



BIBLIOTHÈQUE

CÉGEP DE L'ABITIBI-TÉMISCAMINGUE
UNIVERSITÉ DU QUÉBEC EN ABITIBI-TÉMISCAMINGUE

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 l'auteur 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'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

DÉTECTION, CLASSIFICATION ET LOCALISATION DES DÉFAUTS DANS
LES LIGNES DE TRANSMISSION PAR LES RÉSEAUX DE NEURONES
ARTIFICIELS

MÉMOIRE

PRÉSENTÉ

COMME EXIGENCE PARTIELLE
DE LA MAÎTRISE EN INGÉNIERIE

PAR

RAGHDA ALILOUCH

NOVEMBRE 2022

REMERCIEMENTS

Je remercie Dieu le Tout-Puissant pour sa bénédiction, il est toujours près de moi.

Je tiens à exprimer ma reconnaissance à mon directeur de recherche, Pr Fouad Slaoui Hasnaoui, je le remercie de m'avoir orienté dans le bon chemin, motivé et pour le temps consacré tout au long de cette période, la réalisation de ce mémoire n'aurait jamais pu être possible sans son appui.

Je remercie le personnel et la direction de l'UQAT pour m'avoir permis de vivre et d'apprendre de cette expérience. Je remercie également tous les professeurs du programme de maîtrise en ingénierie concentration génie électrique pour leur formation et leur conseils quotidiens qui m'ont bien aidé dans mon projet de recherche. Je remercie également Isabelle Collin, Mélissa Lacroix et Wissal Charafi pour avoir eu la patience de répondre à mes innombrables questions.

Je tiens à remercier, Pr Fouad Erchiqui et Pr Mourad Nedil d'avoir accepté d'évaluer ce travail.

Je remercie mes chers parents, Mohammed et Malika, ma source d'inspiration, l'œil attentif et compréhensif qui m'a donné le courage et l'ambition de persévérer. Estime et respect je leur dois, pour ce qu'ils m'ont permis d'accomplir. Nul mot ne saurait exprimer l'amour et la reconnaissance que je porte pour eux.

Je remercie ma famille ici au Canada, Khalti Lalla Aicha, ma cousine Yossra, de m'avoir accueilli à bras ouvert et m'encourager tout au long de ce parcours.

TABLE DES MATIÈRES

REMERCIEMENTS	ii
LISTE DES FIGURES.....	vi
LISTE DES TABLEAUX.....	xii
LISTE DES ABRÉVIATIONS, DES SIGLES ET DES ACRONYMES	xiii
LISTE DES SYMBOLES ET DES UNITÉS	xiv
RÉSUMÉ	xvii
ABSTRACT.....	xviii
CHAPITRE 1 INTRODUCTION.....	1
1.1 Contexte général.....	1
1.2 Problématique.....	4
1.3 Motivation et objectifs	6
1.3.1 Objectif général.....	6
1.3.2 Objectifs spécifiques	6
1.4 Méthodologie de recherche	7
1.5 Conclusion.....	7
CHAPITRE 2 APERÇU SUR LA DÉTECTION ET LE DIAGNOSTIC DES DÉFAUTS ÉLECTRIQUES	8
2.1 Réseau électrique.....	8
2.2 Système de protection des lignes de transmission	9
2.3 Les défauts dans le réseau électrique	10
2.3.1 Types de défauts	11
2.3.2 Détection de défaut	14
2.3.3 Classification des défauts.....	15
2.3.4 Localisation des défauts	15
2.4 Les techniques de localisation des défauts dans les lignes de transmission....	16
2.4.1 Méthode basée sur la mesure de l'impédance.....	17
2.4.1.1 Algorithmes à une extrémité	17

2.4.1.2	Algorithmes à deux extrémités.....	21
2.4.2	Les méthodes basées sur les ondes progressives (Travelling-Wave)	23
2.4.3	Facteurs influençant la précision de la localisation des défauts.....	24
2.4.4	Méthodes basées sur l'intelligence artificielle IA.....	25
2.4.4.1	Les techniques du système expert.....	26
2.4.4.2	Systèmes à logique floue.....	27
2.5	Conclusion.....	28
CHAPITRE 3 IDENTIFICATION DES DÉFAUTS PAR LES RÉSEAUX DES NEURONES ARTIFICIELS.....		29
3.1	Introduction au réseau de neurones artificiels.....	30
3.1.1	Description de réseau de neurones.....	30
3.1.2	Réseau de neurones feedforward	32
3.1.3	Algorithme « error back propagation ».....	34
3.2	Fonction de transfert/activation.....	37
3.3	Stratégies d'apprentissage	38
3.4	Algorithmes d'apprentissage.....	40
3.5	Détecteur neuronal	42
3.6	Extraction des données.....	43
3.7	Conclusion.....	45
CHAPITRE 4 IDENTIFICATION DES DÉFAUTS DANS UNE LIGNE DE TRANSMISSION PAR RNA.		46
4.1	Modélisation du système de lignes de transport proposé.....	46
4.2	Traitement des signaux.....	51
4.3	Dataset et entraînement des RNAs.....	53
4.4	Démarches pour la protection de la ligne.....	55
4.5	Méthode d'évaluation des modèles neuronaux	55
4.6	Analyses des performances du modèle détecteur neuronal.....	56
4.6.1	Entraînement du réseau de neurones pour la détection des défauts.....	57
4.6.2	Évaluation du détecteur neuronal adopté.....	60
4.7	Analyses des performances du modèle classificateur neuronal	63
4.7.1	Entraînement du réseau de neurones pour la classification des défauts	63
4.7.2	Évaluation du classificateur neuronal adopté.....	68
4.8	Analyses des performances du modèle localisateur neuronal.....	71

4.8.1	Entraînement du réseau de neurones pour la localisation des défauts	71
4.8.2	Évaluation du localisateur neuronal adopté	75
4.9	Application des modèles conçus sur le système proposé	77
4.10	Relais à base de réseaux de neurones	83
4.11	Conclusion.....	85
CHAPITRE 5 IDENTIFICATION DES DÉFAUTS DANS UN SYSTÈME À DEUX LIGNES PARALLÈLES PAR RNA		
		86
5.1	Modélisation du système de lignes de transport proposé	86
5.2	Base des données d'entraînement/Training Data	90
5.3	Conception des trois modèles : détecteur, classificateur et localisateur neuronal	91
5.3.1	Entraînement du réseau de neurones pour la détection des défauts	91
5.3.2	Entraînement du réseau de neurones pour la classification des défauts	96
5.3.3	Entraînement du réseau de neurones pour la localisation des défauts	102
5.4	Conception d'un modèle neuronal : détecteur, classificateur et localisateur neuronal	108
5.5	Application des modèles conçus sur le système proposé	117
5.6	Conclusion.....	132
CHAPITRE 6 DÉTECTION ET ISOLATION DE LA ZONE DÉFECTUEUSE PAR LE RELAIS INTELLIGENT POUR MISE EN OEUVRE D'UNE PROTECTION EN TEMPS RÉEL		
		133
6.1	Défaut monophasé à la terre	135
6.2	Défaut double phase	140
6.3	Défaut double phase à la terre	143
6.4	Défaut triphasé	147
6.5	Conclusion.....	151
CONCLUSION.....		
		152
ANNEXE A COURBES DES PERFORMANCES ET PARAMÈTRES		
		155
ANNEXE B EXPLOITATION DE LA BASE DES DONNÉES		
		164
BIBLIOGRAPHIE		
		165

LISTE DES FIGURES

Figure 1.1	: Procédure suivie pour identifier les défauts.	4
Figure 2.1	: Modèle d'un réseau électrique.....	9
Figure 2.2	: Schéma unifilaire et la représentation des circuits de défaut de ligne[1].....	18
Figure 2.3	: Schéma de la localisation synchronisée des défauts aux deux extrémités avec utilisation du GPS[1].	22
Figure 2.4	: Schéma de localisation des défauts non synchronisés aux deux extrémités[1].	22
Figure 2.5	: Illustration de la méthode Traveling-Waves.	23
Figure 2.6	: Schéma bloc simplifié d'un système expert	26
Figure 2.7	: Schéma fonctionnel du contrôleur à logique floue.....	28
Figure 3.1	: Illustration d'un réseau de neurones feedforward.	31
Figure 3.2	: La structure de base d'un neurone.....	33
Figure 3.3	: Structure de Back-propagation.	36
Figure 3.4	: Illustration de la méthodologie adoptée.	43
Figure 3.5	: Algorithme simplifié pour la détection, la classification et la localisation des défauts.	44
Figure 4.1	: Modèle du système électrique proposé.....	47
Figure 4.2	: Formes d'onde de tension et de courant du système étudié, sans défaut.....	50
Figure 4.3	: Formes d'onde de tension et de courant pour un défaut entre la phase A et terre.	50
Figure 4.4	: Traitement des signaux de courant et tension.....	52
Figure 4.5	: Courbe de performance du détecteur neuronal 6-26-16-1.....	58
Figure 4.6	: Courbe de performance du détecteur neuronal 6-30-25-9-1.	59
Figure 4.7	: Courbe de performance du détecteur neuronal 6-16-5-1.....	60

Figure 4.8 : Graphe de régression pour le détecteur neuronal.	61
Figure 4.9 : Matrice de confusion du détecteur neuronal.....	62
Figure 4.10 : Configuration du détecteur neuronal adopté.	62
Figure 4.11 : Courbe de performance du classificateur neuronal 6-16-12-6-4.	65
Figure 4.12 : Courbe de performance du classificateur neuronal 6-20-12-4	66
Figure 4.13 : Courbe de performance du classificateur neuronal 6-16-6-4	67
Figure 4.14 : Réseau de neurones adopté pour classification des défauts.	68
Figure 4.15 : Graphe de régression pour le classificateur neuronal.	69
Figure 4.16 : Matrice de confusion du classificateur neuronal.	70
Figure 4.17 : La courbe de la fonction d'efficacité du récepteur ROC.....	70
Figure 4.18 : Courbe de performance du localisateur neuronal 6-30-16-6-3-1.	72
Figure 4.19 : Courbe de performance du localisateur neuronal 6-20-3-1.....	73
Figure 4.20 : Courbe de performance du localisateur neuronal 6-16-9-3-1.....	74
Figure 4.21 : Réseau de neurones adopté pour la localisation des défauts.	74
Figure 4.22 : Graphe de régression pour le localisateur neuronal.....	76
Figure 4.23 : Modèle de protection en temps réel du système électrique proposé.	78
Figure 4.24 : Bloc Relais ANN.	79
Figure 4.25 : Forme d'onde de courant et réponse du détecteur neuronal lors d'un défaut B-G.....	80
Figure 4.26 : Formes d'ondes de courant et tensions après leur traitement.	80
Figure 4.27 : Forme d'onde de courant et réponse du détecteur neuronal lors d'un défaut A-C.....	81
Figure 4.28 : Forme d'onde de courant et réponse du détecteur neuronal lors d'un défaut B-C-G.....	82
Figure 4.29 : Forme d'onde de courant et réponse du détecteur neuronal lors d'un défaut A-B-C.....	82
Figure 4.30 : Réponse de relais pour un défaut A-G à 77 km de Source 1.....	84

Figure 4.31 : Réponse de relais pour un défaut A-B-G à 39 km de Source 1 avec Rf = 10 Ω	84
Figure 4.32 : Réponse de relais pour un défaut B-C à 16 km de Source 1 avec Rf = 24 Ω	84
Figure 4.33 : Réponse de relais pour un défaut A-B-C à 58 km de Source 1 avec Rf = 0.7 Ω	85
Figure 5.1 : Modèle du système électrique proposé.....	87
Figure 5.2 : Formes d'onde de tension et de courant du système étudié au cas de non-défaut.	88
Figure 5.3 : Formes d'onde de tension et de courant pour un défaut entre la phase B et terre dans la ligne1	89
Figure 5.4 : Formes d'onde de tension et de courant pour un défaut entre les phases A-B et terre dans la ligne 2.	90
Figure 5.5 : Courbe de performance du détecteur neuronal 12-16-9-3-2.	93
Figure 5.6 : Courbe de performance du détecteur neuronal 12-14-6-2.....	94
Figure 5.7 : Courbe de performance du détecteur neuronal 12-32-16-2.....	95
Figure 5.8 : Graphe de régression pour le détecteur neuronal.	96
Figure 5.9 : Courbe de performance du classificateur neuronal 12-25-12-6-8.....	98
Figure 5.10 : Courbe de performance du classificateur neuronal 12-15-8.....	99
Figure 5.11 : Courbe de performance du classificateur neuronal 12-30-16-8.	100
Figure 5.12 : Graphe de régression pour le classificateur neuronal.....	101
Figure 5.13 : La courbe de la fonction d'efficacité du récepteur ROC.....	102
Figure 5.14 : Courbe de performance du localisateur neuronal 12-16-4-2.....	103
Figure 5.15 : Courbe de performance du localisateur neuronal 12-16-9-2.....	104
Figure 5.16 : Courbe de performance du localisateur neuronal 12-32-16-4-2.....	105
Figure 5.17 : Graphe de régression pour le localisateur neuronal.....	106
Figure 5.18 : Courbe de performance du réseau neuronal 12-30-12.	110
Figure 5.19 : Graphe de régression pour le réseau neuronal 12-30-12.	110

Figure 5.20 : Courbe de performance du réseau neuronal 12-32-20-5-12.....	111
Figure 5.21 : Graphe de régression pour le réseau neuronal 12-32-20-5-12.	112
Figure 5.22 : Courbe de performance du réseau neuronal 12-30-26-16-4-12.....	113
Figure 5.23 : Graphe de régression pour le réseau neuronal 12-32-26-16-4-12.	113
Figure 5.24 : Courbe de performance du réseau neuronal 12-27-15-12.	114
Figure 5.25 : Graphe de régression pour le réseau neuronal 12-27-15-12.....	115
Figure 5.26 : Courbe de performance du réseau neuronal 12-31-16-12.	116
Figure 5.27 : Graphe de régression pour le réseau neuronal 12-31-16-12.....	117
Figure 5.28 : Ensemble de blocs de protection pour l'approche1.....	118
Figure 5.29 : Composants du bloc relais à réseaux de neurones artificiels.....	119
Figure 5.30 : Ensemble de blocs de protection pour l'approche2.....	120
Figure 5.31 : Résultats obtenus par l'approche 1 pour un défaut de type phase A-Terre à 6 km du terminal de la ligne 1.....	121
Figure 5.32 : Résultats obtenus par l'approche 2 pour un défaut de type phase A-Terre à 6 km du terminal de la ligne 1.....	122
Figure 5.33 : Résultats obtenus par l'approche 1 pour un défaut de type phase C-Terre à 17 km du terminal de la ligne 1.....	123
Figure 5.34 : Résultats obtenus par l'approche 2 pour un défaut de type phase C-Terre à 17 km du terminal de la ligne 1.....	124
Figure 5.35 : Résultats obtenus par l'approche 1 pour un défaut de type double phase B-C à 29 km du terminal de la ligne 1.....	125
Figure 5.36 : Résultats obtenus par l'approche 2 pour un défaut de type double phase B-C à 29 km du terminal de la ligne 1.....	126
Figure 5.37 : Résultats obtenus par l'approche 1 pour un défaut de type double phase A-B-Terre à 5 km du terminal de la ligne 2.....	127
Figure 5.38 : Résultats obtenus par l'approche 2 pour un défaut de type double phase A-B-Terre à 5 km du terminal de la ligne 2.....	128
Figure 5.39 : Résultats obtenus par l'approche 1 pour un défaut de type double phase B-C-Terre à 13 km du terminal de la ligne 2.....	129

