédance de la bobine de la pièce contrôlée et celle d'une pièce de référence (sans défauts). En ajustant la fréquence du courant d'excitation et la géométrie des bobines, il est possible de contrôler jusqu'à quelques millimètres de la surface [9].




Figure I. 5: Principe de la détection par courants de Foucault [10].

L'archivage électronique des signatures de défauts et le traitement du signal sont des développements actuels qui visent à simplifier l'utilisation de la technique du CND par courants de Foucault et à élargir son champ d'application. Ils sont utilisés à la fois pour mesurer la corrosion uniforme et la corrosion localisée. Par exemple, les courants de Foucault sont souvent utilisés pour mesurer la corrosion sous contrainte, qui peut entraîner le développement de fissures [9].




Figure I.6: Détection d'un défaut avec une sonde encerclant différentielle [10].

I.4.2 Effet de peau

L'effet de peau (skin depth) est un phénomène électromagnétique crucial dans le domaine des contrôles non destructifs par courants de Foucault. La profondeur de pénétration est la distance à laquelle l'intensité du courant circule dans la pièce.

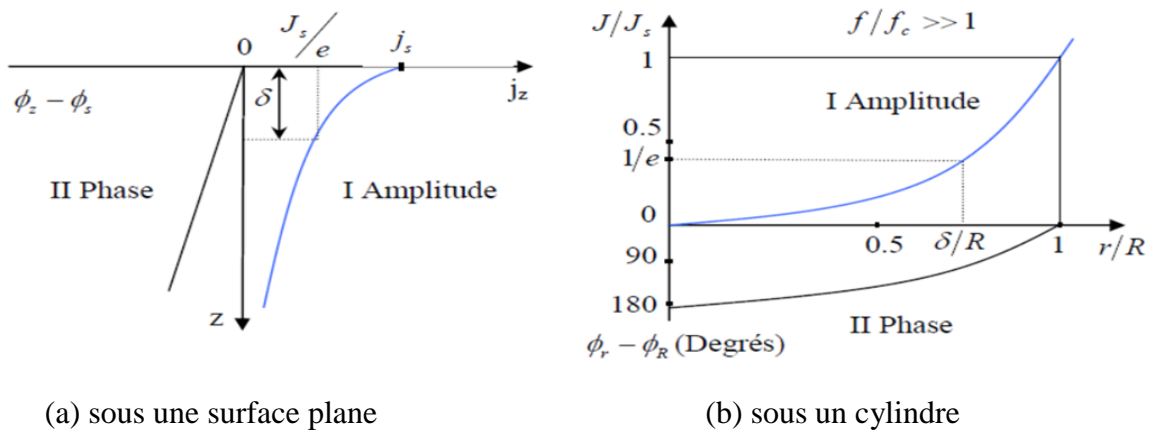
La profondeur de peau δ est donnée par la formule :

$$\Delta = \sqrt{\frac{2}{\mu\sigma\omega}} \quad (\text{I.1})$$

Ou :

- σ est la résistivité électrique du matériau [$\Omega\cdot\text{m}$].
- μ est la perméabilité magnétique du matériau [H/m].
- ω est la pulsation angulaire du champ magnétique [rad/s].

Cette profondeur est purement conventionnelle. Elle est appelée profondeur de pénétration ou épaisseur de peau. Seuls 63 % des courants de Foucault circulent dans cette épaisseur, ce qui en fait les couches les plus importantes du point de vue de la sensibilité aux interactions avec les défauts de surface. [8]



(a) sous une surface plane

(b) sous un cylindre

Figure I.7: Répartition des courants Foucault [8].

Avec :

R : Rayon de la barre pleine [m].

J : Densité de courant [A/m^2].

J_s : Densité de courant en surface [A/m^2].

J_z : Densité de courant à la profondeur z [A/m^2].

Φ_z : Phase des courants induits à une surface de profondeur z [Rad].

Φ_s : Phase des courants induits à la surface [Rad].

f_c : Fréquence caractéristique (ou fréquence limite) [Hz].

Les courants de Foucault induits sont parallèles au courant inducteur et ont la même fréquence. Ils sont progressivement déphasés à partir de la surface ($z = 0$) et diminuent exponentiellement en amplitude (figure I.7). L'effet de peau résultant est caractérisé par une profondeur de pénétration δ définie par l'équation (I.1).

I.4.3 Différences modes d'excitations

Les capteurs à courants de Foucault peuvent fonctionner selon différents modes d'excitation pour générer le champ électromagnétique nécessaire à la détection des défauts dans les matériaux conducteurs. Voici les principaux modes d'excitation des capteurs à courants de Foucault :

I.4.3.1 Alimentation mono fréquence

Cette technique utilise une seule fréquence et l'excitation peut être une onde sinusoïdale. De plus, elle est utilisée lorsqu'une seule bobine transmet et reçoit (capteur double fonction). Elle convient aux matériaux aux propriétés linéaires.

Cette méthode est rarement utilisée, d'une part parce que les interférences sont difficiles à éliminer, et d'autre part parce qu'en revanche, il est difficile de caractériser les défauts.

I.4.3.2 Alimentation multi fréquentielle

La phase et l'amplitude d'un signal produit par un paramètre quelconque qui agit sur l'équilibre d'un pont de bobines varient en fonction de la fréquence d'excitation. Cette variation dépend du type de paramètre considéré. Par exemple, certains paramètres donnent une réponse en amplitude forte à basse fréquence, tandis que d'autres le font à haute fréquence. Il est donc possible de discriminer différents paramètres d'action en utilisant simultanément plusieurs

fréquences d'excitation des sondes. C'est le principe de la technique multifréquence, qui permet en pratique de réduire fortement l'effet des facteurs perturbateurs dans les cas de contrôle difficile, ou encore de détecter simultanément plusieurs types de défauts bien différenciés.

Le contrôle par courants de Foucault multifréquence est très couramment utilisé pour inverser les données fournies par le capteur, afin de déterminer les paramètres du matériau en question.

La méthode multifréquence consiste à choisir soigneusement les fréquences d'excitation du capteur afin d'obtenir des informations riches et complémentaires sur le matériau à contrôler. L'idéal serait que chaque paramètre exerce une influence sur le signal de mesure à une fréquence unique. Cependant, cela s'avère difficile, voire impossible à réaliser en pratique. Le nombre de fréquences d'alimentation nécessaires est étroitement lié au nombre de paramètres à identifier et à la complexité du dispositif complet utilisé [9].

I.4.3.3 Alimentation par des courants pulsés

La méthode de contrôle présentée ici s'inscrit dans la continuité de l'approche multifréquence, offrant deux avantages significatifs par rapport au contrôle mono fréquence. Comparé à un signal sinusoïdal traditionnel d'une amplitude d'environ cent milliampères, un signal d'excitation pulsé (qui a une durée finie) atteint une valeur d'intensité nettement plus élevée, mesurant dans la plage de plusieurs ampères. Ce type unique d'excitation utilise un signal à large bande spectrale qui englobe efficacement le contrôle multifréquence.

I.4.4 Types de capteurs à CF

Les capteurs à courants de Foucault sont des dispositifs essentiels dans le domaine des contrôles non destructifs (CND) pour la détection de défauts dans les matériaux conducteurs. Il existe différents types de capteurs à courants de Foucault, chacun ayant des caractéristiques spécifiques adaptées à diverses applications et types de matériaux. Voici les principaux types de capteurs à courants de Foucault :

I.4.4.1 Capteurs à bobine absolue

Les capteurs à bobine absolue sont constitués d'une seule bobine qui génère un champ magnétique alternatif. Ces capteurs mesurent les variations d'impédance de la bobine lorsqu'elle est placée près de la surface du matériau inspecté. Ils sont principalement utilisés pour détecter les défauts de surface et sous-surface. [11]

I.4.4.2 Capteurs différentiels

Les capteurs différentiels comportent deux bobines disposées de manière à mesurer les différences de champ magnétique entre deux points adjacents de la surface inspectée. Ce type de capteur est particulièrement sensible aux petits défauts de surface et est souvent utilisé pour détecter des fissures fines. [11]

I.4.4.3 Capteurs à multi-éléments

Les capteurs à multi-éléments (ou matrices de capteurs) contiennent plusieurs bobines ou éléments de détection disposés en réseau. Ils permettent de couvrir une plus grande surface en une seule passe et sont utilisés pour les inspections rapides de grandes zones. Ils offrent une haute résolution et sont capables de détecter des défauts complexes. [12]




Figure I.7: Multi-capteurs à CF [12].

I.4.4.4 Capteurs à enroulement bobiné

Ces capteurs sont conçus avec des enroulements de bobines spécialement fabriqués pour s'adapter à la géométrie de la pièce inspectée. Ils sont souvent utilisés pour inspecter des pièces aux formes irrégulières ou difficiles d'accès. Leur conception sur mesure permet une meilleure adaptabilité aux contours spécifiques des pièces [12].

I.4.4.5 Capteurs rotatifs

Les capteurs rotatifs sont utilisés pour l'inspection de surfaces cylindriques ou de pièces de forme complexe. Ils sont montés sur un mécanisme rotatif qui permet de balayer la surface de la pièce, offrant ainsi une inspection complète et uniforme. Ces capteurs sont souvent utilisés dans l'industrie aéronautique et automobile pour inspecter des pièces telles que les axes et les arbres [12].

I.4.5 Objectifs des CND-CF

Un capteur à courants de Foucault peut accomplir diverses tâches. Du fait que l'impédance du système Capteur/Pièce est fonction des différentes caractéristiques électromagnétiques et géométriques. Cette technique est parfois utilisée pour la caractérisation géométrique et électromagnétique, d'autre fois pour le contrôle de l'état de santé en cherchant et caractérisant les défauts [10].

- Caractérisation géométrique
 - Mesure de l'entrefer.
 - Mesure de l'épaisseur.
- Caractérisation électromagnétique
 - Mesure de la conductivité.
 - Mesure de la perméabilité.
- Contrôle de l'état de la santé
 - Détection du défaut.
 - Position du défaut.
 - Taille du défaut.
 - Forme du défaut.
 - Propriété physique.

I.4.6 Avantages et limites de la technique

Les contrôles non destructifs (CND) par courants de Foucault sont largement utilisés pour l'inspection des matériaux conducteurs, offrant de nombreux avantages mais également certaines limitations. Voici une analyse détaillée des avantages et des limites de cette technique.

I.4.6.1 Avantages de la technique des courants de Foucault

- Permet d'inspecter les matériaux sans les endommager, ce qui est crucial pour les composants critiques.
- Très efficace pour détecter les fissures, les inclusions et autres défauts proches de la surface.
- Permet des inspections rapides et souvent en temps réel, ce qui est avantageux pour le contrôle de production et la maintenance.
- Peut inspecter les matériaux recouverts de peinture ou d'autres revêtements, réduisant ainsi le besoin de préparation de surface.

- Capable de fournir des informations quantitatives sur la taille, la profondeur et l'orientation des défauts détectés.
- Peut être facilement automatisée et intégrée dans les systèmes de production pour une surveillance continue.

I.4.6.2 Limites de la technique des courants de Foucault

- La profondeur de pénétration des courants de Foucault est limitée, surtout à haute fréquence, ce qui rend difficile la détection des défauts profonds.
- La technique est principalement limitée aux matériaux conducteurs. Elle n'est pas efficace pour les matériaux non conducteurs ou à faible conductivité.
- Les variations dans les propriétés matérielles, telles que la conductivité et la perméabilité, peuvent affecter les résultats de l'inspection et nécessitent une calibration précise.
- Les signaux obtenus peuvent être complexes à interpréter et nécessitent des systèmes de traitement du signal sophistiqués et des compétences spécialisées.

Conclusion

Le contrôle non destructif (CND) par les méthodes électromagnétiques, en particulier les courants de Foucault, est une technique très utilisée dans l'industrie pour détecter les défauts de surface dans les matériaux conducteurs d'électricité.

Dans ce chapitre on a donné les différentes techniques du contrôle non destructif par les méthodes électromagnétiques. De plus nous avons essayé tout le long de ce chapitre de définir quelques notions sur les capteurs à courants de Foucault tel que : leurs principes de détection, leurs constitutions, les différents modes d'excitation et on a terminé par les différents types de sonde à courants de Foucault.

Chapitre II

**Modélisation et simulation d'un
capteur à courant de foucault**

Introduction

Le monde qui nous entoure est rempli de phénomènes fascinants, régis par les lois de la physique. Parmi ces phénomènes, les courants de Foucault occupent une place particulière. Présents dans de nombreux dispositifs électromagnétiques, ils jouent un rôle crucial dans leur fonctionnement et leurs performances.

Ce chapitre s'aventure dans l'univers des courants de Foucault, explorant leurs principes fondamentaux, leurs applications diverses et les méthodes de modélisation employées pour les analyser.

En premier lieu, nous plongerons dans les origines des courants de Foucault, découvrant le phénomène d'induction électromagnétique qui les sous-tend. Nous étudierons ensuite les équations de Maxwell, qui constituent le fondement théorique de leur comportement.

Par la suite, nous nous tournerons vers les applications concrètes des courants de Foucault. Commencant notre travail tout d'abord en simulant un capteur à fonction double (émetteur-récepteur) constitué d'une seule bobine et observant sa variation d'impédance pour un défaut surfacique.

