



Mise en garde

La bibliothèque du Cégep de l'Abitibi-Témiscamingue et de l'Université du Québec en Abitibi-Témiscamingue (UQAT) a obtenu l'autorisation de la personne autrice de ce document afin de diffuser, dans un but non lucratif, une copie de son œuvre dans [Depositum](#), site d'archives numériques, gratuit et accessible à tous. L'autrice ou l'auteur conserve néanmoins ses droits de propriété intellectuelle, dont son droit d'auteur, sur cette œuvre.

Warning

The library of the Cégep de l'Abitibi-Témiscamingue and the Université du Québec en Abitibi-Témiscamingue (UQAT) obtained the permission of the author to use a copy of this document for nonprofit purposes in order to put it in the open archives [Depositum](#), which is free and accessible to all. The author retains ownership of the copyright on this document.

UNIVERSITÉ DU QUÉBEC EN ABITIBI-TÉMISCAMINGUE

TAXINOMIE EN TEMPS RÉEL DES DÉFAUTS DE COURT-CIRCUIT
DANS LES RÉSEAUX ÉLECTRIQUES MAILLÉS

MÉMOIRE
PRÉSENTÉ
COMME EXIGENCE PARTIELLE
DE LA MAÎTRISE EN INGÉNIERIE

PAR
POLSTER KADER MBAKOB NDAGOUA

NOVEMBRE 2025

Remerciements

Au terme de ce travail, j'ai l'honneur et la gratitude de remercier :

Mon directeur de recherche, **Pr. Fouad Slaoui Hasnaoui**, dont l'écoute, les encouragements et les conseils ont été déterminants tout au long de mon parcours. Ce mémoire n'aurait pas pu être possible sans son appui.

Je souhaite exprimer ma profonde gratitude à l'ensemble du personnel ainsi qu'à la direction de l'UQAT pour m'avoir offert l'opportunité de vivre cette expérience académique des plus enrichissantes. Je vous remercie sincèrement pour l'accueil chaleureux que vous m'avez réservé, ainsi que pour votre implication dans mon intégration et le bon déroulement de mon parcours. Je tiens également à remercier tous les professeurs du programme de maîtrise en ingénierie, concentration en génie électrique, pour la qualité de leur enseignement et la richesse de leurs conseils, qui ont largement contribué à la réussite de mon projet de recherche.

Mes remerciements s'adressent également aux membres du jury pour l'attention qu'ils porteront à l'évaluation de ce travail. J'espère que ce mémoire saura répondre à leurs attentes en termes de clarté, de rigueur et de motivation.

Je tiens à exprimer toute ma gratitude à ma famille pour l'amour constant, les conseils avisés et le soutien indéfectible, tant moral que financier, qui m'ont permis de poursuivre les études auxquelles j'aspirais depuis longtemps.

Merci à toute personne ayant participé de près ou de loin à l'élaboration de ce travail.

Dédicaces

Je dédie ce travail,

A mes parents : papa *Mbakob Mbating Dieudonné* et maman *Nkwamegni Martine*
Qui m'ont soutenu et m'encouragé durant mes années d'études et ne manquaient pas
de me recadrer à chaque fois que c'était nécessaire. Qu'ils trouvent ici le témoignage
de ma profonde considération.

A eux deux,

Ils n'ont jamais cessé, de formuler des prières à mon égard, de me soutenir et de
m'épauler pour que je puisse atteindre mes objectifs.

A mes frères et sœurs, *Aldo, Maurice, Idris et Harlette, Caroline, Elsa*
Pour leurs soutiens moraux et leur conseils précieux tout au long de mes études.

A ma très chère *Yolande Corine*
Pour son indéfectible soutien, ses conseils, sa patience infinie et sa tolérance.

A mes chers ami(e)s de par le monde et à mes proches collègues de l'UQAT
Pour leurs aides, leurs apports multiformes et le support dans les moments difficiles.

Table des matières

Remerciements	ii
Dédicaces	iii
Liste des figures	vii
Liste des tableaux	ix
Liste des abréviations	x
Résumé	xi
Abstract	xii
CHAPITRE 1 : INTRODUCTION	1
1.1 Contexte général	1
1.2 Problématique	6
1.3 Originalités	7
1.4 Objectifs	7
1.4.1 Objectif général	7
1.4.2 Objectifs spécifiques	7
1.5 Hypothèses de recherche	8
1.6 Méthodologie de recherche	8
1.7 Conclusion	9
CHAPITRE 2 : REVUE DE LITTÉRATURE	10
2.1 Structure des réseaux électriques	10
2.1.1 La production.....	11
2.1.2 Le transport.....	12
2.1.3 La répartition	13
2.1.4 La distribution.....	13
2.2 Topologie des réseaux électriques	15
2.3 Les différents défaut dans les réseaux électriques	17
2.3.1 Origines des défauts.....	17
2.3.2 Les formes de défauts dans les réseaux électriques	19

2.4 Technique de détection et classification des défauts dans les réseaux électriques.....	22
2.4.1 Technique de détection des défauts	22
2.4.2 Technique de classification des défauts.....	24
2.5 Technique de localisation des défauts dans les réseaux électriques	25
2.5.1 La méthodes d'impédance	25
2.5.2 Techniques transitoires à ondes voyageuses.....	27
2.5.3 La logique floue.....	28
2.5.4 La triangulation.....	28
2.5.5 Méthodes basées sur l'intelligence artificielle IA	29
2.6 Conclusion	30
CHAPITRE 3 : DÉTECTION ET CLASSIFICATION EN TEMPS RÉEL DES COURTS CIRCUITS À PARTI DE L'AUTO-ENCODEUR LSTM.....	31
3.1 Présentation du système électrique d'études.....	31
3.2 Base de données de contingence	36
3.3 Détection en temps réel des courts circuits à parti de l'auto-encodeur LSTM	38
3.3.1 Réseaux de Neurones Récurents (RNN) et LSTM.....	38
3.3.1.1 Réseaux de Neurones Récurents (RNN).....	38
3.3.1.2 Les réseaux de mémoire à long terme (LSTM)	39
3.3.2 Présentation de l'auto-encodeur LSTM.....	41
3.3.3 Formation de l'auto-encodeur LSTM pour la détection des défauts	44
3.3.4 Application de l'auto-encodeur LSTM pour la détection des défauts en temps réel	46
3.3.4.1 Détection des défauts en temps réel dans une ligne de transmission	49
3.3.4.2 Détection des défauts en temps réel dans deux lignes de transmission ...	55
3.3.4.3 Détection des défauts en temps réel dans trois lignes de transmission	61
3-4 Application du LSTM pour la classification des défauts en temps réel	66
3.4.1 Préparation des données pour la classification des défauts	67
3.4.2 Architecture du modèle LSTM utilisé	69
3.4.3 Résultats de la classification	72

3.4.4 Analyse des résultats de la classification en temps réel.....	74
3.5 Conclusion	78
CHAPITRE 4 :LOCALISATION DES DÉFAUTS DE COURT CIRCUIT DANS LES RÉSEAUX ÉLECTRIQUE MAILLÉS	80
4.1 Localisation des défauts par les réseaux de neurones	81
4.1.1 Principe de base des réseaux de neurone.....	81
4.1.1.1 Description des réseaux de neurone.....	81
4.1.1.2 Réseau de neurones à propagation en avant	82
4.1.1.3 Fonction d'activation	84
4.1.1.4 Stratégie d'apprentissage	85
4.1.2 Application des RNA pour la localisation des défauts de court-circuit.....	86
4.1.2.1 Base des données de contingence	86
4.1.2.2 Dataset et entraînement du réseau neuronal	88
4.1.3 Analyse des performances du modèle neuronal.....	88
4.1.3.1 Entraînement du réseau neuronal.....	89
4.1.3.2 Évaluation du modèle adopté	93
4.2 Localisation des défauts par la méthode de triangulation	96
4.2.1 Adaptation du principe de la triangulation pour la localisation des défauts dans les réseaux électriques	97
4.2.2 Simulation et analyse des résultats	100
4.2.2.1 Simulation	100
4.2.2.2 Analyse des résultats	101
5 Conclusion	102
CONCLUSION GÉNÉRALE.....	104
ARTICLES SOUMIS POUR LA PUBLICATION:	106
ANNEXE A COURBES DES PERFORMANCES ET PARAMÈTRES	107
BIBLIOGRAPHIE	109

Liste des figures

Figure 1. 1 : Procédure suivie pour analyser les défauts	5
Figure 2. 1 : Organisation du transport de l'énergie électrique [2].....	15
Figure 2. 2 : Les topologies des réseaux électriques : (a) Réseau maillé (b) Réseau bouclé (c) Réseau radiale (d) Réseau arborescent	16
Figure 2. 3 : Schéma unifilaire et représentation du circuit de défaut de ligne [3]	26
Figure 2. 4 : Schéma de la localisation synchronisée des défauts aux deux extrémités avec utilisation du GPS [3].....	27
Figure 2. 5 : Illustration de la méthode Traveling-Waves [4]	28
Figure 3. 1: Modèle du système électrique test IEEE-9 bus proposé.....	32
Figure 3. 2 :Présentation de la ligne 1 de notre système IEEE-9 bus.....	33
Figure 3. 3 : Le schéma unifilaire du réseau de test IEEE 09-bus [1]	34
Figure 3. 4 : Architecture déroulée du réseau RNN [5].....	39
Figure 3. 5 : Structure d'un réseau LSTM	40
Figure 3. 6 : Architecture du réseau LSTM.....	40
Figure 3. 7 : Architecture simplifiée de l'auto-encodeur LSTM.....	42
Figure 3. 8 : Formes d'onde de tension et de courant du système étudié, sans défaut	44
Figure 3. 9 : Modèle Simulink pour la détection des défauts en temps réel dans une ligne de transmission	47
Figure 3. 10 : Visualisation sur le scope du modèle Deep Signal Anomaly Detector	48
Figure 3. 11 : Courbe de perte d'apprentissage	49
Figure 3. 12 : Sortie du scope d'un défaut de type A-G	50
Figure 3. 13 : Sortie du scope d'un défaut de type AB.....	51
Figure 3. 14 : Sortie du scope d'un défaut de type AB-G.....	52
Figure 3. 15 : Sortie du scope d'un défaut de type ABC	53
Figure 3. 16 : Sortie du scope d'un défaut de type ABC-G.....	55
Figure 3. 17 : Modèle simulink pour la détection des défauts en temps réel dans deux lignes de transmission.....	56

Figure 3. 18 : Sortie du scope d'un défaut de type A-G sur la ligne 1 et d'un défaut de type ABC sur la ligne 6	57
Figure 3. 19 : Sortie du scope d'un défaut de type AB sur la ligne 2 et d'un défaut de type AC-G sur la ligne 5	59
Figure 3. 20 : Sortie du scope d'un défaut de type AC-G sur la ligne 5 et d'un défaut de type ABC sur la ligne 6	60
Figure 3. 21 : Modèle simulink pour la détection des défauts en temps réel dans trois lignes de transmission.	62
Figure 3. 22 : Sortie du scope d'un défaut de type AB-G sur la ligne 1, un défaut de type B-G sur la ligne 2 et d'un défaut de type BC sur la ligne 6	63
Figure 3. 23 : Sortie du scope d'un défaut de type ABC sur la ligne 3, un défaut de type BC sur la ligne 4 et d'un défaut de type AB-G sur la ligne 5.....	65
Figure 3. 24 : Cadre proposé pour la classification des défauts.	68
Figure 3. 25 : Performances du classificateur LSTM.....	72
Figure 3. 26 : Matrice de confusion.....	73
Figure 3. 27 : Évolution de l'apprentissage.....	74
Figure 3. 28 : Sortie du LSTM pour la prédiction de la classe 1.....	75
Figure 3. 29 : Sortie du LSTM pour la prédiction du défaut simple de classe 2.....	76
Figure 3. 30 : Sortie du LSTM pour la prédiction du défaut hybride de classe 16.	77
Figure 3. 31 : Sortie du LSTM pour la prédiction du défaut hybride de classe 26.	78
Figure 4. 1 : Structure d'un réseau de neurone artificiel	82
Figure 4. 2 : Structure classique d'un neurone de type feedforward	83
Figure 4. 3 : Graphique de performance du localisateur neuronal 36-10-3-3	90
Figure 4. 4 : Graphique de performance du localisateur neuronal 36-15-3-3	91
Figure 4. 5 : Graphique de performance du localisateur neuronal 36-50-3-3	92
Figure 4. 6 : Diagramme du réseau de neurone adopté	93
Figure 4. 7 : Graphique de régression du modèle adopté	94
Figure 4. 8 : Méthode de localisation par triangulation.	98

Liste des tableaux

Tableau 3. 1 : Paramètres du modèle PI de chaque ligne de transmission	33
Tableau 3. 2 : Les données des générateurs du réseau IEEE 09-bus.....	35
Tableau 3. 3 : Les données des transformateurs du réseau IEEE 09-bus	35
Tableau 3. 4 : Les données des charges du réseau IEEE 09-bus.....	35
Tableau 3. 5 : Base de données de contingence	37
Tableau 3. 6 : Description des notations	43
Tableau 3. 7 : Classes des différents défauts.....	67
Tableau 4. 1 : Fonctions d'activation.....	84
Tableau 4. 2 : Base des données de contingence de génération du dataset.....	87
Tableau 4. 3 : Comparaison entre la sortie réelles et la sortie prédite du localisateur neuronal.....	95
Tableau 4. 4 : Base de données des défauts.....	101
Tableau 4. 5 : Résultat de la simulation.....	101

Liste des abréviations

ANN	: Artificial Neural Network (Réseau de Neurones Artificiels)
CNN	: Convolutional Neural Network
RNN	: Recurrent Neural Network
LSTM	: Long Short-Term Memory
DNN	: Deep Neural Network
AE	: Autoencodeur
FFNN	: Feedforward Neural Network
ML	: Machine Learning (Apprentissage automatique)
DL	: Deep Learning (Apprentissage profond)
AI	: Artificial Intelligence (Intelligence artificielle)
MSE	: Mean Squared Error (Erreur quadratique moyenne)
MAE	: Mean Absolute Error (Erreur absolue moyenne)
RMSE	: Root Mean Square Error
PMU	: Phasor Measurement Unit
TDOA	: Time Difference of Arrival
TOA	: Time of Arrival
GPS	: Global Positioning System
HT	: Haute tension
MT	: Moyenne tension
THT	: Très haute tension
IEEE	: Institute of Electrical and Electronics Engineers
UQAT	: Université du Québec en Abitibi-Témiscamingue

Résumé

Ces dernières années, la surveillance et la protection en temps réel des systèmes électriques à grande échelle sont devenues un défi majeur en raison de l'intégration accrue des sources d'énergie renouvelables et de la complexité croissante des réseaux électriques modernes. Cette complexité, bien qu'innovante, les rend vulnérables à divers défauts, notamment les courts-circuits, qui représentent environ 90 % des contingences et figurent parmi les plus fréquents et les plus dommageables. Par conséquent, une gestion efficace de ces défauts nécessite une détection rapide, une localisation précise et une classification fiable.

Dans ce cadre, notre recherche propose une méthodologie performante pour l'analyse en temps réel des défauts de court-circuit dans les réseaux électriques maillés. Un autoencodeur *Long Short-Term Memory* (LSTM) est utilisé pour détecter en temps réel les anomalies dans les signaux de tension et de courant triphasés mesurés sur différentes lignes du réseau. Un modèle de réseaux LSTM a été adapté pour classer avec précision, en temps réel, les défauts détectés selon leur nature. Enfin, des méthodes basées sur les réseaux de neurones profonds et sur la triangulation ont été appliquées pour la localisation précise de ces défauts. L'ensemble de ces approches a été testé sur un réseau électrique maillé IEEE 9-bus modélisé sous MATLAB/Simulink. Les résultats obtenus démontrent une excellente performance du système en termes de rapidité, de précision et de robustesse, y compris dans des scénarios complexes impliquant des défauts multiples et simultanés sur plusieurs lignes du réseau.

Mots clés: Réseaux électriques maillés, défaut de courts-circuits, défaut multilignes, analyse en temps réel, autoencodeur LSTM, triangulation, réseau de neurones profond.

Abstract

In recent years, real-time monitoring and protection of large-scale power systems have become a major challenge due to the increased integration of renewable energy sources and the growing complexity of modern power networks. This complexity, while innovative, makes them vulnerable to various faults, particularly short-circuits, which account for about 90% of contingencies and rank among the most frequent and damaging. Consequently, effective management of these faults requires rapid detection, accurate localization, and reliable classification.

In this context, our research proposes an efficient methodology for real-time analysis of short-circuit faults in meshed power networks. A Long Short-Term Memory (LSTM) autoencoder is employed to detect anomalies in real time from three-phase voltage and current signals measured on different network lines. An LSTM-based model has been adapted to accurately classify the detected faults in real time according to their type. Finally, methods based on deep neural networks and triangulation have been applied for precise fault localization. All these approaches were tested on an IEEE 9-bus meshed power system modeled in MATLAB/Simulink. The results demonstrate excellent system performance in terms of speed, accuracy, and robustness, including in complex scenarios involving multiple simultaneous faults on several network lines.

Keywords: Meshed power networks, short-circuit faults, multi-line default, real-time analysis, LSTM autoencoder, triangulation, deep neural network

CHAPITRE 1 : INTRODUCTION

Les réseaux électriques modernes, de plus en plus complexes et interconnectés, jouent un rôle crucial dans la distribution de l'énergie à travers le monde. Ces réseaux sont vulnérables à divers types de défauts, parmi lesquels les courts-circuits, avec environ 90 % des contingences, figurent parmi les plus fréquents et les plus dommageables. Un court-circuit peut entraîner des interruptions de service, des dommages matériels, voire des risques pour la sécurité humaine. Dans les architectures maillées, où les interconnexions sont nombreuses, un défaut peut se propager rapidement et plusieurs défauts peuvent même apparaître simultanément sur différentes lignes du réseau. Cette situation rend indispensable la mise en place de méthodes performantes capables d'identifier rapidement ces défauts, d'en déterminer la localisation exacte, et de le classer avec précision. Ce premier chapitre présente le contexte général de cette recherche, sa problématique tout en précisant les objectifs poursuivis et la méthodologie adoptée pour y répondre de manière rigoureuse et efficace à ce problème.

1.1 Contexte général

L'électricité est devenue l'un des piliers fondamentaux de notre société moderne, soutenant une multitude d'activités allant des usages quotidiens aux processus industriels les plus complexes. Dans nos foyers, elle alimente les appareils essentiels à notre confort et notre productivité, tandis que dans les secteurs industriels, elle est indispensable au fonctionnement des machines, des systèmes de production et des équipements de haute technologie [6, 7]. La fiabilité et la disponibilité constante de l'électricité sont donc des exigences cruciales, en particulier dans les industries où même une courte interruption peut entraîner des pertes de production et des coûts importants. Les réseaux électriques, en assurant cette distribution continue d'énergie,

se doivent d'être robustes et résilients face aux fluctuations de la demande et aux diverses contraintes auxquelles ils sont exposés [8]. De plus, avec l'expansion des réseaux électriques, en particulier avec l'intégration croissante de sources d'énergie renouvelable et l'évolution vers des réseaux intelligents, la capacité à détecter, localiser et gérer les défauts rapidement devient une nécessité pour garantir non seulement l'intégrité du système mais aussi la sécurité des utilisateurs et des opérateurs [9-13].

Cependant, les systèmes électriques, essentiels pour la transmission et la distribution de l'énergie, sont souvent soumis à des contraintes techniques et environnementales pouvant engendrer diverses pannes. Ces pannes sont causées par des facteurs variés, tels que l'usure des équipements, les surcharges, les erreurs humaines, les conditions climatiques extrêmes ou des éléments extérieurs comme les chocs mécaniques et les débris [14]. Parmi ces défaillances, les courts-circuits (environ 90% des contingences) se révèlent particulièrement fréquents et dangereux, car ils apparaissent lorsque le courant dévie de son trajet prévu, traversant une zone de faible résistance, ce qui entraîne une concentration anormale d'énergie électrique en un point précis [15]. Cette situation peut provoquer des échauffements, des arcs électriques, voire des incendies et des explosions, mettant en péril la sécurité des installations et du personnel. Ces courts-circuits représentent un défi majeur dans les réseaux électriques maillés car ils peuvent entraîner des perturbations à large échelle, affectant des milliers de consommateurs et entraînant des conséquences économiques considérables.

Par exemple, en 2002, il y avait une panne d'électricité très importante en Amérique du Nord [16]. Cet accident a plongé environ 50 millions de personnes dans l'obscurité pendant plus que deux jours. Les pertes économiques ont été estimées à 11 milliards de dollars. En février 2021 à Texas, une vague de froid extrême a provoqué des défaillances massives dans le réseau, laissant des millions de personnes sans électricité pendant des jours. Les pertes économiques ont été estimées à des dizaines de milliards de dollars, sans compter l'impact humain tragique, avec des décès dus au froid [8, 16-18]. De plus, ils imposent de fortes contraintes sur les dispositifs de protection, tels que les disjoncteurs et les relais, qui doivent intervenir rapidement pour isoler la partie

endommagée du réseau [14, 19, 20]. Dans les cas où ces dispositifs échouent, le risque de défaillance en cascade augmente, avec pour conséquence des dégâts importants non seulement sur les parties directement touchées mais aussi sur d'autres segments du réseau, affectant ainsi l'ensemble du système. Pour cette raison, la détection, localisation et classification rapides des courts-circuits dans les réseaux maillé est d'une importance cruciale afin d'intervenir de manière ciblée et de limiter les dommages [21]. Toutefois, les méthodes de détection traditionnelles reposent souvent sur des processus hors ligne et manuels, insuffisants pour une intervention en temps réel. Les recherches actuelles se concentrent donc sur le développement de solutions dynamiques capables d'identifier et d'isoler instantanément les courts-circuits dans un réseau en évolution constante. En intégrant des approches machine Learning et Deep Learning pour analyser les données en temps réel, il devient possible d'atteindre une détection proactive et instantanée, assurant ainsi une sécurité accrue des infrastructures et une meilleure continuité de service pour les utilisateurs finaux.

Au cours de la dernière année, les approches basées sur l'intelligence artificielle (IA) ont connu un essor significatif pour la détection, la localisation, et la classification des défauts dans les réseaux électriques [16, 21-27]. Ces méthodes offrent une alternative prometteuse aux techniques conventionnelles grâce à leur capacité d'apprentissage à partir de données, leur rapidité de traitement, et leur aptitude à modéliser des systèmes non linéaires complexes [14, 28, 29]. Toutefois, une limite importante des travaux actuels réside dans leur application majoritairement hors ligne, où les modèles sont entraînés et testés sans intégration directe dans un système de surveillance en temps réel [30, 31]. De plus, la plupart des recherches se focalisent sur l'analyse des défauts sur une seule ligne de transmission, sans prendre en compte la possibilité que plusieurs défauts apparaissent simultanément sur différentes lignes. Un scénario pourtant plausible et critique dans les réseaux maillés interconnectés [32, 33]. Par ailleurs, les modules de classification sont souvent conçus pour distinguer les défauts classiques (monophasés, biphasés, triphasés) sans traiter efficacement les défauts hybrides ou multiples, tandis que la localisation est encore majoritairement envisagée sur une base

unilinéaire avec des méthodes hors ligne [34-36]. Ces limitations rendent les systèmes de protection actuels inadaptés aux exigences croissantes en termes de réactivité, de résilience et de fiabilité dans les réseaux intelligents. D'où la nécessité de développer une méthodologie capable de détecter, localiser et classifier en temps réel tout type de défaut, y compris ceux survenant simultanément sur plusieurs lignes, afin de garantir une gestion dynamique et robuste des incidents dans les réseaux électriques maillés. Cette étude propose une approche de détection, classification et localisation des défauts de court-circuit en temps réel dans les réseaux électriques maillés, un auto-encodeur LSTM pour la détection, un réseau LSTM pour la classification, et des réseaux de neurones feedforward pour la localisation précise des défauts.