Figure 5.40 : Résultats obtenus par l'approche 2 pour un défaut de type double phase B-C-Terre à 13 km du terminal de la ligne 2.....	130
Figure 5.41 : Résultats obtenus par l'approche 1 pour un défaut de type triphasé A-B-C à 20 km du terminal de la ligne 2.....	131
Figure 5.42 : Résultats obtenus par l'approche 2 pour un défaut de type triphasé A-B-C à 20 km du terminal de la ligne 2.....	131
Figure 6.1 : Modèle de protection intelligent en temps réel basé sur le réseau de neurones artificiels.....	135
Figure 6.2 : Formes d'ondes au cas d'un défaut phase B-Terre à 26 km.....	136
Figure 6.3 : Signaux de déclenchement au cas d'un défaut phase B-Terre à 26 km.....	137
Figure 6.4 : Formes d'ondes au cas d'un défaut phase A-Terre à 63 km.	138
Figure 6.5 : Signaux de déclenchement au cas d'un défaut phase A-Terre à 63 km.....	139
Figure 6.6 : Résultats de simulation obtenue au cas d'un défaut de type phase A-terre à 63 km.	139
Figure 6.7 : Formes d'ondes au cas double phases A-B à 43 km.	140
Figure 6.8 : Signaux de déclenchement au cas double phases A-B à 43 km.	141
Figure 6.9 : Formes d'ondes au cas double phases B-C à 75 km.....	142
Figure 6.10 : Signaux de déclenchement au cas double phases B-C à 75 km.	143
Figure 6.11 : Formes d'ondes au cas double phases à la terre A-C-Terre à 40 km.....	144
Figure 6.12 : Signaux de déclenchement au cas double phases à la terre A-C-Terre à 40 km.....	145
Figure 6.13 : Formes d'ondes au cas double phase à la terre B-C-Terre à 87 km.....	146
Figure 6.14 : Signaux de déclenchement au cas double phase à la terre B-C-Terre à 87 km.	147
Figure 6.15 : Formes d'ondes au cas triphasé A-B-C à 13 km.	148

Figure 6.16 : Signaux de déclenchement au cas triphasé A-B-C à 13 km.	149
Figure 6.17 : Formes d'ondes au cas triphasé A-B-C à 99 km.	150
Figure 6.18 : Signaux de déclenchement au cas triphasé A-B-C à 99 km.	150

LISTE DES TABLEAUX

Tableau 3-1 : Fonctions d'activation.	38
Tableau 3-2 : Algorithmes d'apprentissage dans Neural Network Toolbox.....	41
Tableau 4-1 : Paramètres du modèle PI de ligne de transmission.....	48
Tableau 4-2: Paramètres pour la génération de Dataset.....	49
Tableau 4-3 : Exemples d'entrées du réseau de neurones pour différents cas de défaut.	53
Tableau 4-4 : Sorties désirées du classificateur neuronal.	64
Tableau 4-5 : Comparaison entre sorties réelles et sorties prédites par le localisateur neuronal.....	76
Tableau 5-1 : Paramètres pour la génération de Dataset.....	91
Tableau 5-2 : Sorties désirées du classificateur neuronal.	97
Tableau 5-3 : Comparaison entre sorties réelles et sorties prédites par le localisateur neuronal.....	107
Tableau 5-4 : Sorties du réseau de neurones et leurs correspondants états.....	108

LISTE DES ABRÉVIATIONS, DES SIGLES ET DES ACRONYMES

ANN	:	Artificial Neural Network
BP	:	Back-propagation
C-C	:	Court-Circuit
DEI	:	Dispositif électronique intelligent
DL	:	Deep Learning
EMTP	:	Electromagnetic Transient Program
ETAP	:	Electrical Transient and Analysis Program
FL	:	Fault Locator
GPS	:	Global Positioning System
IA	:	Intelligence Artificielle
IEEE	:	Institute of Electrical and Electronics Engineers
L-L	:	Double lignes
L-L-L	:	Triphasé
L-L-L-T	:	Triphasé à la terre
L-L-T	:	Double ligne à la terre
L-T	:	Ligne à la Terre
ML	:	Machine Learning
MLP	:	Multi Layer Perceptron
RMS	:	Root Mean Square
RNA	:	Réseau de Neurones Artificiels
UQAT	:	Université de Québec en Abitibi-Témiscamingue

LISTE DES SYMBOLES ET DES UNITÉS

%	:	Pourcentage
$b_j^{(i)}$:	Le biais (seuil) du neurone j .
$u_j^{(i)}$:	La j ième entrée de la i ème couche cachée
$w_j^{(i)}$:	Représente les coefficients de poids de la connexion entre les entrées et le neurone j
$e_{jp}^{(L)}$:	L'erreur entre la sortie donnée par le réseau y_s et le vecteur $y_{s\text{-désirée}}$ désiré à la sortie
I_0	:	Courant homopolaire
I_F	:	Courant du défaut
I_s	:	Courant sortant de la source S
R_F	:	Résistance de défaut
V_R	:	La tension à la borne R
V_s	:	La tension à la borne S
W^i	:	Matrice des poids
$y_j^{(i)}$:	Représente les signaux d'entrée du neurone j et n nombre de neurones dans la couche cachée i
y_s	:	La sortie donnée par le réseau
$y_{s\text{-désirée}}$:	Le vecteur désiré à la sortie
Z_{0L}	:	L'impédance homopolaire de la ligne
Z_{1L}	:	L'impédance de la ligne de séquence positive
δ_j^i	:	Le j ième erreur local de la i ème couche cachée

°	:	Degré
A	:	Ampère
F	:	Farad
f(.)	:	Fonction d'activation
G	:	Générateur
H	:	Henry
I	:	Courant
i	:	Couche cachée
Ia	:	Courant à la phase A
Ib	:	Courant à la phase B
Ic	:	Courant à la phase C
Km	:	Kilomètres
KV	:	Kilovolts
KW	:	Kilowatts
m	:	Milli
m	:	La distance entre défaut et source par unité
n	:	Nano
R	:	Récepteur
s	:	Seconde
S	:	Source
T	:	Tension
T	:	Période

t	:	Temps
U_i	:	Couche d'entrée
V	:	Volt
V_a	:	Tension à la phase A
Vars	:	Voltampère réactif
V_b	:	Tension à la phase B
V_c	:	Tension à la phase C
Y_i	:	Couche de sortie
Z_0	:	Impédance homopolaire
Z_L	:	Impédance de ligne
Z_R	:	Impédance de récepteur
Z_s	:	Impédance de source
μ	:	Taux d'apprentissage de faible magnitude et compris entre 0 et 1.
Ω	:	Ohm

RÉSUMÉ

La croissance rapide des systèmes d'énergie électrique observée au cours des dernières décennies a entraîné une forte augmentation du nombre de lignes de transmission et de distribution en service dans le monde. En outre, la commercialisation et la déréglementation introduites partout dans le monde imposent des exigences de plus en plus restrictives pour assurer une alimentation électrique continue et de bonne qualité, sans augmentation significative du coût de l'énergie fournie.

Les défauts électriques sont l'un des facteurs les plus importants qui entravent la fourniture continue d'électricité et de courant. La détection des défauts sur les lignes de transmission constitue une partie majeure et importante de la surveillance et contrôle des systèmes électriques, l'intégration d'un système de protection intelligent va permettre de détecter rapidement voire prévoir l'occurrence d'un défaut, par conséquent éviter les dommages catastrophiques aux biens matériels et humains. Ce projet analyse l'utilisation des réseaux de neurones pour la détection, classification et localisation des défauts dans les lignes de transport de l'énergie électrique pour soutenir une nouvelle génération de système de relais de protection à grande vitesse et avec précision.

Les défauts entraînent des temps d'arrêt du système, des dommages aux équipements et présentent un risque élevé pour l'intégrité du réseau électrique, et affectent son opérabilité et sa fiabilité. Le réseau de neurones de type feedforward sera utilisé ainsi qu'un algorithme de rétropropagation (backpropagation) pour chacune des trois phases pour indiquer l'absence ou la présence du défaut, le classifier en fonction de ses caractéristiques transitoires et pointer son emplacement sur une ligne de transmission.

Mots clés : Réseaux électriques, réseau de neurones, détection, classification, localisation des défauts, réseau de neurones feedforward, algorithme de back-propagation, relais intelligent.

ABSTRACT

The rapid growth of electric power systems over the last few decades has led to a sharp increase in the number of transmission and distribution lines in service around the world. In addition, commercialization and deregulation introduced worldwide are imposing increasingly restrictive requirements to ensure a continuous and good quality power supply without significant increases in the cost of the energy supplied.

Electrical faults are one of the most important factors hindering the continuous supply of electricity and power. The detection of faults on transmission lines is a major and important part of the monitoring and control of electrical systems. The integration of an intelligent protection system will allow the rapid detection or even prediction of the occurrence of a fault, thus avoiding catastrophic damage to material and human assets. This project analyzes the use of neural networks for the detection, classification, and location of faults in electrical power transmission lines to support a new generation of high-speed and accurate protective relay systems.

Faults result in system downtime, equipment damage, and present a high risk to the integrity of the power system and affect network operability and reliability. The feedforward neural network will be used as well as a backpropagation algorithm for each of the three phases to indicate the absence or presence of the fault on a transmission line, classify it according to its transient characteristics and indicate its location on the line.

Keywords: Electrical networks, neural network, detection, classification, fault location, feedforward neural network, Back-propagation algorithm.

CHAPITRE 1

INTRODUCTION

Les réseaux électriques, dont la taille et complexité augmentent au fil des temps, seront toujours exposés aux défaillances de leurs composants. En cas de défaut électrique, l'élément défectueux doit être isolé et déconnecté du reste du système électrique afin de minimiser les dommages sur la structure intégrale. Cette action doit être rapide, précise et réalisée par un système de protection intelligent, par exemple les relais de protection automatique. Ce premier chapitre présente le contexte général du projet et sa problématique, en soulignant les objectifs fixés et la méthodologie de recherche adoptée pour la traiter et résoudre.

1.1 Contexte général

La croissance rapide des systèmes d'énergie électrique observée au cours des dernières décennies a entraîné une forte augmentation du nombre de lignes de transmission et de distribution en service dans le monde. En outre, la commercialisation et la déréglementation introduites partout dans le monde imposent des exigences de plus en plus restrictives pour assurer une alimentation électrique continue et de bonne qualité, sans augmentation significative du coût de l'énergie fournie [1]. Des termes tels que la continuité de l'approvisionnement en électricité, la fiabilité, la sécurité et les nouvelles technologies intelligentes (Intelligence Artificielle) jouent un rôle très important pour les systèmes d'électricité contemporains. Les défauts électriques sont l'un des facteurs les plus importants qui entravent la fourniture continue d'électricité et de courant [2]. Ces défauts ne peuvent pas être complètement évités, car une partie de ces défauts est due à des raisons naturelles qui échappent au contrôle de l'humain, par exemple la foudre ou bien un court-circuit causé par un contact momentané avec un arbre ou bien un oiseau, etc. Ces défauts peuvent être dus aussi aux erreurs humaines, à la surcharge

et au mauvais fonctionnement d'un composant ou bien son vieillissement. Ces derniers peuvent être de différents types, à savoir transitoires, persistants, symétriques ou asymétriques. Le processus de détection de chacun de ces défauts est distinctement unique en ce sens qu'il n'existe pas de méthode universelle de localisation pour tous ces types [3-6].

Depuis quelques années, des méthodes basées sur l'intelligence artificielle [5-10] ont été utilisées pour localiser avec précision les défauts. En raison des exigences restrictives imposées, une demande accrue de haute qualité des dispositifs de protection et de contrôle des systèmes d'alimentation électrique ainsi que de leurs équipements supplémentaires est apparue comme primordiale [1]. Parmi les différentes capacités de ces dispositifs, la fonction de localisation des défauts est considérée comme très importante, si la localisation d'un défaut ne peut être identifiée rapidement et que cela entraîne une interruption prolongée de la ligne pendant une période de charge de pointe, de graves pertes économiques peuvent survenir et la fiabilité du service peut être remise en question. Toutes ces circonstances ont fait ressortir la grande importance des études de recherche sur la localisation des défauts [2, 3, 7-12].

Les concepts associés au réseau intelligent préoccupant de plus en plus les chercheurs, on ne saurait trop insister sur l'importance d'un système intelligent de surveillance et de diagnostic des défauts capable de classifier et de localiser différents types de défauts. Les progrès des techniques de traitement du signal, de l'intelligence artificielle et de l'apprentissage automatique, du système de positionnement global (GPS) et des communications ont permis à un nombre croissant de chercheurs de mener des études d'une grande ampleur et d'une grande profondeur, au point de repousser les limites des techniques classiques de diagnostic des défauts, telles que la méthode basée sur la mesure de l'impédance [13-15], la méthode des ondes progressives [16, 17].

Depuis quelques années, des méthodes basées sur l'intelligence artificielle ont été largement utilisées pour localiser avec précision les défauts sur les lignes de transmission [2-6, 9, 12, 18-25]. Cette étude présente une méthode de détection, classification et localisation des défauts électriques, l'approche des réseaux neuronaux à rétropropagation est étudiée et mise en œuvre. Trois grandes techniques basées sur l'intelligence artificielle ont été largement utilisées dans les industries du système électrique [1]:

- Technique du système expert;
- Réseau de neurones artificiels;
- Système de logique floue.