Sachant que le capteur est constitué d'une bobine cylindrique, une modélisation 2D axisymétrique est faisable. Mais, la présence d'un défaut de forme quelconque, et d'une bobine qui se déplace suivant la longueur de la pièce, nous obligent d'effectuer une étude en 3D. Ici, le logiciel Comsol multiphysique est utilisé pour la modélisation du système.

II.1 Phénomènes électromagnétiques

Quel que soit le problème de type électromagnétique il peut de manière générale être schématisée par la figure suivante :

Le problème est constitué des régions suivantes :

- Une boîte d'air qui englobe toutes les autres régions,
- Une bobine inductrice (capteur) dans laquelle circule un courant connu de densité (on suppose que les courants de Foucault ne développent pas dans cette région),
- Une région conductrice et ferromagnétique (pièce métallique) caractérisée par une conductivité σ et une perméabilité μ (les courants de Foucault se développent dans cette région)

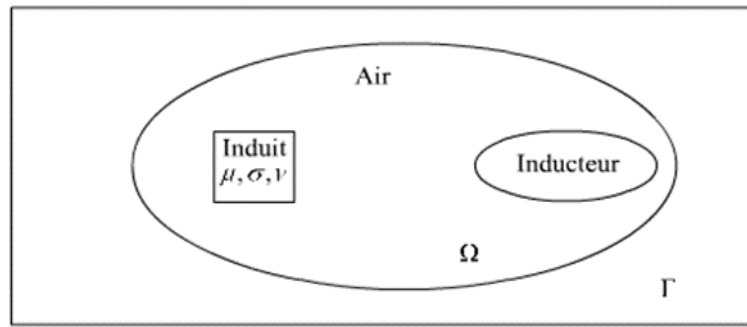


Figure II.1 : Problème type de courant-foucault on électrotechnique [13].

II.1.1 Lois classiques de l'électromagnétisme

II.1.1.1 Equation de Maxwell

Tous les phénomènes électromagnétiques sont régis par les quatre équations de Maxwell et les lois de comportement des milieux. Quelle que soit la nature des phénomènes électromagnétiques, ils sont modélisés par les équations de Maxwell, dont la forme la plus générale est définie comme suit [14] :

- Equation Maxwell-faraday

$$r\vec{\partial}t\vec{E} = -\frac{\partial\vec{B}}{\partial t} \quad (\text{II.1})$$

- Equation de conservation du flux magnétique

$$\text{div}\vec{B} = 0 \quad (\text{II.2})$$

- Equation Maxwell-Ampere

$$r\vec{\partial}t\vec{H} = \vec{J}_{tot} \quad (\text{II.3})$$

- Equation Maxwell-Gauss

$$\text{div}\vec{D} = \rho \quad (\text{II.4})$$

Avec :

\vec{E} : Le vecteur champ électrique [V/m].

\vec{H} : Le vecteur champ magnétique [A/m].

\vec{B} : La vecteur induction magnétique [T].

\vec{J} : Le vecteur densité de courant [A/m²].

\vec{D} : L'induction électrique [A.S/m²].

ρ : La densité de charge [C/m^3].

t : le temps [s].

μ : La perméabilité absolue [H/m].

σ : La conductivité du matériau [s/m].

II.1.1.2 Relations du milieu

Pour modéliser le comportement des milieux, des relations entre les grandeurs électromagnétiques sont rajoutées. Sans ces relations, le système formé par les équations électromagnétiques est indéterminé. Le champ électrique \vec{E} est lié à la densité de courant \vec{j} par [15] :

- Relation magnétique :

$$\vec{B} = \mu \cdot \vec{H} \quad (\text{II.5})$$

- Relation électrique :

$$\vec{D} = \varepsilon \cdot \vec{E} \quad (\text{II.6})$$

- Loi d'ohm :

$$\vec{j} = \sigma \cdot \vec{E} \quad (\text{II.7})$$

Avec : $\mu = \mu_0 \cdot \mu_r$

$\varepsilon = \varepsilon_0 \varepsilon_r$

ε : permittivité électrique [F/m].

σ : conductivité électrique [S/m].

μ : perméabilité magnétique [H/m].

\vec{B}_r : Induction rémanente de l'aimant permanent [T].

II.1.1.3 Relation de passage

Pour les équations de Maxwell, il est nécessaire d'exprimer les conditions de passage entre les différents milieux du problème considéré. Dans les problèmes de la compatibilité électromagnétique on rencontre des structures qui comportent différents milieux avec des propriétés physiques différentes, les conditions de passage aux interfaces sont obtenues à partir des équations de Maxwell [15].




Figure II.2 : interface entre deux milieux [15].

Les conditions de passage appliquent dans l'interface entre deux milieux de propriétés physiques différent.

- Conservation de la composante tangentielle du champ électrique $[\vec{E}]$.

$$(\vec{E}_2 - \vec{E}_1) \times \vec{n} = 0 \quad (\text{II.8})$$

- Conservation de la composante normale de l'induction magnétique $[\vec{B}]$.

$$(\vec{B}_2 - \vec{B}_1) \cdot \vec{n} = 0 \quad (\text{II.9})$$

- Discontinuité de la composante tangentielle du champ magnétique due aux courants surfaciques s'ils existent.

$$(\vec{H}_2 - \vec{H}_1) \times \vec{n} = \vec{J}_s \quad (\text{II.10})$$

- Discontinuité de la composante normale de l'induction électrique due aux charges surfaciques s'ils existent.

$$(\vec{D}_2 - \vec{D}_1) \cdot \vec{n} = \rho_s \quad (\text{II.11})$$

Avec:

ρ_s : Densité de charge surfacique a l'interface.

\vec{n} : Vecteur normale a la surface.

J_s : La densité surfacique de charge libre à l'interface.

II.1.1.4 Hypothèses simplificatrices

Le régime quasi-stationnaire dans les courants de Foucault se caractérise par des basses fréquences (< 20 MHz) et l'absence de mouvement des pièces conductrices. Dans ce régime, les courants de déplacement sont négligeables par rapport aux courants de conduction $\sigma \vec{E}$. L'équation de conservation de la densité de courant stipule que la divergence de la densité de courant est nulle, ce qui implique que le flux de courant à travers une surface fermée est toujours nul. Cette propriété fondamentale est essentielle pour l'analyse des courants de Foucault dans divers systèmes électromagnétiques.

L'équation (II.12) permet d'écrire que la densité de courant est à flux conservatif :

$$\text{div} \vec{j} = 0 \quad (\text{II.12})$$

En récapitulant, les équations de base utilisée :

- Equation de Maxwell-Faraday.

$$r \vec{\partial} t \vec{E} = - \frac{\partial \vec{B}}{\partial t} \quad (\text{II.13})$$

- Equation de conservation du flux magnétique.

$$\text{div} \vec{B} = 0 \quad (\text{II.14})$$

- Equation de Maxwell-Ampere.

$$r \vec{\partial} t \vec{H} = \vec{j} \quad (\text{II.15})$$

- Equation de Maxwell-Gauss.

$$\text{div} \vec{D} = 0 \quad (\text{II.16})$$

Les équations de Maxwell, bien que fondamentales, présentent des difficultés de résolution analytique. L'introduction de grandeurs intermédiaires vectorielles ou scalaires, permet de

simplifier les équations et d'en faciliter la résolution. L'utilisation de ces variables constitue une formulation.

II.1.1.5 Différentes formulations du champ électromagnétique

II.1.1.5.a Formulation magnétostatique

La magnétostatique consiste en l'étude des phénomènes magnétiques en régime stationnaire [9].

Typiquement, un problème magnétostatique est composé des parties suivantes (Fig. II.3) :

- Des inducteurs parcourus par des courants continus de densité donnée
- Des aimants permanents d'induction rémanente B_r , donnée
- Des régions composées des matériaux magnétiques saturables ou non-saturables
- Une boîte d'air englobante

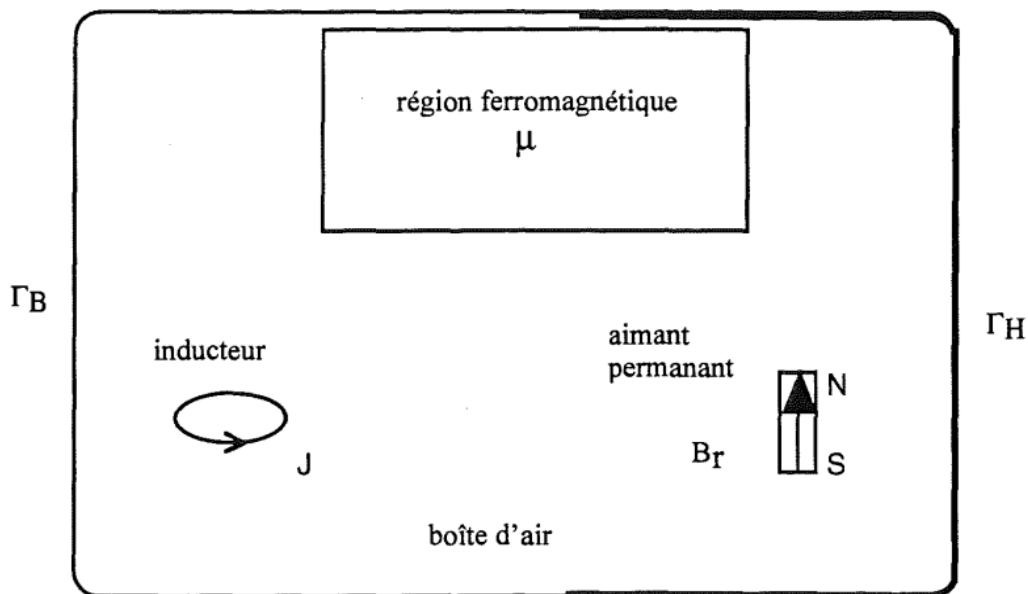


Figure II.3 : Problème général magnétostatique [9].

II.1.1.5.b Formulation magnétodynamique

La magnétodynamique consiste en l'étude des phénomènes électromagnétiques couplés, en régime dynamique, en négligeant les courants de déplacement [9].

Typiquement, un problème magnétodynamique est composé des parties suivantes (Fig. II.4) :

- des inducteurs dans lesquelles circulent de courants variables en fonction du temps et dans lesquelles aucun courant de Foucault n'est supposé se développer
- des régions composées des matériaux magnétiques saturables ou non-saturables qui sont supposées isolantes
- des conducteurs où peuvent circuler des courants induits
- une boîte d'air englobante

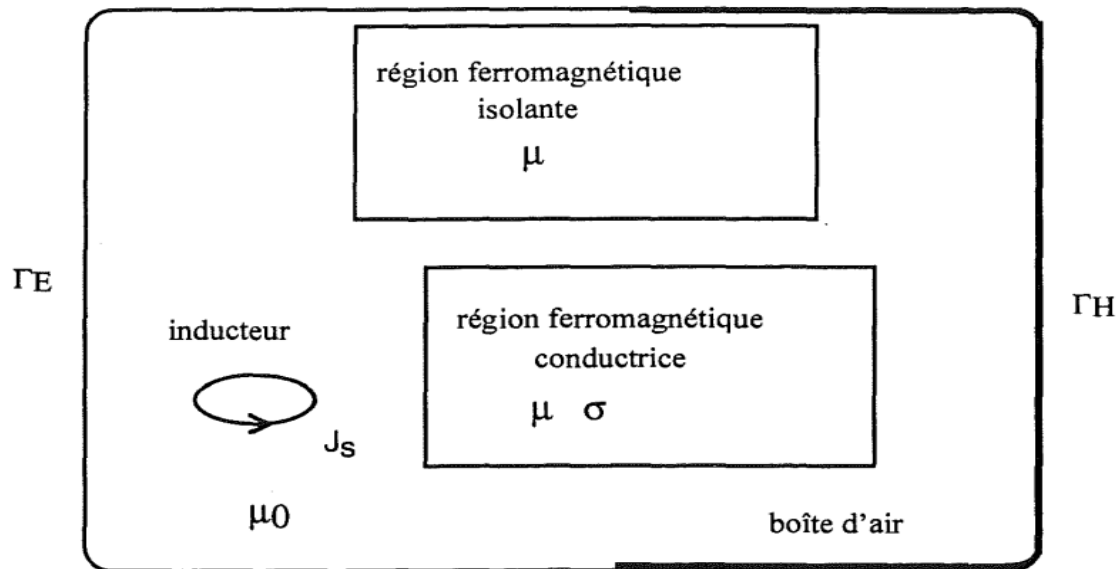


Figure II.4 : Problème général magnétodynamique [9].

II.2 Méthodes de traitement et de résolution

II.2.1 Méthodes analytiques

L'analyse des équations de Maxwell permet d'obtenir une solution mathématique précise du problème, mais elle est restreinte à des configurations simples.

Par exemple, on peut mentionner les recherches de Dodd et ses collègues qui ont mis en place des solutions.

La méthode de séparation des variables permet de réaliser des équations différentielles directes. Ces travaux incluent :

- ✓ Une bobine à air axisymétrique de section rectangulaire au-dessus de deux couches métalliques parallèles de matériaux différents.
- ✓ Une bobine de section rectangulaire encerclant deux cylindres métalliques.