Ces dernières années, plusieurs travaux ont exploré l'utilisation des approches d'intelligence artificielle, notamment les réseaux neuronaux profonds, pour la détection, la classification et la localisation des défauts dans les réseaux électriques. L'auto-encodeur LSTM, bien que récemment étudié pour la détection d'anomalies dans des séquences temporelles électriques, a principalement été utilisé dans des contextes hors ligne, souvent sur des scénarios limités à des défauts isolés sur une seule ligne [37-39]. De même, des études exploitant le LSTM pour la classification des défauts, telles que celles de Omar et al. [40] ou Belagoune et al. [41], montrent des résultats prometteurs, mais restent limitées à la reconnaissance de défauts simples, sans prendre en compte les défauts hybrides ou multiples pouvant survenir simultanément sur plusieurs lignes d'un réseau maillé. En ce qui concerne la localisation des défauts, de nombreux travaux se sont appuyés sur les réseaux de neurones artificiels (ANN) en tant qu'outils de régression efficaces. Par exemple, R. Alilouch et al. [42] ont proposé un modèle basé sur l'ANN pour localiser les défauts dans les lignes de transmission, mais leur approche reste confinée à une seule ligne à la fois, et ne prend pas en compte les cas complexes impliquant plusieurs segments du réseau. A. Aljohani et al. [43] ont développé un localisateur intelligent de défaut monophasé à la terre pour les réseaux de distribution, tandis que I. Sadinezhad et al. [44] ont intégré des ANN avec la logique

floue pour améliorer la protection des lignes. Toutefois, ces approches sont souvent statiques, exécutées hors ligne, et limitées à des défauts élémentaires.

Dans l'ensemble, la majorité des travaux existants dans la littérature se focalisent sur des environnements simplifiés avec une seule ligne de défaut et n'intègrent pas les contraintes de traitement en temps réel ni les scénarios complexes à défauts multiples. Ce constat met en évidence la nécessité d'une approche plus globale et dynamique, capable de traiter la détection, la classification et la localisation des défauts en temps réel dans des réseaux maillés, avec la prise en compte de défauts simples, hybrides et triples. Dans ce travail nous utiliserons les algorithmes d'apprentissage automatique plus précisément l'auto-encodeur LSTM, les réseaux de neurone et la méthode de triangulation pour l'analyse des défauts en temps réel dans les réseaux électriques maillé. La figure 1.1 montre la procédure suivie pour l'analyse des défauts dans les réseaux électriques.




Figure 1. 1: Procédure suivie pour analyser les défauts

1.2 Problématique

Dans les réseaux électriques fortement maillés, les défauts de court-circuit représentent un risque majeur pour la stabilité et l'intégrité du système. En raison de la topologie dense et de l'interconnexion étroite entre les lignes, un défaut peut apparaître simultanément sur une ou plusieurs lignes, compliquant considérablement sa détection et son traitement. Ce type d'architecture favorise la propagation rapide des perturbations, si bien qu'un défaut non détecté à temps peut se répercuter sur d'autres parties du réseau et entraîner des dysfonctionnements généralisés [45]

L'analyse en temps réel de ces défauts constitue un défi important, car elle nécessite de traiter de grandes quantités de données instantanément tout en fournissant une réponse rapide. Les méthodes traditionnelles, souvent fondées sur l'exploitation de données historiques ou statiques, ne sont généralement pas conçues pour gérer l'apparition simultanée de défauts sur plusieurs lignes [46, 47]. Cela limite leur capacité à assurer une détection, une localisation et une classification fiables dans des conditions critiques.

Face à ces limites, les approches basées sur l'apprentissage automatique et l'apprentissage profond suscitent un intérêt croissant. Toutefois, la plupart des travaux existants se concentrent sur des modèles entraînés hors ligne, qui ne tiennent pas compte des variations réelles du réseau au moment de la survenue des défauts [48, 49]. Ces modèles n'intègrent pas la capacité d'adaptation requise pour opérer efficacement en temps réel, notamment dans les contextes où plusieurs lignes sont affectées simultanément. Cela souligne la nécessité de concevoir des solutions capables de réagir immédiatement à l'apparition de défauts multiples afin d'en minimiser l'impact et de protéger l'ensemble du réseau contre les effets en cascade[50-52].

1.3 Originalités

Notre contribution a porté sur les éléments suivants :

- La réduction du temps de réponse à l'organe de coupure (inférieur à 10 ms) pour l'analyse des défauts de courts-circuits en temps réel. Contrairement aux organes de coupure existants, dont le temps de réaction peut être limité par des délais de détection et de prise de décision.
- Détection, localisation et classification des défauts en temps réel
- Proposer une approche simple de triangulation pour la localisation des défauts de court-circuit dans les réseaux électrique
- Amélioration des résultats de détection des défauts de court-circuit existant dans la littérature
- Détection des défauts de court-circuit dans deux lignes simultanément
- Détection des défauts de court-circuit dans trois lignes simultanément

1.4 Objectifs

1.4.1 Objectif général

L'objectif général de mon sujet de recherche est de mettre en œuvre une méthode fiable, efficace, simple et rapide pour l'analyse en temps réel des défauts pouvant survenir sur une ou plusieurs lignes simultanément, en particulier des courts-circuits, dans les réseaux électriques maillés.

1.4.2 Objectifs spécifiques

Notre approche vise à améliorer la réactivité du réseau face aux incidents, en assurant une détection, une localisation et une classification précises des défauts, afin de réduire

les temps d'interruption, limiter les dommages et préserver l'intégrité globale de l'infrastructure électrique.

- 1) Détecter et classifier en temps réel les défauts de court-circuit qui apparaissent de façons simultanées sur une, deux et trois lignes de transmission avec l'algorithme auto-encodeur LSTM
- 2) Localiser en temps réel les défauts de court-circuit qui apparaissent de façons simultanées sur une, deux et trois lignes de transmission avec les réseaux de neurone profond
- 3) Localiser en temps réel les défauts de court-circuit qui apparaissent de façons simultanées dans les lignes de transmission par la méthode de triangulation

1.5 Hypothèses de recherche

- Le réseau serait supposé stable et équilibré avant l'apparition de tout défaut.
- On considère que les défauts de court-circuit se produisent uniquement sur les lignes de transmission de notre réseau électrique maillé.
- Seuls les défauts de court-circuit seraient pris en compte dans le cadre de cette étude, excluant les autres types de défaillances.
- L'analyse se baserait exclusivement sur les grandeurs électriques mesurées, notamment les tensions et courants triphasés.

1.6 Méthodologie de recherche

Pour atteindre les objectifs de mes recherches, j'ai tout d'abord réalisé une revue de littérature en m'appuyant sur des actes de conférences, des articles scientifiques et d'autres sources internet afin de cadrer et souligner l'originalité de notre travail. J'ai identifié les algorithmes d'apprentissage profond les plus prometteurs pour la détection, la classification et la localisation des défauts. Ensuite, j'ai élaboré une base de données

des contingences de défauts, effectué des simulations de ces défauts dans notre réseau test qui est un système électrique IEEE 9-bus à l'aide du logiciel Matlab/Simulink.

- Effectuer une revue de la littérature.
- Etablir la base de données de contingences des différents défauts.
- Implémenter le modèle de réseau électrique maillée (IEEE-9Bus) dans la plateforme Matlab/Simulink
- Simuler différent type de défaut de court-circuit dans le réseau test

1.7 Conclusion

Ce chapitre a présenté une introduction générale de notre sujet de recherche en exposant la problématique liée aux défauts de court-circuit dans les réseaux électriques maillés, les objectifs visés ainsi que la méthodologie adoptée. Il a également permis de formuler les hypothèses de base sur lesquelles repose notre étude.

CHAPITRE 2 : REVUE DE LITTÉRATURE

Ce chapitre présente une revue de littérature centrée sur les réseaux électriques et les défauts de court-circuit qui peuvent les affecter. Il débute par une description de la structure générale des réseaux électriques et de leur topologie, en particulier celle des réseaux maillés. Ensuite, les différents types de défauts de court-circuit sont présentés, suivis d'un état de l'art sur les méthodes de détection, de classification et de localisation de ces défauts, telles qu'elles sont abordées dans la littérature scientifique.

2.1 Structure des réseaux électriques

Un réseau électrique est un ensemble d'infrastructures permettant d'acheminer l'énergie électrique des centres de production vers les consommateurs d'électricité. Il est constitué des lignes électriques exploitées à différents niveaux de tension, connectées entre elles dans des postes électriques. Les postes électriques permettent de répartir l'électricité et de la faire passer d'une tension à l'autre grâce aux transformateurs. Un réseau électrique doit aussi assurer la gestion dynamique de l'ensemble production-transport-consommation, mettant en œuvre des réglages ayant pour but d'assurer la stabilité de l'ensemble.

La distinction des différents sous-systèmes d'un réseau électrique se base, d'une part, sur

la différence de niveaux de tension et, d'autre part, sur les fonctions que chacun doit assumer [16, 53]

2.1.1 La production

La production d'énergie électrique constitue la première étape du processus d'acheminement de l'électricité vers les consommateurs. Elle repose essentiellement sur le principe de la conversion de l'énergie primaire en énergie électrique, à travers des procédés thermiques, mécaniques ou électromagnétiques.

Les sources primaires utilisées pour cette transformation peuvent être classées en deux grandes catégories selon leur origine :

➤ Les sources d'origine fossile :

Il s'agit des sources non renouvelables telles que le charbon, le gaz naturel et le fioul. Ces sources sont historiquement les plus utilisées dans les grandes centrales thermiques. Le fonctionnement de ces centrales repose sur la combustion de ces combustibles pour produire de la chaleur, qui est ensuite utilisée pour chauffer de l'eau et générer de la vapeur sous pression. Cette vapeur fait tourner des turbines couplées à des alternateurs synchrones de grande puissance, qui produisent alors l'énergie électrique. Ce processus est très répandu dans les centrales nucléaires (fission de l'uranium), à charbon ou à gaz [16, 54, 55]

➤ Les sources d'origine renouvelable :

Elles comprennent notamment l'énergie hydraulique (mouvements de l'eau), l'énergie éolienne (vent), et dans certains cas, l'énergie solaire. Par exemple, les centrales hydrauliques utilisent la force motrice de l'eau (barrages, chutes) pour entraîner directement une turbine hydraulique reliée à un alternateur. De même, les éoliennes convertissent l'énergie cinétique du vent en énergie mécanique puis électrique à l'aide de génératrices [16, 54, 55]

La principale caractéristique de l'électricité est qu'elle ne se stocke pas facilement à grande échelle. Il devient donc indispensable que la production soit en permanence équilibrée avec la consommation. Cet équilibre en temps réel est assuré par la

coordination entre les systèmes de production, de transport et de distribution, pilotée par des centres de dispatching.

Les grandes centrales de production sont généralement situées loin des zones urbaines, pour des raisons d'espace, de sécurité, ou de disponibilité des ressources primaires. L'énergie produite est alors transmise vers le réseau de transport à très haute tension (THT) à travers des transformateurs élévateurs de tension, assurant ainsi une première étape critique dans la chaîne de l'énergie électrique [16, 54, 55]

2.1.2 Le transport

Après sa production dans les centrales, l'énergie électrique est acheminée sur de longues distances vers les zones de consommation à travers le réseau de transport. Cette étape est essentielle pour minimiser les pertes énergétiques, assurer la stabilité du réseau, et relier efficacement les différents centres de production et de consommation.

➤ Fonction du réseau de transport

Le réseau de transport a pour principale mission de transmettre l'énergie produite vers les postes de répartition, en traversant parfois des centaines de kilomètres. Il fonctionne à des niveaux de tension très élevés généralement entre 220 kV et 800 kV, voire plus pour réduire les pertes par effet Joule (qui sont proportionnelles au carré du courant). Pour cela, l'électricité est élevée en tension par des transformateurs élévateurs à la sortie des centrales de production[2, 16, 56].

Ce réseau est composé principalement : de lignes à très haute tension (THT) aériennes ou souterraines, de postes de transformation, de disjoncteurs haute tension pour assurer la sécurité, et de systèmes de contrôle pour la gestion en temps réel des flux.

➤ Interconnexion des réseaux

Le réseau de transport est fortement interconnecté, non seulement à l'intérieur d'un pays mais aussi avec les réseaux des pays voisins (interconnexion transfrontalière) [2,

56]. Cette interconnexion permet d'assurer une sécurité d'approvisionnement en cas de défaillance locale, de faciliter les échanges d'électricité entre régions ou pays, et de mutualiser les réserves de production en temps réel.

2.1.3 La répartition

La répartition constitue une étape intermédiaire essentielle entre le transport à très haute tension (THT) et la distribution finale de l'électricité aux consommateurs. Son rôle principal est d'assurer une descente progressive du niveau de tension pour adapter l'énergie transportée aux besoins des utilisateurs tout en maintenant une efficacité maximale.

Le réseau de répartition moyenne tension (MT) a pour mission de recevoir l'énergie électrique à partir du réseau de transport, généralement via des postes sources ou postes de transformation THT/HT, puis de la rediriger vers des zones de consommation plus localisées ou vers des utilisateurs industriels de grande puissance.

Les tensions utilisées dans les réseaux de répartition sont généralement comprises entre 45 kV et 160 kV, ce qui constitue une gamme de tension intermédiaire entre la THT (220 kV–800 kV) du transport et la HT/MT de la distribution. Ces niveaux de tension permettent de minimiser les pertes énergétiques à l'échelle régionale, éviter les surtensions locales, et préparer l'électricité pour la distribution finale [2].

2.1.4 La distribution

La distribution constitue l'ultime maillon du système électrique, chargé d'acheminer l'énergie depuis les postes de répartition jusqu'aux utilisateurs finaux. Elle intervient après l'abaissement de la tension par les transformateurs de répartition, et se fait à différents niveaux de tension selon la nature des consommateurs.

➤ Distribution en Haute Tension (HT)

La distribution en haute tension concerne principalement les grands consommateurs industriels, les infrastructures critiques comme les usines de grande capacité, les centres logistiques, ou encore les lignes ferroviaires à grande vitesse (TGV). Elle s'effectue généralement à des niveaux de tension compris entre 60 kV et 150 kV.

Ces clients sont généralement directement raccordés à des postes HT, et disposent d'équipements spécialisés pour adapter l'énergie à leurs besoins internes (transformateurs, cellules HT, protections, etc.). Leur consommation est constante, importante, et souvent répartie sur de longues plages horaires.

➤ Distribution en Moyenne Tension (MT)

Le niveau de distribution moyenne tension, souvent compris entre 1 kV et 36 kV, dessert les moyennes industries, les entreprises régionales, ainsi que certaines zones urbaines denses. À ce niveau, l'électricité est délivrée à des postes de transformation locaux, qui abaissent encore la tension avant qu'elle ne soit utilisée.

Les lignes de distribution MT peuvent être aériennes ou souterraines selon la densité urbaine, les contraintes environnementales ou les politiques d'aménagement. Ce réseau est organisé de façon radiale, arborescente ou maillée partiellement, et peut inclure des équipements tels que transformateurs MT/BT, tableaux de distribution moyenne tension, dispositifs de commutation ou de sectionnement.

➤ Distribution en Basse Tension (BT)

La basse tension, généralement de 230/400 V, est le niveau auquel l'énergie est directement livrée aux consommateurs résidentiels, petits commerces, fermes, et zones rurales. C'est le niveau de tension utilisé dans les foyers pour alimenter les équipements domestiques, les systèmes d'éclairage, et les petits appareils industriels.

Le réseau BT est fortement ramifié et local, composé principalement de lignes aériennes ou câbles souterrains BT, armoires de distribution, compteurs électriques.




Figure 2. 1: Organisation du transport de l'énergie électrique [2].

2.2 Topologie des réseaux électriques

La topologie des réseaux électriques diffère d'un type de réseau à un autre et elle est conditionnée par le niveau de fiabilité, de maintenance et du coût d'investissement. On distingue généralement quatre types de topologies de réseaux : le réseau maillé, le réseau bouclé, le réseau radial et le réseau arborescent. Ces topologies sont illustrées dans la figure 2.2




Figure 2. 2: Les topologies des réseaux électriques : (a) Réseau maillé (b) Réseau bouclé (c) Réseau radiale (d) Réseau arborescent

▪ Réseau maillé

D'une façon générale, les réseaux de transport ont une topologie maillée. Cette topologie offre une meilleure fiabilité et une grande stabilité. Cependant, elle nécessite un système de surveillance complexe, à l'échelle nationale, voire continentale [2, 16]. les postes électriques sont reliés entre eux par de nombreuses lignes électriques, apportant une grande sécurité d'alimentation.

▪ Réseau bouclé

Les réseaux de répartition et les réseaux de distribution ont généralement une structure bouclée. En effet, dans le but d'augmenter la disponibilité, les postes de répartition sont alimentés par le réseau HTB et ils sont reliés entre eux sous forme de boucles. Cependant, les réseaux de moyennes tensions ne sont pas forcément bouclés [2, 16]

- **Réseau radial**

Cette structure est considérée la plus simple et elle est utilisée généralement dans les réseaux de distribution HTA et BT. Elle se compose d'une ligne alimentée par des postes de distribution HTA ou BT. Ces derniers sont alimentés au départ par un poste source HTB ou HTA. En moyenne tension et dans le but d'assurer une meilleure disponibilité, cette structure est souvent alimentée des deux côtés [2, 16]

- **Réseau arborescent**

Cette structure est très utilisée en milieu rural et quelquefois en milieu urbain où la charge n'est pas trop affectée par les interruptions. Elle est constituée d'un poste de répartition alimentant plusieurs postes de distribution (BT) grâce à des piquages à différents niveaux des lignes qui alimentent les postes HTA/BT [2, 16]

2.3 Les différents défaut dans les réseaux électriques

Les réseaux de distributions d'énergie électrique peuvent être le siège d'un certain nombre d'incidents qui sont dus, en générale, à l'apparition de défaut. Ces défauts donnent lieu à l'établissement de courant de court-circuit, soit entre conducteurs, soit entre un ou plusieurs conducteurs et le sol. Un défaut est caractérisé par un phénomène non conforme au fonctionnement normal du réseau et pouvant, dans certain cas, conduire à un effondrement électrique de celui-ci et à la mise en danger de son environnement [57].

2.3.1 Origines des défauts

Les réseaux de distribution moyenne tension (HTA) sont régulièrement confrontés à divers types de défauts pouvant affecter aussi bien les infrastructures aériennes que

souterraines. Ces défauts peuvent résulter de causes électriques, atmosphériques ou humaines, avec une prédominance des défaillances liées aux phénomènes électriques. Les équipements présents sur le réseau, notamment dans les postes de transformation, contiennent des matériaux isolants (solides, liquides ou gazeux) placés entre les parties actives (sous tension) et la masse. Avec le temps, ces isolants peuvent se détériorer, entraînant une dégradation de l'isolation qui se manifeste généralement sous forme de courts-circuits. De plus, les types de défauts rencontrés varient en fonction de la nature du réseau, qu'il soit urbain ou rural [16, 21, 58-60].

➤ Réseaux aériens

Les lignes aériennes sont particulièrement exposées aux agressions climatiques en raison de leur élévation et de l'espacement entre les conducteurs. Elles sont sensibles aux intempéries telles que la foudre, les tempêtes, ou encore le verglas. Dans certaines zones géographiques, comme les régions montagneuses, la foudre représente une cause dominante, responsable de 60 à 80 % des défauts, selon le niveau de tension du réseau[57, 61]

➤ Réseaux souterrains

En étant enfouis, les câbles souterrains sont protégés des conditions climatiques, mais ils sont en revanche vulnérables aux agressions mécaniques, notamment celles causées par les engins de terrassement lors de travaux publics. Ce type d'agression aboutit généralement à des défauts permanents, souvent coûteux à localiser et à réparer en raison de l'inaccessibilité du câblage[57, 61].

➤ Dégradations internes des équipements

Les composants des réseaux électriques, qu'ils soient installés en poste ou sur les lignes, peuvent également présenter des défaillances internes, liées à l'évolution naturelle des matériaux isolants qu'ils contiennent. Ces défaillances entraînent des défauts d'isolement, pouvant se traduire par des phénomènes de surtension, de

surintensité, ou encore de résonance, parfois sans intervention extérieure apparente[57, 62].

Ces défauts peuvent être regroupés en deux grandes catégories : les défauts d'origine externe et ceux d'origine interne. Les défauts d'origine externe sont les défauts mécaniques qui comprennent par exemple la rupture d'un conducteur, d'un isolateur ou d'un support, ainsi que les amorçages causés par le contact d'éléments extérieurs comme des branches d'arbres, des oiseaux, ou des objets volants, les défauts atmosphériques qui sont principalement dus à la foudre qui peut frapper directement une ligne ou un poste, ou encore aux dépôts conducteurs sur les isolateurs entraînant des amorçages. Les défauts d'origine interne qui prennent naissance à l'intérieur même du système, sans cause externe immédiate. Ils peuvent résulter de surtensions, courants de surcharge, courts-circuits internes ou de phénomènes transitoires liés à l'ouverture de circuits en charge. Ces phénomènes altèrent la stabilité du système et peuvent engendrer des dommages sévères[57, 63].

La plupart des défauts se produisent sur les lignes de transmission, notamment sur les lignes aériennes, qui constituent l'un des éléments les plus exposés du système. Ces lignes, chargées de transporter l'énergie à grande échelle entre les centres de production et les centres de consommation, sont soumises à un environnement ouvert, ce qui les rend plus vulnérables aux défaillances climatiques et mécaniques. En conséquence, une grande partie des travaux de recherche et des efforts en ingénierie se concentre sur la protection de ces lignes et sur le développement de techniques fiables de localisation des défauts[64-68].

2.3.2 Les formes de défauts dans les réseaux électriques

- Les défauts de court-circuit

Les défauts de court-circuit dans les réseaux électriques sont parmi les incidents les plus critiques, car ils génèrent des courants de forte intensité susceptibles de détériorer

gravement les équipements s'ils ne sont pas traités rapidement. Ils peuvent être classés selon leur configuration, leur durée, et leur symétrie [16, 21, 69].

➤ Classification selon la configuration des phases impliquées

Les défauts de court-circuit peuvent être catégorisés selon les phases touchées :

- Défaut monophasé à la terre (L-G) : une seule phase entre accidentellement en contact avec la terre ou avec une masse métallique. C'est le défaut le plus courant dans les réseaux moyenne tension.
- Défaut biphasé (L-L) : deux conducteurs de phase entrent en contact l'un avec l'autre sans nécessairement toucher la terre.
- Défaut biphasé à la terre (L-L-G) : deux phases sont court-circuitées entre elles et connectées à la terre.
- Défaut triphasé (L-L-L) : les trois phases sont court-circuitées entre elles, sans mise à la terre.
- Défaut triphasé à la terre (L-L-L-G) : les trois phases sont en court-circuit avec la terre.

Les défauts biphasés et triphasés sont globalement désignés comme des défauts polyphasés [60, 61].

➤ Classification selon la durée

La durée du défaut influe directement sur ses conséquences. On distingue :

- Défaut permanent : Il subsiste tant que l'alimentation n'est pas interrompue. Il est généralement causé par une dégradation irréversible de l'isolation (ex. : câble endommagé, isolant brûlé), souvent rencontré dans les réseaux souterrains où les isolants sont solides.
- Défaut fugitif : Il disparaît spontanément dès la coupure de l'alimentation, typiquement en raison de l'extinction de l'arc électrique. Ce phénomène est plus fréquent dans les réseaux aériens, où les isolants sont principalement gazeux.