Les réseaux de neurones artificiels (RNA) ont une importance majeure dans les applications des réseaux électriques. De plus en plus, de nombreuses études ont été menées dans le monde entier pour utiliser la technique RNA dans le domaine de la protection des réseaux électriques. A. Aljohani et al [26] ont conçu un localisateur intelligent de défaut monophasé à la terre basé sur les RNA pour les alimentations de distribution, Resmi et al [3] ont proposé un algorithme pour la détection, la classification et la localisation des défauts non symétriques en utilisant les RNA. Cependant, les défauts symétriques n'étaient pas pris en considération et ne pouvaient localiser que la zone du défaut. A. Isa et al [27] ont combiné l'utilisation du réseau neuronal et de la logique floue pour développer un algorithme de protection des lignes de transmission. Cuicui L et al [28] ont proposé une méthode de diagnostic des défauts basée sur la combinaison d'une transformée en ondelettes (Wavelet Transform) et d'un réseau neuronal dans le système à haute tension et à courant continu. Kaur et al [29] ont appliqué la classification basée sur le réseau neuronal artificiel ANN comme schéma de protection à un système à 14 bus IEEE et ont prouvé leur efficacité à être appliqué à des réseaux électriques encore plus compliqués avec une grande précision.

Le réseau de neurones artificiel sera utilisé dans cette étude, vu son efficacité et performance démontrée dans la revue de littérature pour l'identification et la localisation des défauts sur les lignes de transmission d'énergie électrique. Ces méthodes basées sur le réseau neuronal artificiel ne nécessitent pas de base de connaissance pour la localisation des défauts, contrairement aux autres méthodes basées sur l'intelligence artificielle. La figure 1.1 montre la procédure suivie pour l'identification des défauts.

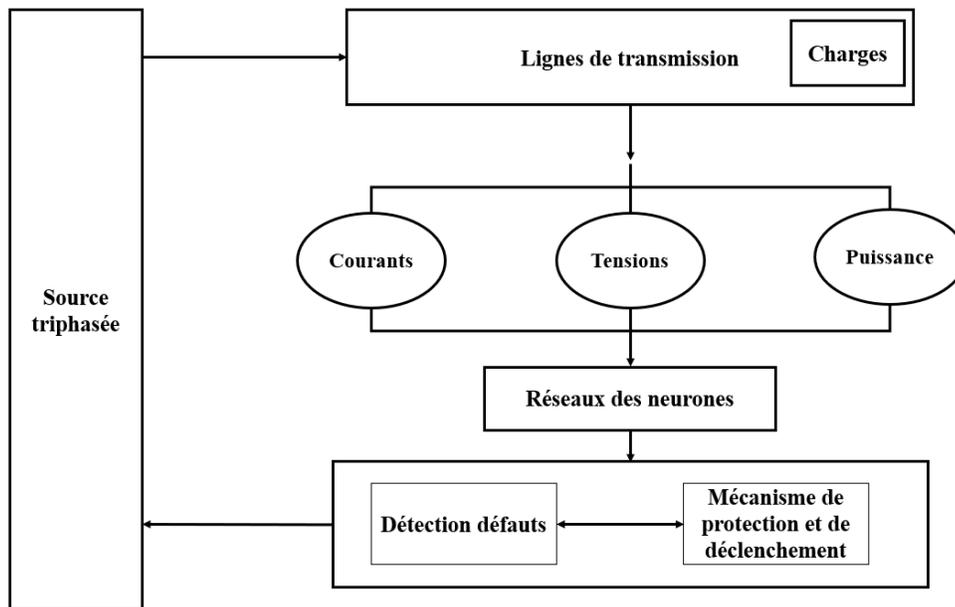


Figure 1.1 : Procédure suivie pour identifier les défauts.

1.2 Problématique

En raison du fait que leurs câbles ne sont pas isolés et sont directement exposés à des conditions atmosphériques sévères, les lignes de transmission sont plus sujettes à l'apparition des défauts que les lignes de distribution locales. De plus, elles sont relativement très longues et peuvent traverser des terrains géographiques variés, ce qui peut prendre beaucoup de temps pour vérifier physiquement la présence de défauts sur

la ligne [30], d'où l'attention portée par la plupart des chercheurs dans le domaine des relais de protection des systèmes électriques.

Différents algorithmes ont été développés afin d'obtenir une meilleure estimation de la position de défaut en fonction des données extraites d'une ou des deux extrémités de la ligne de transmission. Le sujet de la localisation des défauts présente un intérêt considérable pour les ingénieurs et les chercheurs depuis de nombreuses années. La plupart des recherches effectuées jusqu'à présent visaient à localiser les défauts des lignes de transmission. Ceci est principalement dû à l'impact des défauts des lignes de transmission sur les systèmes électriques et le temps nécessaire pour vérifier physiquement les lignes [1, 2, 23]. La localisation d'un défaut dans le système de transport de l'énergie électrique n'est pas une tâche facile en raison de sa grande complexité et de la difficulté causée par la non-homogénéité de la ligne, la résistance aux défauts, l'incertitude de la charge et le déséquilibre des phases.

En outre, les défauts électriques et leur impact sur les charges des clients constituent le problème de qualité de l'énergie le plus courant des systèmes électriques [31]. Ils peuvent entraîner le déclenchement des équipements des clients et l'arrêt des lignes de production, ce qui entraîne une perte de production et des procédures de redémarrage coûteuses. Parmi les exemples de défauts électriques, on peut citer la chute de la tension, où des équipements électriques sensibles tels que les processus contrôlés par ordinateur, les variateurs de vitesse et les moteurs à induction, verraient leurs performances se détériorer en raison de la chute de tension. Selon certaines estimations, ces défauts peuvent causer des problèmes encore plus graves que les interruptions, où un seul défaut électrique peut entraîner l'arrêt d'une production et entraîne donc des coûts de recouvrement très élevés et des pertes de recettes en raison de perte de production [32].

1.3 Motivation et objectifs

Dans la société contemporaine, les clients sont plus sensibles aux coupures en courant. Par conséquent, des méthodes plus efficaces pour la localisation des défauts, le rétablissement de l’approvisionnement, qui réduisent les coûts globaux, sont nécessaires.

Le motif principal de cette étude est l’impact significatif du localisateur de défauts que pourrait faire si on l’employait dans un système de transmission et de distribution d’électricité, en termes d’argent et de temps qui peuvent être économisés. Un des aspects importants sur lequel cette recherche se concentre est l’analyse des tensions et des courants de phase de la ligne de transmission sous diverses conditions de défaut et comment ils peuvent être utilisés efficacement dans la conception d’un localisateur de défaut.

1.3.1 Objectif général

L’objectif principal de cette recherche est d’étudier et concevoir avec succès un système de protection intelligent, basé sur le réseau de neurones artificiels, qui peut détecter, classifier et localiser les défauts dans les lignes de transmission d’électricité.

1.3.2 Objectifs spécifiques

1. Implémenter un modèle de réseau électrique dans la plateforme Matlab/Simulink pour la simulation.
2. Mesurer les valeurs de courants et tensions.
3. Traitement des signaux et extraction des caractéristiques fondamentales.
4. Générer la base des données.
5. Entraînement des réseaux de neurones.
6. Détecter, classifier et localiser les défauts électriques en temps réel.
7. Isoler la section défectueuse.

1.4 Méthodologie de recherche

Pour atteindre les objectifs de cette étude, on étudie une section du réseau électrique constituée d'une ligne de transmission dans laquelle un défaut électrique est appliqué, ce qui est basé sur une étude de simulation. D'un point de vue pratique, il faut du temps à une industrie pour diagnostiquer les défauts de la ligne de transmission, mais en utilisant des études de simulation, le diagnostic et les mesures correctives peuvent être planifiés plus efficacement.

Dans ce rapport, la littérature a été passée en revue à partir d'actes de conférences, d'articles de journaux et des livres qui ont constitué la base d'une recherche bibliographique.

Des simulations complètes vont être réalisées pour valider les performances des réseaux de neurones conçus. Pour ce faire, une base des données d'entraînement sera générée à l'aide de modèle de Simulink, basée sur différents régimes et conditions de fonctionnement d'un modèle de ligne de transmission. Cela comprend les variations de la charge électrique, les variations de la longueur de la ligne de transmission et les variations des caractéristiques de la ligne de transmission. Chacune de ces conditions est simulée et des données consolidées seront ensuite utilisées pour entraîner le réseau de neurones artificiels.

1.5 Conclusion

Ce chapitre a présenté une introduction sur le sujet à traiter tout en élaborant sa problématique, les objectifs fixés et la méthodologie de recherche suivie. Reste à évaluer les méthodes de détection des défauts et d'analyser l'identification des défauts par l'application de réseaux neuronaux artificiels, il constituera la principale contribution de ce rapport.

CHAPITRE 2

APERÇU SUR LA DÉTECTION ET LE DIAGNOSTIC DES DÉFAUTS ÉLECTRIQUES

Ce chapitre présente l'état des recherches dans le domaine de détection des défauts, donne une revue sur les différents types de défauts, les différentes méthodes utilisées pour les détecter, les localiser et une comparaison entre ces méthodes.

2.1 Réseau électrique

Les systèmes d'alimentation électrique en courant alternatif sont constitués de systèmes de production triphasés, de réseaux de transport et de distribution, et des charges. Les réseaux alimentent de grandes charges industrielles triphasées à différentes tensions de distribution et de transmission, ainsi que des charges résidentielles et commerciales monophasées. Par conséquent, ces systèmes se composent d'un certain nombre d'unités de production, de lignes de transmission, de lignes de distribution et de sous-stations. Ces derniers fonctionnent ensemble pour former un système complet d'énergie électrique (Electrical Power System).

Dans certains pays, par exemple en Amérique du Nord, le terme sous-transmission est utilisé pour désigner les réseaux ayant des classes de tension entre la transmission et la distribution. Les tensions de distribution sont généralement de 10 à 60 kV, les tensions de sous-transmission sont généralement de 66 à 138 kV et les tensions de transmission sont généralement supérieures à 138 kV [33].

Les lignes de transmission ont des résistances, des capacités et des inductances qui varient avec la longueur de la ligne et qui ont un rôle à jouer dans leur comportement dynamique. De plus, elles sont modélisées comme des sections de topologie π ou T sur

la longueur de la ligne, où la ligne est l'agrégation de plusieurs sections π ou T. Il est ainsi plus facile de modéliser la ligne de transmission. Avant que l'électricité ne soit injectée dans le réseau, elle doit être transmise par la ligne à haute tension, comme le montre la figure 2.1. Une ligne de transport typique est divisée en trois parties fonctionnelles, comme indiqué ci-dessous :

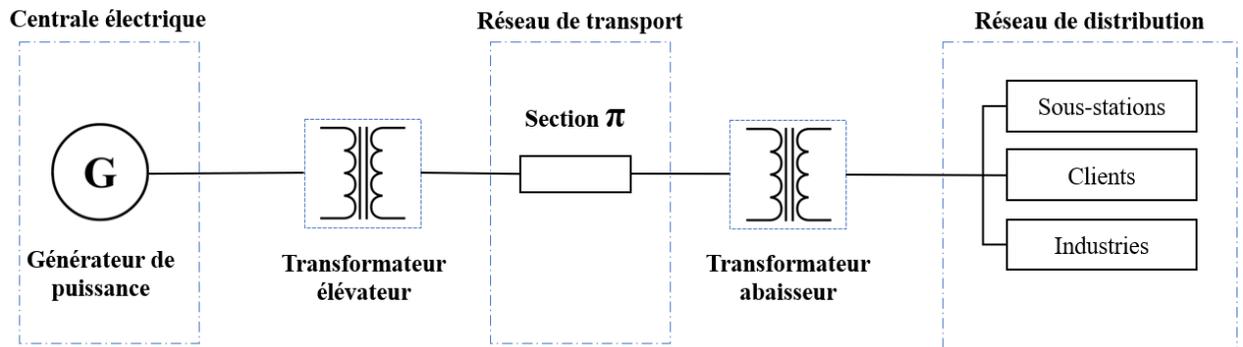


Figure 2.1 : Modèle d'un réseau électrique.

2.2 Système de protection des lignes de transmission

La protection des lignes de transmission joue un rôle important pour répondre aux exigences de stabilité des réseaux d'énergie électrique, tout d'abord, en termes de stabilité de la tension et surtout en contrôlant et protégeant les lignes de transmission contre les défauts. Par conséquent, la protection du réseau électrique est l'un des aspects les plus importants des systèmes d'alimentation électrique.

Ses objectifs sont les suivants :

- Assurer la sécurité du personnel;
- Améliorer le fonctionnement du système électrique, y compris sa stabilité;
- Protéger les actifs du réseau électrique tel que les générateurs et les transformateurs, etc.

La protection du système, en général, est nécessaire pour détecter toute condition anormale et isoler le nombre minimum de dispositifs afin de ramener le système à un état de fonctionnement normal le plus rapidement possible. Beaucoup de travail a été fait dans le domaine de la protection et de nombreuses normes ont été compilées, par exemple la norme IEEE 242-2001, le Buff Book de l'IEEE. Le IEEE Bu Book est une norme typique pour l'utilisation finale (guide d'application), qui décrit les techniques pour la sélection, l'application et la coordination appropriées des dispositifs de protection pour les installations industrielles et les bâtiments commerciaux [34].

Tout type de protection doit être sélectif, fiable, rapide, et adaptable aux conditions changeantes d'exploitation et/ou de topologie du réseau [35, 36].

2.3 Les défauts dans le réseau électrique

Un défaut est une condition anormale qui implique une défaillance des équipements du système d'alimentation fonctionnant à l'une des tensions primaires du système. Les causes des défauts survenant dans les systèmes électriques sont diverses. La rupture de l'isolation peut être causée par des coups de foudre sur les lignes aériennes. La liaison avec la terre est alors établie par un fil de terre. De plus, cette connexion à la terre se produit lorsqu'un arbre ou un objet artificiel fournit le chemin de la liaison. Certains défauts sont également causés par des erreurs de commutation du personnel de la station.

Les défauts peuvent être des défauts shunt, en série ou une combinaison de défauts shunt et en série. Dans le cas d'un défaut shunt, il y a un flux de courant entre deux ou plusieurs phases, ou entre les phases et la terre. Un défaut en série est une anomalie pour laquelle les impédances des trois phases ne sont pas égales, généralement causée par l'interruption d'une ou deux phases [1].

La plupart des défauts du système électrique se produisent dans les lignes de transmission, en particulier sur les lignes aériennes. Les lignes sont les éléments du système qui sont chargés de transporter d'importantes quantités d'énergie des centrales électriques aux clients (charges). En raison de leur caractéristique inhérente d'être exposées aux conditions atmosphériques, elles présentent le taux de défaillance le plus élevé du système. C'est pourquoi un certain nombre de chercheurs ont consacré beaucoup d'efforts à la protection des lignes et à la localisation des défauts [5-10, 18-20, 35, 37].

2.3.1 Types de défauts

Les défauts électriques dans le réseau triphasé sont principalement classés en deux types, à savoir les défauts de circuit ouvert et de court-circuit. En outre, ces défauts peuvent être symétriques ou non symétriques.