Des développements plus récents permettent notamment de considérer le cas d'une bobine avec noyau magnétique sur une pièce plane ou le cas d'une bobine à air inclinée sur une pièce plane. Cependant, la complexité des configurations de CND par CF fait qu'une solution analytique est souvent soit impossible à obtenir, soit très complexe et très coûteuse en ressources de calcul. Une alternative est alors de mettre en œuvre des méthodes numériques.

Parmi ces méthodes on cite la méthode de séparation des variables, le noyau de Green, loi de Biot et Savart et le théorème de réciprocité de Lorentz [16].

II.2.2 Méthodes numériques

Les techniques numériques offrent la possibilité d'analyser des configurations sonde-pièce plus diverses. Grâce au développement de l'informatique dans les années 50, de nombreuses méthodes numériques ont été développées dans le domaine de l'électromagnétisme. Cela est d'autant plus vrai.

Les configurations à traiter sont plus couramment utilisées, que ce soit du point de vue géométrique ou phénoménologiquement hétérogène et non linéaire. Plusieurs méthodes numériques existent pour les approcher et obtenir des solutions approchées précises. Parmi ces méthodes, on trouve [16] :

II.2.2.1 Méthode des différences finis

La méthode des différences finis est l'une des techniques de résolution approchée d'équations aux dérivées partielles qui consiste à résoudre un système de relations (schéma numérique) liant les valeurs des fonctions inconnues en certains points suffisamment proches les uns des autres. En apparence, cette méthode est en général simple à mettre en œuvre, elle procède en la discrétisation du domaine d'étude (l'espace discrétisé ou maillage) et des opérateurs de dérivation/différentiation. Une discrétisation des opérateurs différentiels (dérivées premières, secondes, etc., dérivées partielles) peut être obtenue par les formules de Taylor, en particulier celle de Taylor avec reste intégral permet de mesurer les erreurs [14].

II.2.2.2 Méthode des volumes finis (MVF)

En analyse numérique, la méthode des volumes finis est utilisée pour résoudre numériquement des équations aux dérivées partielles, comme la méthode des différences finies et celle des éléments finis.

Contrairement à la méthode des différences finies qui met en jeu des approximations des dérivées, les méthodes des volumes finis et des éléments finis exploitent des approximations d'intégrales. Toutefois, la méthode des volumes finis se base directement sur la forme dite forte de l'équation à résoudre, alors que la méthode des éléments finis se fonde sur une formulation variationnelle de l'équation (on parle aussi de formulation faible) [14].

II.2.2.3 Méthode des éléments finis

La méthode des éléments finis est basée sur la transformation des équations aux dérivées partielles en un système d'équations algébriques. Elle s'adapte très bien aux milieux hétérogènes et aux domaines de formes complexes.

D'une façon générale, la résolution par la MEF inclut les étapes suivantes :

- ✓ Obtention de la formulation variationnelle du problème et définition des espaces fonctionnels de solutions admissibles.
- ✓ Réalisation d'un maillage, correspondant à la discrétisation du domaine d'étude en éléments (triangles, tétraèdres, hexaèdres...) sur lesquels les champs sont écrits en termes d'un nombre fini de degrés de liberté et de fonctions de base à support local
- ✓ Calcul des matrices élémentaires qui, après assemblage, génèrent un système matriciel creux.
- ✓ Résolution du système algébrique pour l'obtention d'une solution approchée du problème [16].

II.2.3 Résolution des EDP par la MEF

II.2.3.1 Etapes de résolution par la MEF

La méthode des éléments finis (MEF) est un puissant outil de résolution des problèmes complexes en ingénierie et en physique. Voici les principales étapes de cette méthode :

II.2.3.1.a Maillage éléments finis

Le maillage par éléments finis consiste à diviser le domaine spatial de la solution en éléments géométriques simples (comme des triangles ou des quadrilatères en 2D, ou des tétraèdres ou des hexaèdres en 3D). Chaque élément est défini par des nœuds (points) où les solutions approchées sont évaluées [17].

II.2.3.1.b Forme de la matrice élémentaire

Pour chaque type d'élément fini (comme un élément fini triangulaire ou quadrilatéral en 2D), une matrice élémentaire est définie. Cette matrice est caractérisée par sa structure et ses coefficients, qui dépendent des propriétés physiques du matériau et des conditions aux limites du problème [17].

II.2.3.1.c Résolution du système algébrique

Une fois le maillage créé et les matrices élémentaires assemblées, un système d'équations algébriques est formé. Ce système résulte de l'application des conditions d'équilibre (ou d'autres lois physiques) à chaque nœud du maillage. Ce système est souvent linéaire mais peut devenir non linéaire selon la nature du problème physique [17].

II.3 Modélisation par éléments finis sous COMSOL Multi physique

De nos jours, de nombreux logiciels commerciaux et académiques utilisent la méthode des éléments finis pour la simulation dans divers domaines (mécanique, thermique, électromagnétisme, etc.). Parmi les logiciels les plus couramment utilisés dans le domaine scientifique de l'électromagnétisme, on peut citer Maxwell, Flux, Matlab, COMSOL Multi physiques, et bien d'autres.

Pour implémenter le modèle magnétostatique qui décrit le comportement d'un capteur à courant de foucault dans l'environnement COMSOL Multiphysiques, nous suivrons plusieurs étapes afin de déterminer la solution de l'équation magnétostatique précédemment décrite.

$$(j\omega\sigma - \omega^2\varepsilon_o\varepsilon_r)\vec{A} + \nabla \times (\mu_o^{-1}\mu_r^{-1}\nabla \times \vec{A}) = \vec{J}_0 \quad (\text{II.17})$$

II.3.1 Description d'un capteur de référence JSAEM n° 2-5

Dans cette partie, pour évaluer la solidité et la puissance du logiciel de modélisation par éléments finis sous COMSOL Multiphysique, nous avons tenté de représenter un capteur de référence, qui est le problème de benchmark JSAEM n° 2-5 en cas d'existence d'un défaut [18].




Figure II.5 : Structure du système JSAEM [18].

Le capteur est constitué d'une bobine simple qui se déplace le long d'une plaque en aluminium avec un défaut rectangulaire (figure II.5). Le tableau II.1 regroupe les caractéristiques et les propriétés physiques de la bobine et de la plaque. Une boîte d'air doit être définie de telle façon à avoir un bon compromis entre temps de calcul et précision de la solution.

| Plaque métallique | | Bobine | |
|------------------------------------|--------|----------------------------|---------------------|
| Longueur de la plaque | 25mm | Rayon externe de la bobine | 1.6mm |
| Largeur de la plaque | 15mm | Rayon interne de la bobine | 0.6mm |
| Profondeur de la plaque | 1.25mm | Hauteur de la bobine | 0.8mm |
| Longueur du défaut | 10mm | Nombre de spires | 140 |
| Largeur du défaut | 0.21mm | Lift-off | 0.25 |
| Profondeur du défaut | 0.75mm | Fréquence | $1.5 \cdot 10^5$ Hz |
| Conductivité de la plaque | 1 MS/m | Densité de courant | 0.8 (A) |
| Perméabilité relative de la plaque | 1 | Épaisseur de peau | 1.5mm |

Tableau II.1 : caractéristiques de la sonde et de la plaque métallique

II.3.2 Simulation de la réponse du capteur

Afin de réaliser une simulation de la réponse du capteur, en utilisant la méthode des éléments finis, le logiciel Comsol multiphysique a été utilisé. Ce dernier permet de traiter des pro-

blèmes électromagnétiques, mécaniques, thermiques, dynamiques des fluides, etc... Il contient un module électromagnétisme dont on a utilisé dans ce travail. Pour faire une bonne modélisation avec Comsol multiphysique, il faut suivre les étapes de simulation présentées ci-dessous :

a. Choix du type de formulation

b. Préprocesseur

- Création de la structure géométrique du modèle.
- Choix des types d'éléments à utiliser.
- Affectation des propriétés électriques et magnétiques des matériaux constituant chaque entité géométrique.
- Maillage de la géométrie.

c. Solution

- Introduction des conditions aux limites et application des sources électromagnétiques (courants, tensions, ...).
- Résolution du problème.

d. Post-processeur

- Analyse et visualisation des résultats.
- Création et enregistrement de fichiers des résultats.

II.3.2.1 Choix de la formulation

Parmi les modules du logiciel Comsol Multiphysique, nous avons sélectionné le module AC/DC > Champ électrique et magnétique (mef) > Courants induits (EMQA) pour une analyse en régime fréquentiel.

II.3.2.2 Modélisation du capteur

La bobine est constituée d'un ensemble des spires (N spires) parcourues par un courant I . Ce courant a une densité moyenne uniforme J_0 sur une section S (figures II.6 et II.7).




Figure II. 6 : Bobine réelle et son modèle simplifié [13].




Figure II.7 : Orientation de la bobine pour la définition de J_0 [18].

Dans le cas d'une modélisation 3D de la bobine, la densité du courant d'excitation a une distribution surfacique dépendante des coordonnées de la bobine. Dans ce cas, l'amplitude ainsi que les composantes de cette densité sont définies selon les équations II.18 et II.19

$$J_0 = \frac{N_s * I}{h_{Bobine} * (r_{ext} - r_{int})} \quad (II.18)$$

Avec N_s est le nombre de spires, h_{Bobine} est la hauteur de la bobine, r_{ext} et r_{int} sont le rayon externe et interne de la bobine respectivement et I est le courant d'excitation.

$$J_0 = \left[\frac{\|J_0\|y}{\sqrt{x^2+y^2}}, \frac{-\|J_0\|x}{\sqrt{x^2+y^2}}, 0 \right] \quad (II.19)$$

Selon l'équation (II.14) la composante verticale du courant d'excitation (suivant Z) est nulle.

II.3.2.3 Détermination de l'impédance du capteur

Le but de cette simulation est de déterminer l'impédance complexe du capteur. Pour ce faire, on peut calculer l'énergie magnétique (W_m) emmagasinée dans l'ensemble de la zone d'étude ainsi que les pertes Joule (P_J) en utilisant les relations suivantes :

$$W_m = \frac{1}{2} \iiint_{espace} \frac{1}{\mu} \|B\|^2 dv \quad (II.20)$$

Et

$$P_J = \frac{1}{2} \iiint_{conducteur} \rho \|J\|^2 dv \quad (II.21)$$

Avec : \mathbf{J} et ρ représentent respectivement la densité de courant et la résistivité électrique.

Connaissant W_m et P_J , nous pouvons facilement remonter à l'inductance (L) et à la résistance équivalente (R) du capteur. Les expressions reliant l'énergie magnétique et l'inductance ainsi que les pertes Joule et la résistance sont :

$$W_m = \frac{1}{2} L I_{eff}^2 \quad (II.22)$$

Et

$$P_J = \frac{1}{2} R I_{eff}^2 \quad (II.23)$$

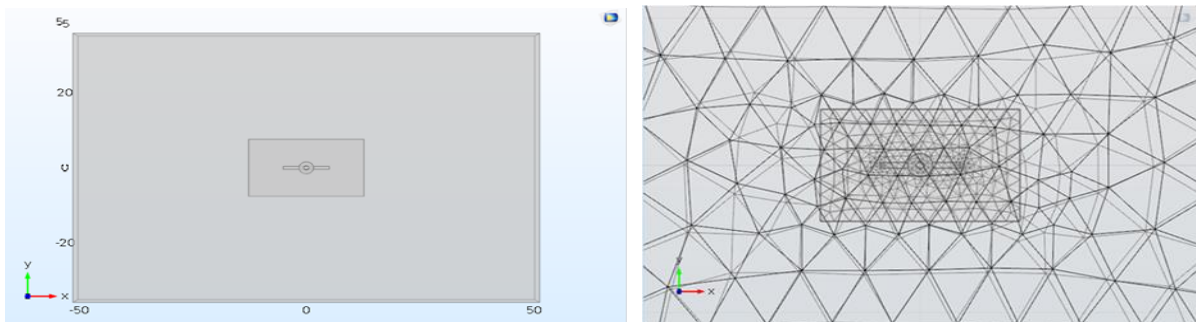
Avec : I_{eff} représente la valeur efficace du courant, parcourant la bobine, déterminé à partir de la densité du courant.