- Défaut intermittent : Il apparaît et disparaît de manière répétée dans de courts intervalles. Cela peut être causé, par exemple, par le balancement de conducteurs, ou le contact épisodique de branches d'arbres en cas de vent fort.
- Défaut semi-permanent : Il persiste pendant une certaine durée avant de disparaître avec la cause (ex. : accumulation d'humidité sur les isolateurs).
- Défaut auto-extincteur : Il disparaît de lui-même sans intervention humaine, souvent rencontré dans les réseaux HTA lors de défauts monophasés

➤ Classification selon la symétrie du défaut

Les défauts peuvent être symétriques ou asymétriques, selon leur impact sur l'équilibre des trois phases du système :

- Défauts symétriques : Ils affectent les trois phases de manière identique. Par exemple, un défaut triphasé (L-L-L) ou triphasé à la terre (L-L-L-G) donne naissance à des courants symétriques déphasés de 120° les uns par rapport aux autres. Bien que rares (environ 2 à 5 % des cas), ces défauts sont les plus sévères, car ils provoquent des courants très élevés et imposent des contraintes mécaniques importantes aux équipements. Leur analyse se fait souvent à l'aide du théorème de Thévenin ou de la matrice d'impédance nodale [21, 70, 71].
- Défauts asymétriques : Ce sont les plus fréquents dans la pratique. Ils impliquent une ou deux phases et provoquent un déséquilibre dans le système. Ils engendrent des courants de défaut de valeurs et phases inégales. Les défauts monophasés, biphasés et biphasés à la terre en font partie. L'étude de ces défauts repose sur l'analyse par composantes symétriques, une méthode introduite par Fortescue, permettant d'analyser chaque composante (positive, négative et homopolaire) séparément [21, 70, 71].

- Les défauts de circuit ouvert (défauts en série)

Bien que moins souvent évoqués, les défauts de circuit ouvert ou défauts en série sont également importants. Ils surviennent lors de la rupture d'un ou plusieurs conducteurs,

d'un fusible fondu, ou d'un disjoncteur défaillant. Ces défauts entraînent un déséquilibre de charge, des surtensions transitoires, et des effets mécaniques sur les alternateurs, pouvant même accélérer la machine en cas de perte de charge sur une phase. Ils doivent donc être correctement détectés pour éviter la propagation du défaut sur d'autres lignes [72].

2.4 Technique de détection et classification des défauts dans les réseaux électriques

2.4.1 Technique de détection des défauts

La détection des défauts constitue l'une des étapes fondamentales pour garantir la stabilité, la sécurité et la fiabilité des réseaux électriques. Elle consiste à identifier rapidement toute perturbation anormale dans les grandeurs électriques caractéristiques du réseau, telles que le courant, la tension, ou leurs dérivées. La capacité à détecter un défaut à un stade précoce permet de limiter les dommages aux équipements, de réduire les pertes économiques et d'éviter la propagation du dysfonctionnement à d'autres parties du système.

Dans la littérature, différentes méthodes de détection ont été développées, reposant principalement sur l'analyse des signaux électriques. Ces techniques s'appuient généralement sur le franchissement d'un seuil prédéfini ou sur l'observation d'un comportement dynamique anormal. Selon le paramètre utilisé, on distingue plusieurs approches.

➤ Surveiller les courants de phase

Lorsqu'un court-circuit survient, le courant de phase augmente brusquement. Cette variation soudaine est utilisée comme indicateur de défaut. La détection se fait en

comparant le courant mesuré à une valeur seuil : si le dépassement est confirmé durant un intervalle de temps significatif, le défaut est identifié. Cette méthode est largement utilisée pour les défauts monophasés, biphasés et triphasés, en particulier dans les réseaux à neutre impédance ou solidement mis à la terre [16, 73, 74].

➤ Tension et courant résiduels

La somme vectorielle des trois phases (appelée tension ou courant résiduel) est en principe nulle en fonctionnement normal. Lorsqu'un défaut à la terre apparaît, cette somme devient non nulle. En surveillant ces composantes, il est possible de détecter non seulement les défauts permanents mais aussi des défauts transitoires, par exemple causés par la foudre ou des objets tombant sur la ligne. Cette méthode est particulièrement efficace dans les réseaux moyenne tension (HTA)[75-77].

➤ Analyse des harmoniques

Certaines techniques exploitent la présence d'harmoniques spécifiques, notamment le cinquième harmonique produit par les non-linéarités des transformateurs. Dans un système sain, les harmoniques s'annulent entre phases. En revanche, en présence d'un défaut, une asymétrie dans la répartition des harmoniques est observable. Ce déséquilibre est analysé pour détecter et localiser le défaut. Bien que performante, cette approche dépend fortement du niveau d'harmonique présent, qui peut être faible dans les réseaux bien filtrés [78, 79].

➤ Écarts tension/courant par rapport à la normale

Une autre méthode très répandue consiste à comparer les valeurs mesurées de tension et de courant triphasés avec les valeurs nominales attendues. Toute déviation significative est interprétée comme un signal d'alerte. Cette technique reste largement utilisée dans les systèmes de supervision modernes grâce à sa simplicité de mise en œuvre et à son efficacité pour tous les types de défauts (monophasé, biphasé, triphasé) [80, 81].

2.4.2 Technique de classification des défauts

Dans les réseaux électriques, la classification des défauts représente une étape essentielle pour le bon fonctionnement des systèmes de supervision et de protection. Après la détection d'un événement anormal, il est crucial d'en identifier précisément la nature, notamment s'il s'agit d'un défaut monophasé, biphasé, triphasé, avec ou sans mise à la terre. La classification permet ainsi de déterminer rapidement le type d'intervention à engager et d'optimiser la réponse du système.

Chaque type de défaut génère une signature distincte dans les signaux de courant et de tension. Ces variations caractéristiques, souvent transitoires et de très courte durée, servent de base pour la reconnaissance automatique à l'aide d'algorithmes de classification. Selon [74], la classification précise permet de réduire considérablement le temps de localisation du défaut, d'éviter des coupures prolongées et de limiter les risques de propagation.

Traditionnellement, les premières méthodes reposaient sur des approches déterministes utilisant des seuils fixes appliqués aux courants et aux tensions mesurées (méthodes à base de règles). Toutefois, ces techniques, bien qu'efficaces dans des réseaux simples, deviennent moins fiables dans les réseaux modernes à topologies complexes. Pour pallier cela, les chercheurs se sont tournés vers des modèles basés sur l'apprentissage automatique, capables d'adapter leur comportement à partir des données.

Parmi les plus populaires, les réseaux de neurones artificiels (ANN) ont été largement utilisés. Par exemple, dans l'étude de [82], un réseau de neurones multicouches a permis d'atteindre une précision de plus de 98 % pour la classification de défauts dans des lignes de transmission. De même, les machines à vecteurs de support (SVM), comme présentées par [83], ont montré une forte capacité à distinguer les défauts en présence de bruit et d'incertitudes.

Ces dernières années, les réseaux de neurones profonds (DNN) et les modèles de deep learning tels que les réseaux convolutifs (CNN) ou récurrents (LSTM) ont été appliqués

avec succès à la classification automatique. [84] a proposé un modèle LSTM pour classifier les types de défauts dans un réseau de distribution, atteignant un taux de reconnaissance de plus de 99 %. Ce type d'approche présente l'avantage de ne pas nécessiter une extraction manuelle des caractéristiques, contrairement aux méthodes plus anciennes.

Par ailleurs, des approches hybrides, combinant l'analyse fréquentielle (par exemple les transformées en ondelettes) avec des classificateurs intelligents, sont également explorées. L'étude de [85] a démontré que l'utilisation conjointe d'un prétraitement par ondelettes et d'un classificateur SVM permet d'améliorer la robustesse de la classification, notamment pour les défauts transitoires. [86] a proposé un modèle basé sur un réseau LSTM combiné avec une attention temporelle, permettant d'identifier à la fois le type de défaut et son instant précis d'apparition dans des conditions proches du temps réel. Ces travaux s'inscrivent dans la tendance actuelle qui vise à intégrer des outils issus de l'intelligence artificielle dans des environnements de surveillance dynamique.

2.5 Technique de localisation des défauts dans les réseaux électriques

La localisation précise des défauts dans les lignes de transmission permet de réparer rapidement les lignes endommagées et de réduire les interruptions de service. Plusieurs méthodes sont proposées dans la littérature, que l'on peut organiser en plusieurs catégories :

2.5.1 La méthodes d'impédance

Les techniques basées sur l'impédance estiment la distance du défaut en mesurant la tension et le courant à une ou deux extrémités de la ligne. Les méthodes monopoints

utilisent uniquement des mesures locales, reposant souvent sur l'idée que l'impédance apparente atteint une valeur proportionnelle à la distance du défaut. Elles sont simples à mettre en œuvre car elles ne nécessitent pas de communication entre les deux extrémités, mais leur précision décroît en présence de forte impédance du défaut, de couplage mutuel, ou de variations de charge. Les méthodes bipoint synchronisent les mesures des deux terminaux par GPS ; elles compensent les erreurs liées à la source et à la charge, et offrent une meilleure précision.

➤ La méthode à une extrémité :

Elle repose sur l'utilisation des grandeurs électriques mesurées au niveau d'un seul poste de la ligne (tension et courant triphasés) au moment du défaut. Un exemple de schéma unifilaire et la représentation de défauts dans la ligne sont présentés dans la figure 2.3. Le calcul de l'impédance apparente permet alors d'estimer la position du défaut par une simple règle de proportion. Ce type de méthode est largement utilisé pour sa facilité d'implémentation dans les réseaux à moyenne et haute tension. Cependant, elle est très sensible aux effets de l'arc de défaut, aux charges asymétriques et à la non-uniformité de la ligne. Des techniques complémentaires, comme l'analyse des composantes symétriques, sont parfois introduites pour améliorer la fiabilité de l'estimation [3, 21, 87].




Figure 2. 3: Schéma unifilaire et représentation du circuit de défaut de ligne [3]

➤ La méthode à deux extrémités :

Elle tire profit des mesures synchronisées de tension et de courant capturées simultanément aux deux extrémités de la ligne. Grâce à la synchronisation par GPS, cette approche permet de calculer la distance du défaut en éliminant les incertitudes dues aux charges, à la source

et aux paramètres de ligne variables. Elle repose sur une modélisation plus complète de la ligne et offre une précision nettement supérieure, ce qui en fait une solution idéale pour les lignes de transmission longue distance à haute tension. Toutefois, elle nécessite un investissement important en infrastructures (unité de mesure phaseur PMU, système de positionnement globale GPS, liaisons de communication fiables), ce qui limite son usage dans certains réseaux secondaires [3, 21, 87].




Figure 2. 4: Schéma de la localisation synchronisée des défauts aux deux extrémités avec utilisation du GPS [3]

2.5.2 Techniques transitoires à ondes voyageuses

Lorsqu'un défaut survient, des ondes transitoires électromagnétiques se propagent dans les deux directions. Les méthodes appelées Traveling-Wave Based Methods utilisent la différence de temps d'arrivée de ces ondes pour estimer la distance du défaut avec une très grande précision, souvent $< 1 \%$ de la longueur de la ligne. Elles nécessitent

des capteurs haute fréquence et une synchronisation millimétrée des horloges, ce qui rend la mise en œuvre plus complexe et coûteuse [4].




Figure 2. 5: Illustration de la méthode Traveling-Waves [4]

2.5.3 La logique floue

La logique floue est constituée d'un moteur d'inférences linguistiques de haut niveau tolérant aux incertitudes présentes dans un système. Elle utilise des relations simples basées sur l'expérience pour la prise de décision sur un événement. Elle a aussi une capacité inhérente à traiter des données imprécises les rendant ainsi adaptées au diagnostic des pannes. Cependant, elle est dépourvue de capacités d'apprentissage [88, 89]

2.5.4 La triangulation

La triangulation est une méthode permettant de déterminer la position d'un point en mesurant ses distances ou angles par rapport à au moins deux ou trois points de référence connus. Initialement développée dans le domaine des télécommunications pour localiser des appareils mobiles en analysant les signaux reçus par plusieurs antennes relais, cette

technique a progressivement été adaptée à d'autres domaines, notamment la localisation des défauts dans les réseaux électriques.

2.5.5 Méthodes basées sur l'intelligence artificielle IA

L'intelligence artificielle (IA) constitue un domaine de recherche qui vise à reproduire, par des moyens informatiques, certaines fonctions cognitives humaines comme l'apprentissage, la prise de décision, la reconnaissance de formes ou encore l'adaptation à des situations complexes. Contrairement aux approches classiques basées uniquement sur des équations déterministes, les techniques issues de l'IA permettent d'intégrer la capacité à traiter des données bruitées, incomplètes ou non linéaires, tout en s'adaptant aux conditions évolutives des réseaux électriques [21, 90]. En matière de localisation de défauts, les méthodes basées sur l'IA présentent un avantage important : elles permettent une meilleure précision, une réponse plus rapide et une robustesse face aux incertitudes et aux variations topologiques du réseau[22, 91]. Parmi les familles d'approches les plus utilisées, on retrouve les réseaux de neurones artificiels (ANN), les systèmes à logique floue, ainsi que les modèles neuro-flous hybrides (ANFIS)[21].

Les ANNs sont largement exploités pour leur capacité d'apprentissage supervisé à partir de données historiques de défauts. Ils sont capables d'identifier et de généraliser des motifs complexes entre les signaux mesurés et la position du défaut, même en présence de bruit ou de fluctuations de charge. Leur tolérance aux perturbations et leur adaptabilité en font une solution efficace pour les lignes à haute variabilité [42, 62, 92]. Par ailleurs, les systèmes à logique floue permettent de gérer les imprécisions dans les mesures et les conditions limites grâce à un raisonnement basé sur des règles linguistiques, ce qui est particulièrement pertinent pour les réseaux où les seuils classiques ne suffisent pas à discriminer un défaut réel d'un événement transitoire[93]. Les approches ANFIS combinent les avantages des réseaux de neurones (capacité

d'apprentissage) et de la logique floue (raisonnement incertain), ce qui permet une modélisation plus flexible du comportement du système en défaut. Ces systèmes hybrides apprennent automatiquement les règles floues à partir de données d'entrée/sortie, ce qui les rend particulièrement efficaces dans des environnements complexes et dynamiques[94-97].

2.6 Conclusion

Ce chapitre a permis d'explorer en profondeur les caractéristiques structurelles des réseaux électriques, les formes de défauts pouvant survenir dans les lignes de transmission, ainsi que leurs origines et leurs classifications. Une attention particulière a été portée aux défauts de court-circuit, qui constituent les perturbations les plus fréquentes et les plus critiques dans les réseaux électriques maillés. Les différentes approches de détection, de classification et de localisation des défauts ont été passées en revue à travers une analyse critique de la littérature existante. Il ressort que, malgré l'efficacité des méthodes conventionnelles basées sur les mesures d'impédance ou les signaux transitoires, les approches modernes basées sur l'intelligence artificielle (telles que les réseaux de neurones et les systèmes neuro-flous) offrent des performances supérieures en termes de précision, de rapidité et de robustesse face à la complexité croissante des réseaux électriques actuels. Ces avancées technologiques ouvrent de nouvelles perspectives pour le développement de systèmes de protection intelligents, capables de réagir dynamiquement aux défauts en minimisant les interruptions et les dommages. Le prochain chapitre sera consacré à la proposition méthodologique de cette recherche, en mettant en œuvre une approche intelligente pour la détection et la classification en temps réel des défauts dans un réseau électrique maillé.

CHAPITRE 3 : DÉTECTION ET CLASSIFICATION EN TEMPS RÉEL DES COURTS CIRCUITS À PARTI DE L'AUTO-ENCODEUR LSTM

Dans les réseaux électriques fortement maillés, la détection rapide et la classification précise des défauts de court-circuit constituent des enjeux cruciaux pour assurer la stabilité, la continuité de service et la protection des équipements. Ces défauts, souvent imprévisibles et pouvant survenir simultanément sur plusieurs lignes, exigent une réponse en temps réel. Face aux limites des approches traditionnelles, notamment en matière d'adaptation aux données dynamiques et bruitées, les techniques d'apprentissage profond offrent une alternative prometteuse. Ce chapitre présente une méthode basée sur l'auto-encodeur Long Short-Term Memory (LSTM) pour la détection et la classification des défauts de court-circuit en temps réel. L'objectif est d'exploiter la capacité du LSTM à apprendre les représentations temporelles complexes des signaux électriques afin d'identifier de manière autonome les comportements anormaux.

3.1 Présentation du système électrique d'études

Le réseau-test IEEE 9-bus constitue un système électrique maillé de transport simplifié, couramment utilisé pour valider des méthodologies de détection, de localisation et de classification des défauts. Il comprend trois sources de production, neuf jeux de barres, trois générateurs, trois transformateurs, trois charges, de douze disjoncteurs placés à l'extrémité de chaque ligne et de six lignes de transmission interconnectées modélisée en Π (Pi). Ce réseau permet d'analyser le comportement du système lors de perturbations et de tester des algorithmes de protection dans un environnement

représentatif mais gérable. Dans le cadre de cette étude, le réseau IEEE 9-bus a été modélisé à l'aide de la boîte à outils *SimPowerSystems* de MATLAB/Simulink comme montre la figure 3.1. La représentation unifilaire du réseau considéré est présentée à la figure 3.3.




Figure 3. 1: Modèle du système électrique test IEEE-9 bus proposé

L'alimentation électrique est générée par les trois sources de tensions triphasées, puis transmise aux charges par l'intermédiaire des lignes de transmission. Les disjoncteurs servent à établir ou interrompre la connexion électrique entre la ligne et le reste du réseau. Cet élément joue un rôle majeur dans la protection des réseaux électriques : il permet, en cas de défaut, d'isoler la partie défectueuse du reste du système électrique afin d'éviter des dommages catastrophiques aux biens matériels et humains. Le bloc « bus » permet de mesurer les valeurs triphasées de courant et de tension aux différents

nœuds du réseau. Les trois générateurs sont configurés en mode « Swing » pour assurer la régulation de l'amplitude et de l'angle de phase de la tension à leurs bornes. Par ailleurs, les transformateurs présents dans le réseau IEEE 9-bus jouent un rôle crucial dans l'adaptation des niveaux de tension entre les différents segments du réseau, permettant ainsi de limiter les pertes d'énergie, d'optimiser le transfert de puissance, et d'assurer la coordination entre les générateurs et les charges.

Le simulateur de défaut triphasé est utilisé pour simuler différents types de défauts à différentes positions le long de la ligne de transmission avec différentes valeurs de résistances de défaut. Un exemple de la ligne 1 de notre réseau électrique est présenté à la figure 3.2 et les paramètres de cette ligne de transmission sont donnés dans le tableau 3.1.




Figure 3. 2:Présentation de la ligne 1 de notre système IEEE-9 bus

Tableau 3. 1: Paramètres du modèle PI de chaque ligne de transmission

Spécifications	Valeurs	Unités
Longueur	La distance est variable (Line 1a et Line 1b) mais la longueur totale de la ligne 1 est de 100	Km
Résistance de séquence positive (Système direct)	0.01273	Ω/km
Résistance de séquence zéro (système homopolaire)	0.3864	Ω/km

Inductance de séquence positive	0.9337e-3	H/km
Inductance homopolaire	4.1264e-3	H/km
Capacitance de séquence positive	12.74e-9	F/km
Capacitance de séquence zéro	7.751e-9	F/km




Figure 3. 3: Le schéma unifilaire du réseau de test IEEE 09-bus [1]

Les caractéristiques du réseau IEEE 09-bus sont présentées dans [1]. Ainsi, les données des générateurs, des transformateurs et des charges sont présentées respectivement dans les tableaux suivants (Tableau 3.2, Tableau 3.3 et Tableau 3.4).

➤ **Données des générateurs**

Les 3 générateurs sont placés au niveau des jeux de barres 1, 2 et 3. Le tableau 3.2 décrit l'emplacement de chaque générateur ainsi que la tension générée. Le réseau fonctionne avec une fréquence de 60 Hz.

Tableau 3. 2: Les données des générateurs du réseau IEEE 09-bus

Générateur	Emplacement	Tension(KV)	Fréquence(Hz)
1	Bus 1	16,5	60
2	Bus 2	18	60
3	Bus 3	13,8	60

➤ **Données des transformateurs**

Le tableau 3.3 présente les caractéristiques des trois transformateurs en termes de tension d'entrée, de tension de sortie, de puissance et de fréquence.

Tableau 3. 3: Les données des transformateurs du réseau IEEE 09-bus

Transformateur	Emplacement	Tension d'entrée/ Tension de sortie (KV)	Puissance apparente nominal (MVA)	Fréquence (Hz)
1	Bus 1	16,5 / 230	100	60
2	Bus 2	18 / 230	100	60
3	Bus 3	13,8 / 230	85	60

➤ **Données des charges**

Le tableau 3.4 présente l'emplacement de chaque charge, sa tension et les puissances active et réactive demandées.

Tableau 3. 4: Les données des charges du réseau IEEE 09-bus

Charge	Emplacement	Tension (KV)	Puissance active (MW)	Puissance réactive (MVAR)	Fréquence (Hz)
1	Bus 5	230	125	50	60
2	Bus 6	230	90	30	60
3	Bus 8	230	100	35	60

3.2 Base de données de contingence

Dans les réseaux électriques maillés comme le réseau IEEE 9-bus utilisé dans cette étude, les défauts peuvent apparaître soudainement sur une ou plusieurs lignes, de manière simultanée ou successive. Cette caractéristique rend leur détection, classification et localisation particulièrement complexe, en raison de la multiplicité des chemins de circulation du courant et de la redondance structurelle du réseau. Pour évaluer les performances de l'auto-encodeur LSTM dans un contexte de diagnostic en temps réel, une base de données de contingence a été construite en simulant un large éventail de scénarios de défauts dans MATLAB/Simulink comme présente le tableau 3.5.

Cette base de données comprend différents types de défauts classés en trois grandes catégories :

- défauts simples (sur une seule ligne),
- défauts hybrides (sur deux lignes),
- défauts triples (affectant trois lignes).

Les défauts simulés incluent les défauts monophasés à la terre (A-G, B-G, C-G), biphasés (AB, BC, AC), biphasés à la terre (AB-G, AC-G, BC-G), ainsi que les défauts triphasés (ABC) ou triphasés à la terre (ABC-G). Cette diversité permet de couvrir un large spectre de situations pouvant survenir dans des conditions réelles.

Le tableau contient aussi les informations suivantes : la ligne de survenue du défaut, le type de défaut, sa résistance (en Ohm), la distance d'apparition du défaut exprimée sous la forme « x-Bn, y-Bm » où x et y représente la distance d'apparition du défaut par rapport au bus Bn ou bus Bm, ainsi que l'identifiant du bloc de défaut. Par exemple, une distance indiquée comme « 20-B7, 80-B8 » à la ligne 1 signifie que le défaut est situé à 20 km du bus 7 et 80 km du bus 8, ces deux bus représentant les extrémités de la ligne concernée. Cette représentation est essentielle pour la localisation du défaut :

en cas de détection, il sera nécessaire de connaître la position exacte du défaut sur la ligne par rapport au bus.