- **Défauts de circuit ouvert**

Ces défauts sont dus à la rupture d'un ou de plusieurs conducteurs[38]. Leurs causes les plus courantes sont les défaillances de câbles et de lignes aériennes, d'une ou de plusieurs phases du disjoncteur et la fusion d'un fusible ou d'un conducteur dans une ou plusieurs phases. Les défauts de circuit ouvert sont également appelés défauts en série.

Pendant ce type de défaut, un courant déséquilibré circule dans le système, chauffant ainsi les machines tournantes[39]. En outre, considérons qu'une ligne de transmission fonctionne avec une charge équilibrée avant l'apparition d'un défaut de circuit ouvert. Si l'une des phases fond, la charge réelle de l'alternateur est réduite et cela provoque une augmentation de l'accélération de l'alternateur, qui fonctionne alors à une vitesse légèrement supérieure à la vitesse synchrone. Cette vitesse excessive entraîne des

surtensions dans d'autres lignes de transmission. Des dispositifs de protection donc doivent être mis en œuvre pour faire face à de telles conditions anormales.

En effet, c'est la ligne de transmission qui contribue le plus à l'instabilité du système électrique, ce qui justifie l'intérêt porté à la protection des lignes de transmission[23]. D'autre part, il existe de nombreuses solutions de protection de la ligne de transmission proposées par les principales entreprises de protection des lignes de transmission[40]. Cependant, les solutions proposées ne sont pas parfaites, ce qui laisse la place à d'autres études afin d'améliorer les solutions actuelles. En intégrant des solutions basées sur l'intelligence artificielle capable de détecter rapidement le défaut, identifier son type et donner sa localisation précise afin de l'éliminer.

- **Défauts de court-circuit**

Un court-circuit peut être défini comme une connexion anormale de très faible impédance entre deux points de potentiel différent, qu'elle soit faite intentionnellement ou accidentellement. Il s'agit du type de défaut le plus courant et le plus grave, qui entraîne la circulation de courants anormalement élevés dans les équipements ou les lignes de transmission. Si on laisse ces défauts persister, même pendant une courte période, cela entraîne des dommages importants aux équipements.

Les défauts de court-circuit sont également appelés défauts de dérivation (shunt). Ces défauts sont causés par un défaut d'isolation entre les conducteurs de phase ou entre la terre et les conducteurs de phase ou les deux[40].

Les différentes conditions de court-circuit possibles sont les suivantes : triphasé à la terre (L-L-L-T), triphasé hors terre (L-L-L), phase à phase (L-L), monophasé à la terre (L-T) et biphasé à la terre (L-L-T). Les défauts triphasés hors terre et les défauts

triphasés à la terre sont des défauts de court-circuit équilibrés ou symétriques, tandis que les autres défauts restants sont des défauts non symétriques.

- **Les défauts symétriques**

Un défaut symétrique donne lieu à des courants de défaut symétriques qui sont décalés de 120° l'un par rapport à l'autre. Il est également appelé défaut équilibré. Ce défaut se produit lorsque les trois phases sont simultanément court-circuitées.

Ces défauts se produisent rarement en pratique par rapport aux défauts non symétriques. Il existe deux types de défauts symétriques : les défauts triphasés (L-L-L) et les défauts triphasés à la terre (L-L-L-T).

Les défauts symétriques représentent en gros entre 2 et 5 % de l'ensemble des défauts du système[38]. Cependant, s'ils se produisent, ils causent un dommage très grave aux équipements même si le système reste en état d'équilibre. L'analyse de ces défauts est nécessaire pour sélectionner la capacité de rupture des disjoncteurs, choisir le réglage des relais de phase et autres dispositifs de protection. Ces défauts sont analysés par phase en utilisant la matrice d'impédance de bus ou le théorème de Thevenin.

- **Les défauts non symétriques**

Les défauts les plus courants qui se produisent dans le réseau électrique sont les défauts asymétriques. Ce type de défaut donne lieu à des courants de défaut asymétriques (ayant des amplitudes différentes avec un déphasage inégal). Ils sont également appelés défauts déséquilibrés, car ils provoquent des courants déséquilibrés dans le système. Les défauts asymétriques comprennent à la fois les défauts de circuit ouvert (état ouvert monophasé et biphasé) et les défauts de court-circuit (à l'exclusion des L-L-L-T et L-L-L).

Les défauts asymétriques sont analysés en utilisant des méthodes de composants asymétriques afin de déterminer la tension et les courants dans toutes les parties du système. Son analyse est plus difficile que celle des défauts symétriques.

2.3.2 Détection de défaut

La détection des défauts est une question qui occupe les ingénieurs depuis la création de la technologie des systèmes électriques. Non seulement elle joue un rôle important dans l'exploitation et le contrôle des réseaux électriques, mais une détection précise des défauts améliore les performances opérationnelles et protège contre des éventualités indésirables. La précision et la vitesse de détection sont des mesures de l'efficacité du mécanisme de détection ; plus ce mécanisme est rapide, plus il est possible de protéger l'équipement et éviter des dépenses énormes, en général, la détection des défauts est effectuée avant la classification et la localisation des défauts.

En général, les algorithmes utilisés sont similaires à ceux appliqués à des relais de protection, cependant, lorsqu'ils sont réalisés hors ligne, ils peuvent adopter des principes plus sophistiqués pour la réduction des erreurs[1]. Souvent, cette partie de la procédure commune est réalisée par le relais de protection qui fournit au localisateur de défauts les informations nécessaires sur le défaut identifié et les données enregistrées.

Un certain nombre d'approches de la détection des défauts sont proposées dans la littérature. Les conditions anormales (pas nécessairement des défauts) sont détectées en surveillant les impédances de phase et/ou les amplitudes de courant de phase et/ou les amplitudes de tension de phase et/ou l'amplitude de courant homopolaire[33]. En fonction d'une application particulière, différents critères d'activation sont combinés de manière différente.

La mise en œuvre d'un détecteur de défauts n'est pas une procédure difficile, car les microprocesseurs électroniques à grande vitesse, les techniques avancées de traitement

numérique des signaux et les systèmes matériels embarqués spécialisés offrent des méthodes de mise en œuvre matérielles suffisantes et satisfaisantes.

2.3.3 Classification des défauts

Les défauts des lignes de transmission peuvent être classifiés en différents types de défauts en fonction de leur caractéristique. Les tensions et les courants transitoires présentent un comportement différent, ce qui permet aux méthodes de classification des défauts de pouvoir les identifier et les classifier avec précision.

La classification des types de défauts joue un rôle important dans les relais de protection des lignes de transmission et des systèmes de distribution d'énergie. C'est pourquoi les chercheurs s'intéressent depuis des décennies à la mise au point de nouveaux algorithmes et modèles de classification des défauts, robustes et précis. La majorité des méthodes de classification adoptent des modèles de classification basés sur la théorie de l'apprentissage statistique [41], tandis que d'autres travaux utilisent des méthodes intelligentes basées sur l'expérience et l'exploitation des données collectées. Il est à noter l'évolution des études dans ce domaine particulier a été très pertinent pour le développement de la reconnaissance des formes et de l'apprentissage des machines (Machine Learning) [9] (plus précisément, les algorithmes d'apprentissage supervisé pour la classification).

2.3.4 Localisation des défauts

Un nombre considérable d'études ont porté sur la localisation des défauts, dans la mesure où la localisation précise des défauts dans les lignes de transmission et les systèmes de distribution peuvent réduire considérablement le délai de rétablissement. Un examen complet de la localisation des défauts dans les réseaux électriques est fourni dans [1].

La plupart des défauts qui se produisent habituellement sur les lignes aériennes haute tension sont des défauts monophasés à la terre. Les relais de protection et le réenclencheur automatique ont été utilisés pour surveiller les lignes de transmission et de distribution. En cas de défaut, le réenclencheur déclenche la ligne et, une fois le défaut éliminé, il met immédiatement la ligne sous tension. Si le défaut se produit sur la ligne de transmission ou de distribution, le relais doit être capable de détecter le plus rapidement possible tout type de défaut qui pourrait se produire et envoyer un signal de déclenchement au disjoncteur.

2.4 Les techniques de localisation des défauts dans les lignes de transmission

Le processus de localisation des défauts dans les lignes de transmission, comme mentionné précédemment, a fait l'objet de plusieurs recherches et plusieurs techniques innovantes et efficaces ont été proposées et analysées par plusieurs auteurs [3, 42-46]. Ces techniques peuvent être classées en trois grandes catégories : méthodes à haute fréquence, les méthodes basées sur les ondes progressives et les méthodes basées sur l'intelligence artificielle.

Les méthodes actuelles de localisation des défauts sur les lignes aériennes et les câbles souterrains peuvent être classées en deux types fondamentaux : les méthodes basées sur la mesure de l'impédance de la ligne après défaut (post-fault) et les méthodes basées sur la mesure de la composante de l'onde progressive générée par le défaut.

Des efforts de recherche considérables ont été consacrés au développement de méthodes basées sur l'impédance pour la localisation des défauts. Cependant, comme toutes les autres méthodes de mesure basées sur la fréquence du réseau, elles souffrent de limitations dues à la résistance du cheminement des défauts, à la charge de la ligne et aux paramètres de la source, etc[47]. En conséquence, la précision obtenue dans la localisation des défauts est plutôt limitée.

2.4.1 Méthode basée sur la mesure de l'impédance

Les algorithmes de localisation des défauts basés sur l'impédance sont largement utilisés pour déterminer l'emplacement des défauts des lignes de transmission, car ils sont simples à mettre en œuvre et donnent des estimations raisonnables de l'emplacement[48].

Les formes d'ondes de tension et de courant captées pendant un défaut par des dispositifs électroniques intelligents (DEI) tels que les relais numériques, les enregistreurs numériques de défauts et les enregistreurs d'événements séquentiels sont utilisées pour estimer l'impédance apparente entre le dispositif DEI et l'emplacement du défaut de court-circuit. Étant donné l'impédance de ligne en ohms, la distance par unité au défaut peut être estimée.

Un certain nombre d'algorithmes de localisation de défauts basés sur l'impédance ont été développés pour les lignes de transmission. Ces algorithmes utilisant des données capturées par un dispositif DEI à une extrémité de la ligne sont communément appelés algorithmes à une extrémité, tandis que ceux utilisant des données capturées par des DEI aux deux extrémités d'une ligne de transmission sont appelés algorithmes à deux extrémités.

2.4.1.1 Algorithmes à une extrémité

Les méthodes d'impédance à une extrémité pour la localisation des défauts qui sont une caractéristique standard de la plupart des relais numériques. Ces localisateurs de défauts calculent l'emplacement du défaut à partir de l'impédance apparente vue en regardant la ligne d'une extrémité. Un exemple de schéma unifilaire et la représentation de défauts dans la ligne sont présentés dans la figure 2.2. Pour localiser tous les types de défauts, il faut mesurer les tensions et les courants phase-terre de chaque phase. (Si, seules les tensions ligne à ligne sont disponibles, il est possible de localiser les défauts

phase-phase, et de plus, si l'impédance homopolaire Z_0 de la source est connue, nous pouvons estimer la localisation des défauts phase-terre)[48].

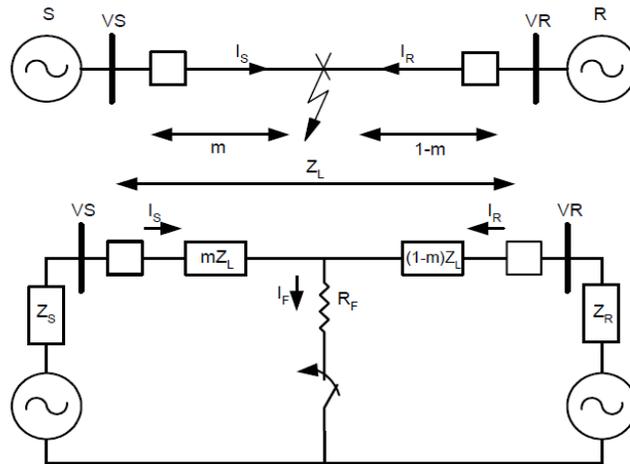


Figure 2.2 : Schéma unifilaire et la représentation des circuits de défaut de ligne[1]

Les méthodes de localisation de défauts basées sur l'impédance les plus populaires sont :

i. Méthode de réactance simple :

D'après la figure 2.2, la chute de tension à l'extrémité S de la ligne est :

$$V_s = m * Z_{1L} * I_s + R_F * I_F \tag{2.1}$$

Avec

- V_s : La tension à la borne S
- V_R : La tension à la borne R
- m : La distance entre défaut et source par unité

Z_{1L} : L'impédance de la ligne de séquence positive

Z_{0L} : L'impédance homopolaire de la ligne

I_s : Courant sortant de la source S

I_0 : Courant homopolaire

R_F : Résistance de défaut

I_F : Courant du défaut

Pour le défaut de type phase A-terre on a

$$V_s = V_{a-g} \text{ et } I_s = I_a + k * 3 * I_0 \quad (2.2)$$

$$\text{Avec } k = \frac{(Z_{0L} - Z_{1L})}{3 * Z_{1L}}$$

L'objectif est de minimiser l'effet du terme $R_F * I_F$. La méthode de réactance simple divise tous les termes par I_s (I mesuré au localisateur de défauts) et ignore le terme $R_F * I_F / I_s$.

On a donc

$$\text{Im} \left(\frac{V_s}{I_s} \right) = \text{Im}(m * Z_{1L}) = m * X_{1L} \quad (2.3)$$

Donc

$$m = \frac{\text{Im} \left(\frac{V_s}{I_s} \right)}{X_{1L}} \quad (2.4)$$

ii. Méthode de TAKAGI :

La méthode TAKAGI nécessite des données de pré défaut $I_{\text{pre-défaut}}$ (valeur avant le défaut) et de défaut I . Elle améliore la méthode de réactance simple en réduisant l'effet du flux de charge et en minimisant l'effet de la résistance de défaut[15].

En utilisant la même équation (2.1) et en posant $I_{\text{sup}} = I - I_{\text{pre-défaut}}$.

En multipliant les deux termes de l'équation (2.1) par le conjugué complexe de I_{sup}

$$\text{Im}(V_S * I_{\text{sup}}^*) = m * \text{Im}(Z_{1L} * I_S * I_{\text{sup}}^*) + R_F * \text{Im}(I_F * I_{\text{sup}}^*) \quad (2.5)$$

$$m = \frac{\text{Im}(V_S * I_{\text{sup}}^*)}{\text{Im}(Z_{1L} * I_S * I_{\text{sup}}^*)} \quad (2.6)$$

La clé du succès de la méthode TAKAGI est que l'angle du I_S est le même que l'angle du I_F . Pour un système homogène idéal, ces angles sont identiques. Plus l'angle entre I_S et I_F augmente, plus l'erreur dans l'estimation de la localisation des défauts augmente.