L'impédance du capteur est donnée par :

$$\begin{cases} \text{Re}(Z) = \frac{JL}{I^2} \Delta Z \rightarrow I^2 \text{Re}(\Delta Z) \\ = \int_{\Omega_c} \frac{1}{\sigma} (|J_f|^2 - |J|^2) d\Omega \\ \text{Im}(Z) = \frac{\sigma W_M}{I^2} \Delta Z \rightarrow I^2 \text{Im}(\Delta Z) \\ = \omega \int_{\Omega_c} \frac{1}{\mu} (|B_f|^2 - |B|^2) d\Omega \end{cases} \quad (II.24)$$

II.3.2.4 Maillage généré par COMSOL Multiphysique

Étant donné que le capteur est composé d'une bobine cylindrique, il est possible de réaliser une modélisation axisymétrique en 2D. Cependant, l'existence d'un défaut de forme carrée, dont la largeur diffère de la largeur de la pièce, ainsi que d'une bobine qui se déplace en fonction de la longueur de la pièce, nécessite une étude en 3D. Dans cette situation, le logiciel Comsol multiphysique est employé afin de représenter le système capteur cible. La géométrie et le maillage réalisés sont illustrés respectivement par les figures II.8 (a,b)



(a) Géométrie du système

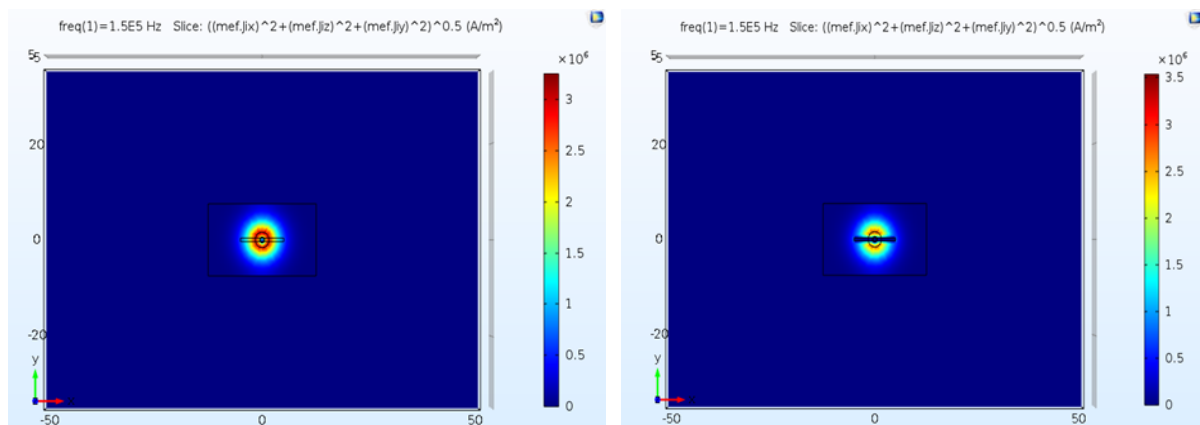
(b) Maillage éléments finis du système

Figure II.8 : La géométrie et le maillage du système

Après avoir résolu le problème, nous avons obtenu la répartition des courants induits dans la plaque métallique, que ce soit en présence ou en absence du défaut. Ces répartitions, ainsi


qu'un agrandissement selon une coupe dans le plan (xoy), sont présentées dans les figures II.9 (a,b) et II.9 (c,d) respectivement.

À partir de ces figures, on observe que la répartition des courants induits dans la cible varie entre les deux cas, avec et sans défaut. Dans le cas où un défaut est présent, cette répartition est perturbée. Cela s'explique par le changement des propriétés physiques de la pièce (conductivité électrique nulle).



a) Sans défaut

b) Avec défaut



c) Sans défaut

d) Avec défaut

Figure II.9 : Zoom de la répartition des courants induits

Pour calculer l'impédance du capteur se déplaçant au-dessus de la pièce à inspecter, nous avons modélisé le système capteur-cible et calculé l'impédance à chaque position du capteur, dans les deux situations, avec et sans défaut. Pour réaliser cette tâche, nous avons utilisé l'interface Comsol avec Matlab (Comsol with Matlab). L'organigramme ci-dessous résume les étapes de simulation et de calcul de la réponse du capteur.

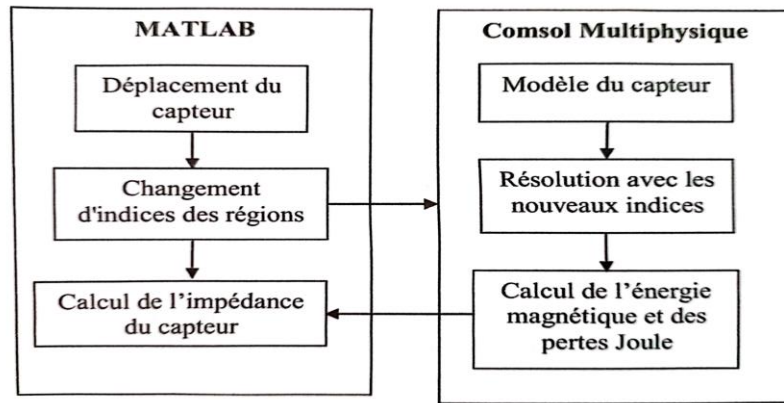


Figure II.10 : Etapes de calcul de l'impédance du système [13].

Après avoir calculé l'impédance du système, nous avons mené une étude comparative. Autrement dit, nous avons comparé l'impédance du système en présence du défaut avec celle sans défaut. La figure II.11 illustre la variation de l'impédance en fonction de la position du capteur, obtenue par simulation et par expérimentation qui est représenté dans les travaux de Chelabi figure II.12 [13].




Figure II.11 : Variation de l'impédance du système.




Figure II.12 : Variation de l'impédance du système du thèse de Chelabi [13].

À partir de cette figure, on constate que les valeurs issues de la simulation sont presque superposées aux valeurs mesurées, avec une légère différence. Cette différence est attribuable aux erreurs numériques (erreurs de troncature, erreurs de maillage, etc.). Les résultats obtenus permettent de confirmer la robustesse de la méthode basée sur l'énergie pour le calcul des impédances.

Conclusion

Dans ce chapitre, nous avons abordé l'utilisation de la méthode des éléments finis pour la modélisation d'un capteur à courants de Foucault à l'aide de Comsol Multiphysiques. Nous avons présenté les principes fondamentaux de la méthode des éléments finis et expliqué comment cette technique permet de résoudre des problèmes complexes de manière précise et efficace.

Ensuite, nous avons détaillé le processus de modélisation du capteur à courants de Foucault, en mettant en évidence les particularités du système étudié, notamment la bobine cylindrique et la présence de défauts dans la pièce inspectée. Une modélisation en 3D a été nécessaire pour prendre en compte les aspects géométriques et les déplacements de la bobine.

Nous avons ensuite utilisé Comsol avec Matlab pour effectuer les calculs d'impédance à différentes positions du capteur, en comparant les situations avec et sans défaut. Les résultats

obtenus montrent une bonne concordance entre les simulations et les mesures expérimentales, avec des différences mineures attribuables aux erreurs numériques.

Enfin, nous avons confirmé la robustesse de la méthode basée sur l'énergie pour le calcul des impédances, démontrant ainsi l'efficacité de l'approche adoptée. Ce travail valide l'utilisation de la simulation par éléments finis avec Comsol Multiphysique et Matlab comme outil puissant pour l'analyse et l'optimisation des capteurs à courants de Foucault.

Chapitre III

**L'application d'IA au CND par
courant de foucault**

Introduction

L'intelligence artificielle (IA) est de plus en plus présente dans notre quotidien, notamment au travers de nouveaux produits ou services. Elle repose cependant sur des algorithmes gourmands en données, souvent personnelles, et son usage nécessite le respect de certaines précautions.

L'intelligence artificielle n'est pas une technologie à proprement parler mais plutôt un domaine scientifique dans lequel des outils peuvent être classés lorsqu'ils respectent certains critères. Pour se familiariser avec ce domaine, il peut être utile de se référer au glossaire de l'IA publié par la CNIL [19].

Pour le Parlement européen, l'intelligence artificielle représente tout outil utilisé par une machine afin de « reproduire des comportements liés aux humains, tels que le raisonnement, la planification et la créativité ».

Cette définition pourrait être élargie en incluant les comportements dépassant les capacités humaines, puisque les ordinateurs actuels parviennent aujourd'hui à les surpasser dans certaines tâches (bien que la compétence de l'ordinateur s'arrête généralement à l'exécution de cette tâche). À titre d'exemple, le système d'IA AlphaGo, capable de battre le champion du jeu de go Lee Sedol, est très doué pour élaborer des stratégies à ce jeu, mais ses capacités s'arrêtent ici. Il sera incapable de jouer aux échecs ou d'effectuer d'autres tâches tant que celles-ci ne lui auront pas été inculquées.

Tout système mettant en œuvre des mécanismes proches de celui d'un raisonnement humain pourrait ainsi être qualifié d'intelligence artificielle [19].

III.1 Principe d'IA

Le principe central de l'intelligence artificielle (IA) consiste à reproduire, puis à dépasser, la perception et les réactions des êtres humains dans le monde réel. L'IA vise à imiter l'intelligence humaine à travers des algorithmes et des modèles informatiques pour accomplir des tâches variées. Elle repose sur des techniques telles que l'apprentissage automatique, qui permettent aux machines d'identifier des tendances dans les données et de générer des prévisions. L'IA peut améliorer les performances et la productivité des entreprises en automatisant des processus, en exploitant des données à un niveau inatteignable pour les humains, et en offrant des avantages commerciaux substantiels.

En résumé, le principe fondamental de l'IA est de créer des systèmes capables de simuler l'intelligence humaine, d'apprendre à partir de données, de prendre des décisions et d'accomplir

des tâches de manière autonome, en s'appuyant sur des modèles et des algorithmes sophistiqués[20].

III.2 Types d'IA

Les trois types d'intelligence artificielle (IA) sont les suivants :

III.2.1 Intelligence artificielle étroite (ANI)

L'intelligence artificielle étroite (ANI), également appelée IA faible ou IA étroite, est le seul type d'intelligence artificielle que nous ayons réussi à réaliser à ce jour. L'IA étroite est orientée vers un but précis, elle est conçue pour accomplir des tâches uniques par exemple, la reconnaissance faciale, la reconnaissance vocale/les assistants vocaux, la conduite d'une voiture ou la recherche sur Internet – et elle est très intelligente pour accomplir la tâche spécifique pour laquelle elle est programmée.

Bien que ces machines puissent sembler intelligentes, elles fonctionnent avec un ensemble restreint de contraintes et de limitations, ce qui explique pourquoi ce type d'IA est communément appelé IA faible. L'IA étroite n'imité ni ne reproduit l'intelligence humaine, elle se contente de simuler le comportement humain sur la base d'une gamme étroite de paramètres et de contextes.

L'IA étroite a connu de nombreuses percées au cours de la dernière décennie, grâce aux réalisations en matière d'apprentissage automatique et d'apprentissage profond. Par exemple, les systèmes d'IA sont aujourd'hui utilisés en médecine pour diagnostiquer le cancer et d'autres maladies avec une extrême précision grâce à la reproduction d'une cognition et d'un raisonnement semblables à ceux des humains.

L'intelligence artificielle de l'IA étroite provient de l'utilisation du traitement du langage naturel (NLP) pour effectuer des tâches. Le NLP est évident dans les chatbots et les technologies d'IA similaires. En comprenant la parole et le texte en langage naturel, l'IA est programmée pour interagir avec les humains de manière naturelle et personnalisée.

L'IA étroite peut être réactive ou avoir une mémoire limitée. L'IA réactive est incroyablement basique ; elle n'a aucune capacité de mémoire ou de stockage de données, imitant la capacité de l'esprit humain à répondre à différents types de stimuli sans expérience préalable. L'IA à mémoire limitée est plus avancée, dotée de capacités de stockage de données et d'apprentissage qui permettent aux machines d'utiliser des données historiques pour prendre des décisions.

La plupart des IA sont des IA à mémoire limitée, où les machines utilisent de grands volumes de données pour l'apprentissage profond. L'apprentissage profond permet des expériences d'IA personnalisées, par exemple des assistants virtuels ou des moteurs de recherche qui stockent vos données et personnalisent vos expériences futures [21].

III.2.2 Intelligence artificielle générale (AGI)

L'intelligence générale artificielle (AGI), également appelée IA forte ou IA profonde, est le concept d'une machine dotée d'une intelligence générale qui imite l'intelligence et/ou les comportements humains, avec la capacité d'apprendre et d'appliquer son intelligence pour résoudre tout problème. L'IA peut penser, comprendre et agir d'une manière indiscernable de celle d'un être humain dans une situation donnée.

Les chercheurs et les scientifiques spécialisés dans l'IA n'ont pas encore atteint une IA forte. Pour y parvenir, ils devraient trouver un moyen de rendre les machines conscientes, en programmant un ensemble complet de capacités cognitives. Les machines devraient faire passer l'apprentissage par l'expérience à un niveau supérieur, en améliorant non seulement l'efficacité de certaines tâches, mais en acquérant la capacité d'appliquer les connaissances acquises par l'expérience à un éventail plus large de problèmes différents.

L'IA forte utilise un cadre d'IA basé sur la théorie de l'esprit, qui fait référence à la capacité de discerner les besoins, les émotions, les croyances et les processus de pensée d'autres personnes intelligentes. L'IA de niveau théorie de l'esprit ne consiste pas à reproduire ou à simuler, mais à entraîner les machines à comprendre réellement les humains.

L'immense défi que représente la réalisation d'une IA forte n'est pas surprenant si l'on considère que le cerveau humain est le modèle de création de l'intelligence générale. En raison du manque de connaissances approfondies sur la fonctionnalité du cerveau humain, les chercheurs s'efforcent de reproduire les fonctions de base de la vue et du mouvement.

Le K, construit par Fujitsu, l'un des superordinateurs les plus rapides, est l'une des tentatives les plus notables pour parvenir à une IA forte, mais étant donné qu'il a fallu 40 minutes pour simuler une seule seconde d'activité neuronale, il est difficile de déterminer si une IA forte sera atteinte dans un avenir prévisible. Au fur et à mesure que la technologie de reconnaissance des images et des visages progresse, il est probable que nous verrons une amélioration de la capacité des machines à apprendre et à voir [21].