Tableau 3. 5: Base de données de contingence

Nature du défaut	Ligne d'apparition du défaut	Type de défaut	Résistance du défaut (Ohm)	Distance (Km)	Nom du bloc de défaut
Défauts Simple (Sur une seule ligne)		No défaut	//	//	//
	Line 1	A-G	100	20-B7, 80-B8	F1_Line1
		AB-G	80	10-B7, 90-B8	
	Line 2	B-G	70	7-B8, 93-B9	F2_Line2
		AB	0,7	80-B8; 20-B9	
	Line 3	C-G	0,0029	5-B7, 95-B5	F3_Line3
		AC-G	0,023	58-B7, 42-B5	
	Line 4	AC	0,004	83-B6, 17-B9	F4_Line4
		BC-G	0,0059	36-B9, 64-B6	
	Line 5	AB-G	0,0052	28-B5, 72-B4	F5_Line5
		AC-G	0,093	70-B5; 30-B4	
	Line 6	ABC	0,0088	8-B6, 92-B4	F6_Line6
		BC-G	0,069	3-B6, 97-B4	
Défauts hybride (Sur deux lignes)	Line 1 - Line 6	A-G, ABC	0,0012-0,0088	15-B7, 85-B8; 10-B6, 90-B4	F1_Line1; F6_Line6
		AB-G, BC-G	0,25-0,069	5-B7, 95-B8; 23-B6, 77-B4	
		B-G, AB-G	0,0063-0,0052	7-B8, 93-B9; 28-B5, 72-B4	
	Line 2 - Line 5	AB, AC-G	0,7-0,093	2-B8, 98-B9; 8-B5, 92-B4	F2_Line2; F5_Line5
		C-G, AC	0,0029-0,004	37-B7, 63-B5; 21-B9, 79-B6	
		AC-G, BC-G	0,023-0,0059	15-B7, 85-B5; 12-B9, 88-B6	
	Line 3 - Line 4	AB-G, BC-G	0,0052-0,069	77-B5, 23-B4; 88-B6, 12-B4	F3_Line3; F4_Line4
		AC-G, ABC	0,093-0,0088	55-B5, 45-B4; 64-B6, 36-B4	
		AB-G, AC	0,25-0,004	39-B7, 61-B8; 29-B9, 71-B6	
	Line 5 - Line 6	A-G, BC-G	0,0012-0,0059	44-B7, 56-B8; 70-B9, 30-B6	F1_Line1; F4_Line4
		B-G, C-G	0,0063-0,0029	27-B8, 73-B9; 13-B7, 87-B5	
		AB, AC-G	0,7-0,023	62-B8, 38-B9; 59-B7, 41-B5	
Défauts triple (Sur trois lignes)	Line 1- Line 2- Line 6	AB-G, B-G, BC	0,0014-0,0063-0,0088	69-B7, 31-B8; 75-B8, 25-B9; 57-B6, 43-B4	F1_Line1; F2_Line2; F6_Line6
	Line 3-Line 4-Line 5	ABC, BC, AB-G	0,0029-0,0059-0,093	90-B7, 10-B5; 80-B6, 20-B9; 45-B4, 55-B5	F3_Line3; F4_Line4; F5_Line5

Contrairement à une étude hors ligne, où toutes les données sont stockées pour un traitement ultérieur, le présent travail s'inscrit dans une logique de traitement en temps réel. Ainsi, il n'y a pas de stockage massif des données issues des simulations ; celles-ci sont injectées en continu dans le modèle Simulink. Cette contrainte impose au modèle de disposer d'une capacité de généralisation efficace, car chaque détection repose uniquement sur les signaux disponibles à l'instant donné.

Ce tableau de contingence représente donc l'ensemble des cas de défauts que nous allons simulés en temps réel sur le réseau IEEE 9-bus. Il permet de garantir que le modèle soit entraîné et testé sur une variété réaliste de conditions, incluant des défauts isolés ou multiples, répartis sur différentes lignes du réseau. Cette approche assure une évaluation rigoureuse et représentative des performances du système de détection basé sur l'auto-encodeur LSTM dans un environnement dynamique et complexe.

3.3 Détection en temps réel des courts circuits à parti de l'auto-encodeur LSTM

Les réseaux de neurones artificiels (RNA) font partie des outils fondamentaux de l'intelligence artificielle et sont largement utilisés dans les tâches de reconnaissance, de classification et de détection d'anomalies. Ils s'inspirent du fonctionnement du cerveau humain et sont capables de modéliser des relations complexes entre les données d'entrée et de sortie. L'apprentissage profond (deep learning) constitue une sous-catégorie de l'apprentissage automatique, caractérisée par l'utilisation de réseaux de neurones profonds à plusieurs couches permettant l'extraction automatique de caractéristiques hiérarchiques [98].

Les auto-encodeurs sont une classe de réseaux de neurones non supervisés dont l'objectif principal est de reconstruire les données d'entrée à partir d'un espace latent compressé. Ils sont composés de deux parties : un encodeur, qui transforme l'entrée en une représentation de plus faible dimension, et un décodeur, qui tente de reconstituer l'entrée initiale à partir de cette représentation réduite. Ces modèles sont utilisés pour la réduction de la dimensionnalité, l'extraction de caractéristiques pertinentes, et la détection d'anomalies, en mesurant la différence entre l'entrée et la sortie reconstruite[99]. Lorsqu'un écart significatif est détecté, cela peut signaler une anomalie telle qu'un défaut de court-circuit.

3.3.1 Réseaux de Neurones Récurents (RNN) et LSTM

3.3.1.1 Réseaux de Neurones Récurents (RNN)

Les RNN (Récurent Neural Networks) sont spécialement conçus pour le traitement des données séquentielles, telles que les signaux électriques variant dans le temps. Contrairement aux réseaux classiques, les RNN possèdent des connexions récurrentes qui leur permettent de maintenir une mémoire des états précédents, ce qui est crucial

pour modéliser des dépendances temporelles dans les séries chronologiques. Toutefois, les RNN souffrent d'un problème majeur : la disparition ou l'explosion du gradient lors de l'apprentissage sur de longues séquences, ce qui empêche le réseau de mémoriser efficacement des informations distantes [100]. La figure 3.4 présente l'architecture déroulée du réseau RNN, avec x_t qui désigne l'entrée courante du pas de temps t , $h(t)$ la sortie de ce pas de temps et A qui désigne l'unité connectée de manière récurrente au réseau. La sortie du pas de temps précédent est transmise au pas de temps suivant comme entrée supplémentaire. Si une couche dense suit, le dernier état caché $h(t)$ est transmis et traité pour former $y(t)$, ou si une couche dense suit, $h(t)$ est transmis et traité pour former $y(t)$ [5].




Figure 3. 4: Architecture déroulée du réseau RNN [5]

3.3.1.2 Les réseaux de mémoire à long terme (LSTM)

Les réseaux de mémoire à long terme (LSTM) sont une version développée des RNN simples mentionnés précédemment. Hochreiter et Schmidhuber les ont proposés pour la première fois en 1997 [101] et ont démontré des performances précises dans la modélisation des dépendances à long et à court terme des données séquentielles [102]. En théorie, ils ont été créés expressément pour les dépendances à long terme afin de surmonter le problème de gradient évanouissant/explosant. La figure 3.5 montre la structure d'un réseau LSTM simple pour la prédiction, qui comprend une couche d'entrée de séquence, une couche LSTM et une couche de sortie de prédiction (classification).



Figure 3. 5: Structure d'un réseau LSTM

L'architecture LSTM repose sur l'existence d'une cellule mémoire capable de maintenir son état au fil du temps et dotée d'un mécanisme de contrôle non linéaire contrôlant le flux d'informations entrant et sortant de la cellule. Le réseau LSTM est utilisé pour créer un réseau neuronal non linéaire plus complexe et plus profond, capable de démontrer l'effet de la mémoire à long terme [103].

Les réseaux LSTM comportent une couche d'entrée, une couche de sortie et une multitude de couches cachées entre elles. La cellule mémoire est intégrée à la couche cachée. Chaque cellule possède trois portes (entrée f_t , oubli i_t et sortie o_t) et une unité de connexion récurrente [104]. L'architecture LSTM est illustrée à la figure 3.6, telle qu'elle se déploie au fil du temps.




Figure 3. 6: Architecture du réseau LSTM

À chaque instant t , la cellule LSTM reçoit trois informations principales : l'entrée actuelle X_t , l'état caché précédent $h_{(t-1)}$, et l'état de la cellule précédente $C_{(t-1)}$. La porte d'oubli $f_t = \sigma(W_f[h_{(t-1)}, X_t] + b_f)$ détermine quelles informations issues de $C_{(t-1)}$ doivent être conservées ou supprimées. Ensuite, la porte d'entrée $i_t = \sigma(W_i[h_{(t-1)}, X_t] + b_i)$ sélectionne les nouvelles informations $\hat{C}_t = \tanh(W_c[h_{(t-1)}, X_t] + b_c)$ qui seront ajoutées à la mémoire. L'état de la cellule est alors mis à jour par $C_t = f_t * C_{(t-1)} + i_t * \hat{C}_t$, combinant l'ancienne mémoire filtrée et les nouvelles données pertinentes. Enfin, la porte de sortie $o_t = \sigma(W_o[h_{(t-1)}, X_t] + b_o)$ détermine quelle partie de l'état de la cellule sera transmise à la sortie, calculée comme $h_t = o_t * \tanh(C_t)$. Dans cette structure, W_f , W_i , W_c , et W_o représentent respectivement les matrices de poids associées à chaque porte. Les variables $C_{(t-1)}$ et $h_{(t-1)}$ sont issues de la cellule précédente, b_f , b_i , b_c et b_o représentent les biais associés aux différentes portes, tandis que C_t et h_t représentent l'état actuel de la mémoire et la sortie. Ce mécanisme permet à la cellule LSTM de conserver des informations pertinentes sur de longues périodes tout en oubliant celles devenues inutiles, rendant ainsi le réseau particulièrement adapté à la détection d'événements dans des séquences temporelles complexes comme les signaux électriques.[105]

3.3.2 Présentation de l'auto-encodeur LSTM

L'auto-encodeur LSTM est un modèle hybride qui combine les avantages des LSTM avec la structure des auto-encodeurs. Les auto-encodeurs sont une classe d'algorithmes d'apprentissage profond composée de deux composants : un « encodeur » suivi d'un « décodeur ». L'encodeur encode les données d'entrée X^t (qui sont les valeurs de tension et de courant triphasées) au pas de temps t , vers une représentation de faible dimension, en utilisant une fonction de codage (équation 1).

$$g(X) = \sigma(W * X^t + b) \quad (1)$$

Le décodeur reconstruit les valeurs de tension et de courant triphasés de faible dimension codées z' en utilisant la fonction de décodage (équation 2).

$$f(z') = \sigma(W * z' + b) \quad (2)$$

La figure 3.7 montre une simple architecture de l'auto-encodeur LSTM.




Figure 3. 7: Architecture simplifiée de l'auto-encodeur LSTM

Le tableau 3.6 résume les symboles définis dans les équations (1) et (2).

Tableau 3. 6: Description des notations

Symbole	Notations
b	Vecteur du Biais
W	Matrice de poids
X^t	Vecteur de caractéristiques d'entrée, $X \in R^d$
$X' = f(z')$	Vecteur de caractéristiques de sortie décodé
$\sigma(f) = \frac{1}{1 + \exp(f)}$	Fonction d'activation sigmoïde

Cette recherche utilise l'auto-encodeur LSTM comme algorithme de détection d'anomalies en temps réel spécialisé pour les données temporelles. La fonction d'objectif d'apprentissage peut être formulée comme suit : étant donnée une fenêtre glissante de mesures, la partie encodeur LSTM de l'auto-encodeur LSTM vise à encoder le vecteur de caractéristiques d'entrée d'origine en un vecteur de caractéristiques de faible dimension à l'aide d'une fonction de mappage approximative $h(-)$. Et la partie décodeur LSTM de l'auto-encodeur LSTM vise à reconstruire/décompresser le vecteur de caractéristiques de faible dimension en utilisant $h(-)$ au vecteur de caractéristiques de dimension d'origine, comme indiqué dans l'équation 3.

$$\left[X^{(t)}, \dots, X^{(t+n)} \right]_{\text{encodeur}} \xrightarrow{h(-)} \left[X'^{(t)}, \dots, X'^{(t+n)} \right]_{\text{décodeur}} \quad (3)$$

L'auto-encodeur LSTM vise à minimiser l'erreur de reconstruction entre x et x' en utilisant l'équation 4 : l'erreur quadratique moyenne (MSE) comme fonction de perte.

$$MSE = \frac{1}{N} \sum_{i=1}^n (X_i - X'_i)^2 \quad (4)$$

3.3.3 Formation de l'auto-encodeur LSTM pour la détection des défauts

La détection d'anomalies dans un réseau électrique triphasé repose sur l'entraînement d'un modèle d'apprentissage profond capable de reconnaître les comportements normaux du système électrique, afin d'identifier toute déviation comme étant potentiellement anormale. Pour ce faire, un autoencodeur LSTM a été conçu à l'aide de la fonction `deepSignalAnomalyDetectorLSTM` dans MATLAB-Simulink. L'entraînement de ce réseau se base exclusivement sur des données issues de conditions normales, c'est-à-dire sans défauts présents sur les lignes, afin que toute future divergence par rapport à ce comportement soit perçue comme une anomalie.

Dans le cadre de cette étude, le réseau maillé IEEE 9-bus implémenté précédemment dans MATLAB-Simulink est utilisé pour simuler le système électrique triphasé. À ce stade, aucun défaut n'est injecté dans le réseau comme montre la figure 3.8, ce qui garantit que les données collectées pour l'apprentissage représentent uniquement un fonctionnement sain. Ces données comprennent les tensions et courants triphasés extraits des différents jeux de barres, qui constituent les caractéristiques d'entrée du modèle d'apprentissage.




Figure 3. 8: Formes d'onde de tension et de courant du système étudié, sans défaut

Cependant, comme les amplitudes de courant et de tension peuvent varier d'un scénario à un autre, une étape de normalisation est appliquée. Celle-ci consiste à diviser les signaux par leur écart-type, ce qui permet d'harmoniser l'échelle des données d'entrée, de faciliter la convergence de l'apprentissage et d'améliorer la robustesse du modèle. Les signaux de tensions et courants normalisés sont ensuite concaténés dans une seule matrice d'entrée à six canaux (trois pour la tension, trois pour le courant). Ce format permet de représenter fidèlement la dynamique du réseau électrique triphasé, tout en respectant les contraintes de la fonction `deepSignalAnomalyDetector`. En effet, cette fonction exige que les données d'entrée soient fournies sous forme d'un tableau de cellules, chaque cellule contenant une matrice de dimension $M \times N$, où M correspond à la longueur temporelle de la séquence et N au nombre fixe de canaux (qui est de 6). Il est important que toutes les séquences aient exactement le même nombre de canaux, sans aucune valeur manquante. Par ailleurs, chaque séquence doit avoir une longueur minimale supérieure ou égale à la fenêtre temporelle (`WindowLength`) définie lors de la création du détecteur (dans notre cas 50). Enfin, les signaux utilisés doivent être parfaitement synchronisés dans le temps, car les LSTM analysent les dépendances temporelles entre les canaux. Le respect de ces contraintes garantit une analyse temporelle cohérente et une détection fiable des anomalies par le réseau.

Pour entraîner l'auto-encodeur LSTM, une architecture simple est utilisée, comprenant une seule couche pour l'encodeur et une autre pour le décodeur, chacune contenant 32 unités cachées. Cette configuration permet de capturer les dépendances temporelles tout en conservant une complexité modérée adaptée au traitement en temps réel.

Le seuil de détection d'anomalie est ensuite configuré en se basant sur les pertes de reconstruction observées durant l'entraînement. En effet, en cas de court-circuit, les courants et tensions enregistrés diffèrent fortement de ceux du fonctionnement normal, entraînant une hausse significative de la perte de reconstruction. Le seuil de détection est donc défini sur la base de la valeur maximale de perte observée pendant l'entraînement. Cette approche améliore la sensibilité tout en réduisant les faux positifs.

L'entraînement est effectué sur 100 époques en utilisant l'algorithme Adam (Adaptive Moment Estimation). Cet algorithme combine les avantages de deux méthodes d'optimisation classiques (le moment et l'adaptation du taux d'apprentissage) et permet une convergence rapide et stable. Le choix de la fonction de perte MSE (Mean Squared Error) s'explique par sa capacité à quantifier efficacement la différence entre la sortie reconstruite du décodeur et la séquence originale, ce qui est essentiel pour la détection des anomalies, puisque toute anomalie entraînera une augmentation notable de cette erreur. Une fois l'entraînement terminé, le modèle et ses paramètres optimaux sont enregistrés dans un fichier .MAT, ce qui permet leur réutilisation dans Simulink. Lorsqu'un défaut survient, la reconstruction par l'auto-encodeur échoue à reproduire fidèlement la séquence, ce qui entraîne une hausse instantanée de la perte, déclenchant ainsi la détection automatique du défaut. Cette approche permet une détection rapide, fiable, de divers défauts de court-circuit dans les systèmes électriques complexes. Une représentation détaillée de cette formation de l'Autoencodeur est présentée dans la figure 3.9.

3.3.4 Application de l'auto-encodeur LSTM pour la détection des défauts en temps réel

Dans cette section, nous procédons à l'application de l'auto-encodeur LSTM pour la détection en temps réel des défauts dans un réseau électrique maillé de type IEEE 9-bus. Dans un premier temps, nous évaluons le comportement du détecteur dans un scénario sans défaut, afin de valider la capacité du modèle à reconstruire fidèlement les signaux normaux du système électrique. Le modèle a été préalablement entraîné uniquement sur des données représentatives du fonctionnement sain du réseau, c'est-à-dire en l'absence de tout court-circuit. Cette démarche est conforme au principe de détection d'anomalies par reconstruction, dans lequel le modèle apprend à prédire les séquences temporelles normales de tension et de courant, et tout écart significatif de reconstruction est interprété comme une anomalie potentielle.

Les signaux de tension et de courant triphasés (phases A, B et C) sont traités en temps réel, sans qu'aucun stockage intermédiaire ne soit effectué comme l'illustre la figure 3.9.




Figure 3. 9: Modèle Simulink pour la détection des défauts en temps réel dans une ligne de transmission

Dans la figure 3.10 qui présente la visualisation du scope du modèle Deep Signal Anomaly Detector, les signaux des trois phases des courants et tensions sont stables et périodiques, ce qui témoigne de l'absence de perturbation dans le réseau. De plus, la courbe de la fonction de perte (Loss) reste extrêmement faible (tend vers 0) et stable sur toute la durée de la simulation, confirmant que le modèle reconstruit les signaux avec une grande précision. Par ailleurs, la courbe No Fault représentant l'indicateur de détection reste elle aussi très proche de zéro, ce qui indique que le seuil de déclenchement n'a jamais été franchi. Cela confirme qu'aucune anomalie n'a été détectée par le système, et que le réseau est resté dans un état de fonctionnement normal durant toute la simulation.




Figure 3. 10: Visualisation sur le scope du modèle Deep Signal Anomaly Detector

Cette évaluation est également confirmée par l'analyse de la courbe de perte d'apprentissage (Training Loss) illustrée dans la figure 3.11. La courbe montre une décroissance rapide et progressive de la fonction de perte, passant d'une valeur initiale élevée 1.0798 à une valeur minimale inférieure à 0.0015188 au terme de l'entraînement. Ce comportement traduit une convergence efficace du modèle auto-encodeur LSTM vers une solution optimale, démontrant sa capacité à apprendre avec précision les motifs réguliers et les dynamiques normales du réseau électrique. L'entraînement s'est déroulé sur 100 époques et 700 itérations avec une durée d'apprentissage de 2 minutes et 26 secondes. Il pourra ainsi être utilisé comme modèle de référence pour comparer les signaux à venir et détecter toute déviation indicative d'un défaut. Ce type de comportement est particulièrement crucial dans les réseaux électriques critiques, où une détection rapide, précise et fiable des anomalies est essentielle pour garantir la sécurité du système, limiter les interruptions de service et prévenir les dommages matériels.




Figure 3. 11: Courbe de perte d'apprentissage

3.3.4.1 Détection des défauts en temps réel dans une ligne de transmission

Dans cette expérimentation, nous avons appliqué notre auto-encodeur LSTM au réseau électrique maillé IEEE 9-bus afin d'évaluer sa capacité à détecter des défauts en temps réel sur une ligne de transmission.

➤ Défaut de type A-G (général pour les défauts monophasés terre)

Un défaut monophasé de type A-G a été injecté sur la ligne 1 de notre système électrique pendant deux intervalles temporels : de 0,5 s à 1 s, puis de 2 s à 2,5 s. La figure 3.12 présente la sortie du scope simulink obtenue au cours de cette simulation.




Figure 3. 12: Sortie du scope d'un défaut de type A-G

- Analyse des signaux :

L'analyse des signaux de tension et de courant triphasés montre clairement une perturbation significative durant les deux intervalles concernés. En particulier, la composante de la phase A est fortement affectée, ce qui est conforme à la nature du défaut simulé (A-G). Cette perturbation se reflète directement sur la courbe de la fonction de perte (Loss), dont l'amplitude augmente de manière marquée durant les périodes de défaut, atteignant une valeur largement supérieure à celle observée durant le fonctionnement normal qui est de 0.

En parallèle avec cette élévation de perte, la courbe Fault detect line 1 passe de 0 à 1 précisément pendant les deux intervalles où le défaut est actif, avant de revenir à 0 lorsque le système retrouve un fonctionnement normal. Cette courbe représente la réponse de notre système de détection face à présence de défaut de court-circuit dans la ligne. Cela confirme que le modèle d'auto-encodeur LSTM détecté les anomalies en temps réel tout en respectant les délais d'apparition du défaut.

➤ Défaut de type AB (général pour les défauts doubles phases sans terre)

Un défaut double phase de type AB a été injecté sur la ligne 1 de notre système électrique pendant deux intervalles temporels : de 0,5 s à 1 s, puis de 2 s à 2,5 s. La figure 3.13 présente la sortie du scope simulink obtenue au cours de cette simulation.




Figure 3. 13: Sortie du scope d'un défaut de type AB

- Analyse des signaux :

La figure précédente illustre la détection d'un défaut de type AB simulé sur la ligne 1 du réseau IEEE 9-bus. Comme l'indiquent les deux zones de perturbation situées entre 0,5–1 s et 2–2,5 s, le défaut est correctement détecté par notre modèle d'auto-encodeur LSTM, ce qui est confirmé par la courbe Fault detect line 1 qui passe de 0 à 1 pendant ces intervalles.

Comparée au défaut monophasé à la terre précédemment analysé, l'amplitude de la fonction de perte (Loss) atteint ici une valeur moyenne avoisinant 4, contre 2.5 pour le défaut A-G. Cette augmentation s'explique par la nature plus sévère du défaut : un défaut biphasé entraîne une déformation plus importante et plus complexe des signaux

de tension et de courant sur les deux phases concernées, ce qui rend la reconstruction par l'auto-encodeur encore plus difficile.

➤ Défaut de type AB-G (général pour les défauts doubles à la terre)

Un défaut double phase de type AB-G a été injecté sur la ligne 1 de notre système électrique pendant deux intervalles temporels : de 0,5 s à 1 s, puis de 2 s à 2,5 s. La figure 3.14 présente la sortie du scope simulink obtenue au cours de cette simulation.




Figure 3. 14: Sortie du scope d'un défaut de type AB-G

- Analyse des signaux :

La figure précédente présente la sortie du scope lors de la simulation d'un défaut de type AB-G sur la ligne 1 du réseau IEEE 9-bus. Comme observé précédemment, la courbe Fault detect line 1 passe de 0 à 1 dans les intervalles de 0,5 à 1 s et de 2 à 2,5 s, signalant avec précision l'occurrence du défaut. Parallèlement, la courbe de la fonction de perte (Loss) montre une nette augmentation de l'amplitude, avec une valeur moyenne avoisinant 5. En comparant avec les défauts précédents, on constate que le

défaut monophasé à la terre (A-G) a entraîné une perte moyenne d'amplitude de 2,5, le défaut biphasé sans terre (AB) a généré une perte d'amplitude moyenne d'environ 4, tandis que le défaut biphasé à la terre (AB-G) engendre une perte encore plus élevée, proche de 5.

Cette différence s'explique par le degré croissant de sévérité et de déséquilibre que chaque type de défaut introduit dans le système électrique. Un défaut biphasé à la terre perturbe à la fois deux phases et introduit une liaison avec la terre, créant ainsi des distorsions plus complexes dans les signaux de tension et de courant. Ces perturbations sont plus difficiles à reconstruire fidèlement par l'auto-encodeur, ce qui se traduit par une perte de reconstruction plus élevée.