Les difficultés liées à la précision de la localisation des défauts à une extrémité sont bien connues et sont décrites dans plusieurs sources [13-15, 22, 48]. En résumé, les conditions suivantes peuvent entraîner des erreurs pour les méthodes de localisation de défauts basées sur l'impédance à une extrémité :

- Effet combiné de la résistance de défaut et de la charge ;
- Couplage mutuel à séquence zéro (homopolaire) ;
- Erreurs de modélisation en séquence zéro ;
- Non-homogénéité du système ;

- Mesure inexacte des relais, du transformateur de l'instrument ou des paramètres de la ligne.

2.4.1.2 Algorithmes à deux extrémités

Dans le but de surmonter les limites des techniques de localisation de défauts à une extrémité et d'améliorer la précision de la localisation des défauts, des algorithmes de localisation de défauts à deux extrémités et à plusieurs extrémités ont été proposés dans [1, 13, 15].

Les algorithmes basés sur l'impédance à deux extrémités utilisent des données de forme d'onde captées aux deux extrémités d'une ligne de transmission pour estimer l'emplacement d'un défaut. Le principe de localisation des défauts est similaire à celui des méthodes à une extrémité, c'est-à-dire qu'il utilise la tension et le courant pendant un défaut pour estimer l'impédance apparente entre le lieu de surveillance et le défaut. Des mesures supplémentaires à partir de l'extrémité distante d'une ligne de transmission sont utilisées pour éliminer toute erreur de réactance causée par la résistance du défaut, le courant de charge ou la non-homogénéité du système. La classification des types de défauts n'est pas non plus nécessaire. Un canal de communication transfère les données d'un dispositif électronique intelligent DEI à l'autre. Les données des deux DEI peuvent également être collectées et traitées à un endroit central. Une description détaillée de la méthode est fournie dans [1], en fonction de la disponibilité des données, les méthodes basées sur l'impédance à deux extrémités sont également classées comme suit :

Méthode synchronisée à deux extrémités : Cette méthode suppose que les mesures des deux extrémités d'une ligne de transmission sont synchronisées à une référence de temps commune via un système de positionnement global (GPS).

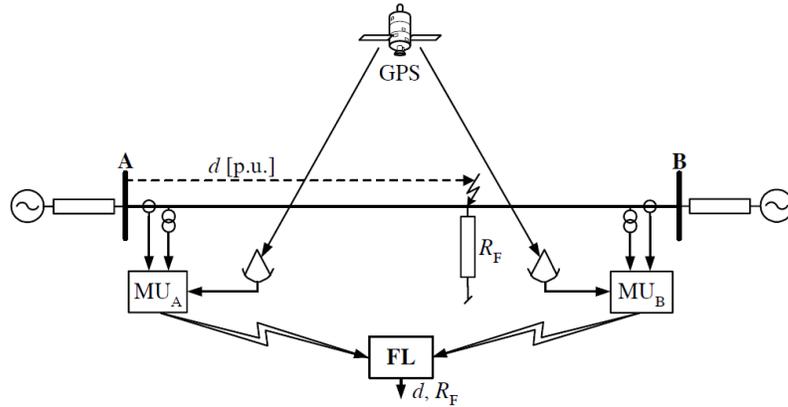


Figure 2.3 : Schéma de la localisation synchronisée des défauts aux deux extrémités avec utilisation du GPS[1].

Avec MUA et MUB sont des unités de mesure à l'extrémité A et B respectivement, FL est le localisateur de défaut, R_F est la résistance du défaut et d est la distance entre le lieu du défaut et le terminal A.

Méthode non synchronisée à deux extrémités : Les formes d'onde captées par les dispositifs DEI aux deux extrémités d'une ligne de transmission peuvent ne pas être synchronisées entre elles. Le dispositif GPS peut être absent ou ne pas fonctionner correctement. Par ailleurs, les DEI peuvent avoir des taux d'échantillonnage différents ou ils peuvent détecter le défaut à des instants légèrement différents.

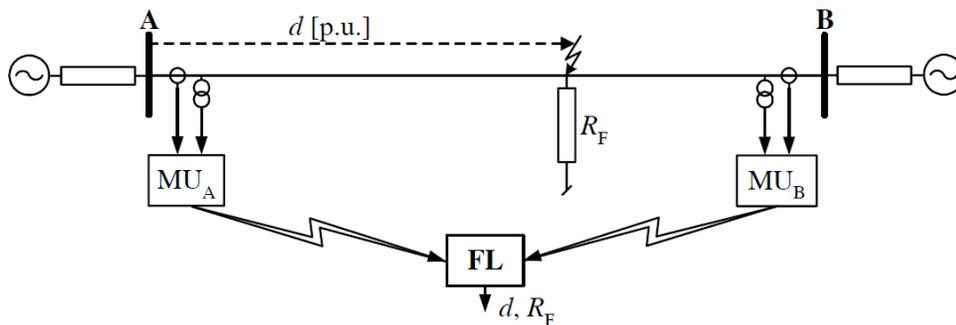


Figure 2.4 : Schéma de localisation des défauts non synchronisés aux deux extrémités[1].

2.4.2 Les méthodes basées sur les ondes progressives (Travelling-Wave)

Les méthodes basées sur les ondes progressives ont été largement utilisées [17-19, 48, 49] pour la localisation du défaut et sont généralement basées sur la corrélation entre les ondes progressives et les ondes rétrogrades se déplaçant le long de la ligne de transmission, comme le montre la figure 2.5 . Les récentes améliorations en matière d'acquisition de données, de synchronisation du temps par GPS et de systèmes de communication ont accru l'intérêt pour cette technologie.

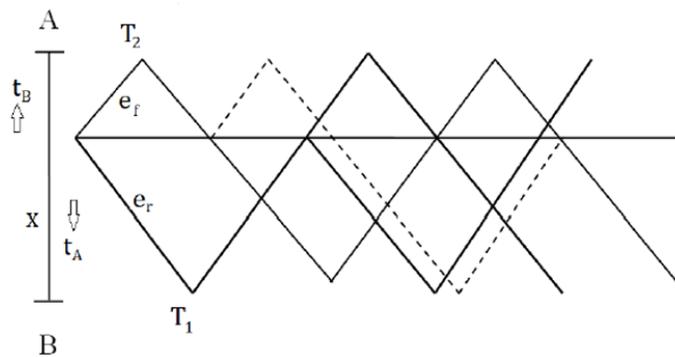


Figure 2.5 : Illustration de la méthode Traveling-Waves.

Le temps de propagation des composants à haute fréquence est utilisé pour localiser le défaut. Dans la figure 2.5, une ligne de transmission monophasée sans perte de longueur « l » est considérée avec une vitesse d'onde progressive de v , une capacité et une inductance par unité de longueur L' et C' et une impédance caractéristique de ZC . En supposant qu'un défaut se produise à une distance de « x » de la borne A, les valeurs de tension et de courant sont données par (2.7) et (2.8).

$$\frac{\partial e}{\partial x} = -L' \frac{\partial i}{\partial t} \quad (2.7)$$

$$\frac{\partial i}{\partial x} = -C' \frac{\partial e}{\partial t} \quad (2.8)$$

Leurs solutions sont:

$$e(x, t) = e_f(x - vt) + e_r(x + vt) \quad (2.9)$$

$$i(x, t) = \frac{1}{Z_c} e_f(x - vt) - \frac{1}{Z_c} e_r(x + vt) \quad (2.10)$$

Les temps de parcours des vagues entre le défaut et la discontinuité τ_A et τ_B sont à déterminer à l'aide de la technologie GPS. Une fois cela fait, l'emplacement du défaut x peut être facilement déterminée par l'équation suivante (2.11).

$$x = \frac{l - c(\tau_A - \tau_B)}{2} \quad (2.11)$$

Où $c = 299.72$ m/sec c 'est la vitesse de propagation.

2.4.3 Facteurs influençant la précision de la localisation des défauts

Différents facteurs affectent la précision des méthodes de localisation des défauts. En général, sans préciser la méthode de localisation, les principaux facteurs peuvent être énumérés comme suit :

- Compensation inexacte de l'effet de réactance dans le cas d'algorithmes de localisation de défauts utilisant des mesures à une extrémité.
- Des paramètres de ligne imprécises, qui ne correspondent pas aux paramètres réels. Notez que, même si la géométrie des conducteurs de ligne est prise avec précision pour calculer les impédances de ligne, la longueur totale de la ligne pourrait être connue avec une certaine erreur.
- Présence de réacteurs et de condensateurs shunt ou de dispositifs de compensation de condensateurs en série.
- Déséquilibre charge-flux.

Pour améliorer l'estimation de la localisation des défauts, il est important d'éliminer, ou au moins de réduire les erreurs possibles pour la méthode considérée. D'où l'intérêt d'introduire des méthodes intelligentes, insensible aux facteurs mentionnés ci-dessus et capable de préciser l'emplacement du défaut.

2.4.4 Méthodes basées sur l'intelligence artificielle IA

L'IA est un sous-domaine de l'informatique qui étudie comment la pensée et l'action des êtres humains peuvent être imitées par des machines. Les calculs numériques et non numériques sont inclus dans le domaine de l'IA. L'imitation du renseignement comprend non seulement la capacité à prendre des décisions rationnelles, mais aussi à traiter les données manquantes, à s'adapter aux situations existantes et à s'améliorer à long terme sur la base de l'expérience accumulée.

Les techniques basées sur l'IA ont l'avantage par rapport aux techniques conventionnelles, d'améliorer considérablement la précision de la localisation des défauts.

Trois grandes familles de techniques d'IA sont considérées comme étant appliquées dans l'automatisation et le contrôle des systèmes électriques :

- Les techniques du système expert ;
- Systèmes à logique floue ;
- Les réseaux de neurones artificiels.

Une brève description des deux premières techniques est présentée dans la section suivante. Ce rapport se focalise sur l'utilisation des réseaux de neurones artificiels pour la détection, classification et localisation des défauts dans les lignes de transmission, le prochain chapitre donne une description détaillée de cette technique.

2.4.4.1 Les techniques du système expert

Un système expert est généralement défini comme un système interactif capable de manifester un niveau de connaissance d'expert dans un domaine spécifique et de résoudre des problèmes dans ce domaine pour juger ou former une opinion. Ces connaissances utilisent la syntaxe « Si... Alors... » (base de connaissances). Le système comprend également les faits qui décrivent généralement le domaine et l'état du problème à résoudre (base des données). Un moteur d'inférence générique utilise les faits et les règles pour déduire de nouveaux faits qui permettent d'appliquer d'autres règles. Une description plus détaillée est donnée dans [50]. La base de connaissances est un ensemble de connaissances spécifiques à un domaine et le système d'inférence est le composant logique permettant de traiter la base de connaissances pour résoudre le problème. La figure 2.6 montre le schéma bloc simplifié d'un système expert.

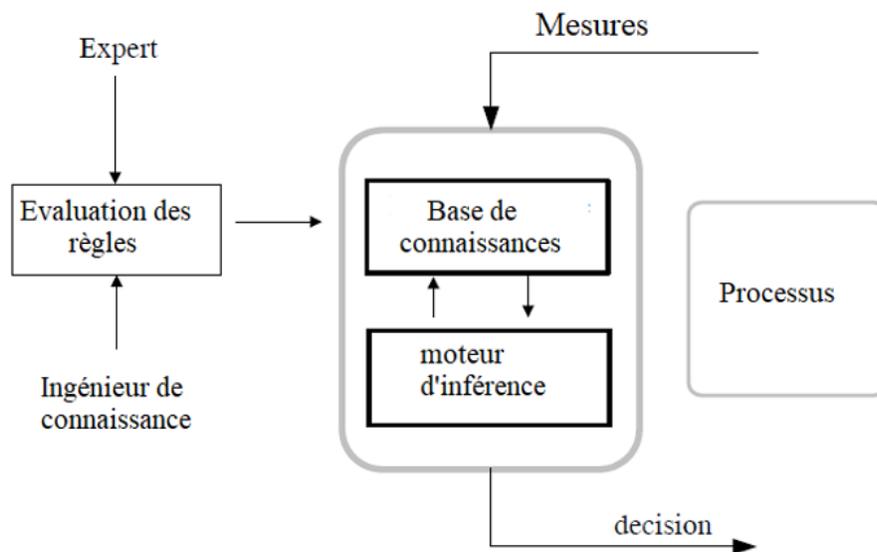


Figure 2.6 : Schéma bloc simplifié d'un système expert

Il existe peu d'application de systèmes experts dans l'automatisation et le contrôle des systèmes électriques, ces applications résoudront les tâches hors ligne telles que la coordination des paramètres, l'analyse de post-défait ou le diagnostic des défauts [51] et la classification des défauts[52], et l'identification des sections défectueuses [1].

2.4.4.2 Systèmes à logique floue

La logique floue est une extension de la logique booléenne créée par Lotfi Zadeh en 1965 en se basant sur sa théorie mathématique des ensembles flous. Les techniques de traitement des signaux flous ont fait l'objet d'une attention remarquable pendant au moins 15 ans, de nombreuses études ont été réalisées dans des centres de recherche en ce qui concerne leur application aux tâches de protection et de contrôle des systèmes électriques.

Les systèmes de logique floue sont bien adaptés à la résolution de divers problèmes de prise de décision, en particulier lorsque le modèle analytique n'est pas connu ou est très compliqué (c'est-à-dire non linéaire)[53]. Le principe de fonctionnement du contrôleur en logique floue est similaire à celui d'un opérateur humain. Il effectue les mêmes actions qu'un opérateur humain en ajustant le signal d'entrée en ne regardant que la sortie du système. La logique floue comporte trois étapes comme le montre la figure 2.7:

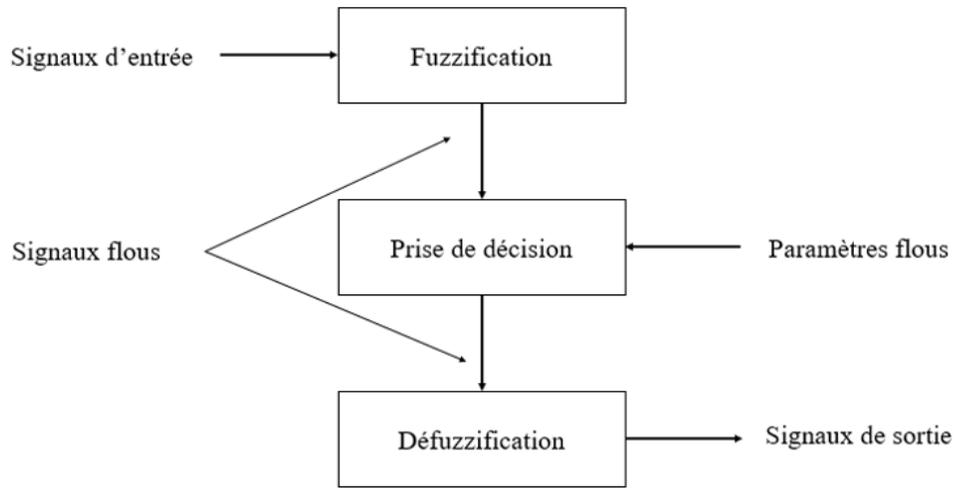


Figure 2.7 : Schéma fonctionnel du contrôleur à logique floue.