III.2.3 Super intelligence artificielle (ASI)

La super intelligence artificielle (ASI) est l'IA hypothétique qui ne se contente pas d'imiter ou de comprendre l'intelligence et le comportement humains ; l'ASI est l'endroit où les machines deviennent conscientes d'elles-mêmes et dépassent la capacité de l'intelligence et des aptitudes humaines.

La super intelligence a longtemps été une source d'inspiration pour la science-fiction dystopique, où des robots envahissent, renversent ou asservissent l'humanité. Le concept de super intelligence artificielle voit l'IA évoluer pour devenir si proche des émotions et des expériences humaines qu'elle ne se contente pas de les comprendre, mais suscite des émotions, des besoins, des croyances et des désirs qui lui sont propres.

En plus de reproduire l'intelligence à multiples facettes des êtres humains, l'ASI serait théoriquement bien meilleure dans tout ce que nous faisons : mathématiques, sciences, sports, art, médecine, loisirs, relations émotionnelles, tout. L'ASI aurait une meilleure mémoire et une capacité plus rapide à traiter et à analyser les données et les stimuli. Par conséquent, les capacités de prise de décision et de résolution de problèmes des êtres super intelligents seraient bien supérieures à celles des êtres humains.

La possibilité de disposer de machines aussi puissantes peut sembler séduisante, mais le concept lui-même a une multitude de conséquences inconnues. Si des êtres super intelligents conscients d'eux-mêmes voyaient le jour, ils seraient capables d'idées comme l'auto-préservation. L'impact que cela aura sur l'humanité, notre survie et notre mode de vie, est une pure spéculation [21].

III.3 Différentes Techniques d'Intelligence Artificielle

L'intelligence artificielle (IA) englobe un large éventail de techniques et de sous-domaines qui permettent aux machines d'accomplir des tâches qui nécessitent généralement une intelligence humaine. Voici les principales techniques d'IA :

III.3.1 Apprentissage automatique (Machine Learning)

L'apprentissage automatique est une méthode qui permet aux machines d'apprendre à partir de données et de s'améliorer au fil du temps sans être explicitement programmées.

III.3.1.1 Apprentissage non supervisé

L'apprentissage non supervisé est une méthode d'apprentissage automatique où les modèles sont formés sur des données non étiquetées. Contrairement à l'apprentissage supervisé, qui

utilise des données étiquetées pour entraîner des modèles, l'apprentissage non supervisé cherche à trouver des structures cachées ou des motifs dans les données. Cette technique est particulièrement utile pour explorer des données, réduire leur dimensionnalité, ou pour regrouper des données similaires [22].

Les modèles trouvent des structures cachées dans des données non étiquetées. Exemples : clustering (k-means, DBSCAN), réduction de dimension (ACP, t-SNE).

III.3.1.2 Apprentissage supervisé

L'apprentissage supervisé utilise un jeu d'entraînement pour apprendre aux modèles à produire les résultats souhaités. Ce jeu de données d'apprentissage comprend des entrées et des sorties correctes, qui permettent au modèle d'apprendre au fil du temps. L'algorithme mesure sa précision par le biais de la fonction de perte, et s'ajuste jusqu'à ce que l'erreur soit suffisamment minimisée. Les modèles sont entraînés sur un ensemble de données étiquetées. Exemples : régression linéaire, machines à vecteurs de support (SVM), réseaux de neurones supervisés.

L'apprentissage supervisé peut être divisé en deux types de problèmes lors de l'extraction de données, à savoir la classification et la régression .

III.3.1.3 Apprentissage par renforcement

L'apprentissage par renforcement est une branche de l'intelligence artificielle dans laquelle un agent apprend à prendre des décisions en interagissant avec un environnement. L'objectif de l'agent est de maximiser une récompense cumulative au fil du temps. Contrairement à l'apprentissage supervisé, où des exemples de réponses correctes sont fournis, l'apprentissage par renforcement repose sur l'exploration et l'exploitation pour découvrir quelles actions mènent aux meilleures récompenses. Exemples: Q-learning, Deep Q-Network (DQN).

III.3.2 Apprentissage profond (Deep Learning)

L'apprentissage profond est une sous-catégorie de l'apprentissage automatique qui utilise des réseaux de neurones artificiels avec de multiples couches (profondes) pour modéliser des relations complexes dans les données. Il est particulièrement efficace pour traiter des données volumineuses et non structurées comme les images, le texte et les vidéos. Parmi les techniques disponibles, on distingue :

III.3.2.1 Réseaux de neurones convolutionnels (CNN) :

Les réseaux de neurones convolutionnels, ou CNN (convolutional neural networks), sont des modèles particulièrement efficaces pour traiter les données structurées en grille, comme les

images. Leur architecture unique leur permet d'extraire automatiquement des caractéristiques pertinentes à partir des données d'entrée, réduisant ainsi la complexité du prétraitement des données. Les réseaux neuronaux convolutifs sont caractérisés par :

➤ **Couches de Convolution**

- ✓ **Filtrage** : Les couches de convolution utilisent des filtres (ou noyaux) pour balayer l'image d'entrée et créer des cartes de caractéristiques. Chaque filtre détecte des motifs spécifiques, tels que des bords ou des textures.
- ✓ **Paramètres partagés** : Les filtres partagent les mêmes paramètres à travers l'image, ce qui réduit le nombre de paramètres et permet d'apprendre des caractéristiques invariantes à la translation.

➤ **Couches de Pooling**

- ✓ **Réduction de Dimensionnalité** : Les couches de pooling, comme le maxpooling, réduisent la taille des cartes de caractéristiques tout en conservant les informations les plus importantes. Cela diminue la charge computationnelle et aide à prévenir le surapprentissage.
- ✓ **Invariance à la Translation** : Le pooling aide également à rendre le modèle plus robuste aux variations de position des caractéristiques dans l'image.

➤ **Couches Complètement Connectées**

- ✓ **Classification** : Les couches complètement connectées, situées en fin de réseau sont utilisées pour la classification ou la régression. Elles combinent les caractéristiques extraites par les couches précédentes pour prédire les classes ou les valeurs.

➤ **Fonctions d'Activation**

- ✓ **Non-linéarités** : Des fonctions d'activation comme ReLU (Rectified Linear Unit) introduisent des non-linéarités dans le modèle, permettant au réseau d'apprendre des relations complexes.

III.3.2.2 Réseaux de neurones récurrents (RNN) :

Les réseaux de neurones récurrents (RNN) s'imposent comme des outils incontournables pour traiter des données séquentielles, telles que le langage, la parole ou les séries temporelles. Contrairement aux réseaux de neurones traditionnels, les RNN possèdent une mémoire interne qui leur permet de prendre en compte le contexte passé lors de l'analyse de l'information présente. Cette capacité unique les rend particulièrement adaptés à des tâches comme la reconnaissance vocale, la traduction automatique ou la génération de texte.

III.3.3 Traitement du langage naturel (NLP)

Le traitement du langage naturel (NLP) est un domaine fascinant de l'intelligence artificielle (IA) qui explore l'interaction entre les ordinateurs et le langage humain. Son objectif principal est de permettre aux machines de comprendre, d'interpréter et de générer un langage de manière similaire à celle des humains.

Imaginez un monde où les ordinateurs peuvent converser avec nous de manière fluide, comprendre nos intentions et répondre à nos questions de manière informative. C'est la promesse du NLP, un domaine en plein essor qui ouvre de nouvelles perspectives dans de nombreux domaines.

III.4 Réseaux de neurones artificiels

Les réseaux de neurones artificiels, nés il y a environ une cinquantaine d'années, sont toujours en cours de développement. Cet axe de recherche a attiré l'attention de beaucoup de chercheurs de différentes disciplines. Ces réseaux de neurones artificiels sont issus de méthodes de résolution des problèmes inverses combinant entre la neurobiologie comme idée de base, la physique comme champs d'application et les mathématiques et l'informatique autant que moyens de réalisation.

Les réseaux de neurones artificiels sont des ensembles de neurones formels associés en couches et fonctionnant en parallèle. Chaque neurone (processeur) élémentaire calcule une sortie unique sur la base des informations qu'il reçoit. Dans un réseau, chaque sous-groupe fait un traitement indépendant des autres et transmet le résultat de son analyse au sous-groupe suivant. L'information donnée au réseau va donc se propager couche par couche, de la couche d'entrée à la couche de sortie, en passant soit par aucune, une ou plusieurs couches intermédiaires (dites couches cachées). Les réseaux de neurones ont la capacité de stocker l'information dans les poids synaptiques, obtenus par des processus d'adaptation ou d'apprentissage et de la rendre disponible à l'usage [23].

III.4.1 Neurone

Un neurone est une cellule du système nerveux dont la fonction est de faire circuler des informations. Chaque neurone est constitué d'un corps cellulaire contenant le noyau et de deux types d'extensions qui assurent les connexions entre les neurones.

III.4.2 Bases biologiques

Il se compose essentiellement de :

- **Corps cellulaire (soma)** : il est centré par un noyau, toutes les informations recueillies par les synapses sont acheminées vers le corps cellulaire
- **Synapse** : une synapse est une jonction entre deux neurones ; et généralement entre l'axone d'un neurone et une dendrite d'un autre neurone.
- **Dendrites** : ce sont de fines extensions tubulaires qui se ramifient autour du neurone et forment une sorte de vaste arborescence. Elles captent les signaux envoyés au neurone.
- **L'axone** : qui est la partie qui s'occupe de la transmission de l'information issue du corps cellulaire ; conduisant des signaux électriques de la sortie d'un neurone vers l'entrée d'un autre neurone.




Figure III.1 : Représentation schématique d'un neurone biologique [23].

III.4.3 Neurone artificiel

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

Par analogie avec la biologie, un neurone artificiel, reçoit l'information provenant des entrées x_i ($i=1,2,3 \dots n$) par l'intermédiaire des connexions dont on affecte à chacune d'elles un poids

w abrégiation de weight (poids en anglais) pondérant l'information, et aussi représentatif de la force de la connexion.

Le neurone artificiel fonctionne en deux étapes :

La première phase représente les prétraitements des données reçus en calculant le potentiel v_j des neurones j par la fonction suivante :

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

Ou :

$w_{j,t}$: désigne le poids de la connexion liant le neurone j à l'entrée i ;

b_i : terme constant appelé biais, il est considéré comme le poids d'une entrée x_0 égal à 1. Ainsi la relation s'écrit plus simplement :

$$v_j = \sum_{i=1}^e w_{j,x} x_i \quad (\text{III.2})$$

Dans la deuxième phase, une fonction de transfert g appelée également fonction d'activation, calcule la valeur de l'état interne S_j du neurone j à partir de la valeur du potentiel v_j . Cette valeur désigne la sortie du neurone :

$$S_j = g(v_j) = g\left(\sum_{i=0}^n w_{i,j} x_i\right) \quad (\text{III.3})$$

Le choix de la fonction d'activation se révèle dans certains cas être un élément constitutif important des réseaux de neurones. Ainsi, le neurone peut être défini mathématiquement comme étant une fonction algébrique, a priori non linéaire (suivant g) et bornée, des entrées x_i et paramétrée par les poids $w_{f,4}$

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

La figure ci-dessous illustre la représentation d'un neurone artificiel.

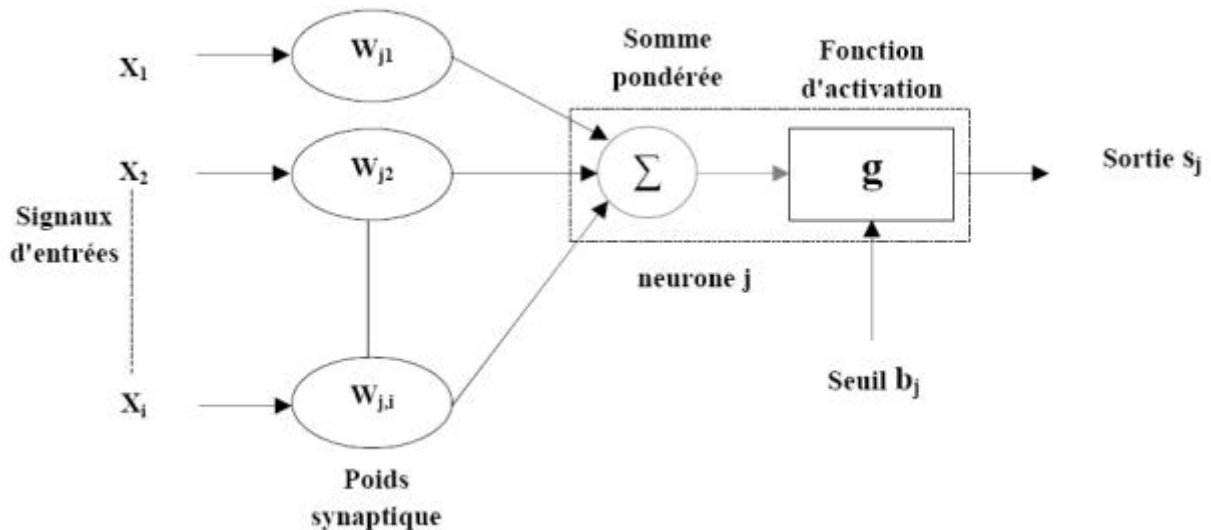


Figure III.2 : Représentation d'un neurone artificiel [23].