➤ Défaut de type ABC (général pour les défauts triphasés sans la terre)

Un défaut triphasé ABC a été injecté sur la ligne 1 pendant deux intervalles temporels : de 0,5 s à 1 s, puis de 2 s à 2,5 s. La figure 3.15 présente la sortie du scope simulink obtenue au cours de cette simulation.




Figure 3. 15: Sortie du scope d'un défaut de type ABC

- Analyse des signaux :

La figure précédente montre le comportement du réseau lorsqu'un défaut triphasé (ABC) est injecté sur la ligne 1 à deux reprises : entre 0,5 et 1 s, puis entre 2 et 2,5 s. Le défaut est bien détecté par le modèle, comme en témoigne la courbe Fault detect line 1 qui passe de 0 à 1 pendant les intervalles de défaut correspondants. La courbe de la fonction de perte (Loss), quant à elle, connaît une augmentation significative avec une amplitude moyenne avoisinant 5,7.

En comparaison avec les autres défauts testés précédemment, le défaut monophasé à la terre (A-G) génère une perte moyenne de 2,5, le défaut biphasé sans terre (AB) atteint une perte moyenne d'environ 4, le défaut biphasé à la terre (AB-G) se situe autour de 5, tandis que le défaut triphasé (ABC) enregistre la valeur la plus élevée, avec 5,7.

Cette différence s'explique par la nature du défaut triphasé, qui affecte simultanément les trois phases du réseau, provoquant ainsi une perturbation complète de la symétrie et des caractéristiques temporelles du signal. Cette altération globale est plus difficile à reconstruire, d'où une perte plus importante.

Par ailleurs, on remarque que la courbe de la fonction de perte est moins concentrée et présente davantage de fluctuations que pour les autres types de défauts. Cela s'explique par le caractère hautement dynamique et instable des signaux pendant un défaut triphasé, qui introduit une grande variabilité dans les données. L'auto-encodeur peine davantage à stabiliser l'erreur de reconstruction, ce qui se traduit visuellement par une fonction de perte plus « irrégulière » sur toute la durée du défaut.

➤ Défaut de type ABC-G (général pour les défauts triphasés terre)

Un défaut triphasé terre ABC-G a été injecté sur la ligne 1 pendant deux intervalles temporels : de 0,5 s à 1 s, puis de 2 s à 2,5 s. La figure 3.16 présente la sortie du scope simulink obtenue au cours de cette simulation.




Figure 3. 16: Sortie du scope d'un défaut de type ABC-G

- Analyse des signaux

D'après la figure 3.16, On remarque que pour un défaut triphasé terre, la représentation de la fonction de perte est identique à celui du défaut triphasé simple. Cela vient du fait que la perturbation simultanée des trois phases domine la réponse du système, rendant l'effet de la terre négligeable dans la détection.

3.3.4.2 Détection des défauts en temps réel dans deux lignes de transmission

Dans les réseaux électriques maillés, des défauts de court-circuit peuvent apparaître simultanément sur plusieurs lignes de transmission, en raison de perturbations sévères ou de conditions de fonctionnement instables. La détection en temps réel de ces défauts multilignes est alors cruciale pour éviter la propagation des anomalies, assurer la protection des équipements et maintenir la continuité de service. La figure 3.17

présente le modèle Simulink développé pour la détection simultanée des défauts dans deux lignes de transmission du réseau IEEE 9-bus.




Figure 3. 17: Modèle simulink pour la détection des défauts en temps réel dans deux lignes de transmission.

- Détection des défauts en temps réel de type A-G sur la ligne 1 et ABC sur la ligne 6

Afin d'évaluer la capacité du modèle à détecter plusieurs défauts de court-circuit sur différentes lignes, deux défauts ont été simulés dans le réseau IEEE 9-bus. Un défaut monophasé à la terre de type A-G a été introduit sur la ligne 1 entre 0,5 s et 1 s, suivi d'un défaut triphasé de type ABC injecté sur la ligne 6 entre 2 s et 2,5 s. Cette simulation vise à observer le comportement du détecteur LSTM face à des événements successifs sur des tronçons distincts du réseau. La figure 3.18 illustre la sortie du scope Simulink obtenue au cours de cette simulation.




Figure 3. 18: Sortie du scope d'un défaut de type A-G sur la ligne 1 et d'un défaut de type ABC sur la ligne 6

- Analyse des signaux

L'analyse des signaux de tensions et de courants sur les lignes 1 et 6 met en évidence des perturbations nettes durant les intervalles de défaut. On observe clairement les variations des grandeurs électriques au moment des défauts, reflétant la présence d'un court-circuit monophasé A-G sur la ligne 1 (entre 0,5 s et 1 s) et d'un défaut triphasé ABC sur la ligne 6 (entre 2 s et 2,5 s). Le modèle d'auto-encodeur LSTM a

correctement détecté ces défauts en temps réel, comme le montrent les courbes de détection correspondantes.

Cependant, ce qui est particulièrement remarquable, c'est que la ligne 6, bien qu'elle ne soit pas directement affectée par le défaut, présente également une réponse. En effet, la courbe de détection de la ligne 6 (en rouge) passe brièvement à 1 sur le même intervalle de temps (0,5 s à 1 s), et bien que la fonction de perte reste très faible, elle subit une légère perturbation. Pareillement, la courbe de détection de la ligne 1 (bleue) passe à 1 durant l'intervalle de temps (2 s à 2,5 s), malgré une fonction de perte presque nulle.

Ces pertes secondaires peuvent s'expliquer par la propagation des perturbations électriques dans le réseau, affectant légèrement les signaux des autres lignes non directement impliquées. En effet, dans un réseau interconnecté, un défaut sur une ligne peut engendrer des déséquilibres ou des courants de circulation dans d'autres branches, ce qui est détecté par le modèle comme des anomalies mineures. L'auto-encodeur LSTM, sensible aux moindres variations dans les signaux temporels, enregistre donc ces déviations, bien qu'elles soient de faible amplitude comparée aux pertes majeures observées pendant les périodes actives de défaut.

Cette simulation montre non seulement la robustesse du modèle de l'auto-encodeur LSTM pour détecter les défauts complexes en temps réel, mais également sa capacité à capturer l'impact systémique des défauts sur l'ensemble du réseau.

➤ Détection des défauts en temps réel de type AB sur la ligne 2 et AC-G sur la ligne 5

Un défaut biphasé terre de type AC-G a été introduit sur la ligne 5 entre 0,5 s et 1 s, suivi d'un défaut biphasé simple de type AB injecté sur la ligne 2 entre 2 s et 2,5 s. La figure 3.19 illustre la sortie du scope simulink obtenue au cours de cette simulation.




Figure 3. 19: Sortie du scope d'un défaut de type AB sur la ligne 2 et d'un défaut de type AC-G sur la ligne 5

- Analyse des signaux

L'analyse des signaux de tension et de courant sur les lignes 2 et 5 montre des perturbations significatives durant les périodes de défaut, correspondant respectivement à un court-circuit biphasé AB sur la ligne 2 entre 0,5 s et 1 s, et à un défaut de type AC-G sur la ligne 5 entre 2 s et 2,5 s. Ces variations traduisent bien la présence d'anomalies électriques sur les lignes concernées. Le modèle basé sur l'auto-

encodeur LSTM a détecté avec précision chacun de ces défauts en temps réel, comme l'indiquent les courbes de détection. De plus, une influence croisée est observable entre les lignes : la ligne 2 a réagi au défaut sur la ligne 5, et inversement, confirmant la sensibilité du modèle même en cas d'impact indirect.

- Détection des défauts en temps réel de type AC-G sur la ligne 5 et ABC sur la ligne 6

Un défaut biphasé terre de type AC-G a été introduit sur la ligne 5 entre 0,5 s et 1 s, suivi d'un défaut biphasé simple de type ABC injecté sur la ligne 2 entre 2 s et 2,5 s. La figure 3.20 illustre la sortie du scope simulink obtenue au cours de cette simulation.




Figure 3. 20: Sortie du scope d'un défaut de type AC-G sur la ligne 5 et d'un défaut de type ABC sur la ligne 6

- Analyse des signaux

L'analyse des signaux de tensions et de courants des lignes 5 et 6 montre clairement la survenue de deux défauts distincts : un défaut de type AC-G sur la ligne 5 entre 0,5 s et 1 s, et un défaut triphasé ABC sur la ligne 6 entre 2 s et 2,5 s. Ces événements se traduisent par des perturbations nettes dans les signaux électriques durant les intervalles correspondants. Les courbes de détection confirment que le modèle d'auto-encodeur LSTM a efficacement identifié ces défauts en temps réel sur leurs lignes respectives. De plus, il est important de noter que le défaut appliqué sur la ligne 5 a entraîné une élévation modérée de la fonction de perte sur la ligne 6 durant le même intervalle, bien qu'aucun défaut n'y soit injecté à ce moment. Inversement, durant le défaut triphasé sur la ligne 6, la fonction de perte sur la ligne 5 atteint une amplitude plus importante que celle observée sur la ligne 6 entre 0,5 s et 1 s. Cette différence peut s'expliquer par le caractère plus sévère et symétrique du défaut triphasé, qui engendre des perturbations de plus grande ampleur susceptibles d'influencer fortement le comportement électrique des lignes voisines, en particulier dans un réseau maillé. Ces résultats démontrent non seulement la performance du modèle de détection, mais aussi la sensibilité du réseau aux interactions entre lignes lors de perturbations majeures.

3.3.4.3 Détection des défauts en temps réel dans trois lignes de transmission

Lorsque plusieurs lignes d'un réseau électrique sont soumises simultanément à des défauts de court-circuit, les interactions dynamiques entre ces lignes deviennent plus complexes, rendant la détection encore plus délicate. Donc il est essentiel de disposer de mécanismes de surveillance capables de suivre en temps réel l'évolution des signaux électriques sur plusieurs branches du réseau. La figure 3.21 illustre le modèle Simulink mis en œuvre pour la détection simultanée des défauts dans trois lignes distinctes du réseau IEEE 9-bus.




Figure 3. 21: Modèle simulink pour la détection des défauts en temps réel dans trois lignes de transmission.

- Détection des défauts en temps réel de type AB-G sur la ligne 1, B-G sur la ligne 2 et BC sur la ligne 6

Un défaut biphasé terre de type AB-G a été introduit sur la ligne 1 entre 2,5 s et 3 s, un défaut monophasé terre de type B-G injecté sur la ligne 2 entre 1.5 s et 2 s et un défaut biphasé simple de type BC sur la ligne 6 entre 0.5 et 1 s. La figure 3.22 illustre la sortie du scope simulink obtenue au cours de cette simulation.




Figure 3. 22: Sortie du scope d'un défaut de type AB-G sur la ligne 1, un défaut de type B-G sur la ligne 2 et d'un défaut de type BC sur la ligne 6

- Analyse des signaux

L'analyse des signaux de tension et de courant sur les lignes 1, 2 et 6 met en évidence la présence de trois défauts de nature différente sur des intervalles de temps distincts : un défaut biphasé BC sur la ligne 6 entre 0,5 s et 1 s, un défaut monophasé à la terre B-G sur la ligne 2 entre 1,5 s et 2 s, et un défaut biphasé à la terre AB-G sur la ligne 1 entre 2,5 s et 3 s. Les signaux montrent clairement des perturbations significatives dans les courants et tensions durant ces périodes, reflétant l'impact direct de chaque défaut sur sa ligne respective. Le modèle d'auto-encodeur LSTM a permis de détecter efficacement et en temps réel ces défauts, comme en témoignent les courbes de détection et les valeurs de la fonction de perte correspondantes.

Par ailleurs, une influence interlignes est observée. Le défaut BC sur la ligne 6 a eu une répercussion modérée sur la ligne 2 (fonction de perte légèrement élevée), mais très faible sur la ligne 1. Cette propagation partielle s'explique par la proximité topologique entre les lignes 6 et 2 dans le réseau. Inversement, le défaut B-G sur la ligne 2 a fortement influencé la ligne 1, comme en témoigne une fonction de perte notablement élevée, alors que l'effet sur la ligne 6 reste limité. Enfin, le défaut AB-G sur la ligne 1 a fortement impacté la ligne 2 (forte perte détectée), mais très faiblement la ligne 6. Cette propagation peut s'expliquer par le fait que la ligne 2 est très proche de la ligne 1.

Cette analyse souligne que plus les lignes sont proches dans le réseau, plus la perturbation d'une ligne peut se répercuter sur les autres lignes. De plus, la nature du défaut (monophasé, biphasé, avec ou sans terre) joue un rôle important dans l'amplitude des pertes détectées. Les défauts incluant la terre, notamment ceux de type AB-G et B-G, ont tendance à générer une réponse plus marquée, en raison de la dissymétrie introduite dans le système, comparativement à un défaut biphasé simple tel que BC.

- Détection des défauts en temps réel de type ABC sur la ligne 3, BC sur la ligne 4 et AB-G sur la ligne 5

Un défaut triphasé ABC a été introduit sur la ligne 3 entre 0,5 s et 1 s, un défaut biphasé simple de type BC injecté sur la ligne 4 entre 1.5 s et 2 s et un défaut biphasé a terre de type AB-G sur la ligne 5 entre 2.5 et 3 s. La figure 3.23 illustre la sortie du scope Simulink obtenue au cours de cette simulation.




Figure 3. 23: Sortie du scope d'un défaut de type ABC sur la ligne 3, un défaut de type BC sur la ligne 4 et d'un défaut de type AB-G sur la ligne 5

- Analyse des signaux

Les formes d'onde illustrent trois perturbations bien distinctes affectant les lignes 3, 4 et 5 à différents instants : un court-circuit triphasé sur la ligne 3 (0,5 à 1 s), un défaut biphasé BC sur la ligne 4 (1,5 à 2 s), et un défaut de type AB-G sur la ligne 5 (2,5 à 3 s). Ces événements sont marqués par des déformations visibles dans les signaux de tension et de courant dans chaque intervalle de défaut. Le système de détection basé sur l'auto-encodeur LSTM a identifié chaque anomalie avec précision au moment de son apparition.

Des effets de couplage entre lignes ont également été constatés. L'incident sur la ligne 3 s'est répercuté de manière notable sur la ligne 5, alors que son influence sur la ligne 4 reste négligeable. Le défaut sur la ligne 4, quant à lui, a provoqué une réponse intermédiaire sur la ligne 5, mais peu de perturbation sur la ligne 3. Enfin, l'anomalie sur la ligne 5 a généré une élévation importante de la fonction de perte sur la ligne 3, ce qui traduit un effet de proximité. Par ailleurs, les défauts impliquant un contact avec la terre, comme AB-G, tendent à produire des réponses dynamiques plus intenses que les défauts biphasés simples, en raison de l'asymétrie qu'ils introduisent dans le système électrique.

3-4 Application du LSTM pour la classification des défauts en temps réel

Après avoir démontré l'efficacité de l'auto-encodeur LSTM pour la détection en temps réel des défauts de court-circuit dans différentes configurations du réseau, il devient pertinent d'exploiter son potentiel pour la classification de ces défauts. En effet, au-delà de la simple détection d'une anomalie, il est important d'identifier avec précision le type de défaut survenu (monophasé, biphasé, triphasé, avec ou sans terre), afin de permettre une intervention ciblée et rapide. Cette section présente donc l'application du

LSTM dans un contexte de classification, où le modèle est entraîné à distinguer les différents scénarios de défauts à partir des signaux de tension et de courant en temps réel. Le tableau 7 suivant répertorie l'ensemble des 27 classes de défauts considérées dans cette étude, regroupant des défauts simples, hybrides et triples, injectés sur différentes lignes du réseau IEEE 9-bus.

Tableau 3. 7: Classes des différents défauts

Nature du défaut	Ligne d'apparition du défaut	Type de défaut	Nom du bloc de défaut	Classe du défaut
Défauts Simple (Sur une seule ligne)		No défaut	//	C1
	Line 1	A-G	F1_Line1	C2
		AB-G		C3
	Line 2	B-G	F2_Line2	C4
		AB		C5
	Line 3	C-G	F3_Line3	C6
		AC-G		C7
	Line 4	AC	F4_Line4	C8
		BC-G		C9
	Line 5	AB-G	F5_Line5	C10
		AC-G		C11
	Line 6	ABC	F6_Line6	C12
		BC-G		C13
Défauts hybride (Sur deux lignes)	Line 1 - Line 6	A-G, ABC	F1_Line1; F6_Line6	C14
		AB-G, BC-G		C15
	Line 2 - Line 5	B-G, AB-G	F2_Line2; F5_Line5	C16
		AB, AC-G		C17
	Line 3 - Line 4	C-G, AC	F3_Line3; F4_Line4	C18
		AC-G, BC-G		C19
	Line 5 - Line 6	AB, BC	F5_Line5; F6_Line6	C20
		AC-G, ABC		C21
	Line 1 - Line 4	AB-G, AC	F1_Line1; F4_Line4	C22
		A-G, BC-G		C23
	Line 2 - Line 3	B-G, C-G	F2_Line2; F3_Line3	C24
		AB, AC-G		C25
Défauts triple (Sur trois lignes)	Line 1- Line 2- Line 6	AB-G, B-G, BC	F1_Line1; F2_Line2; F6_Line6	C26
	Line 3-Line 4-Line 5	ABC, BC, AB-G	F3_Line3; F4_Line4; F5_Line5	C27

3.4.1 Préparation des données pour la classification des défauts

La réussite de toute classification par apprentissage profond repose en grande partie sur la qualité et la structuration des données en entrée. Dans cette étude, les signaux de courant et de tension triphasés extraits du réseau électrique modélisé sous Simulink constituent les principales entrées du modèle de classification LSTM.

La figure 3.24 présente le cadre proposé pour la classification des défauts. Le processus débute par la génération de la base de données à partir du réseau électrique, où chaque scénario de défaut (ou l'absence de défaut) est simulé dans différentes lignes du réseau. Les signaux correspondants (courants et tensions triphasés) sont collectés pour chaque cas de simulation. Ces données sont ensuite séparées en deux ensembles : 70 % sont dédiés à l'apprentissage du modèle, et 30 % sont réservés au test.




Figure 3. 24: Cadre proposé pour la classification des défauts.

Afin d'assurer une meilleure stabilité de l'apprentissage, chaque ensemble de données est soumis à une normalisation min-max, telle que définie par l'équation 5:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (5)$$

Où X , $X_{\min}$ et $X_{\max}$ représentent respectivement les valeurs originales, les bornes inférieure et supérieure de tous les échantillons. La normalisation convertit les valeurs de différentes caractéristiques ou attributs dans la même plage sans perte d'information ni de relation entre les éléments. Il n'est pas toujours nécessaire de convertir la plage. Si la normalisation n'est pas effectuée, la fonction de perte oscille trop [106].

Une fois les données normalisées, elles sont introduites dans le modèle Long Short-Term Memory (LSTM) pour l'apprentissage de la classification. Chaque échantillon est étiqueté selon la nature du défaut simulé. L'étiquetage suit une numérotation de classe C1 à classe C27, en fonction du type de défaut (monophasé, biphasé, triphasé, avec ou sans mise à la terre) de la ligne concernée tel que présenté dans le tableau 3.7 de la section précédente. Le module entraîné permet ensuite, à partir d'un échantillon en temps réel, de prédire la classe de défaut correspondante. L'identification de la classe 1 (C1) est associée à un état normal sans défaut, tandis que les autres classes correspondent à des types de défauts spécifiques.

3.4.2 Architecture du modèle LSTM utilisé

Afin de réaliser la classification en temps réel des défauts dans le réseau électrique, un modèle de réseau de neurones récurrent Long Short-Term Memory (LSTM) a été développé. Ce modèle est particulièrement adapté au traitement de données séquentielles comme les signaux de tension et de courant.

L'architecture proposée repose sur une entrée de 54 caractéristiques (composantes triphasées de tension et de courant), normalisées à l'aide de la méthode min-max, garantissant une convergence stable durant l'entraînement. Les données sont organisées sous forme de séquences, chaque défaut étant représenté par une séquence temporelle unique.

Le modèle LSTM est structuré comme suit :

- Une couche d'entrée séquentielle correspondant à la taille des vecteurs caractéristiques ;
- Une couche LSTM contenant 50 couches cachées, chargée d'extraire les motifs temporels caractéristiques des différents types de défauts ;
- Une couche de régularisation (dropout) avec un taux de 0,3, visant à réduire le surapprentissage ;
- Une couche entièrement connectée en sortie, avec autant de neurones que de classes de défauts (27 au total) ;
- Une couche softmax, transformant les sorties en probabilités de chaque classe ;
- Et enfin, une couche de classification.

Le modèle est entraîné avec l'optimiseur Adam sur 30 époques, avec un taux d'apprentissage initial de 0,005, un mini-batch de taille 16, et une stratégie de réduction de taux d'apprentissage à palier pour améliorer la convergence. Après l'entraînement, les performances du modèle ont été évaluées et plusieurs métriques de classification ont été calculées, notamment :

- La précision qui montre la capacité du modèle à prédire correctement un défaut parmi les cas détectés (équation 6).

$$précision = \frac{TP}{TP + FP} \quad (6)$$

Avec :

- TP (True Positive) qui est le nombre de défauts correctement classés dans leur vraie classe.
- FP (False Positive) : le nombre d'éléments incorrectement classés dans une classe.

- Le rappel (Sensitivity) qui montre la capacité à détecter effectivement les défauts présents (équation 7).

$$Rappel = \frac{TP}{TP + FN} \quad (7)$$

Avec :

- FN (False Negative) : le nombre de défauts non détectés (classés dans une autre classe ou comme "pas de défaut").
- La spécificité qui a pour aptitude à reconnaître correctement les cas sans défaut (équation 8).

$$Spécificité = \frac{TN}{TN + FP} \quad (8)$$

Avec :

- TN (True Negative) : Le nombre de cas sans défaut correctement identifiés.
- La valeur prédictive négative (NPV) : qui est la probabilité qu'un cas classé sans défaut le soit réellement (équation 9).

$$NVP = \frac{TN}{TN + FN} \quad (9)$$

- L'exactitude globale (Accuracy) qui est le rapport entre les classifications correctes et le nombre total d'échantillons (équation 10).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (10)$$

Ces indicateurs ont été visualisés sous forme de graphiques en barres, facilitant l'interprétation des performances du modèle pour chaque classe de défaut. Une matrice

de confusion a également été générée pour analyser les cas de mauvaise classification entre classes voisines.

Afin d'intégrer ce classificateur dans un environnement de simulation temps réel, le réseau entraîné ainsi que les paramètres de normalisation ont été sauvegardés dans un fichier .mat. Ce fichier peut ensuite être exploité dans Simulink à travers un bloc ClassLSTMNet.mat, permettant l'implémentation embarquée du modèle de classification dans un système de surveillance en temps réel.

3.4.3 Résultats de la classification

Les résultats obtenus après l'entraînement du modèle LSTM démontrent une performance remarquable dans la classification en temps réel des défauts de court-circuit. La précision globale atteint 100 % montre la figure 3.25, ce qui signifie que toutes les classes de défauts, y compris les défauts simples, hybrides et triples, ont été correctement identifiées.




Figure 3. 25: Performances du classificateur LSTM

Cette performance est confirmée par la matrice de confusion comme présente la figure 3.26, qui montre une classification parfaite sans aucune confusion entre les 27 classes, chacune contenant 3000 échantillons.




Figure 3. 26: Matrice de confusion

Le graphique d'évolution de l'exactitude (accuracy) et de la fonction de perte (loss) montre une convergence rapide de l'apprentissage dès les premières itérations comme montre la figure 3.27. L'accuracy atteint rapidement sa valeur maximale, tandis que la perte décroît de manière continue vers zéro, indiquant une excellente capacité de généralisation du modèle sur les données testées.