2.5 Conclusion

Ce chapitre présente un aperçu de la revue de la littérature réalisée. Il s'est concentré sur l'intérêt, l'importance et les techniques proposées pour la détection et la localisation des défauts électriques, tout en présentant les différents types des défauts qui peuvent se produire dans les lignes de transmission de l'énergie électrique. Dans ce rapport, le réseau de neurones est proposé pour la détection, classification et localisation des défauts. En effet, la méthodologie adoptée et suivie est présentée dans le chapitre suivant.

CHAPITRE 3

IDENTIFICATION DES DÉFAUTS PAR LES RÉSEAUX DES NEURONES ARTIFICIELS

L'occurrence des défauts dans les lignes de transmission est un phénomène imprédictible et inévitable, le gestionnaire de réseau doit être à tout temps informé de l'état et performance de son réseau. Cela lui permet de prendre une décision éclairée sur les mesures correctives nécessaires et d'effectuer des travaux de réparation pour éliminer un défaut. En effet, ce chapitre explique plus en détail les démarches à suivre pour identifier, analyser et diagnostiquer les défauts des lignes de transmission par les réseaux de neurones artificiels.

Afin de détecter les défauts, il est important de bien comprendre sa nature et ses caractéristiques. Les relais conventionnels de détection des défauts, tel qu'ils sont appliqués aux systèmes électriques, ont été principalement utilisés. Les systèmes conventionnels de détection de défauts sont basés sur des paramétrages et des limiteurs pour différents réglages de tension et de courant de défaut. Cependant, pour détecter plus intelligemment les défauts, le réseau neuronal artificiel (RNA) a été introduit comme détecteur de défauts.

Les premiers travaux sur l'analyse des défauts des systèmes de relais dans les lignes de transmission par les réseaux de neurones remontent à 1995 [5], où le modèle de perceptron multicouche (MLP) est utilisé pour classifier les défauts. Une autre technique basée sur ces derniers pour la classification et la localisation des défauts est explorée dans [54] où les signaux de tension et de courant sont utilisés comme entrées. De plus, dans [55] et [10] seuls les signaux de courant ont été utilisés pour étudier les caractéristiques cachées qui ont permis d'identifier et de classifier les défauts dans la ligne aérienne à double circuit. D'autres travaux ont démontré l'analyse des défauts des

lignes de transmission à six phases à l'aide de RNA [10, 37], compte tenu de l'infrastructure croissante des systèmes de transmission à haut niveau de phase dans le scénario actuel.

3.1 Introduction au réseau de neurones artificiels

3.1.1 Description de réseau de neurones

Le réseau neuronal artificiel RNA est un modèle mathématique inspiré des réseaux de neurones biologiques, développés pour imiter intelligemment la façon dont le cerveau humain traite l'information et apprend par l'expérience. Il s'agit d'un système adaptatif dont la structure change en fonction de la phase d'apprentissage et qui réagit aux nouveaux événements de la manière la plus appropriée sur la base des expériences acquises lors de l'entraînement[56]. Leur capacité à apprendre les relations complexes non linéaires d'entrée/sortie a motivé les chercheurs à les appliquer pour résoudre des problèmes non linéaires liés à divers domaines. Ils présentent les avantages inhérents d'une excellente immunité au bruit et d'une grande robustesse, ce qui fait que les approches basées sur les RNA sont moins susceptibles de changer avec les conditions de fonctionnement que les approches conventionnelles liées à l'ingénierie des systèmes électriques.

Le RNA est un graphe orienté de nœuds, appelés neurones, interconnectés et disposés en couches. Ces nœuds reçoivent une information de la couche précédente et combinent cette information selon des pondérations (poids) identifiées par $w_{i,j}^{(i)}$. Chaque nœud possède également un seuil d'activation (biais) $b_k^{(i)}$. Autour de ce seuil, la valeur de sortie est beaucoup plus sensible aux changements de la valeur d'entrée. Une description plus détaillée est fournie par [56, 57]. La figure 3.1 présente la structure d'un RNA à propagation avant (feedforward) connu sous le nom de perceptron.

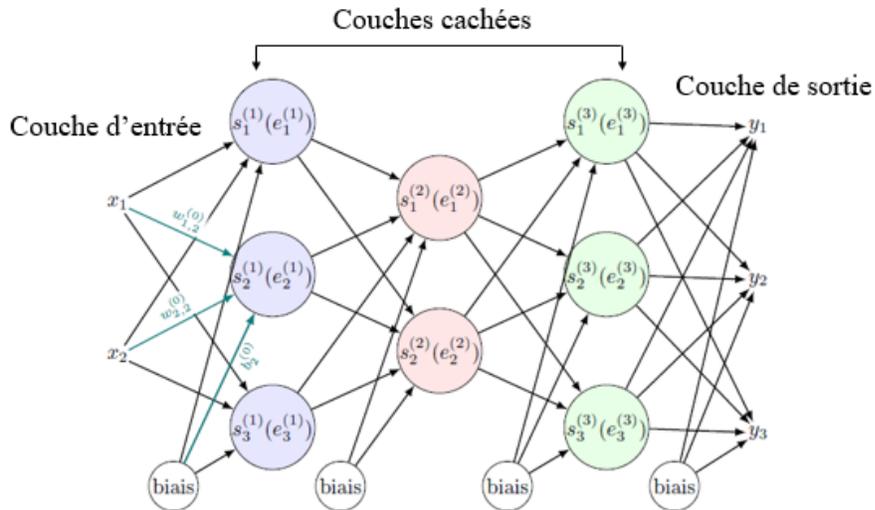


Figure 3.1 : Illustration d'un réseau de neurones feedforward.

Les RNAs ne sont pas programmés ou soutenus par une base de connaissances comme le sont les systèmes experts. Au lieu de cela, ils apprennent une réponse basée sur des entrées données et une sortie requise en ajustant les poids et les biais des nœuds en conséquence. On peut donc dire que l'RNA traite les informations sur la base d'exemples « apprentissage » précédemment[6].

Comme les RNAs peuvent fournir une excellente reconnaissance des formes, ils sont proposés par de nombreux chercheurs pour effectuer différentes tâches dans le relais des systèmes d'alimentation pour le traitement du signal et la prise de décision[5, 22, 24, 36, 53, 58], détection [6-8, 10, 19, 30, 37], classification [2-5, 8, 11, 24, 38] et la localisation de défauts [9, 20, 49, 59, 60].

Un problème majeur des RNAs est qu'il n'existe pas d'une méthode ou guide pour le choix du nombre de couches cachées et de neurones par couche cachée. Cependant, la possibilité de généraliser est l'un des principaux avantages de leur utilisation. Leur spécificité est la mesure dans laquelle ils sont dédiés au calcul parallèle.

De plus, il est conçu pour généraliser les entrées observées et produire une cartographie entrée-sortie correcte même lorsque l'entrée n'a pas été présentée au réseau lors du processus d'apprentissage.

Une étape très importante dans le développement de l'RNA a été la synthèse de l'algorithme pour l'apprentissage adaptatif du réseau. L'algorithme de base est connu sous le nom de méthode de propagation avant d'erreur (error back propagation) dans laquelle, au cours des étapes consécutives, les poids des neurones sont corrigés pour obtenir une erreur globale minimale entre le résultat réel et attendu du réseau. En général, cette méthode est connue sous le nom d'apprentissage supervisé, fournit une réponse (cible) souhaitée.

3.1.2 Réseau de neurones feedforward

Il existe plusieurs typologies et architectures de réseau de neurones artificiels, on peut citer les réseaux récurrents Elman [9], les réseaux de neurones autoorganisés (Self-Organized) ou ce qu'on appelle carte de Kohonen [24, 25] et RNA de type extrême learning machine[58]. Les réseaux de feedforward sont les réseaux neuronaux les plus utilisés, simples et faciles à mettre en œuvre. Dans ce réseau, l'information ne se déplace que dans une seule direction, vers l'avant, à partir des nœuds d'entrée, en passant par les couches cachées et vers les nœuds de sortie. Il n'y a pas de cycle ou de boucle dans le réseau, d'où leur utilisation.

En plus du type de réseau de neurones, il faut également choisir une fonction d'erreur et une fonction d'activation pour les neurones. Ces choix sont souvent guidés par le type de données traitées.

Un réseau de neurones multicouche (MLP) typique se compose de trois couches : une couche d'entrée, une couche de sortie et une ou plusieurs couches cachées. Chaque couche est constituée d'un nombre prédéfini de neurones.

Le neurone utilisé est un type standard. Il consiste à faire la somme de toutes les entrées pondérées par ses coefficients synaptiques qui représente la sortie linéaire puis à l'appliquer à une fonction d'activation. La sortie obtenue est ensuite connectée à toutes les entrées de la couche suivante. La structure de base d'un neurone est présentée dans la figure 3.2.

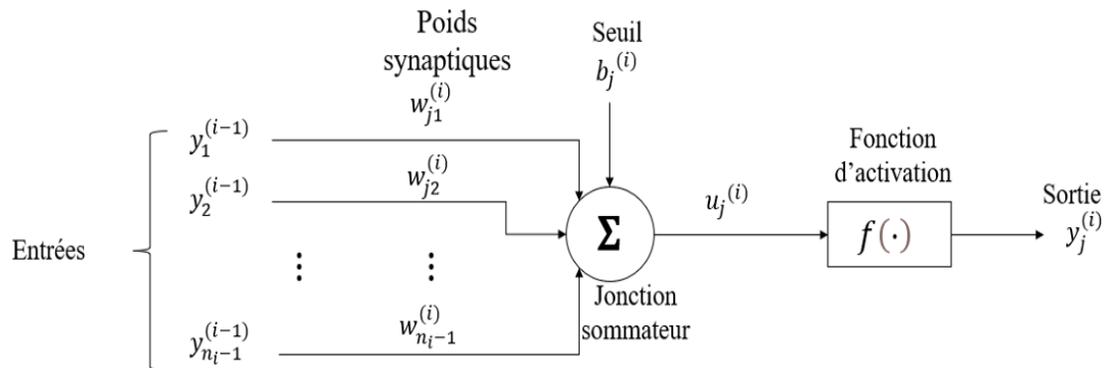


Figure 3.2 : La structure de base d'un neurone.

Le modèle mathématique de neurone artificiel a une structure très simple par rapport à un neurone biologique. Ainsi, un neurone j peut être décrit mathématiquement avec l'équation suivante :

$$y_j^{(i)} = f \left(b_j^{(i)} + \sum_{k=1}^{n_i-1} w_{jk}^{(i)} y_k^{(i-1)} \right) \quad (3.1)$$

Avec :

f représente la fonction de transfert (fonction d'activation) du neurone j ;

i représente la couche cachée.

$y_k^{(i-1)}$, $k = 1, \dots, n_{i-1}$, 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 ;

$b_j^{(i)}$ est le biais (seuil) du neurone j .

L'erreur dans la couche de sortie entre la sortie y_s et sa valeur désirée $y_{s\text{-désirée}}$ ($y_s - y_{s\text{-désirée}}$) est minimisée par l'erreur quadratique moyenne à la couche de sortie, définie comme suit :

$$\text{Erreur} = \frac{1}{2} \sum_{s=1}^R (y_s - y_{s\text{-désirée}})^2 \quad (3.2)$$

Avec R nombre de neurones dans la couche de sortie.

3.1.3 Algorithme « error back propagation »

Back-propagation (propagation arrière) a été créée en généralisant la règle d'apprentissage de Windrow-Hoff aux réseaux de neurones multicouches et aux fonctions de transfert différentiables non linéaires. Les vecteurs d'entrée et les vecteurs cibles correspondants sont utilisés pour entraîner un réseau jusqu'à ce qu'il puisse se rapprocher d'une fonction, qui associe des vecteurs d'entrée à des vecteurs de sortie spécifiques.

L'erreur pour chaque itération est calculée en partant de la dernière étape et en envoyant l'erreur calculée à l'envers. Les poids de l'algorithme de rétropropagation pour le réseau neuronal sont choisis de manière aléatoire. Après chaque étape, ces poids sont

mis à jour avec les nouveaux poids et le processus est répété pour l'ensemble complet de la combinaison entrées-sorties disponible dans l'ensemble de données d'entraînement qui est fourni par le développeur[56]. L'ensemble de ce processus est adopté par chacune des couches du réseau dans le sens inverse. Cet algorithme utilise la technique de l'erreur quadratique moyenne pour calculer l'erreur à chaque itération.

L'algorithme de rétropropagation a été mis en œuvre de nombreuses façons, mais l'idée de base reste la même. La seule chose qui change dans chacune de ces implémentations est la méthode utilisée pour le calcul des poids qui sont mis à jour de manière itérative lorsqu'ils passent en arrière de couche en couche. Le nombre total d'itérations nécessaires pour atteindre un taux de convergence satisfaisant dépend des facteurs suivants :

- La taille du réseau de neurones ;
- Structure du réseau ;
- Le problème faisant l'objet de l'enquête ;
- La stratégie d'apprentissage utilisée ;
- La taille de l'ensemble de Training Data.