III.4.4 Types des réseaux de neurones

Un réseau de neurones est constitué d'un ensemble de neurones interconnectés, souvent organisés en couches. Pour concevoir un réseau de neurones, il est essentiel de définir sa topologie, qui comprend son architecture et la manière dont les neurones sont connectés entre eux.

III.4.4.1 Architecture de réseaux de neurones

L'architecture d'un réseau de neurones est fonction du nombre de couches de ce dernier et surtout de la structure des connexions entre neurones. Il existe plusieurs types d'architectures, on peut citer :

- ✓ réseaux mono couche.
- ✓ réseaux multicouches.
- ✓ réseaux à connexions locales.
- ✓ réseaux à connexions complètes.

Dans notre étude, le type du réseau qui nous intéresse est le réseau multicouche.

III.4.4.2 Connexions de réseaux de neurones

La nature des connexions définit la manière dont sont interconnectés les neurones et le sens de transfert d'information dans le réseau, où on distingue :

- ✓ Les connexions directes, celles dirigées d'une couche d'indice inférieur vers une couche d'indice supérieur (Figure III.3).
- ✓ Les connexions récurrentes dont les sorties de neurones d'une couche sont connectées aux entrées d'une couche d'indice inférieur (Figure III.4) [24].




Figure III.3 : Connexions directes [24].




Figure III.4 : Connexions récurrentes [24].

Par ailleurs entre deux couches, les connexions peuvent être partielles ou totales comme le montre les (Figure III.5) et (Figure III.6). L'utilisation de connexions partielles permet de regrouper certaines zones du réseau pour effectuer une fonction spécifique.




Figure III.5 : Connexions partielles [24].




Figure III.6 : Connexions totales [24].

On peut avoir éventuellement en plus des connexions citées précédemment des connexions inter-couches (interconnexions entre neurones de couches voisines), des connexions intracouches (connexions entre neurones d'une même couche) et l'auto connexion (un neurone avec lui-même) [23].

III.4.4.3 Réseaux de neurones multicouches

Un réseau multicouche n'est rien d'autre qu'un assemblage de couches les unes aux autres, de la gauche vers la droite, en prenant les sorties d'une couche et en les injectant comme les entrées de la couche suivante. Ce type de réseau comme le montre la figure III.7, est organisée

en couches de neurones. Généralement, il n'y a pas de connexions entre neurones d'une même couche, et les connexions ne se font qu'avec ceux des couches en aval [24].




Figure III.7 : Réseau de neurones multicouches [24].

III.4.5 Réseaux de neurone et l'apprentissage profond

Les réseaux de neurones et l'apprentissage profond continuent de transformer les capacités des systèmes informatiques, permettant des avancées spectaculaires dans divers domaines de la science et de la technologie. La recherche continue d'améliorer ces techniques, rendant les modèles plus efficaces, interprétables et accessibles, on trouve :

III.4.5.1 Réseaux de neurones convolutifs (CNN)

Les réseaux de neurones convolutifs (CNN) sont un type particulier de réseau de neurones, largement utilisé dans les tâches de vision par ordinateur. Les CNN sont conçus pour traiter des données ayant une grille topologique, comme les images, en exploitant la structure spatiale des données.

Les couches de convolution sont les éléments fondamentaux des réseaux de neurones convolutionnels (CNN). Elles sont conçues pour automatiquement et adaptativement apprendre les caractéristiques spatiales des données d'entrée, généralement des images. Voici les composantes et le fonctionnement des couches de convolution [25]:

- **Filtre (ou noyau)** : Un petit ensemble de poids utilisé pour balayer l'image d'entrée. Chaque filtre extrait une caractéristique spécifique de l'image (par exemple, les bords, les textures).

- Convolution : L'opération de convolution consiste à faire glisser le filtre sur l'image d'entrée et à calculer le produit scalaire entre les poids du filtre et les valeurs de la fenêtre de l'image qu'il couvre.
- Cartes de Caractéristiques (Feature Maps) : Les résultats de la convolution forment des cartes de caractéristiques, où chaque carte représente l'activation d'un filtre spécifique sur l'ensemble de l'image.

III.4.5.2 Réseaux de neurones convolutifs profonds (DCNN)

Les réseaux de neurones convolutifs profonds (Deep Convolutional Neural Networks, DCNN) sont une extension des réseaux de neurones convolutifs (CNN) caractérisés par une grande profondeur, incluant de nombreuses couches de convolution, de pooling, et entièrement connectées, permettant l'extraction et l'apprentissage de caractéristiques de plus en plus complexes à partir des données d'entrée, ce qui les rend particulièrement efficaces pour des tâches de vision par ordinateur et d'autres applications impliquant des données structurées [25].

III.4.5.3 Réseaux neuronaux récurrents (RNN)

Un réseau neuronal récurrent (RNN) est un type de réseau neuronal conçu pour traiter des données séquentielles, telles que des séries chronologiques ou du texte. Contrairement aux réseaux neuronaux traditionnels, les RNN ont des connexions récurrentes qui permettent aux informations de l'étape précédente de la séquence d'influencer la sortie actuelle. Cela leur permet de conserver une « mémoire » interne qui capture les dépendances à court et à long terme dans les données séquentielles [26].

III.4.5.4 Machines à états liquides (LSM)

La machine à état liquide (MEL, machine à état liquide anglais, LSM) est un type spécial de réseau neuronal dopé. MEL se compose d'un grand groupe d'unités appelées nœuds ou neurones. Chaque nœud reçoit des entrées temporelles provenant de sources externes (entrées) et d'autres nœuds. Les nœuds sont également connectés les uns aux autres de manière aléatoire. Les parties récurrentes de ces liens, ainsi que les entrées dépendant du temps, génèrent des modèles d'activation spatio-temporels des nœuds. Ces activations spatio-temporelles sont lues par l'unité via un discriminant linéaire.

Cet ensemble de nœuds connectés cycliquement finira par calculer avec succès diverses fonctions non linéaires de l'entrée. Si l'on se donne suffisamment de ces fonctions non linéaires, on peut théoriquement obtenir des combinaisons linéaires (à l'aide d'unités de lecture) qui

permettraient de calculer toutes les opérations mathématiques nécessaires à l'exécution de certaines tâches, comme la reconnaissance vocale ou la vision industrielle.

Le mot « liquide » dans le nom de la méthode vient de l'analogie avec le placement d'une pierre dans un réservoir (ou un autre liquide). Les chutes de pierres créent des ondes de choc dans le liquide. Le signal d'entrée (le mouvement de la chute de pierre) est ainsi converti en un modèle spatio-temporel de mouvement du liquide (l'onde de choc) [27].

III.4.5.5 Mémoire longue à court terme (LSTM)

Les réseaux de mémoire à long terme (LSTM) sont des extensions de réseaux neuronaux récurrents qui étendent leur mémoire. Par conséquent, il est idéal pour apprendre des expériences importantes avec de longs délais entre elles. Les unités d'un LSTM servent d'éléments constitutifs de chaque couche d'un RNN, souvent appelé réseau LSTM.

LSTM permet aux RNN de se souvenir de leurs entrées pendant de longues périodes. En effet, les LSTM contiennent leurs informations dans une mémoire, qui est très similaire à la mémoire d'un ordinateur, car LSTM peut lire, écrire et supprimer des informations de sa mémoire. Cette mémoire peut être considérée comme une cellule fermée, où la cellule décide de stocker ou de supprimer des informations (par exemple, d'ouvrir ou non des portes), en fonction de l'importance qu'elle accorde à l'information. L'attribution de l'importance se fait par le biais de poids, qui sont également appris par l'algorithme. Cela signifie simplement qu'il apprend au fil du temps quelles informations sont importantes et lesquelles ne le sont pas.

Dans un LSTM, vous avez trois portes : entrée, oubli et porte de sortie. Ces portes déterminent s'il faut ou non laisser entrer une nouvelle entrée (porte d'entrée), supprimer l'information parce qu'elle n'est pas importante (oublier la porte) ou la laisser influencer la sortie au pas de temps actuel (porte de sortie) [26].

III.4.5.6 Unités récurrentes fermées (GRU)

Cette variante RNN aide à résoudre le problème de mémoire à court terme des modèles RNN, ce qui la rend comparable aux LSTM. Il utilise des états cachés à la place des informations contrôlées sur l'état de la cellule, et il comprend deux portes au lieu de trois : une porte de mise à jour et une porte de réinitialisation. Les portes de réinitialisation et de mise à jour régulent le type et la quantité de données stockées, tout comme les portes LSTM [28].




Figure III.8 : Un exemple d'unit GRU [29].

III.5 Résolution des problèmes direct et inverse

Le problème inverse est de déterminer ou d'obtenir des paramètres utiles à partir des paramètres Observations fournies par un système de mesure. Ces paramètres utiles peuvent être la conductivité Matériaux conducteurs, taille des pièces, taille des défauts, etc. D'une autre manière, Le problème inverse est celui qui cherche à caractériser un paramètre physique ou géométrique. Analyse d'un objet basée sur une série de données mesurées. La question immédiate est Opérations qui donnent des observations en comprenant les propriétés géométriques et électromagnétiques Influence du système de composants du capteur et influence d'éventuelles discontinuités géométriques ou présence défaut. Les entrées du modèle direct sont différentes propriétés géométriques et électromagnétiques Dispositifs ou corps présentant des propriétés différentes (rainures, défauts, oxydation, etc.). Sa sortie se résume au calcul de la réponse (parfois appelée signature) vue par le capteur. Ces modèles se distinguent principalement par les caractéristiques géométriques de l'appareil (une, deux et trois dimensions), propriétés électromagnétiques des matériaux (modèles linéaires et non linéaires), méthodes de modélisation et d'analyse utilisées (analytique, semi-analytique et numérique) [14].

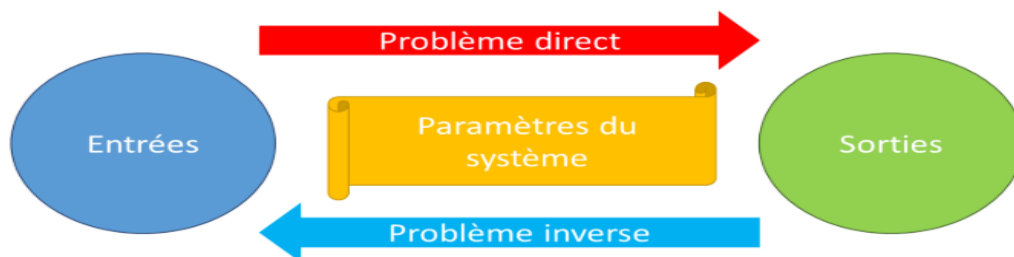


Figure III.9 : Problème direct /problème inverse [14].

III.5.1 Inversion itérative

Cette méthode est utilisée pour des modèles analytiques où la solution est inversée d'une façon mathématique, mais elle est utilisée même pour des modèles inversables mathématiquement (modèle numérique). Ce qui est souvent le cas, le processus est constitué d'une boucle d'itération au sein de laquelle se trouve le modèle direct, qui doit être connu, de façon exacte ou approchée. La sortie du modèle direct est comparée aux acquisitions effectuées, et l'erreur ainsi observé est proposée en entrée d'un algorithme d'optimisation qui modifie alors les estimations des caractéristiques recherchées. A chaque itération, cette modification a pour but de minimiser l'écart obtenue (exemple : Erreur quadratique moyenne (Mean Squared Error (MSE))). L'inversion est supposée correcte et le processus est arrêté lorsque cette erreur devient inférieure à une valeur limite déterminée comme critère d'arrêt des itérations [14]. Explorez le fonctionnement du processus d'inversion grâce au schéma détaillé de la figure III.10.

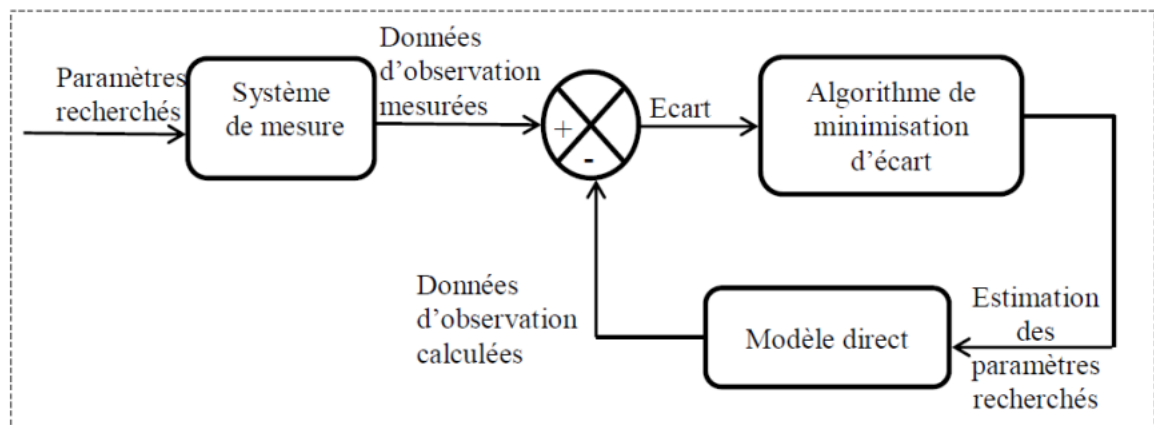


Figure III.10 : Schéma du processus itératif d'inversion [14].