Figure 3. 27: Évolution de l'apprentissage

Ces résultats confirment la robustesse de l'architecture LSTM utilisée et sa capacité à apprendre efficacement les caractéristiques des différents types de défauts à partir des signaux de tension et de courant. Le modèle est donc bien adapté à une intégration pour la surveillance en temps réel des réseaux électriques maillés.

3.4.4 Analyse des résultats de la classification en temps réel

Afin de valider l'efficacité du modèle LSTM dans un contexte de fonctionnement temps réel, une simulation a été menée en intégrant le réseau neuronal entraîné dans un environnement simulink. Cette simulation visait à vérifier la capacité du modèle à classifier correctement les défauts au fil du temps, à partir des signaux de courant et de tension extraits du réseau électrique.

➤ Classe 1 : pas de défaut

La figure 3.28 présente l'évolution temporelle de la classe prédite tout au long de la simulation. La classe C1 a été prédite de manière constante et continue du début à la fin, sans transition vers une autre classe. Cette stabilité de la prédiction confirme qu'aucun événement de court-circuit n'a été détecté pendant cette période, ce qui est en parfaite adéquation avec le scénario simulé.




Figure 3. 28: Sortie du LSTM pour la prédiction de la classe 1.

➤ Classe 2 : défaut simple sur la ligne1 de type A-G

Un défaut monophasé à la terre (A-G) a été introduit sur la ligne 1 afin d'évaluer la réactivité du modèle de classification en situation de court-circuit. Ce défaut correspond à la classe 2 (C2) dans la base d'apprentissage. L'évolution temporelle de la sortie du classificateur montre un changement net de classe vers la valeur 2 à l'instant $t = 0.1s$, moment auquel le défaut a été injecté dans le réseau comme montre la figure 3.29.




Figure 3. 29: Sortie du LSTM pour la prédiction du défaut simple de classe 2

Avant cette perturbation, la classe prédite est restée constante et identifiée comme classe 1 (état normal), ce qui confirme que le modèle reconnaît correctement le régime sain. Dès l'apparition du défaut, le réseau LSTM a immédiatement détecté l'anomalie et a basculé vers la classe appropriée, sans délai perceptible ni instabilité dans la prédiction. Cette transition démontre que le modèle est capable de détecter rapidement et avec précision un défaut simple, et de le classer correctement parmi un ensemble de scénarios appris.

➤ Classe 16 : défaut hybride type B-G sur la ligne 2 et AB-G sur la ligne 5

Dans cette simulation, un défaut hybride a été introduit, impliquant deux types de défauts : un défaut monophasé à la terre (B-G) sur la ligne 2 et un défaut biphasé à la terre (AB-G) sur la ligne 5, correspondant à la classe 16 (C16) dans notre base d'apprentissage. Le graphique obtenu à la figure 3.30 montre que le classificateur prédit en permanence la classe 1 (état sain) jusqu'à 0.1 seconde, puis bascule instantanément vers la classe 16, qu'il maintient avec stabilité jusqu'à la fin de la simulation.




Figure 3. 30: Sortie du LSTM pour la prédiction du défaut hybride de classe 16.

Ce changement, parfaitement synchronisé avec l'injection du défaut dans le réseau, démontre la capacité du modèle LSTM à reconnaître des défauts multiples et synchrones, même lorsque ces derniers affectent plusieurs lignes simultanément avec des caractéristiques de propagation différentes.

- Classe 26 : défaut triple type AB-G sur la ligne 1, B-G sur la ligne 2 et BC sur la ligne 6

La figure 3.31 présente l'évolution temporelle de la sortie du modèle de classification du défaut triple. On y observe une transition nette de la classe 1 (aucun défaut) vers la classe 26, précisément à $t = 0.1s$, ce qui correspond au moment de l'injection du défaut dans le réseau simulé.




Figure 3. 31: Sortie du LSTM pour la prédiction du défaut hybride de classe 26.

Cependant, juste après ce changement, on remarque de légères oscillations entre plusieurs classes proches, avant que le modèle ne se stabilise définitivement sur la classe 26. Ce comportement confirme que le modèle détecte très rapidement l'apparition d'un événement anormal dans le réseau. Les fluctuations temporaires entre plusieurs classes indiquent que le modèle a rencontré un niveau de complexité élevé dans l'identification immédiate du défaut précis, ce qui est compréhensible au vu de la nature triple et simultanée du défaut. La stabilisation finale sur la classe correcte (C26) prouve néanmoins que le modèle parvient à converger vers la bonne classification.

3.5 Conclusion

Ce chapitre a permis de démontrer l'efficacité de l'auto-encodeur LSTM pour la détection en temps réel des défauts de court-circuit dans les réseaux électriques maillés. À travers des scénarios simulés, incluant des défauts simples, hybrides et triples

répartis sur plusieurs lignes, le modèle s'est montré capable de détecter avec précision la survenue des anomalies tout en maintenant une faible latence. Par la suite, l'approche LSTM a été exploitée pour classifier automatiquement les défauts identifiés en temps réel. Les résultats obtenus mettent en évidence une excellente performance de classification, même dans les cas les plus complexes, grâce à la capacité du modèle à capturer les dynamiques temporelles des signaux électriques. Les analyses montrent que le modèle réagit rapidement aux changements de conditions, assurant ainsi une identification fiable des défauts.

Dans le chapitre suivant, nous allons faire la localisation des défauts à l'aide des réseaux de neurones profonds, afin d'identifier précisément la position des anomalies détectées dans le réseau IEEE-9 bus.

CHAPITRE 4 :LOCALISATION DES DÉFAUTS DE COURT CIRCUIT DANS LES RÉSEAUX ÉLECTRIQUE MAILLÉS

Dans un réseau électrique moderne, de plus en plus complexe et interconnecté, la localisation rapide et précise des défauts de court-circuit constitue un enjeu crucial pour assurer la continuité du service, limiter les dommages matériels et garantir la sécurité des infrastructures. Comme évoqué dans les chapitres précédents, les défauts de court-circuit qu'ils soient simples, hybrides ou multiples peuvent se produire de manière soudaine et simultanée sur plusieurs lignes du réseau, rendant leur détection et surtout leur localisation précise particulièrement difficiles.

Ce chapitre s'intéresse à la localisation en temps réel des défauts de court-circuit, une étape complémentaire à la détection et à la classification, mais tout aussi essentielle pour permettre une intervention ciblée, rapide et automatisée sur les éléments défaillants du réseau. En effet, une localisation précise permet de réduire significativement les temps de coupure, de limiter les pertes économiques et d'améliorer la résilience et la fiabilité du système électrique. Pour relever ce défi, deux approches sont explorées dans ce chapitre : les réseaux de neurones artificiels (ANN) et la méthode de triangulation. Les ANN constituent une solution intelligente capable de modéliser les relations complexes et non linéaires entre les signaux électriques (tensions, courants) et la position des défauts. En s'appuyant sur des données d'entraînement représentatives, ils permettent une localisation automatique, rapide et robuste même dans des scénarios complexes où plusieurs défauts apparaissent simultanément sur différentes lignes du réseau. La méthode de triangulation, fondée sur l'analyse angulaire de signaux provenant des différents bus du réseau, offre une approche géométrique efficace pour estimer la position du défaut. Cette technique repose sur le calcul des angles ou des temps d'arrivée des signaux de défaut détectés à différents nœuds, et permet d'en déduire par intersection le lieu probable de l'anomalie.

4.1 Localisation des défauts par les réseaux de neurones

4.1.1 Principe de base des réseaux de neurone

4.1.1.1 Description des réseaux de neurone

Les réseaux de neurones artificiels (ANN) sont des modèles inspirés du fonctionnement du cerveau humain, conçus pour traiter l'information de manière distribuée et parallèle. Ils sont largement utilisés pour résoudre des problèmes complexes tels que la classification, la régression, la reconnaissance de formes, et plus récemment, la localisation des défauts dans les réseaux électriques. Leur force réside dans leur capacité à apprendre des relations non linéaires à partir des données, sans nécessiter de modèle physique explicite [21, 94].

Un réseau de neurones artificiels se compose de trois types de couches interconnectées : une couche d'entrée, une ou plusieurs couches cachées, et une couche de sortie. La couche d'entrée reçoit les données brutes du système, les couches cachées traitent ensuite ces informations à travers des fonctions d'activation non linéaires et enfin, la couche de sortie délivre le résultat final. Chaque connexion entre neurones est associée à un poids synaptique ajusté pendant l'apprentissage, définissant l'importance de chaque signal.

La figure 4.1 présente une architecture d'un réseau de neurone artificiel.




Figure 4. 1: Structure d'un réseau de neurone artificiel

4.1.1.2 Réseau de neurones à propagation en avant

Les réseaux de neurones propagation en avant (feedforward) représentent l'une des architectures les plus couramment utilisées en raison de leur simplicité de conception et de mise en œuvre. Dans ce type de réseau, le flux d'information circule uniquement dans le sens direct, c'est-à-dire depuis la couche d'entrée, à travers une ou plusieurs couches cachées, jusqu'à la couche de sortie, sans rétroaction ni boucle. Cette structure unidirectionnelle facilite l'apprentissage et l'analyse des données [42].

Pour construire un tel réseau, il est également nécessaire de définir une fonction d'erreur (ou fonction de coût) et une fonction d'activation, qui sont choisies en fonction de la nature des données et du problème à résoudre. Le neurone élémentaire utilisé dans ces réseaux effectue une somme pondérée de ses entrées, chaque entrée étant multipliée par un poids synaptique. Cette somme est ensuite transformée à l'aide d'une fonction d'activation, produisant ainsi la sortie du neurone. Cette sortie est ensuite transmise aux neurones de la couche suivante, assurant la propagation de l'information à travers le réseau [42]. La structure classique d'un neurone est illustrée à la figure 4.2.




Figure 4. 2: Structure classique d'un neurone de type feedforward

Sa sortie peut être calculer par une équation mathématique qui se traduit par équation 11 :

$$y_j^i = f \left(b_j^{(i)} + \sum_{k=1}^{n_{i-1}} W_{jk}^{(i)} y_k^{(i-1)} \right) \quad (11)$$

Avec :

- f la fonction d'activation du neurone j
- i la couche cachée.
- $y_k^{(i-1)}$; $k = 1, \dots, n_{(i-1)}$ qui représente les signaux d'entrée du neurone j et n nombre de neurones dans la couche cachée i .
- W_{jk}^i représente les coefficients de poids de la connexion entre les entrées et le neurone j
- $b_j^{(i)}$ représente le biais du neurone j .

L'objectif est de minimiser l'erreur entre la couche de sortie y_s et sa valeur désirée $y_{s-désirée}$. Cela peut être minimiser par l'erreur quadratique moyenne donc l'équation se traduit par équation 12 :






$$\mathcal{E} = \frac{1}{2} \sum_{s=1}^R (y_s - y_{s-\text{désirée}})^2 \quad (12)$$

Dont R représente le nombre de neurones dans la couche de sortie.

4.1.1.3 Fonction d'activation

Les fonctions d'activation jouent un rôle essentiel dans l'introduction de la non-linéarité. Elle est une fonction mathématique appliquée à un signal en sortie d'un neurone artificiel. On retrouve dans le tableau 4.1 suivant les fonctions d'activation les plus utilisées:

Tableau 4. 1: Fonctions d'activation

Nom	Fonction Matlab	Représentation graphique	Équations
Identité/Rampe	Purelin : Linéaire		$f(x) = x$
Marche/Heaviside Step	Heaviside Step		$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1 & \text{si } x \geq 0 \end{cases}$
Logistique ou sigmoïde	Losig		$f(x) = \frac{1}{1 + e^{-x}}$
Tangente Hyperbolique	Tansig		$f(x) = \tanh(x) = \frac{e^{2x} - 1}{e^{2x} + 1}$
Unité de rectification linéaire Relu	Poslin : Positive linéaire		$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ x & \text{si } x \geq 0 \end{cases}$

4.1.1.4 Stratégie d'apprentissage

L'efficacité d'un réseau de neurones artificiels (RNA) dans la localisation des défauts dépend en grande partie de sa phase d'apprentissage, qui constitue le cœur du processus d'intelligence du système. Cette phase vise à ajuster les poids synaptiques entre les neurones de manière à permettre au réseau de généraliser son comportement sur des cas inconnus, à partir d'exemples passés. En localisation des défauts, cela se traduit par la capacité du modèle à identifier avec précision le point d'apparition d'un défaut à partir de motifs de courants et de tensions caractéristiques.

La qualité de l'apprentissage dépend fortement de la pertinence et de la diversité des données utilisées. Dans la pratique, ces données peuvent être extraites de réseaux réels si les systèmes de mesure sont suffisamment développés, mais dans la majorité des cas, notamment pour des réseaux complexes ou pour couvrir une grande variété de scénarios de défauts, des données simulées sont générées à l'aide de plateformes comme MATLAB/Simulink.

Il existe principalement deux grandes stratégies d'apprentissage pour entraîner un RNA dans ce contexte :

➤ Apprentissage supervisé

L'apprentissage supervisé est la méthode la plus couramment utilisée dans les tâches de localisation. Il repose sur un ensemble de données pour lesquelles chaque entrée (vecteur de caractéristiques issu des signaux électriques) est associée à une sortie cible connue (localisation du défaut). Le réseau est alors entraîné à minimiser l'erreur entre les prédictions effectuées et les valeurs de référence fournies.

Cette approche est particulièrement adaptée à la localisation, car elle permet une modélisation précise de la position du défaut lorsqu'un volume suffisant de données annotées est disponible. Elle nécessite cependant une phase préalable de construction rigoureuse du dataset, incluant différentes topologies de défauts, différentes lignes du

réseau, et plusieurs niveaux de sévérité. Une fois entraîné, le RNA peut opérer en temps réel pour localiser les défauts avec une faible latence et une précision élevée, en exploitant les régularités apprises.

➤ Apprentissage non supervisé

Contrairement à la stratégie supervisée, l'apprentissage non supervisé n'utilise pas de sorties cibles. Le réseau cherche à organiser les données selon des critères internes, souvent liés à des similarités statistiques. Dans le contexte de la localisation, cette méthode peut être utilisée pour identifier des regroupements de défauts similaires, même si la position exacte n'est pas directement connue.

Bien qu'elle soit moins précise pour des applications directes de localisation, cette approche peut être utile pour détecter des événements inconnus ou classer des zones du réseau en fonction de leur comportement dynamique. Des techniques comme les cartes auto-organisatrices (SOM) ou les algorithmes de clustering sont typiquement employés dans ce cadre.

4.1.2 Application des RNA pour la localisation des défauts de court-circuit

4.1.2.1 Base des données de contingence

Afin de permettre aux réseaux de neurones artificiels d'apprendre à localiser les défauts de manière précise et fiable, il est indispensable de construire une base de données de contingence structurée et représentative de l'ensemble des défauts de court-circuit pouvant survenir dans le réseau électrique étudié. Le tableau 4.2 ci-dessous synthétise l'ensemble des défauts simulés dans notre réseau de test IEEE 9-bus, et constitue le fondement de l'apprentissage supervisé du modèle neuronal.

Tableau 4. 2: Base des données de contingence de génération du dataset

Nature du défaut	Ligne d'apparition du défaut	Type de défaut	Résistance du défaut (Ohm)	Distance (Km)
Défauts Simple (Sur une seule ligne)		No défaut	//	//
	Line 1	A-G	100	20-B7
		AB-G	80	10-B7
	Line 2	B-G	70	7-B8
		AB	0,7	80-B8
	Line 3	C-G	0,0029	5-B7
		AC-G	0,023	58-B7
	Line 4	AC	0,004	83-B6
		BC-G	0,0059	36-B9
	Line 5	AB-G	0,0052	28-B5
		AC-G	0,093	70-B5
	Line 6	ABC	0,0088	8-B6
		BC-G	0,069	3-B6
Défauts hybride (Sur deux lignes)	Line 1 - Line 6	A-G, ABC	0,0012-0,0088	15-B7; 10-B6
		AB-G, BC-G	0,25-0,069	5-B7; 23-B6
	Line 2 - Line 5	B-G, AB-G	0,0063-0,0052	7-B8; 28-B5
		AB, AC-G	0,7-0,093	2-B8; 8-B5
	Line 3 - Line 4	C-G, AC	0,0029-0,004	37-B7; 21-B9
		AC-G, BC-G	0,023-0,0059	15-B7; 12-B9
	Line 5 - Line 6	AB, BC	0,0052-0,069	77-B5; 88-B6
		AC-G,ABC	0,093-0,0088	55-B5; 64-B6
	Line 1 - Line 4	AB-G,AC	0,25-0,004	39-B7; 29-B9
		A-G, BC-G	0,0012-0,0059	44-B7; 70-B9
	Line 2 - Line 3	B-G,C-G	0,0063-0,0029	27-B8; 13-B7
		AB, AC-G	0,7-0,023	62-B8; 59-B7
Défauts triple (Sur trois lignes)	Line 1- Line 2- Line 6	AB-G, B-G, BC	0,0014-0,0063-0,0088	69-B7; 75-B8; 57-B6
	Line 3-Line 4-Line 5	ABC, BC, AB-G	0,0029-0,0059-0,093	90-B7; 80-B6;45-B4

Ce tableau des données de contingence présente l'ensemble des défauts à simulés pour former le dataset, chacun défini par sa nature (simple, hybride ou triple), les lignes concernées, le type de défaut, la résistance associée, et sa position en kilomètres par rapport à un bus d'extrémité de la ligne qui comporte le défaut. Par exemple « 20-B7 », veut dire que sur la ligne 1, le défaut est situé à 20 km du bus 7. Cette structure permet d'apprendre au réseau de neurones artificiels à identifier la localisation précise dans le réseau électrique. Grâce à cette diversité de cas couvrant plusieurs topologies et combinaisons de défauts, le modèle peut être entraîné de manière robuste, garantissant une bonne généralisation et une capacité à réagir en temps réel, même face à des situations complexes.

4.1.2.2 Dataset et entraînement du réseau neuronal

Dans le cadre de ce travail, la base de données a été construite à partir de simulations réalisées sous différentes configurations de défauts afin de représenter une large gamme de défauts réalistes.

Pour chaque type de défaut qu'il soit monophasé, biphasé et triphasé à la terre ou sans la terre inclus dans le tableau de contingence, 100 échantillons pour chaque défaut ont été générés en faisant varier notamment la distance d'apparition du défaut, la résistance de défaut, ainsi que la nature du défaut. Ainsi, un total de 2700 échantillons a été obtenu pour entraîner les modèles de localisation développés.

Le réseau de neurones à rétropropagation a été utilisé pour la localisation du défaut, où l'erreur de sortie est utilisée pour ajuster les poids de la couche d'entrée, jusqu'à ce que l'erreur carrée moyenne MSE soit minimisée.

Ces données ont été subdivisées en trois ensembles distincts : 70 % ont été utilisés pour l'apprentissage du réseau de neurones, 15 % pour la validation du modèle durant l'entraînement, et les 15 % restants pour l'évaluation finale des performances. La phase d'apprentissage permet au réseau d'ajuster ses paramètres internes (poids synaptiques) afin d'associer les signaux d'entrée à la position estimée du défaut. L'ensemble de validation permet de suivre la progression du modèle pendant l'entraînement afin de prévenir le surapprentissage, tandis que les données de test, totalement indépendantes, servent à mesurer l'efficacité du modèle sur des cas jamais vus. Cette répartition garantit une robustesse dans la généralisation et une localisation fiable, même face à des configurations de défaut complexes.

4.1.3 Analyse des performances du modèle neuronal

Avant d'intégrer un réseau de neurones artificiels dans un système réel de localisation des défauts de court-circuit, il est impératif de s'assurer de sa fiabilité et de sa capacité

à fournir des résultats cohérents face à de nouvelles situations. Cette étape de test constitue une phase critique du processus de validation, car elle permet d'évaluer la capacité de généralisation du modèle développé, c'est-à-dire sa faculté à estimer avec précision la position des défauts à partir d'exemples encore jamais vus. Plusieurs méthodes d'analyse sont utilisées pour mesurer les performances du réseau. La première consiste à suivre l'évolution de l'erreur quadratique moyenne au fil des itérations via la courbe de performance, ce qui donne un aperçu du comportement de l'apprentissage durant les phases d'entraînement, de validation et de test. Ensuite, la qualité de la correspondance entre les sorties du modèle et les distances cibles est évaluée par une régression linéaire ; le coefficient de corrélation associé fournit une indication de la précision de l'apprentissage, plus il est proche de 1, plus le modèle reproduit fidèlement les distances réelles.

4.1.3.1 Entraînement du réseau neuronal

Dans cette étude, des réseaux de neurones de type feedforward ont été utilisés pour développer les localisateurs neuronaux en raison de leur simplicité structurelle, de leur facilité de mise en œuvre et de leur rapidité d'entraînement. Le localisateur neuronal est conçu comme un modèle de régression. Son rôle est de fournir une estimation précise de la position du défaut, exprimée en kilomètres par rapport à un bus d'extrémité de ligne.

Pour entraîner ce modèle de régression, la fonction d'ajustement "Fitting" a été utilisée, combinée à l'algorithme Levenberg-Marquardt, reconnu pour sa rapidité de convergence et son efficacité dans les problèmes de régression non linéaire. Les caractéristiques d'entrée du réseau sont composées de 36 signaux triphasés de tension et de courant (VA, VB, VC, IA, IB, IC), extraits de plusieurs bus du réseau IEEE 9-bus. Cette diversité d'entrées permet au réseau de capter les variations électriques locales et globales causées par les défauts sur différentes lignes.

Le localisateur neuronal a été conçu pour fournir trois sorties continues, chacune représentant la distance estimée du défaut sur une des trois lignes surveillées simultanément. Ces distances sont exprimées par rapport aux bus situés à l'extrémité des lignes concernées. 3 modèles ont été testés afin d'identifier celui offrant la meilleure précision de localisation, avec pour objectif une erreur quadratique moyenne inférieure à 0,1 , garantissant une estimation fiable et exploitable en temps réel.

➤ Modèle 1

Ce modèle 1 de réseau neuronal de type feedforward se compose de 36 neurones en entrée, correspondant aux valeurs triphasées de tension et de courant. Il comprend une seule couche cachée constituée de 10 neurones, utilisant une fonction d'activation de type sigmoïde. La couche de sortie qui utilise une fonction linéaire adaptée aux problèmes de régression, est formée de 3 neurones, correspondant aux trois distances de localisation des défauts sur les lignes surveillées, avec une fonction d'activation linéaire. La figure 4.3 présente les courbes d'évolution de performance du réseau neuronal du modèle 1 pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteinte pendant la meilleure performance de validation. L'erreur quadratique moyenne atteinte à la fin du processus d'entraînement est égale à 0.3473.




Figure 4. 3: Graphique de performance du localisateur neuronal 36-10-3-3

➤ Modèle 2

La figure 4.4 ci-dessus illustre les performances d'un réseau de neurones de type feedforward au cours des trois phases d'apprentissage : entraînement, validation et test. Le modèle se compose de 36 neurones en entrée, correspondant aux valeurs de tension et de courant collectées aux différents nœuds du réseau, d'une couche cachée contenant 15 neurones, et d'une couche de sortie de 3 neurones, chacun représentant la localisation du défaut sur une ligne distincte. La fonction d'activation utilisée dans la couche cachée est de type sigmoïde, tandis que la couche de sortie utilise une fonction linéaire adaptée aux problèmes de régression.

Au terme de l'entraînement, le réseau atteint une performance de validation optimale de 0,01092 au 228e itération , comme en témoigne la courbe verte. La convergence homogène des courbes des trois phases témoigne de la stabilité et de la bonne généralisation du modèle.