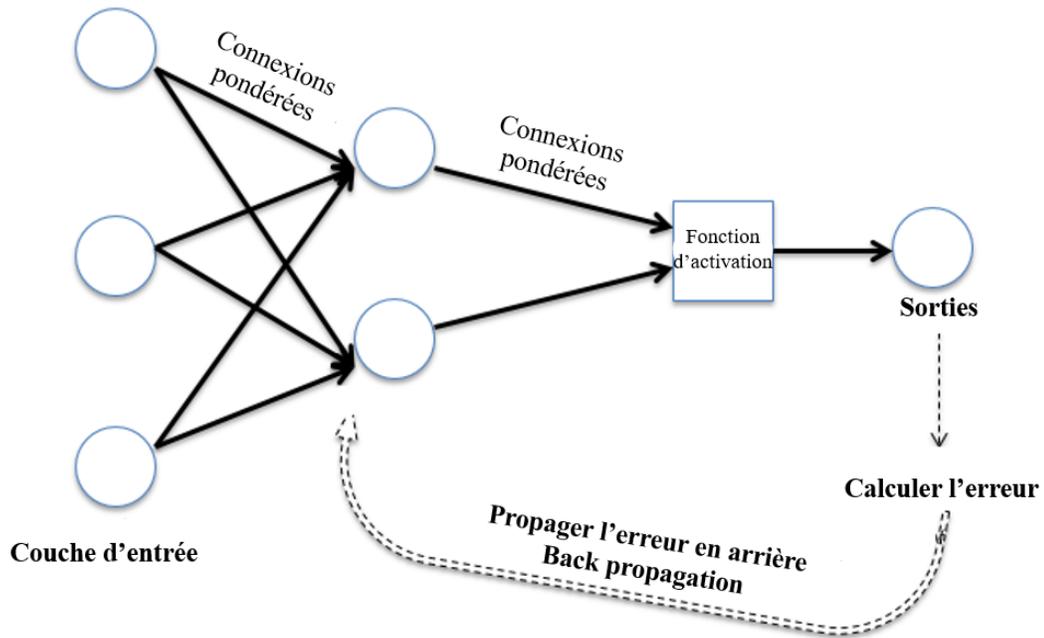


Figure 3.3 : Structure de Back-propagation.

Les principales étapes de l'algorithme de rétropropagation BP (Back-propagation) sont représentées dans l'algorithme suivant :

- **Étape BP 1 : Initialisation :** Initialiser les matrices aléatoires des poids synoptique : $W^i, i = 1, \dots, M$, . M nombre de couches cachées.
- **Étape BP 2 : Propagation :** Calculer pour chaque couche $i = 1, \dots, M$:

$$u_j^{(i)} = \sum_{k=1}^{n_j-1} w_{jk}^{(i)} y_k^{(i-1)} \quad (3.3)$$

$$y_j^{(i)} = f(u_j^{(i)}) \quad (3.4)$$

Étape BP 3 : Calcul des erreurs : Calculer les erreurs locales pour

Couche de sortie :

$$\delta_{jp}^M = e_{jp}^{(L)} f'(u_{jp}^{(L)}) \quad (3.5)$$

Couche : $i = M - 1, \dots, 1$

$$\delta_{jp}^i = f'(u_{jp}^{(i)}) \sum_{k=1}^{n_{i+1}} (\delta_{kp}^{(i+1)} w_{kj}^{(i+1)}) \quad (3.6)$$

$W^{(i+1)}$ est privé de sa première ligne

- **Étape BP 4 : Adaptation des poids :** Modifier les poids synaptiques suivants

$$\Delta w_{jk}^{(i)}(l) = \mu y_{kp}^{(i-1)} \delta_{jp}^i, \quad i = 1, \dots, M \quad (3.7)$$

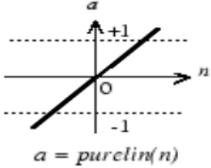
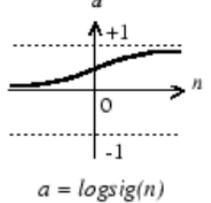
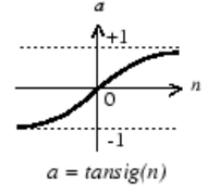
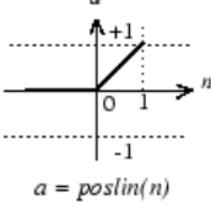
- **Étape BP 5 : Test d'arrêt :** Tester l'erreur quadratique totale.

3.2 Fonction de transfert/activation

Dans le domaine des réseaux de neurones artificiels, la fonction d'activation est une fonction mathématique appliquée à un signal en sortie d'un neurone artificiel. Une fois un seuil est atteint, le neurone donne une réponse. La fonction d'activation est souvent une fonction non linéaire.

Le tableau ci-dessous regroupe les fonctions d'activation les plus utilisées pour les couches neuronales.

Tableau 3-1 : Fonctions d'activation.

Nom	Fonction Matlab	Graphes	Équation
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	Logsig		$f(x) = \frac{1}{1 + e^{-x}}$
Tangente Hyperbolique	Tansig		$f(x) = \tanh(x) = \frac{2}{1 + e^{-2x}} - 1$
Unité de rectification linéaire Relu	Poslin : Positive linéaire		$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ x & \text{si } x \geq 0 \end{cases}$

3.3 Stratégies d'apprentissage

Le problème fondamental de la conception de l'RNA réside dans la détermination des poids afin d'atteindre l'objectif souhaité. Ce processus est généralement appelé apprentissage ou entraînement, c'est l'étape la plus importante dans le développement

des détecteurs et localisateurs neuronaux de défaut. Ainsi, les données d'entraînement, ou ce qu'on appelle en anglais Training Data, doivent donc être préparées de manière méthodique et réfléchie. Dans certaines applications, ces données ne sont pas toujours disponibles dans le cadre d'un système réel, l'utilisation d'un simulateur est nécessaire pour générer ces données.

En général, il existe trois stratégies d'apprentissage de l'ANN : l'apprentissage supervisé ou non supervisé.

L'apprentissage supervisé consiste à modifier les poids du réseau dans le but de minimiser l'erreur entre les exemples d'entrée présentés et les valeurs de sortie cible.

Dans l'apprentissage non supervisé, il n'y a pas de relation définie entre les entrées et les sorties. L'apprentissage est effectué sur la base d'un ensemble d'exemples où seules les conditions d'entrée sont connues. Dans le processus d'apprentissage, ces exemples sont sélectionnés en respectant un certain principe de similarité. Un tel réseau peut être considéré comme un système autoorganisé qui apprend sur un principe de concurrence.

Apprentissage par renforcement : Il consiste, pour un agent autonome (robot, etc.), à apprendre les actions à prendre, à partir d'expériences, de façon à optimiser une récompense quantitative au cours du temps. L'agent est plongé au sein d'un environnement, et prend ses décisions en fonction de son état courant. En retour, l'environnement procure à l'agent une récompense, qui peut être positive ou négative. L'agent cherche, au travers d'expériences itérées, un comportement décisionnel (appelé stratégie ou politique, et qui est une fonction associant à l'état courant l'action à exécuter) optimal, en ce sens qu'il maximise la somme des récompenses au cours du temps.

L'apprentissage par renforcement se distingue de l'apprentissage supervisé par le fait qu'il n'est pas nécessaire de présenter des paires entrées/sorties étiquetées ni de corriger explicitement les actions sous-optimales. Au lieu de cela, l'accent est mis sur la recherche d'un équilibre entre l'exploration (d'un territoire inexploré) et l'exploitation (des connaissances actuelles). Les algorithmes d'apprentissage par renforcement partiellement supervisés peuvent combiner les avantages des algorithmes supervisés. Cette méthode d'apprentissage a été adoptée dans le domaine de l'intelligence artificielle afin de diriger l'apprentissage automatique non supervisé à l'aide de récompenses et de pénalités. Elle est souvent utilisée dans le cadre de la robotique, de la théorie des jeux et des véhicules autonomes.

En outre, lors de l'élaboration des données d'apprentissage, les données doivent être représentatives de tous les scénarios possibles dans lesquels l'RNA sera appelé à exercer ses fonctions de détection, classification et de localisation. Ainsi, training data peuvent devenir d'énormes ensembles de données.

3.4 Algorithmes d'apprentissage

Pour illustrer le fonctionnement de l'apprentissage, considérons l'algorithme d'optimisation le plus simple, la descente de gradient. Il met à jour les poids et les biais du réseau dans la direction dans laquelle la fonction de performance diminue le plus rapidement, le négatif du gradient[61].

Une itération de cet algorithme peut être écrite comme suit :

$$x_{k+1} = x_k - a_k g_k \quad (3.8)$$

Où x_k est un vecteur des poids et des biais actuels, g_k est le gradient actuel, et a_k est le taux d'apprentissage. Cette équation est itérée jusqu'à ce que le réseau converge.

Le tableau 3.2 présente une liste des algorithmes d'apprentissage disponible dans la bibliothèque Neural Network Toolbox de MATLAB et qui utilisent des méthodes basées sur le gradient ou le Jacobien.

Tableau 3-2 : Algorithmes d'apprentissage dans Neural Network Toolbox.

Fonctions	Algorithme
Trainlm	Levenberg-Marquardt
Trainbr	Régularisation bayésienne / Bayesian Regularization
trainbfg	BFGS Quasi-Newton
Trainrpf	Backpropagation résiliente / Resilient Backpropagation
Trainscg	Gradient conjugué échelonné / Scaled Conjugate Gradient
Traincgb	Gradient conjugué avec Powell/Beale Restarts / Conjugate Gradient with Powell/Beale Restarts
Traincgf	Gradient conjugué de Fletcher-Powell / Fletcher-Powell Conjugate Gradient
Trainsgp	Gradient conjugué de Polak-Ribière / Polak-Ribière Conjugate Gradient
Trainoss	Sécante à un pas / One Step Secant
Trainidx	Taux d'apprentissage variable par descente de gradient / Variable Learning Rate Gradient Descent
Trainidm	Descente de gradient avec Momentum / Gradient Descent with Momentum
Trainid	Descente en gradient / Gradient Descent

La fonction d'apprentissage la plus rapide est généralement « `trainlm` », et c'est la fonction d'apprentissage par défaut pour feedforwardnet (réseau de neurones de type Feedforward). La méthode quasi Newton, `trainbfg`, est également assez rapide[61]. Ces deux méthodes ont tendance à être moins efficaces pour les grands réseaux (avec des milliers de poids), car elles nécessitent plus de mémoire et plus de temps de calcul pour ces cas. De plus, `trainlm` est plus performant sur les problèmes d'ajustement de fonctions (régression non linéaire) que sur les problèmes de reconnaissance de formes, c'est pourquoi cette méthode est utilisée pour ce projet de recherche.

Lors de l'entraînement de grands réseaux et les réseaux de reconnaissance de formes, `trainsecg` et `trainrp` sont de bons choix. Leurs besoins en mémoire sont relativement faibles, et pourtant ils sont beaucoup plus rapides que les algorithmes de descente de gradient standard.

3.5 Détecteur neuronal

La détection des défauts est la première étape à la protection des lignes de transmission. L'efficacité du détecteur neuronal de défauts dépend de la précision de ses mesures d'entrée, et de l'efficacité des données d'entraînement. Ces données doivent être bien gérées, filtrées et mises à l'échelle de manière appropriée, afin de permettre de réduire la complexité du problème et par la suite réduire la taille de réseau conçu. Ce processus est illustré dans la figure 3.4.

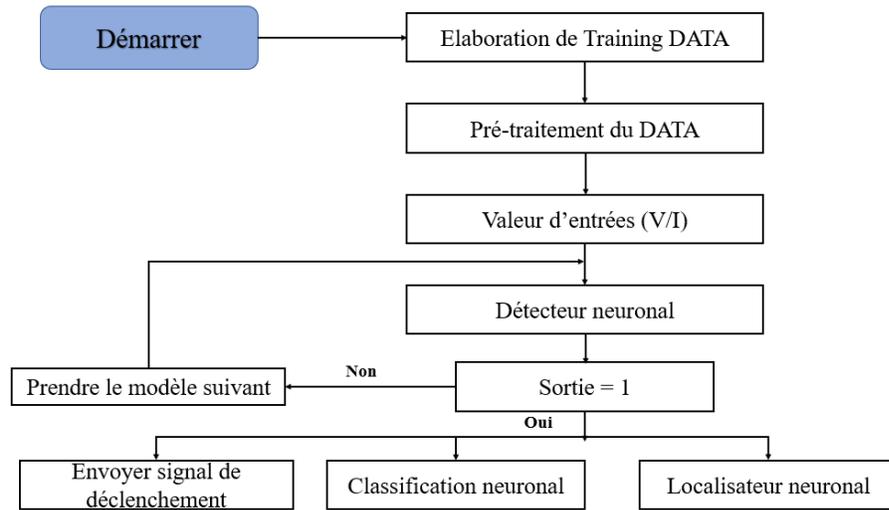


Figure 3.4 : Illustration de la méthodologie adoptée.

Le détecteur neural est conçu pour indiquer la présence ou l'absence d'un défaut de ligne de transmission. L'apparition d'un tel défaut est donnée en identifiant directement l'état du réseau électrique à partir des tensions et courants instantanés ($i_{(t)}, v_{(t)}$). Par conséquent, avant que les signaux de tension et de courant n'entrent dans le réseau neuronal, une technique de mise à l'échelle (ou de normalisation du signal) est adoptée, elle a une grande importance afin de réduire le temps de calcul d'exécution.

3.6 Extraction des données

La simulation du modèle RNA pour la détection, la classification et la localisation des défauts nécessite des données suffisantes pour l'entraînement, les tests et les vérifications. Ces données sont constituées des valeurs d'entrée et des valeurs de sortie cible.

Des données aussi volumineuses ne peuvent pas être collectées dans la pratique. C'est pourquoi les chercheurs collectent les données par la simulation de défauts dans un système électrique soit par Matlab/Simulink, ETAP ou bien EMTP, en variant plusieurs

facteurs tels que le type de défauts pour la classification, la résistance de défauts et localisation de défauts par rapport aux extrémités de la ligne.

Bien que les signaux de courant et de tension contiennent toutes les informations en eux-mêmes, il est extrêmement difficile de faire entrer les signaux bruts dans certains ensembles de règles et de critères capables d'interpréter intelligemment les messages sous-jacents apportés par les signaux. C'est là que les techniques d'extraction de caractéristiques s'avèrent utiles, car elles permettent d'extraire des informations utiles de manière ciblée et de réduire l'impact de la variance au sein du système étudié.

Après avoir utilisé des techniques d'extraction de caractéristiques appropriées, les chercheurs peuvent mieux connaître la nature des problèmes de classification ou de localisation des défauts et ainsi les résoudre de manière plus cohérente et plus efficace. En outre, une dimension réduite des données peut parfois stimuler les performances de certains algorithmes utilisés dans les classificateurs ou les localisateurs, ce qui permet d'obtenir des résultats plus précis et plus robustes le plus rapidement possible.

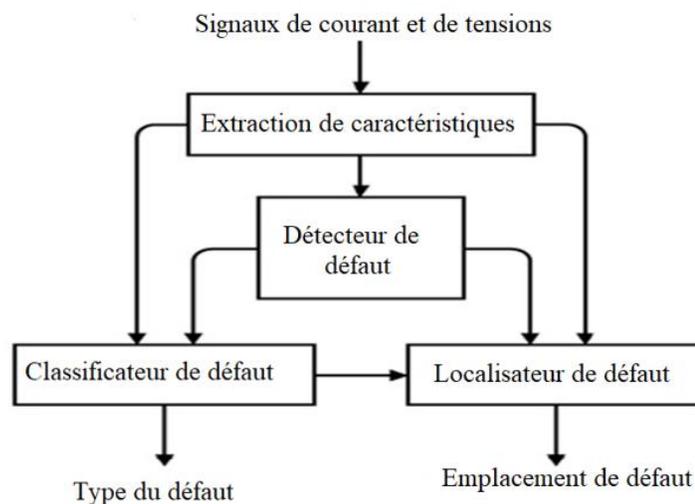


Figure 3.5 : Algorithme simplifié pour la détection, la classification et la localisation des défauts.