III.5.2 Inversion directe

Dans de rares cas, pour des problèmes dont la solution analytique est très simple, on peut explicitement inverser le modèle direct afin d'évaluer les paramètres recherchés. L'absence d'itération dans ce cas permet d'avoir une inversion plus rapide que celle précédemment citée. L'inversion se présente sous la forme symbolique suivante (Figure III.11) :




Figure III.11 : Schéma du processus d'inversion directe utilisant l'inverse du modèle direct [14].

Cependant, pour la plupart des problèmes électromagnétiques, la solution analytique peut être très difficile à obtenir, par conséquent il n'est pas possible de faire de l'inversion directe. Dans ce cas, on peut cependant utiliser un modèle inverse paramétrique dont on règle les paramètres internes à l'aide d'une base de données obtenue par simulation ou par des moyens expérimentaux. Cette base contient des exemples connus de couples paramètres recherchés données d'observation. La procédure est similaire à la précédente mais avec l'inverse du modèle direct remplacé par le modèle inverse paramétrique (Figure III.12) [14].




Figure III.12 : Schéma du processus d'inversion directe basé sur un modèle d'inverse [14].

III.5 Applications des réseaux de neurones au CND par CF

III.5.1 Créations de la base de données

Dans ce travail, nous avons choisi les modèles d'inversion directe pour la caractérisation des défauts, où l'inversion consiste à remonter à partir de la réponse simulée du capteur aux paramètres du défaut. Dans ce cas, l'entrée de ces modèles est composée des parties réelles et imaginaires de l'impédance du capteur et la sortie est l'estimation des paramètres du défaut. Ce type de modèles nécessite une base de données de taille très importante pour réaliser l'inversion. Pour générer cette base de données, on fait tout d'abord la simulation de la réponse du capteur par la méthode des éléments finis (Comsol multiphysique with MATLAB).

Ensuite, les paramètres du défaut sont choisis de manière régulière. Enfin, les données sont sauvegardées pour chaque simulation par éléments finis, incluant la réponse du capteur et les paramètres du défaut correspondants. Nous avons défini un intervalle de variation pour la profondeur, allant de 0,25 mm à 0,9 mm, ainsi qu'un intervalle de 6 mm à 12 mm pour la longueur. Les bases de données, comportant 400 exemples, ont été générées selon cette méthode régulière. La répartition de la base de données dans l'espace est illustrée dans la figure ci-dessous.

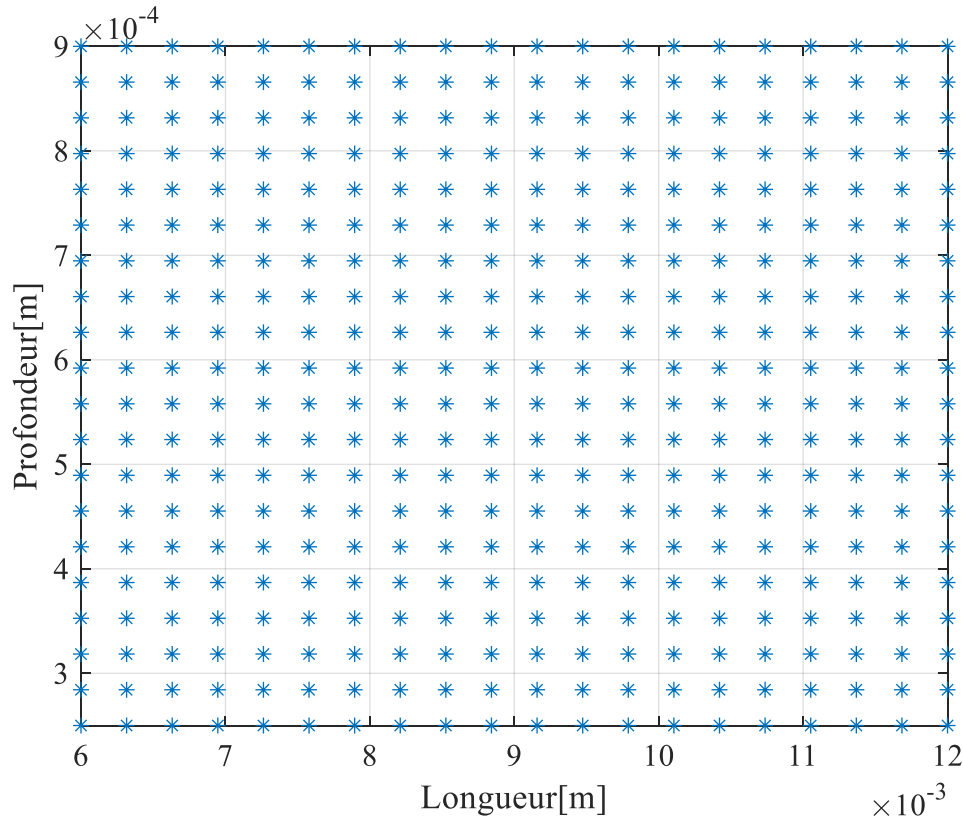


Figure III.13 : Répartition de la base de données dans l'espace de variation

III.5.2 Conditionnement des données

Pour assurer un apprentissage efficace, il est souhaitable de normaliser toutes les variables d'entrée et de sortie. Le conditionnement implique de normaliser et de centrer l'ensemble des données utilisées pour entraîner le modèle de réseau de neurones.

III.5.2.1 Normalisation

La normalisation est employée pour prévenir les anomalies transactionnelles qui peuvent survenir en raison d'une mauvaise modélisation des données. Elle aide à éviter divers problèmes potentiels tels que les anomalies de lecture. Cette technique est particulièrement utile pour des ensembles de données comprenant des variables représentant des phénomènes différents et mesurées avec des unités différentes (par exemple : la longueur du défaut en mm, la conductivité en MS/m, la fréquence en Hz, etc.). Si les données ne sont pas normalisées, certaines variables pourraient avoir une influence disproportionnée sur l'erreur finale, faussant ainsi les résultats.

III.5.2.2 Centrage

Le centrage des données est une astuce pour accélérer l'apprentissage des réseaux de neurones. Il consiste à déplacer les données vers le centre de l'espace, ce qui permet au modèle

de s'adapter plus rapidement. En effet, les fonctions noyaux, utilisées par les réseaux de neurones, fonctionnent mieux lorsqu'elles sont appliquées à des données centrées, dans leur zone quasi-linéaire.

Chaque paramètre scalaire d'entrée ou de sortie X_k recouvre sur la base d'apprentissage un ensemble d'exemples $\{x_i^k\}$. Pour chacun de ces paramètres on calcule la valeur moyenne $\langle X_k \rangle$ et l'écart type σ_k sur la base d'apprentissage en utilisant les équations (III.5) et (III.6) respectivement.

$$\langle X_k \rangle = \frac{1}{N} \sum_{i=1}^N x_i^k \quad (\text{III.5})$$

$$\sigma_k = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i^k - \langle X_k \rangle)^2} \quad (\text{III.6})$$

La nouvelle valeur conditionnée x_{ci}^k est donnée par la relation ci-dessous :

$$x_{ci}^k = \frac{x_i^k - \langle X_k \rangle}{\sigma_k} \quad (\text{III.7})$$

Avec k et i représentent, respectivement, les indices des paramètres et des exemples.

La formule (III.7) permet de conditionner les bases de validation et de test en utilisant la valeur moyenne et l'écart type trouvés sur la base d'apprentissage.

Après l'achèvement du processus d'apprentissage, il faut déconditionner les valeurs désirées (valeurs trouvées par le modèle d'inversion) pour trouver les valeurs réelles. Le déconditionnement se fait selon l'équation suivante :

$$x_i^k = x_{ci}^k \cdot \sigma_k + \langle x_k \rangle \quad (\text{III.8})$$

Dans cette étude, l'objectif est de caractériser les paramètres du défaut (longueur L et profondeur P). Les valeurs réelles et imaginaires de l'impédance représentent les entrées du modèle. Alors que, la sortie de ce dernier donne les valeurs conditionnées des paramètres du défaut (L_{cond} et P_{cond}). Après le déconditionnement on trouve les valeurs réelles du défaut ($L_{\text{déc}}$ et $P_{\text{déc}}$). Le schéma ci-dessous représente les étapes de la procédure d'inversion par le modèle de réseau de neurones [13].




Figure III.14 : Procédure d'inversion par réseau de neurones

III.5.3 Inversion par réseau de neurones

L'inversion par réseau de neurones fait référence à l'utilisation de techniques basées sur les réseaux de neurones pour résoudre des problèmes d'inversion. Dans cette partie les réseaux de neurones peuvent être utilisés pour inverser des relations complexes entre les entrées et les sorties, le réseau MLP (le perceptron multicouches) a été sélectionné pour faire cette inversion. Cette structure est convenable pour les modèles non linéaires.

Un réseau de neurones à deux couches (une couche cachée et une couche de sortie) est largement suffisant pour l'identification d'un système dynamique non linéaire multi-variable (plusieurs entrées, plusieurs sorties). La couche cachée est constituée d'un nombre de neurones qui sera déterminé de façon expérimentale pour le MLP. Les fonctions d'activation choisies pour le MLP sont de type sigmoïde. Les sorties du réseau sont les sorties estimées du système. Les fonctions d'activation choisies pour les sorties sont généralement de type linéaire.

III.5.3.1 Apprentissage

Les poids et les biais sont initialement attribués de manière aléatoire, puis ajustés par un algorithme d'apprentissage, de façon à minimiser l'erreur quadratique.

III.5.3.2 Validation

Une fois le réseau entraîné, on obtient les valeurs finales des poids et des biais. Une étape d'évaluation est nécessaire pour voir si le réseau obéit aux exigences fixées. Pour cela, on réalise un test sur le réseau. Si, malheureusement le réseau n'est pas satisfaisant, on doit s'engager soit à modifier la structure du réseau (augmenter le nombre des entrées, ajouter des neurones dans la couche cachée), ou augmenter le nombre d'itérations de la phase d'apprentissage si les paramètres du réseau n'ont pas encore convergés, ou encore, modifier les valeurs initiales des poids et des biais.

III.5.4 Application sur les données de simulation

Le modèle MLP est constitué d'un réseau avec une couche d'entrée, une couche cachée et une couche de sortie. Des fonctions d'activation linéaires sont appliquées à la sortie de chaque

neurone du réseau. La base de données précédemment créée comprend seulement 400 exemples, dont 350 sont utilisés pour l'apprentissage et 50 pour la validation.

La qualité des résultats de ces modèles de réseaux de neurones artificiels (RNA) est évaluée en mesurant l'erreur quadratique moyenne (MSE, pour Mean Square Error).

La MSE (Mean Square Error) mesure l'écart entre la ligne de régression des valeurs attendues et les valeurs prédites par le modèle. Plus la MSE est faible, plus le modèle est précis.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (\text{III.9})$$

où :

- ✓ N Le nombre total d'observations,
- ✓ y_i Représente les valeurs observées (réelles),
- ✓ \hat{y}_i Représente les valeurs prédites par le modèle.

Les figures III.15 et III.16, montrent l'évolution de la *MSE* sur la base d'apprentissage pour le model MLP destinés à prédire les largeurs et les profondeurs des défauts.




Figure III .15 : Évolution de l'erreur d'apprentissage pour le modèle MLP destiné à prédire les profondeurs




Figure III .16 : Évolution de l'erreur d'apprentissage pour le modèle MLP destiné à prédire les largeurs

Le tableau III.1 regroupe les valeurs de MSE, de R ainsi que de temps CPU obtenues sur les bases d'apprentissage et de validation pour le modèle MLP.

Tableau III.1: Résume les performances des modèles MLP

| | Base d'apprentissage | | Base de validation |
|--------------|----------------------|------------|--------------------|
| | MSE | Temps PCU | MSE |
| Longueur L | 1.0569e-13 | 0.147334 s | 9.2045e-10 |
| Profondeur P | 1.2429e-15 | 0.307821s | 2.4841e-11 |

A partir des résultats présentés dans le tableau III.1 on peut conclure que les MSE obtenues à ce modèle RNA atteints un niveau de précision très élevé.

Des comparaisons entre les valeurs de défaut prédites par le MLP et celles contenues dans les bases de validation, pour les différentes longueurs et profondeurs, sont montrées dans les figures III.17, III.18. Plus les points sont concentrés autour de la diagonale, plus la prédiction du modèle est meilleure.

Les résultats obtenus montrent que la plupart des points sont distribués autour de la diagonale pour le modèle MLP. Cela signifie que le modèle atteint un degré d'apprentissage très élevé. Comme prévu, selon la valeur de MSE, les résultats obtenus sur la base de validation sont un peu moins précis que ceux obtenus sur la base d'apprentissage, ce qui est logique. A partir des résultats obtenus, on peut dire que Le modèle MLP est précis.