Figure 4. 4: Graphique de performance du localisateur neuronal 36-15-3-3

➤ Modèle 3

La figure 4.5 illustre les performances d'apprentissage du troisième modèle de réseau neuronal au cours des trois phases d'entraînement, de validation et de test. Ce modèle est constitué de 36 neurones en entrée, correspondant aux 36 valeurs triphasées mesurées sur les différents bus du réseau IEEE 9-bus. Il comprend une couche cachée contenant 20 neurones avec une fonction d'activation non linéaire de type sigmoïde, suivie d'une couche de sortie composée de 3 neurones linéaires, représentant les distances des défauts par rapport aux trois bus de référence. La courbe de performance montre une convergence progressive et stable de l'erreur quadratique moyenne, avec une valeur optimale de 0.0036433. L'alignement proche des courbes pour les trois phases d'apprentissage indique une bonne généralisation du modèle et une absence de surapprentissage.




Figure 4. 5: Graphique de performance du localisateur neuronal 36-20-3-3

D'après les trois graphiques présentés pour les trois modèles du localisateur neuronal, il est important de noter que la performance satisfaisante a été obtenue pendant la phase d'apprentissage du troisième modèle. L'erreur quadratique moyenne obtenue est égale à 0.0036433 qui est inférieure à la valeur 0.1 fixée comme objectif. Par conséquent, le modèle 3 est adopté pour la localisation des défauts dans notre réseau IEEE-9 bus.




Figure 4. 6: Diagramme du réseau de neurone adopté

4.1.3.2 Évaluation du modèle adopté

L'évaluation de la performance du modèle 3 a été effectuée à l'aide de la courbe de régression linéaire entre les sorties prédites par le réseau neuronal et les valeurs cibles réelles comme montre la figure 4.7. Les résultats sont présentés pour les trois phases d'apprentissage (entraînement, validation et test), ainsi que pour l'ensemble global des données. Dans chacun des quatre graphes, la corrélation linéaire (coefficient R) atteint la valeur maximale de 1, indiquant un ajustement quasi parfait entre les prédictions et les cibles. La pente de la droite d'ajustement est très proche de 1 et les ordonnées à l'origine sont quasi nulles, ce qui confirme la précision du modèle. Cette excellente corrélation sur les trois sous-ensembles suggère que le réseau a bien appris à localiser les défauts avec une grande fidélité, sans présenter de biais ou de surapprentissage. Le

modèle 3 se révèle ainsi particulièrement robuste pour la tâche de localisation des défauts dans le réseau IEEE 9-bus, même en présence de scénarios complexes.

Les autres courbes d'évaluation des modèles conçus sont présentées dans l'Annexe A.




Figure 4. 7: Graphique de régression du modèle adopté

Le tableau 4.3 présente une évaluation détaillée des performances du localisateur neuronal en comparant les distances réelles des défauts à celles prédites par le modèle, pour différentes natures de défauts (simples, hybrides et triples). Il en ressort que le modèle est capable d'estimer avec une grande précision l'emplacement des défauts, indépendamment de leur complexité ou de leur topologie. En effet, les erreurs relatives sont très faibles, avec une moyenne globale d'environ 0.0031, ce qui témoigne de la

fiabilité du modèle. Même dans les cas de défauts hybrides impliquant plusieurs lignes ou de défauts triples complexes, le localisateur neuronal parvient à prédire avec une exactitude remarquable les distances associées à chaque ligne touchée. Cette performance constante, quelle que soit la nature du défaut, montre que le réseau a bien généralisé les relations entre les signaux d'entrée (tensions et courants) et les positions des défauts pendant son entraînement. Par conséquent, le localisateur développé peut être considéré comme un outil robuste et précis pour une application en temps réel dans les réseaux électriques maillés.

Tableau 4. 3: Comparaison entre la sortie réelles et la sortie prédite du localisateur neuronal

Nature du défaut	Ligne d'apparition du défaut	Type de défaut	Résistance du défaut (Ohm)	Distance réel (Km)	Distance prédite (Km)	Erreur en %
Défauts Simple		No defect	//	//		
	Line 1	A-G	100	20-B7	19.99-B7	0.01
		AB-G	80	10-B7	10-B7	0
	Line 2	B-G	70	7-B8	6.958-B8	0.042
		AB	0,7	80-B8	77.99-B8	0.01
	Line 3	C-G	0,0029	5-B7	5.058-B7	0.058
		AC-G	0,023	58-B7	58-B7	0
	Line 4	AC	0,004	83-B6	82.99-B6	0.01
		BC-G	0,0059	36-B9	36-B9	0
	Line 5	AB-G	0,0052	28-B5	28.74-B5	0.74
		AC-G	0,093	70-B5	70-B5	0
	Line 6	ABC	0,0088	8-B6	8.004-B6	0.004
		BC-G	0,069	3-B6	2.817-B6	0.183
	Line 1 - Line 6	A-G, ABC	0,0012-0,0088	15-B7; 10-B6	15.01-B7; 10.01-B6	0.01;0.01
		AB-G, BC-G	0,25-0,069	5-B7; 23-B6	4.949-B7;22.97-B6	0.051;0.03
	Line 2 - Line 5	B-G, AB-G	0,0063-0,0052	7-B8; 28-B5	6.913-B8; 27.95-B5	0.087;0.05
		AB, AC-G	0,7-0,093	2-B8; 8-B5	2.117-B8; 8.133-B5	0.177;0.133

Nature du défaut	Ligne d'apparition du défaut	Type de défaut	Résistance du défaut (Ohm)	Distance réel (Km)	Distance prédite (Km)	Erreur en %
Défauts hybride	Line 3 - Line 4	C-G, AC	0,0029-0,004	37-B7; 21-B9	37.01-B7; 21-B9	0.01;0
		AC-G, BC-G	0,023-0,0059	15-B7; 12-B9	15-B7; 11.99-B9	0;0.01
	Line 5 - Line 6	AB, BC	0,0052-0,069	77-B5; 88-B6	77-B5;87.99-B6	0;0.01
		AC-G,ABC	0,093-0,0088	55-B5; 64-B6	55.01-B5;64-B6	0.01;0
	Line 1 - Line 4	AB-G,AC	0,25-0,004	39-B7; 29-B9	39-B7;29-B9	0;0
		A-G, BC-G	0,0012-0,0059	44-B7; 70-B9	43.99-B7;69.98-B9	0.01;0.02
	Line 2 - Line 3	B-G,C-G	0,0063-0,0029	27-B8; 13-B7	27-B8; 13-B7	0;0
		AB, AC-G	0,7-0,023	62-B8; 59-B7	61.96-B8; 59.03-B7	0.04; 0.03
Défauts triple	Line 1- Line 2- Line 6	AB-G, B-G, BC	0,0014-0.0063-0.0088	69-B7; 75-B8; 57-B6	68.95-B7; 74.98-B8; 57.01-B6	0.05;0.02;0.01
	Line 3-Line 4-Line 5	ABC, BC, AB-G	0.0029-0.0059-0.093	90-B7; 80-B6;45-B4	90.09-B7; 80.13-B6; 45-B4	0.09; 0.13; 0

4.2 Localisation des défauts par la méthode de triangulation

La triangulation est une méthode de localisation bien connue et largement utilisée dans divers domaines scientifiques et techniques. Elle consiste à déterminer la position d'un point inconnu en s'appuyant sur les mesures angulaires ou temporelles prises depuis au moins trois points de référence dont les positions sont connues. Ce principe repose sur

des considérations géométriques simples, et permet, par l'intersection de droites ou de distances estimées, de localiser précisément une source ou un événement.

Historiquement, la triangulation a été employée en géodésie et en cartographie pour établir des relevés topographiques précis. Aujourd'hui, elle joue un rôle fondamental dans de nombreux systèmes de géolocalisation, notamment dans les réseaux de télécommunications cellulaires, le GPS, les réseaux de capteurs, ou encore dans le positionnement de robots mobiles. En télécommunication, par exemple, la triangulation est utilisée pour estimer la position d'un téléphone mobile à partir des signaux reçus par plusieurs antennes relais. Selon le type de mesure, différentes variantes de la méthode existent, telles que :

- La triangulation angulaire (Angle of Arrival - AOA), qui repose sur la mesure des angles d'arrivée d'un signal à différents points ;
- La trilatération, qui s'appuie sur la mesure des distances entre le point cible et des points fixes à l'aide du temps de propagation (Time of Arrival - TOA) ;
- La triangulation hyperbolique, utilisant les différences de temps d'arrivée (Time Difference of Arrival - TDOA).

L'efficacité de la triangulation repose sur la précision des mesures, la configuration spatiale des points d'observation et la synchronisation temporelle dans le cas de mesures basées sur le temps.

4.2.1 Adaptation du principe de la triangulation pour la localisation des défauts dans les réseaux électriques

La triangulation est une méthode permettant de déterminer la position d'un point en mesurant ses distances ou angles par rapport à au moins deux ou trois points de référence connus. Initialement développée dans le domaine des télécommunications pour localiser des appareils mobiles en analysant les signaux reçus par plusieurs antennes relais, cette

technique peut être adaptée à d'autres domaines, notamment la localisation des défauts dans les réseaux électriques.

La triangulation utilise les angles entre la cible et les points de référence pour estimer l'emplacement de la cible [107]. plusieurs types de mesures peuvent être utilisés dans les méthodes de triangulation [108], notamment la force du signal reçu (RSS), l'heure d'arrivée (TOA), la différence de temps d'arrivée (TDOA), le temps de vol aller-retour (RTOF), l'angle d'arrivée (AOA) et la pose de la caméra. Dans ce mémoire, nous nous concentrons uniquement sur l'angle d'arrivée.

Dans les mesures de l'angle d'arrivée (AOA), l'emplacement d'un dispositif suivi est estimé à l'aide de méthodes de recherche de direction et de triangulation. Dans la figure 4.8, la triangulation AOA en 2 dimensions à l'aide de deux bus est illustrée et les coordonnées du dispositif suivi peuvent être estimées à l'aide de l'équation 13, où θ_{v_x} et θ_{v_y} sont respectivement les angles d'arrivée à la station (Bus x ; Bus y) et D est la distance entre les stations de bus.




Figure 4. 8: Méthode de localisation par triangulation.

La localisation de défauts dans les réseaux électrique, plus précisément sur les lignes de transmission électriques point à point, est du point de vue géométrique un problème de recherche d'un point sur une abscisse nous travaillons dans un espace à une dimension, où la seule dimension est la longueur ou la distance à partir d'un point de base.[109]

La situation dans le réseau de distribution est différente. Avec les réseaux à structure maillé, il n'est pas possible de résoudre le problème dans un espace unidimensionnel. Il faut ajouter un autre paramètre représentant la ramification du réseau. Nous résolvons maintenant le problème dans un espace bidimensionnel et le problème est similaire à la recherche d'un point sur un plan. Cette comparaison n'est pas exacte du point de vue électrique, mais conduit à l'idée d'utiliser des principes utilisés pour localiser des points sur un plan (quelque chose comme une triangulation électrique). Le principe est similaire à la localisation d'un téléphone mobile à l'aide d'un réseau de stations [109]

L'adaptation du principe de triangulation pour la localisation des défauts de court-circuit dans les réseaux électrique repose sur l'idée suivante. Nous pouvons utiliser deux points de référence, *Bus x* et *Bus y* situés aux extrémités de la ligne de transmission sur laquelle nous voulons localiser le défaut. Lorsqu'un défaut apparaît à un point quelconque le long de cette ligne, il génère des perturbations électriques (notamment sur les signaux de tension) qui se propagent instantanément vers les deux extrémités. Ces perturbations sont captées par des capteurs installés aux extrémités de la ligne, qui enregistrent les tensions triphasées en temps réel. Une fois ces signaux collectés, nous procédons à l'extraction des séquences positives des tensions triphasées mesurées à chaque extrémité. Ces composantes, que nous noterons respectivement θ_{v_x} pour le *Bus x* et θ_{v_y} pour le *Bus y* représentent les angles de propagation du signal de défaut depuis chaque point de mesure. la position du défaut est donnée par l'intersection des deux droites définies par ces angles. Chacune de ces droites part d'un bus de référence et suit l'orientation donnée par l'angle d'arrivée mesuré. Le point d'intersection des deux lignes représente l'emplacement estimé du défaut comme montre la figure 4.8. Ce point

est défini par des coordonnées cartésiennes (X,Y) , où la valeur X correspond à la distance estimée du défaut par rapport au $Bus\ x$ (ou au $Bus\ y$ selon la convention choisie). Cette distance est calculée en utilisant les relations trigonométriques présentées dans l'équation 13

$$\begin{cases} X = \frac{\tan(\theta_{V_x})}{\tan(\theta_{V_x}) + \tan(\theta_{V_y})} D \\ Y = \frac{\tan(\theta_{V_x}) \tan(\theta_{V_y})}{\tan(\theta_{V_x}) + \tan(\theta_{V_y})} D \end{cases} \quad (13)$$

4.2.2 Simulation et analyse des résultats

4.2.2.1 Simulation

Dans cette section, nous présentons la simulation de la méthode de localisation des défauts de court-circuit par triangulation, appliquée au réseau de test IEEE 9 bus déjà décrit dans les sections précédentes. Cette approche repose sur l'analyse angulaire des tensions mesurées aux extrémités des lignes électriques, permettant de déterminer la position du défaut à partir des angles.

Cette méthode est ici exploitée pour localiser des défauts sur plusieurs lignes du réseau. Concrètement, pour chaque ligne analysée, les phases positives (séquence directe) des tensions sont extraites au niveau des deux bus situés aux extrémités de la ligne concernée. Les valeurs de ces phases qui sont exprimées en degré sont alors utilisées comme paramètre principal dans l'algorithme de localisation, en se basant sur les principes de la triangulation géométrique.

Le tableau 4.4 ci-dessous donne un aperçu détaillé de ces défauts à simuler en précisant leur nature, leur emplacement et la ligne sur laquelle ils ont été injectés.

Cette phase de simulation est essentielle pour évaluer la capacité de la méthode à localiser précisément les défauts, et à vérifier la robustesse de l'approche face aux variations d'angles dues à la dynamique du système électrique.

Tableau 4. 4: Base de données des défauts

Point d'apparition du défaut	Emplacement	Type de défaut	Distance(Km)	Nom du bloc du défaut
Ligne 1	B7-B8	AC-G	80-B7	F1_Line1
Ligne 2	B8-B9	A-G	35-B8	F2_Line2
Ligne 3	B7-B5	AB	39-B5	F3_Line3
Ligne 4	B9-B6	BC	17-B9	F4_Line4
Ligne 5	B5-B4	AC	30-B5	F5_Line5
Ligne 6	B6-B4	ABC	45-B6	F6_Line6

4.2.2.2 Analyse des résultats

Les résultats de simulation présentés dans le tableau 4.5 ci-dessus permettent d'évaluer la performance de notre algorithme de localisation des défauts dans différents scénarios, en tenant compte du type de défaut, de l'emplacement, de la distance réelle par rapport au bus de référence, de la distance prédite, ainsi que de la précision de la méthode.

Tableau 4. 5: Résultat de la simulation

Type de défaut	Emplacement	Distance réelle (Km)	Distance prédite (Km)	Précision en %
AC-G	Ligne 1	80-B7	79.36	99.21
A-G	Ligne 2	35-B8	34.86	99.61
AB	Ligne 3	39-B5	35.55	91.16
BC	Ligne 4	17-B9	16.7	98.22
AC	Ligne 5	30-B5	27.28	90.93
ABC	Ligne 6	45-B6	41.86	93.02

L'analyse des résultats montre que la méthode de triangulation appliquée à la localisation des défauts dans un réseau électrique maillé est capable de fournir des

estimations très proches de la réalité, avec des précisions dépassant les 90 % dans tous les cas étudiés. Le défaut biphasé à la terre AC-G sur la ligne 1 est localisé avec une précision de 99,21 %, ce qui démontre l'efficacité de la méthode même en présence de couplages de phases. Le défaut monophasé A-G sur la ligne 2 affiche une précision remarquable de 99,61 %, soulignant la sensibilité de l'algorithme à des perturbations affectant une seule phase. Pour les défauts biphasés AB sur la ligne 3, BC sur la ligne 4 et AC sur la ligne 5 les précisions atteignent respectivement 91,16 %, 98,22 % et 90,93 %, confirmant la capacité du système à localiser des défauts plus complexes avec une bonne exactitude. Enfin, le défaut ABC sur la ligne 6 présente des précisions 93,02 %, montrant que la méthode reste robuste même face à des défauts polyphasés et plus sévères.

Ces résultats soulignent l'efficacité de la triangulation appliquée aux réseaux électriques maillés, même dans des conditions où les défauts varient en type et en position. La méthode se montre robuste, avec une moyenne de précision supérieure à 95 %, ce qui la rend prometteuse pour des applications en temps réel dans des réseaux complexes. L'écart d'erreur peut dépendre de la sensibilité des angles mesurés entre les tensions de bus, du type de défaut, ou encore de la configuration du réseau (longueur de ligne, impédances).

5 Conclusion

Dans ce chapitre, nous avons présenté en détail deux approches pour la localisation des défauts de court-circuit dans un réseau électrique maillé : les réseaux de neurones et la triangulation. D'une part, le localisateur neuronal, basé sur une architecture feedforward avec fonction de régression, a démontré sa capacité à exploiter efficacement les signaux électriques issus des différents bus pour estimer avec une très grande précision la distance des défauts. Les résultats obtenus, confirmés par les courbes de performance et les comparaisons entre distances réelles et prédites, ont montré une erreur moyenne extrêmement faible (0.0031), validant ainsi la pertinence

de l'architecture choisie, des paramètres d'apprentissage et de la base de données simulée. D'autre part, la méthode de triangulation a confirmé son efficacité pour des défauts simples en fournissant des localisations avec une précision supérieure à 90 % dans tous les cas, et une moyenne globale dépassant 95 %. Les résultats détaillés, comme les précisions de 99,21 % pour un défaut biphasé à la terre (AC-G) sur la ligne 1 ou de 99,61 % pour un défaut monophasé (A-G) sur la ligne 2, témoignent de la robustesse de cette approche même face à des scénarios variés. Toutefois, contrairement au réseau de neurones, la triangulation n'a pas été étendue aux défauts hybrides et triples, ce qui constitue une piste d'amélioration future. L'ensemble de ces résultats démontre que l'application de ces deux méthodes, l'une fondée sur l'apprentissage automatique et l'autre sur un principe géométrique simple, permet d'obtenir une localisation à la fois précise, robuste et adaptée dans les réseaux électriques maillés modernes.

CONCLUSION GÉNÉRALE

L'énergie électrique demeure aujourd'hui un pilier essentiel au développement industriel et sociétal, mais la complexité croissante des réseaux modernes les rend particulièrement vulnérables à divers types de défauts notamment les courts-circuits. Ces perturbations, qu'elles soient simples ou multiples sur une ou plusieurs lignes, représentent un risque majeur pour la fiabilité, la sécurité et la continuité de service du réseau. Dans ce contexte, ce mémoire a proposé une méthodologie innovante pour la détection, la classification et la localisation en temps réel des courts-circuits dans les réseaux maillés, en exploitant les potentialités de l'intelligence artificielle et de méthodes analytiques.

Trois volets principaux ont structuré cette recherche. D'abord, un autoencodeur LSTM a été utilisé pour la détection en temps réel des défauts de court-circuit. Les résultats obtenus ont montré une grande sensibilité du modèle aux perturbations électriques, avec une capacité à distinguer aussi bien les défauts simples que les défauts hybrides affectant simultanément plusieurs lignes. De plus, il a été démontré que l'autoencodeur est capable de capturer les anomalies apparaissant dans les lignes voisines qui ne sont pas directement touchées par le défaut, ce qui illustre la sensibilité du modèle aux interactions entre lignes lors de perturbations majeures.

Pour valider ces approches, l'ensemble des modèles développés a été testé sur le réseau électrique maillé en boucle fermé IEEE-9 bus, qui constitue modèle de réseau réel permettant d'évaluer de manière rigoureuse la robustesse et la précision des méthodes proposées.

Un réseau LSTM a été appliqué pour la classification des défauts, permettant une reconnaissance systématique et précise de 27 classes de scénarios, avec une précision

atteignant 100 %, confirmant l'efficacité de cette approche pour traiter la diversité des situations rencontrées dans les réseaux maillés.

Enfin, la localisation des défauts a été étudiée selon deux approches : d'une part, les réseaux de neurones artificiels qui ont permis d'estimer la distance du défaut avec une erreur moyenne très faible, et d'autre part, la méthode de triangulation, qui a confirmé sa robustesse et sa simplicité de mise en œuvre, atteignant une précision supérieure à 95 % pour différents types de défauts.

L'ensemble des résultats démontre la pertinence d'intégrer des approches hybrides combinant intelligence artificielle et méthodes géométriques simples afin de répondre aux exigences de rapidité, de précision et de fiabilité imposées par les réseaux modernes. Cette recherche contribue ainsi à enrichir le champ des solutions intelligentes pour la protection des réseaux électriques, en proposant une méthodologie capable de traiter en temps réel aussi bien les défauts unitaires que simultanés dans un environnement maillé complexe.

Dans le cadre d'une extension éventuelle de ce travail :

- Une extension plus développée de ces approches à d'autres types de défauts complexes dans les réseaux électriques.
- Une validation expérimentale de notre approche sur des plateformes réduite en conditions réelles.
- L'association des méthodes développées avec des systèmes de communication temps réel basés sur l'IoT

- Valider les résultats avec d'autres logiciels (ETAP, PowerWorld Simulator, DIgSILENT PowerFactory, ou PSCAD).
- Combiner réseaux de neurones et méthodes géométriques pour plus de précision.

ARTICLES SOUMIS POUR LA PUBLICATION:

Polster Kader Mbakob Ndagoua, Slaoui-Hasnaoui Fouad et Georges Semaan " **Real-Time Localization of Short-Circuit Faults in Power Systems Based on the Triangulation Principle for Protection Relays** " Soumis The 4th International Conference on Embedded Systems and Artificial Intelligence (ESAI'25) December 18-19, 2025, | Fez, Morocco ID 19.

Polster Kader Mbakob Ndagoua et Slaoui-Hasnaoui Fouad, " **Real-time Detection of Short-Circuit Faults in Power Systems Using LSTM Autoencoder** " Soumis The 4th International Conference on Energy and Green Computing December 4-5, 2025, | ENSET Mohammeda, Hassan II University, Casablanca Morocco ID 120

Polster Kader Mbakob Ndagoua et Slaoui-Hasnaoui Fouad, "**Deep Neural Network-Based Approach for the Simultaneous Localization of Multi-Line Short-Circuit Faults in Power Networks**" Soumis International Conference on Emerging Research in Electronics, Computer Science and Technology ICERECT- 2025 Organized By P. E. S. College of Engineering, Mandya , Karnataka ID 2352

Polster Kader Mbakob Ndagoua, Slaoui-Hasnaoui Fouad et Semaan Georges "**Intelligent approach for the real-time and simultaneous detection, location, and classification of short-circuit faults in meshed electrical networks**" Article journal Soumis dans Elsevier-ScienceDirect numéro FRAOPE-D-25-01958

ANNEXE A COURBES DES PERFORMANCES ET PARAMÈTRES

- Courbe d'évaluation des modèles neuronal conçus.