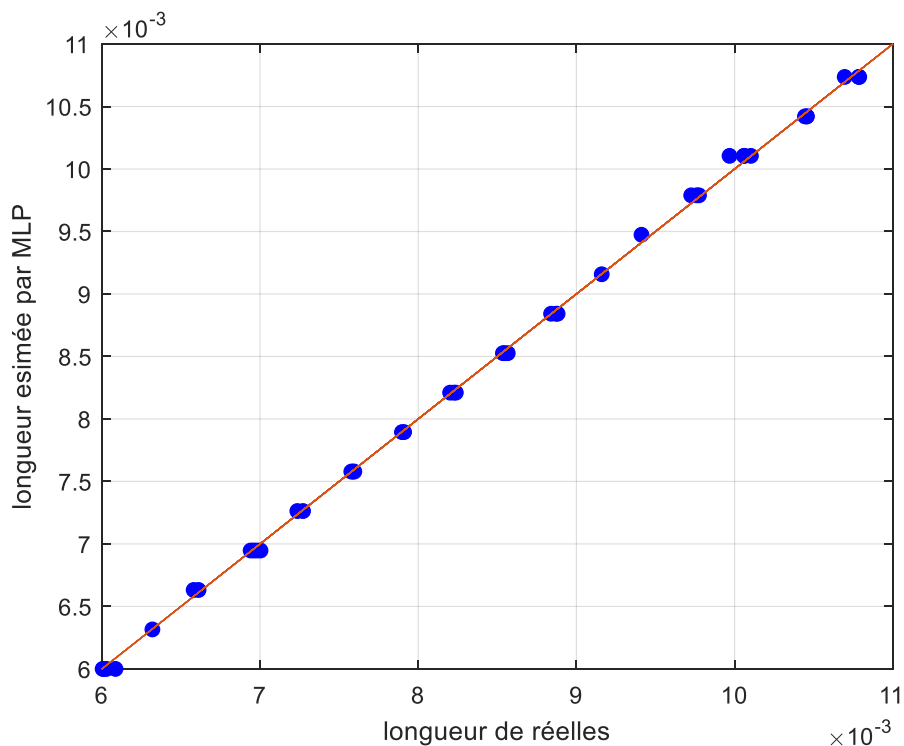


Figure III.17 : Profil de la longueur sur la base de validation obtenu par le modèle MLP




Figure III.18 : Profil de la longueur sur la base de validation obtenu par le modèle MLP

Conclusion

Dans ce chapitre qui est structuré en deux parties distinctes. La première partie s'attache à présenter les concepts fondamentaux de l'intelligence artificielle (IA), La seconde partie a été consacré à la mise en œuvre de la procédure d'inversion à base des MLP. Nous avons pu développer ce model au CND à CF. Dans notre application, une procédure basée sur un modèle MLP a été utilisée dans le but de caractériser le défaut, situés dans les pièces métalliques conductrices, à l'aide d'un capteur avec circuit magnétique de forme cylindrique. De plus, on a essayé de bien appliqué la méthode de génération de base de données. On a pu conclure que les bases régulières permettent de réduire considérablement l'erreur MSE et par conséquent, obtenir un modèle MLP très puissant. Un bon accord entre les résultats de simulation et les données de mesure a été obtenu.

Conclusion générale

Conclusion Générale

L'évolution des processus industriels et des pièces fabriquées, marquée par une complexité croissante, s'accompagne d'enjeux majeurs en termes de sécurité de fonctionnement et d'optimisation de la durée de vie des composants. Ces exigences stimulent le développement de contrôles qualité toujours plus poussés. Parmi les techniques CND disponibles, le contrôle par courants de Foucault s'impose comme une solution fiable, rapide et économique. Sa simplicité d'utilisation, sa robustesse et sa nature électromagnétique "sans contact" en font une méthode privilégiée dans de nombreux secteurs industriels depuis plusieurs décennies.

Le contrôle par courants de Foucault est une technique efficace pour détecter les défauts dans les pièces métalliques. Il permet de repérer rapidement les zones où l'épaisseur du matériau a diminué. Cette méthode est souvent complétée par des contrôles par CF, lorsqu'ils sont possibles, pour confirmer et mesurer précisément les défauts détectés. Le contrôle par courants de Foucault est particulièrement adapté aux canalisations et s'applique sur les surfaces conductrices, signalant les pertes d'épaisseur d'un côté ou des deux côtés des pièces.

L'équation décrivant le fonctionnement de notre système de CND a été obtenue à partir des lois de l'électromagnétisme (équations de Maxwell). Cette équation complexe a été résolue numériquement à l'aide de la méthode des éléments finis. Cette résolution permet de déterminer la distribution du champ magnétique et d'autres grandeurs physiques importantes dans l'ensemble de l'étude (capteur, air et pièce inspectée).

Ce travail de Master s'est concentré sur le développement de modèles d'inversion directe basés sur des réseaux de neurones multicouches (MLP) pour l'estimation des caractéristiques des défauts de perte de métal dans les pièces conductrices. La méthode des éléments finis (MEF), un outil numérique reconnu pour la résolution de problèmes électromagnétiques complexes, a été utilisée pour résoudre le problème direct et générer une base de données complète. Cette base de données a servi à l'entraînement et à l'évaluation des modèles MLP, permettant ainsi une caractérisation précise des défauts de perte de métal.

L'évaluation des défauts s'est concentrée sur deux dimensions clés : la profondeur et la longueur. Les résultats de l'inversion démontrent la performance et la pertinence du modèle proposé pour ce type de problème. Le modèle basé sur les réseaux de neurones artificiels (MLP) présente une convergence rapide et offre une estimation instantanée des dimensions des défauts après la phase d'apprentissage. Un autre avantage réside dans sa capacité à s'entraîner sur une base de données de taille relativement modeste (environ 400 exemples), ce qui le distingue favorablement d'autres outils d'inversion aux performances comparables. Enfin, la qualité acceptable des résultats d'inversion obtenus sur des données simulées atteste de l'efficacité et de la robustesse des modèles MLP employés dans le cadre de cette étude.

Références

Bibliographiques

Références Bibliographiques

- [1] https://www.plastiform.info/controle-dimension/controle-non-destructif-cnd/#title_2.
- [2] <https://master-cnd.com/les-domaines-dapplication/>.
- [3] Emna Amira Fraiech, « Développement d'un outil de simulation du procédé de contrôle non destructif des tubes ferromagnétiques par un capteur à flux de fuite », Université Paris Sud – Paris XI, 2012.
- [4] Safer Omar Adib, « Étude et Modélisation de Capteur à Courants de Foucault pour le Contrôle Non Destructif (CND) », thèse de magistère, Université de Msila, 2014.
- [4] https://www.researchgate.net/figure/Principe-du-CND-par-courants-de-Foucault_fig6_281660656
- [6] <https://www.savoycontrol.fr/savoir-faire/acfm/>.
- [7] https://fac.umc.edu.dz/ista/pdf/cours/Cours_CND_2018_L3_PMI.pdf
- [8] Mourad Zergoug et Ahmed Haddad, « Modélisation de la propagation des micro-ondes dans les matériaux composites », thèse de magistère, Université de Blida, 2004.
- [9] Cristian Golovanov, « Développement de formulations éléments finis 3D en potentiel vecteur magnétique : application à la simulation de dispositifs électromagnétiques en mouvement », thèses de doctorat, de l'institut national polytechnique de Grenoble, 1992.
- [10] Wissem Slimane, « Conception d'un Système Multi-Capteurs à Courants de Foucault pour le Contrôle Non Destructif (CND) », thèses de magistère, Université El Hadj Lakhdar Batna, 2008.
- [11] Berkache Azouaou, « Modélisation de structure CND par la méthode des éléments finis stochastique », thèses de magistère, Université Mouloud Mammeri Tizi-Ouzou, 2015.
- [12] Nabil Benhadda, « Modélisation des Capteurs Inductifs à Courants de Foucault », thèses de magistère, Université El Hadj Lakhdar Batna, 2006.
- [13] Chelabi Mohamed, « Utilisation des Machines à Vecteurs Supports pour le Contrôle Non Destructif par Méthode Electromagnétiques », Thèse de doctorat, Université de Jijel, 2016.

- [14] Gaouir Chemseddine et Rezkoune Rassim, « Modèles neuronaux pour le CND à flux de fuite magnétique », thèses de master, Université de jijel,2019.
- [15] Lamouat Saddik et Benamer Ramadhane, « Simulation de la Détection de Défauts de Corrosion de Rail de Train par CND-CF », thèses de master, Université de Msila, 2022.
- [16] Hamel Meziane, « Etude et réalisation d'un dispositif de détection de défauts par méthodes électromagnétiques », thèse de Magister université Mouloud Mammeri de Tizi-Ouzou 2012.
- [17] Daniel Choi, « Méthode des éléments-finis par l'exemple », Université de Caen, Bld Maréchal Juin, 14032 Caen Cedex, France 2016.
- [18] Laurent Santandrea et Yvette Le Bihan, « Using COMSOL-Multiphysics in an Eddy Current Non-Destructive Testing Context », In Proceedings of the Comsol Conference Paris, vol.1, (2010).
- [19] <https://www.cnil.fr/fr/intelligence-artificielle/intelligence-artificielle-de-quoi-parle-t-on>.
- [20] <https://www.cleml.fr/ressources/ressources-pedagogiques/comprendre-les-principes-de-base-de-lintelligence-artificielle-ia>.
- [21] <https://actualiteinformatique.fr/intelligence-artificielle/quels-sont-les-3-types-ia>.
- [22] <https://www.ibm.com/fr-fr/topics/supervised-learning>.
- [23] Oukacine Nacima, « Utilisation de réseaux de neurones pour la reconstitution de défauts en évaluation non destructive », Mémoire de Magister en électrotechnique, Université Mouloud Mammeri de Tizi-ouzou 2012.
- [24] Seddik Azzaoui, « Utilisation des Méthodes de l'Intelligence Artificielle dans la Modélisation des Phénomènes Electromagnétiques et Thermiques Couplés dans les Systèmes Electriques. Thèse de doctorat, Université Mohamed Khider – Biskra 2017.
- [25] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. Nature, 521(7553), 436-444.
- [26] <https://www.geeksforgeeks.org/introduction-to-recurrent-neural-network/>
- [27] https://www.wikiwand.com/fr/Machine_%C3%A0_%C3%A9tat_liquide.
- [28] https://www.geeksforgeeks.org/gated-recurrent-unit-networks/?ref=header_search
- [29] https://www.researchgate.net/figure/Schema-dun-Gated-Recurrent-Unit-Les-symboles-s-et-tanh-representent-respectivement_fig4_339711360

Résumé

Ce travail explore le contrôle non destructif (CND) par des méthodes électromagnétiques, avec un focus particulier sur les courants de Foucault pour la détection de défauts dans les matériaux conducteurs. Il décrit comment ces méthodes permettent d'identifier les discontinuités sans endommager les pièces inspectées. Ensuite, il se concentre sur la modélisation et la simulation d'un capteur de courant de Foucault à l'aide de la méthode des éléments finis, illustrant comment cette technique aide à évaluer la performance du capteur en présence de défauts. Enfin, l'étude examine l'intégration de l'intelligence artificielle (IA) dans le CND par courants de Foucault, en détaillant les algorithmes d'apprentissage automatique de l'IA utilisés pour améliorer la précision et l'efficacité des inspections.

Mots clés : le contrôle non destructif (CND), les méthodes électromagnétiques, Courant de Foucault, l'intelligence artificielle (IA).

Application of artificial intelligence methods in non-destructive control by electromagnetic methods

Abstract

This work focuses on non-destructive testing (NDT) using electromagnetic methods, particularly eddy currents, for defect detection in conductive materials. It details how these methods enable the identification of discontinuities without damaging the inspected parts. Subsequently, the study explores the modeling and simulation of an eddy current sensor using the finite element method, demonstrating how this technique aids in evaluating sensor performance in the presence of defects. Finally, the research examines the integration of artificial intelligence (AI) into eddy current NDT, detailing the machine learning algorithms employed by AI to enhance inspection accuracy and efficiency.

Keywords: non-destructive testing (NDT), electromagnetic methods, eddy current, artificial intelligence (AI).

ملخص

يستكشف هذا العمل الفحص غير المدمر بالطرق الكهرومغناطيسية ، مع التركيز بشكل خاص على التيارات الدوامة للكشف عن العيوب في المواد الموصلة. يصف كيف يمكن لهذه الطرق تحديد الانقطاعات دون الإضرار بالأجزاء التي يتم فحصها. بعد ذلك ، يركز على نمذجة ومحاكاة مستشعر التيار الدوامة باستخدام طريقة العناصر المحدودة ، يركز على نمذجة ومحاكاة مستشعر التيار الدوامة باستخدام طريقة العناصر المحدودة ، مما يوضح كيف تساعد هذه التقنية في تقييم أداء المستشعر في وجود عيوب. أخيرا ، تبحث الدراسة في دمج الذكاء الاصطناعي في التحكم الغير مدمر عن طريق التيار الدوامة ، مع تفصيل الذكاء الاصطناعي خوارزميات التعلم الآلي المستخدمة لتحسين دقة وكفاءة عمليات التفتيش.

الكلمات المفتاحية: الفحص الغير مدمر ، الطرق الكهرومغناطيسية ، التيار الدوامة ، الذكاء الاصطناعي.