➤ Modèle 1 : 36-10-3-3




Figure A-1: Graphique de régression du modèle 1

➤ Modèle 2 : 36-15-3-3




Figure A-2: Graphique de régression du modèle 2

BIBLIOGRAPHIE

- [1] J. Pettikkattil, "Load Flow analysis of IEEE 9 bus test system," *MATLAB Central File Exchange*, 2014.
- [2] F. Hamoudi, "Réseaux de transport et de distribution électrique," *Polycopié, Université A/Mira-Bejaia*, 2018.
- [3] K. Zimmerman and D. Costello, "Impedance-based fault location experience," in *2006 IEEE Rural Electric Power Conference*, 2006: IEEE, pp. 1-16.
- [4] L. De Andrade and T. P. De Leão, "Travelling wave based fault location analysis for transmission lines," in *EPJ Web of Conferences*, 2012, vol. 33: EDP Sciences, p. 04005.
- [5] F. Z. Dekhandji, A. Recioui, A. Ladada, and T. S. Moulay Brahim, "Detection and classification of power quality disturbances using LSTM," *Engineering Proceedings*, vol. 29, no. 1, p. 2, 2023.
- [6] A. Abdelmoumene and H. Bentarzi, "Etude du Comportement de Transformateur de Puissance lors de la Variation de la Charge," 2010.
- [7] L. Bourquin, "Introduction. La troisième révolution industrielle," *L'esprit économique*, pp. 11-24, 2017.
- [8] M. R. Shadi, M.-T. Ameli, and S. Azad, "A real-time hierarchical framework for fault detection, classification, and location in power systems using PMUs data and deep learning," *International Journal of Electrical Power & Energy Systems*, vol. 134, p. 107399, 2022.
- [9] T. A. Papadopoulos, E. O. Kontis, G. A. Barzegkar-Ntovom, and P. N. Papadopoulos, "A three-level distributed architecture for the real-time monitoring of modern power systems," *IEEE Access*, vol. 10, pp. 29287-29306, 2022.
- [10] G. A. Barzegkar-Ntovom, E. O. Kontis, C. L. Athanasiadis, and T. A. Papadopoulos, "Online data-driven equivalent model derivation based on distribution network signatures using a machine learning approach," *IEEE Transactions on Smart Grid*, 2024.
- [11] G. A. Barzegkar-Ntovom, E. O. Kontis, T. A. Papadopoulos, and P. N. Papadopoulos, "Methodology for evaluating equivalent models for the dynamic analysis of power systems," *IEEE Transactions on Power Delivery*, vol. 37, no. 6, pp. 5059-5070, 2022.
- [12] T. Papadopoulos, G. Barzegkar-Ntovom, E. Kontis, and N. Batzis, "Development of Black-Box Equivalent Models from Ambient Data," in *2023 14th International Conference on Electrical and Electronics Engineering (ELECO)*, 2023: IEEE, pp. 1-5.
- [13] Z. Lin *et al.*, "WAMS-based coherency detection for situational awareness in power systems with renewables," *IEEE Transactions on Power Systems*, vol. 33, no. 5, pp. 5410-5426, 2018.

- [14] B. Roy *et al.*, "Deep learning based relay for online fault detection, classification, and fault location in a grid-connected microgrid," *IEEE Access*, vol. 11, pp. 62674-62696, 2023.
- [15] T. S. Ustun, S. S. Hussain, L. Yavuz, and A. Onen, "Artificial intelligence based intrusion detection system for IEC 61850 sampled values under symmetric and asymmetric faults," *Ieee Access*, vol. 9, pp. 56486-56495, 2021.
- [16] N. Bouchiba, "Application de L'intelligence Artificielle Pour la Détection et la Localisation des Défauts Dans les Réseaux Électriques," Université de Moncton (Canada), 2024.
- [17] E. Michel-Kerjan, "Risques catastrophiques et réseaux vitaux: de nouvelles vulnérabilités 1," *Flux*, no. 1, pp. 006-015, 2003.
- [18] S. Qazi, *Standalone photovoltaic (PV) systems for disaster relief and remote areas*. Elsevier, 2016.
- [19] H. A. Al Hassan, A. Reiman, G. F. Reed, Z.-H. Mao, and B. M. Grainger, "Model-based fault detection of inverter-based microgrids and a mathematical framework to analyze and avoid nuisance tripping and blinding scenarios," *Energies*, vol. 11, no. 8, p. 2152, 2018.
- [20] S. R. Fahim, Y. Sarker, O. K. Islam, S. K. Sarker, M. F. Ishraque, and S. K. Das, "An intelligent approach of fault classification and localization of a power transmission line," in *2019 IEEE International Conference on Power, Electrical, and Electronics and Industrial Applications (PEEIACON)*, 2019: IEEE, pp. 53-56.
- [21] A. Raghda, "Détection, classification et localisation des défauts dans les lignes de transmission par les réseaux de neurones artificiels," Université du Québec en Abitibi-Témiscamingue, 2022.
- [22] M. Kezunovic, "Smart fault location for smart grids," *IEEE transactions on smart grid*, vol. 2, no. 1, pp. 11-22, 2011.
- [23] F. M. Shakiba, M. Shojaei, S. M. Azizi, and M. Zhou, "Real-time sensing and fault diagnosis for transmission lines," *International Journal of Network Dynamics and Intelligence*, pp. 36-47, 2022.
- [24] M. T. Hagh, K. Razi, and H. Taghizadeh, "Fault classification and location of power transmission lines using artificial neural network," in *2007 international power engineering conference (IPEC 2007)*, 2007: IEEE, pp. 1109-1114.
- [25] A. Raza, A. Benrabah, T. Alquthami, and M. Akmal, "A review of fault diagnosing methods in power transmission systems," *Applied Sciences*, vol. 10, no. 4, p. 1312, 2020.
- [26] A. G. Nath, S. S. Udmale, and S. K. Singh, "Role of artificial intelligence in rotor fault diagnosis: A comprehensive review," *Artificial Intelligence Review*, vol. 54, pp. 2609-2668, 2021.
- [27] M. Kezunović, J. Mrkić, and B. Peruničić, "An accurate fault location algorithm using synchronized sampling," *Electric Power Systems Research*, vol. 29, no. 3, pp. 161-169, 1994.

- [28] S. M. Brahma and A. A. Girgis, "Development of adaptive protection scheme for distribution systems with high penetration of distributed generation," *IEEE Transactions on power delivery*, vol. 19, no. 1, pp. 56-63, 2004.
- [29] B. Cannas, G. Celli, M. Marchesi, and F. Pilo, "Neural networks for power system condition monitoring and protection," *Neurocomputing*, vol. 23, no. 1-3, pp. 111-123, 1998.
- [30] S. S. Gururajapathy, H. Mokhlis, and H. A. Illias, "Fault location and detection techniques in power distribution systems with distributed generation: A review," *Renewable and sustainable energy reviews*, vol. 74, pp. 949-958, 2017.
- [31] J. Gracia, A. Mazon, and I. Zamora, "Best ANN structures for fault location in single-and double-circuit transmission lines," *IEEE transactions on power delivery*, vol. 20, no. 4, pp. 2389-2395, 2005.
- [32] S. A. Gafoor and P. R. Rao, "Wavelet based fault detection, classification and location in transmission lines," in *2006 IEEE international power and energy conference*, 2006: IEEE, pp. 114-118.
- [33] Z. Wang, M. Xia, M. Lu, L. Pan, and J. Liu, "Parameter identification in power transmission systems based on graph convolution network," *IEEE Transactions on Power Delivery*, vol. 37, no. 4, pp. 3155-3163, 2021.
- [34] A. Moradzadeh, H. Teimourzadeh, B. Mohammadi-Ivatloo, and K. Pourhossein, "Hybrid CNN-LSTM approaches for identification of type and locations of transmission line faults," *International Journal of Electrical Power & Energy Systems*, vol. 135, p. 107563, 2022.
- [35] B.-S. Lin, J.-S. Cheng, H.-C. Liao, L.-W. Yang, T. Yang, and K.-C. Chen, "Improvement of multi-lines bridge defect classification by hierarchical architecture in artificial intelligence automatic defect classification," *IEEE Transactions on Semiconductor Manufacturing*, vol. 34, no. 3, pp. 346-351, 2021.
- [36] S. El Safty, M. A. El Nasr, S. Mekhemer, and M. Mansour, "New technique for fault location in interconnected networks using phasor measurement unit," in *2008 12th International Middle-East Power System Conference*, 2008: IEEE, pp. 6-10.
- [37] L. Yang, Y. Zhai, and Z. Li, "Deep learning for online AC false data injection attack detection in smart grids: An approach using LSTM-autoencoder," *Journal of Network and Computer Applications*, vol. 193, p. 103178, 2021.
- [38] F. Lachekhab, M. Benzaoui, S. A. Tadjer, A. Bensmaine, and H. Hamma, "LSTM-autoencoder deep learning model for anomaly detection in electric motor," *Energies*, vol. 17, no. 10, p. 2340, 2024.
- [39] D. Guha, R. Chatterjee, and B. Sikdar, "Anomaly detection using lstm-based variational autoencoder in unsupervised data in power grid," *IEEE Systems Journal*, vol. 17, no. 3, pp. 4313-4323, 2023.
- [40] A. M. S. Omar, M. K. Osman, M. N. Ibrahim, Z. Hussain, and A. F. Abidin, "Fault classification on transmission line using LSTM network," *Indonesian*

- Journal of Electrical Engineering and Computer Science*, vol. 20, no. 1, pp. 231-238, 2020.
- [41] S. Belagoune, N. Bali, A. Bakdi, B. Baadji, and K. Atif, "Deep learning through LSTM classification and regression for transmission line fault detection, diagnosis and location in large-scale multi-machine power systems," *Measurement*, vol. 177, p. 109330, 2021.
 - [42] R. Alilouch, F. S. Hasnaoui, and S. Georges, "Intelligent fault locator and zone isolation for transmission line," in *2022 International Conference on Electrical, Computer, Communications and Mechatronics Engineering (ICECCME)*, 2022: IEEE, pp. 1-6.
 - [43] A. Aljohani, T. Sheikhoon, A. Fataa, M. Shafiullah, and M. A. Abido, "Design and implementation of an intelligent single line to ground fault locator for distribution feeders," in *2019 International Conference on Control, Automation and Diagnosis (ICCAD)*, 2019: IEEE, pp. 1-6.
 - [44] I. Sadinezhad and M. Joorabian, "A new adaptive hybrid neural network and fuzzy logic based fault classification approach for transmission lines protection," in *2008 IEEE 2nd International Power and Energy Conference*, 2008: IEEE, pp. 895-900.
 - [45] Y. Zhao, J. Chen, and H. V. Poor, "A learning-to-infer method for real-time power grid multi-line outage identification," *IEEE Transactions on Smart Grid*, vol. 11, no. 1, pp. 555-564, 2019.
 - [46] D. Zhou, Y. Zhao, Z. Wang, X. He, and M. Gao, "Review on diagnosis techniques for intermittent faults in dynamic systems," *IEEE Transactions on Industrial Electronics*, vol. 67, no. 3, pp. 2337-2347, 2019.
 - [47] W. Danilczyk, Y. L. Sun, and H. He, "Smart grid anomaly detection using a deep learning digital twin," in *2020 52nd North American Power Symposium (NAPS)*, 2021: IEEE, pp. 1-6.
 - [48] A. Ahmed, "PMUNET: Anomaly Detection Over Concept Drifting Synchrophasor Data Streams," Washington State University, 2019.
 - [49] Q. He, M. Wu, C. Liu, D. Jin, and M. Zhao, "Management and real-time monitoring of interconnected energy hubs using digital twin: Machine learning based approach," *Solar Energy*, vol. 250, pp. 173-181, 2023.
 - [50] Y. Al Mtawa, A. Haque, and T. Halabi, "A review and taxonomy on fault analysis in transmission power systems," *Computation*, vol. 10, no. 9, p. 144, 2022.
 - [51] A. K. Patel and N. L. Shah, "A Review on Fault Current Limiting Circuits—Its Classification, Benefits and Traditional Methods," *Research Journal of Engineering Technology and Medical Sciences (ISSN: 2582-6212)*, vol. 5, no. 02, 2022.
 - [52] S. Rahman Fahim, S. K. Sarker, S. Muyeen, M. R. I. Sheikh, and S. K. Das, "Microgrid fault detection and classification: Machine learning based approach, comparison, and reviews," *Energies*, vol. 13, no. 13, p. 3460, 2020.

- [53] M.-C. Alvarez-Hérault, "Architectures des réseaux de distribution du futur en présence de production décentralisée," Institut National Polytechnique de Grenoble-INPG, 2009.
- [54] H. Bayem, "Apport des méthodes probabilistes aux études d'intégration des énergies renouvelables aux systèmes électriques," Université Paris Sud-Paris XI, 2009.
- [55] K. Nadhir, "Contribution à la gestion des réseaux de distribution en présence de génération d'énergie dispersée," *Option: Réseaux Electriques. Université de Batna*, 2014.
- [56] D. Tran Khanh Viet, "Interconnexion des sources d'énergie renouvelable au réseau de distribution électrique," Université du Québec à Trois-Rivières, 2009.
- [57] J. Favraud, "Fonctionnement et protection des réseaux de distribution," *EDF centre de perfectionnement électrique de Nanterre, Année*, 1967.
- [58] C. CORROYER, "Protection des réseaux. Généralités," *Techniques de l'ingénieur. Génie électrique*, vol. 10, no. D4800, pp. D4800. 1-D4800. 18, 1991.
- [59] D. Penkov, "Localisation de défauts dans les réseaux HTA en présence de génération d'énergie dispersée," Institut National Polytechnique de Grenoble-INPG, 2006.
- [60] C. Pham, "Détection et Localisation de Défauts dans les Réseaux de Distribution HTA en Présence de Génération d," *Energie Dispersée*, 2005.
- [61] T. Welfonder, "Localisation de défauts monophasés dans les réseaux de distribution à neutre compensé," Institut National Polytechnique de Grenoble-INPG, 1998.
- [62] M. Jamil, S. K. Sharma, and R. Singh, "Fault detection and classification in electrical power transmission system using artificial neural network," *SpringerPlus*, vol. 4, pp. 1-13, 2015.
- [63] T. Dalstein and B. Kulicke, "Neural network approach to fault classification for high speed protective relaying," *IEEE Transactions on Power Delivery*, vol. 10, no. 2, pp. 1002-1011, 1995.
- [64] P. Bhowmik, P. Purkait, and K. Bhattacharya, "A novel wavelet transform aided neural network based transmission line fault analysis method," *International Journal of Electrical Power & Energy Systems*, vol. 31, no. 5, pp. 213-219, 2009.
- [65] M. Geethanjali, "Combined wavelet transoms and neural network (WNN) based fault detection and classification in transmission lines," in *2009 International Conference on Control, Automation, Communication and Energy Conservation*, 2009: IEEE, pp. 1-7.
- [66] P. Gupta and R. Mahanty, "Artificial Neural Network based Fault Classifier and Locator for Transmission Line Protection," *Journal of Electrical and Electronics Engineering (IOSR-JEEE)*, vol. 11, no. 1, pp. 41-53, 2016.
- [67] E. POWER, "HANDBOOK OF ELECTRICAL POWER SYSTEM DYNAMICS."

- [68] E. Koley, A. Jain, A. Thoke, A. Jain, and S. Ghosh, "Detection and classification of faults on six phase transmission line using ANN," in *2011 2nd International Conference on Computer and Communication Technology (ICCT-2011)*, 2011: IEEE, pp. 100-103.
- [69] M. A. F. Garcia, "Interaction des réseaux de transport et de distribution en présence de production décentralisée," Institut National Polytechnique de Grenoble-INPG, 2008.
- [70] P. M. Anderson, *Analysis of faulted power systems*. John Wiley & Sons, 1995.
- [71] J. Glover, T. Overbye, and M. Sarma, "Power System Analysis And Design. Cengage Learning, 2016," *Search in*.
- [72] M. A. Anthony, "Electric power system protection and coordination: a design handbook for overcurrent protection," (*No Title*), 1995.
- [73] E. M. C. Mendoza, "Méthodes de localisation et de détection de défauts d'arcs électriques séries dans un réseau électrique alternatif basse tension," Université de Lorraine, 2018.
- [74] R.-A. Tîrnovan and M. Cristea, "Advanced techniques for fault detection and classification in electrical power transmission systems: An overview," in *2019 8th International Conference on Modern Power Systems (MPS)*, 2019: IEEE, pp. 1-10.
- [75] S. Moussa, M. J. B. Ghorbal, J. A. Ziani, and I. Slama-Belkhodja, "Residual-based short-circuit fault detection and isolation in LVDC microgrid," *Sustainable Energy Technologies and Assessments*, vol. 54, p. 102803, 2022.
- [76] F. Serdio, E. Lughofer, K. Pichler, T. Buchegger, and H. Efendic, "Residual-based fault detection using soft computing techniques for condition monitoring at rolling mills," *Information Sciences*, vol. 259, pp. 304-320, 2014.
- [77] C. Yang *et al.*, "Voltage difference residual-based open-circuit fault diagnosis approach for three-level converters in electric traction systems," *IEEE Transactions on Power Electronics*, vol. 35, no. 3, pp. 3012-3028, 2019.
- [78] S.-I. Jang and K.-H. Kim, "An islanding detection method for distributed generations using voltage unbalance and total harmonic distortion of current," *IEEE transactions on power delivery*, vol. 19, no. 2, pp. 745-752, 2004.
- [79] A. Massoud, K. Ahmed, S. Finney, and B. Williams, "Harmonic distortion-based island detection technique for inverter-based distributed generation," *IET Renewable Power Generation*, vol. 3, no. 4, pp. 493-507, 2009.
- [80] D. P. de Carvalho *et al.*, "A method for real-time wireless monitoring of the efficiency and conditions of three-phase induction motor operation," *Electric Power Systems Research*, vol. 157, pp. 70-82, 2018.
- [81] T. A. Khan, F. A. Shaikh, S. Khan, and M. F. Siddiqui, "Real-Time Wireless Monitoring for Three Phase Motors in Industry: A Cost-Effective Solution Using IoT," in *2019 IEEE International Conference on Smart Instrumentation, Measurement and Application (ICSIMA)*, 2019: IEEE, pp. 1-5.
- [82] N. G. Baltas, P. Mazidi, J. Ma, F. de Asis Fernandez, and P. Rodriguez, "A comparative analysis of decision trees, support vector machines and artificial

- neural networks for on-line transient stability assessment," in *2018 International conference on smart energy systems and technologies (SEST)*, 2018: IEEE, pp. 1-6.
- [83] A. Almounajjed and A. K. Sahoo, "Wavelet-based multi-class support vector machine for stator fault diagnosis in induction motor," *Transactions of the Institute of Measurement and Control*, vol. 45, no. 2, pp. 261-273, 2023.
 - [84] S.-Z. Hou, W. Guo, Z.-Q. Wang, and Y.-T. Liu, "Deep-learning-based fault type identification using modified CEEMDAN and image augmentation in distribution power grid," *IEEE Sensors Journal*, vol. 22, no. 2, pp. 1583-1596, 2021.
 - [85] M. H. Dhend and R. H. Chile, "Fault diagnosis of smart grid distribution system by using smart sensors and symlet wavelet function," *Journal of Electronic Testing*, vol. 33, pp. 329-338, 2017.
 - [86] S. Mishra, V. Kshirsagar, R. Dwivedula, and C. Hota, "Attention-based bi-lstm for anomaly detection on time-series data," in *International Conference on Artificial Neural Networks*, 2021: Springer, pp. 129-140.
 - [87] M. M. Saha, J. J. Izykowski, and E. Rosolowski, *Fault location on power networks*. Springer Science & Business Media, 2009.
 - [88] S. Adhikari, N. Sinha, and T. Dorendrajit, "Fuzzy logic based on-line fault detection and classification in transmission line. SpringerPlus (2016)," ed.
 - [89] O. Castillo, P. Melin, J. Kacprzyk, and W. Pedrycz, "Type-2 fuzzy logic: theory and applications," in *2007 IEEE international conference on granular computing (GRC 2007)*, 2007: IEEE, pp. 145-145.
 - [90] R. Alilouch and F. Slaoui-Hasnaoui, "Intelligent Relay Based on Artificial Neural Networks ANN for Transmission Line," in *2022 IEEE 9th International Conference on Sciences of Electronics, Technologies of Information and Telecommunications (SETIT)*, 2022: IEEE, pp. 468-473.
 - [91] P. AG, "A new measurement technique for tracking voltage phasors, local system frequency, and rate of change of frequency," *IEEE Transactions on Power Apparatus and Systems*, vol. 102, no. 5, pp. 1411-1416, 1983.
 - [92] A. S. Alhanaf, H. H. Balik, and M. Farsadi, "Intelligent fault detection and classification schemes for smart grids based on deep neural networks," *Energies*, vol. 16, no. 22, p. 7680, 2023.
 - [93] A. R. A. Jerin, N. Prabakaran, N. M. Kumar, K. Palanisamy, S. Umashankar, and P. Siano, "Smart grid and power quality issues," in *Hybrid-Renewable Energy Systems in Microgrids*: Elsevier, 2018, pp. 195-202.
 - [94] S. Haykin, *Neural networks and learning machines*, 3/E. Pearson Education India, 2009.
 - [95] T. Hassan, "Adaptive neuro fuzzy inference system (ANFIS) for fault classification in the transmission lines," *Online J. Electron. Electr. Eng.(OJEEE)*, vol. 2, pp. 2551-2555, 2010.
 - [96] M. J. Reddy and D. K. Mohanta, "Adaptive-neuro-fuzzy inference system approach for transmission line fault classification and location incorporating

- effects of power swings," *IET generation, transmission & distribution*, vol. 2, no. 2, pp. 235-244, 2008.
- [97] Y.-Y. Hong, Y.-H. Wei, Y.-R. Chang, Y.-D. Lee, and P.-W. Liu, "Fault detection and location by static switches in microgrids using wavelet transform and adaptive network-based fuzzy inference system," *Energies*, vol. 7, no. 4, pp. 2658-2675, 2014.
 - [98] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *nature*, vol. 521, no. 7553, pp. 436-444, 2015.
 - [99] G. E. Hinton and R. R. Salakhutdinov, "Reducing the dimensionality of data with neural networks," *science*, vol. 313, no. 5786, pp. 504-507, 2006.
 - [100] Y. Bengio, P. Simard, and P. Frasconi, "Learning long-term dependencies with gradient descent is difficult," *IEEE transactions on neural networks*, vol. 5, no. 2, pp. 157-166, 1994.
 - [101] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural computation*, vol. 9, no. 8, pp. 1735-1780, 1997.
 - [102] V. Veerasamy *et al.*, "LSTM recurrent neural network classifier for high impedance fault detection in solar PV integrated power system," *IEEE access*, vol. 9, pp. 32672-32687, 2021.
 - [103] N. Qu, Z. Li, J. Zuo, and J. Chen, "Fault detection on insulated overhead conductors based on DWT-LSTM and partial discharge," *IEEE Access*, vol. 8, pp. 87060-87070, 2020.
 - [104] Y. Xia, F. Yu, X. Xiong, Q. Huang, and Q. Zhou, "A novel microgrid islanding detection algorithm based on a multi-feature improved LSTM," *Energies*, vol. 15, no. 8, p. 2810, 2022.
 - [105] Z. Li, N. Qu, X. Li, J. Zuo, and Y. Yin, "Partial discharge detection of insulated conductors based on CNN-LSTM of attention mechanisms," *Journal of Power Electronics*, vol. 21, no. 7, pp. 1030-1040, 2021.
 - [106] J. A. Deatrick, K. A. Knafl, and C. Murphy-Moore, "Clarifying the concept of normalization," *Image: The Journal of Nursing Scholarship*, vol. 31, no. 3, pp. 209-214, 1999.
 - [107] H. Liu, H. Darabi, P. Banerjee, and J. Liu, "Survey of wireless indoor positioning techniques and systems," *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 37, no. 6, pp. 1067-1080, 2007.
 - [108] F. Gu *et al.*, "Indoor localization improved by spatial context—A survey," *ACM Computing Surveys (CSUR)*, vol. 52, no. 3, pp. 1-35, 2019.
 - [109] M. Hoeger, P. Rafajdus, P. Bracinik, and L. Kankula, "The specification of data needed for fault location in medium voltage distribution networks based on triangulation principle," in *Proc. of International conference Forecasting in Electric Power Engineering 2010*, 2010.