Il existe plusieurs méthodes pour l'extraction et le traitement des signaux, on distingue :

- Transformée de Fourier ;
- Transformée en ondelette ;
- Moyenne quadratique (Root Mean Square RMS).

La troisième méthode (RMS) est utilisée dans ce rapport dans le but d'extraire les caractéristiques fondamentales des signaux étudiés pour élaborer la base des données, cette méthode consiste à calculer la valeur moyenne quadratique réelle du signal d'entrée par la formule suivante :

$$\text{RMS}(f(t)) = \sqrt{\frac{1}{T} \int_{t-T}^t f(t)^2 dt} \quad (3.9)$$

Avec $f(t)$ est le signal d'entrée et $T = \frac{1}{f}$ avec f est fréquence fondamentale.

3.7 Conclusion

Ce chapitre a présenté un aperçu de la méthodologie de la détection des défauts et a également montré l'approche suivie dans ce rapport pour résoudre le problème de la détection et du diagnostic des défauts des lignes de transmission.

CHAPITRE 4

IDENTIFICATION DES DÉFAUTS DANS UNE LIGNE DE TRANSMISSION PAR RNA.

Comme discuté dans les chapitres précédents, les réseaux de neurones artificiels ont été proposés et utilisés pour la protection des lignes de transmission de l'énergie électrique par plusieurs auteurs [3, 7, 30, 62-65]. Leur capacité à résoudre des problèmes de reconnaissance des formes et la classification justifie leurs utilisations dans cette partie pour résoudre le problème d'identification des défauts.

Ce chapitre présente une approche basée sur les réseaux de neurones artificiels pour développer et mettre en œuvre un schéma de protection complet pour le réseau électrique étudié. Afin d'atteindre cet objectif, trois modèles de réseaux de neurones ont été proposés et développés pour la détection, classification et localisation des défauts.

4.1 Modélisation du système de lignes de transport proposé

Le modèle de réseau électrique triphasé considéré est simulé sous l'environnement MATLAB/Simulink. Il s'agit d'un système électrique de 400 kV, 60 HZ, 100 km. Il se compose de deux sources de tension triphasée équivalentes situées aux deux extrémités de la ligne de transmission, d'appareil de mesure de tension et de courant, de deux disjoncteurs, de ligne de transmission modélisée en Π (Pi), de deux charges de (10 kW, 100 vars), un bloc pour le traitement des signaux et d'un simulateur de défaut triphasé, comme montré dans la figure suivante.

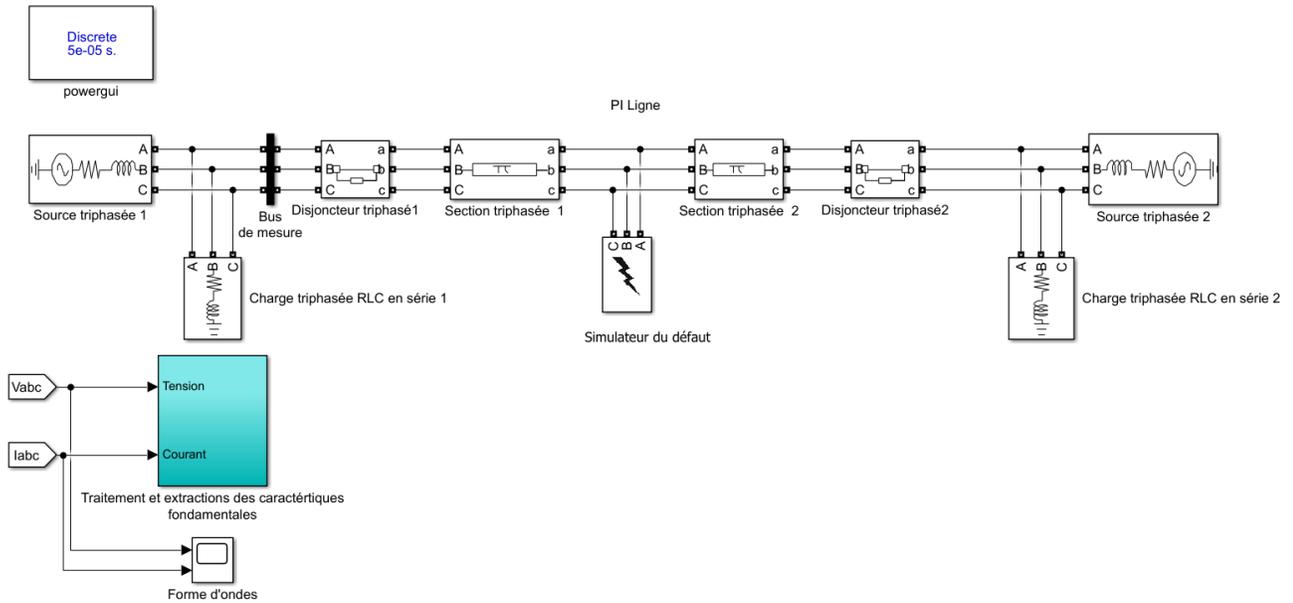


Figure 4.1 : Modèle du système électrique proposé.

L'alimentation électrique est générée par les deux sources de tensions triphasées qui est transmise aux charges par la ligne 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 pour éviter des dommages catastrophiques aux biens matériels et humains. Le bloc « bus » sert à mesurer les valeurs triphasées du courant et tension par rapport la source triphasée 1. Les deux générateurs sont mis en mode « Swing » pour contrôler l'amplitude et l'angle de phase de tension à leurs bornes.

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. Les paramètres de la ligne de transmission sont donnés dans le tableau 4-1.

Tableau 4-1 : Paramètres du modèle PI de ligne de transmission

Spécifications	Valeurs	Unités
Longueur	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	0.9337	mH/km
Inductance homopolaire	4.1264	mH/km
Capacitance de séquence positive	12.74	nF/km
Capacitance de séquence zéro	7.751	nF/km

Les systèmes antérieurs utilisent des algorithmes basés sur les lois de tensions et de courant de Kirchhoff pour la protection des lignes de transmission, ce qui prend du temps pour détecter le défaut et donne des résultats imprécis dus aux paramètres inexacts de ligne. Par ailleurs, les relais de distance conventionnels considèrent les variations de tension et de courant comme un défaut et un mécanisme de déclenchement, par exemple le courant de démarrage d'un moteur, déclencher dans ce cas peut avoir de graves conséquences et contribuer à l'instabilité du système électrique. L'application des réseaux de neurones artificiels pour protéger les lignes de transmission s'avère nécessaire pour pallier ces dysfonctionnements.

Ce modèle de ligne de transmission a été utilisé pour créer l'ensemble de base des données de défauts pour la conception des modèles de réseaux de neurones pour la détection, classification et localisation des défauts, cette base se constitue des valeurs triphasées de tension et de courant mesurées au niveau du bus de mesure triphasé pour

les conditions avant et pendant le défaut. Ces valeurs des tensions et des courants triphasés sont introduites dans le réseau de neurones comme entrées.

Différents paramètres et conditions, telles que la localisation, la résistance et le type de défaut, ont été variés pour élaborer la base des données « Dataset ». Le tableau 4-2 présente les différentes valeurs variées.

Tableau 4-2: Paramètres pour la génération de Dataset.

Localisation de défaut L_f (km)	La distance du défaut a été modifiée d'un pas de 4km sur la ligne de transmission de 100km
Résistance de défaut R_f (Ω)	0.25, 0.75, 1, 10 ,25.
Types de default	Pas de défaut, AG, BG, CG, AB,AC,BC, ABG,ACG,BCG,ABC

Les formes d'onde de tension et de courant triphasés ont été générées et échantillonnées à une fréquence de 20 kHz. Une réduction de la taille globale du réseau de neurones artificiels RNA améliore sa performance, ce qui peut être réalisé en optimisant l'extraction des caractéristiques. En procédant ainsi, toutes les informations importantes et pertinentes présentes dans les formes d'onde des signaux de tension et de courant peuvent être utilisées efficacement. La figure 4.2 présente les formes d'ondes de tensions et courants obtenues dans le cas du non-défaut.

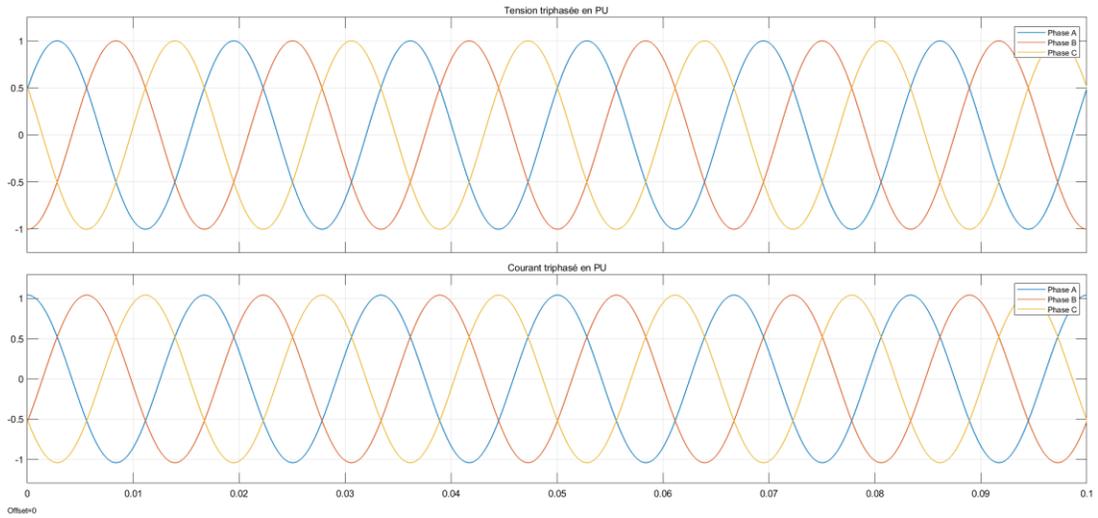


Figure 4.2 : Formes d'onde de tension et de courant du système étudié, sans défaut.

La figure 4.3 présente le cas d'un défaut entre la phase A et la terre à une distance de 47 km du terminal (Source1).

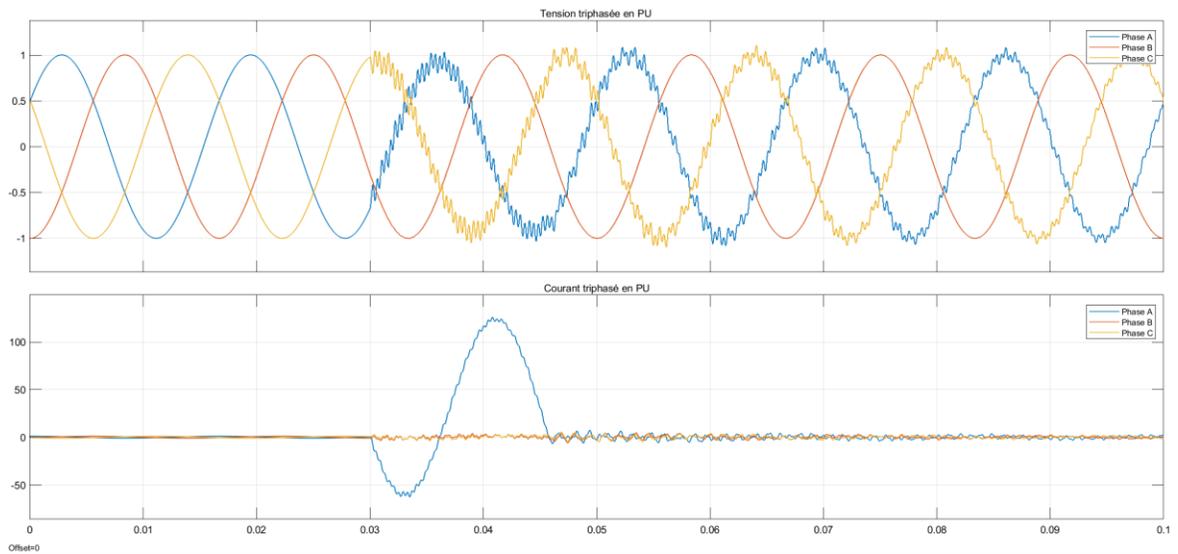


Figure 4.3 : Formes d'onde de tension et de courant pour un défaut entre la phase A et terre.

L'objectif principal de ce chapitre est de concevoir, développer, tester et mettre en œuvre des modèles de réseaux de neurones, capables de détecter, classifier et localiser les défauts dans la ligne de transmission. Dans un premier temps, l'ensemble des données collectées est subdivisé en trois ensembles, à savoir l'ensemble des données d'entraînement « Training Data », l'ensemble des données de validation et l'ensemble des données de tests.

La première étape du processus est d'indiquer la présence ou l'absence du défaut. Au cas de son occurrence, la deuxième étape consistera à identifier les phases en défauts, par la suite, la dernière étape est de déterminer la position du défaut sur la ligne de transmission de 100 km.

4.2 Traitement des signaux

Les mesures de tension et de courant sont généralement entachées avec du bruit et des harmoniques parasites, ce qui peut perturber la précision des performances de l'RNA. Dans un système réel, le filtrage analogique des signaux est utilisé pour éliminer ces harmoniques, afin de minimiser les signaux indésirables.

Les caractéristiques d'apprentissage pour le réseau de neurones sont les valeurs triphasées de la tension et de courant ($V_A, V_B, V_C, I_A, I_B, I_C$). Les données obtenues sont filtrées, échantillonnées et finalement traitées pour extraire les tensions et courants fondamentaux, chaque étape est expliquée ci-dessous.

- **Filtrage** : les composantes haute fréquence indésirables sont éliminées et filtrées en utilisant un filtre analogique passe-bas Butterworth de 10e ordre avec 480 Hz comme fréquence de coupure.
- **Échantillonnage** : les formes d'onde de tension et de courant ont été échantillonnées à une fréquence de 2 kHz. La fréquence du système est de

60 Hz, par conséquent, la fréquence d'échantillonnage choisie satisfait au théorème de Nyquist et fournit une meilleure résolution.

- **Extraction des données :** la méthode Root Mean Square RMS est utilisée pour extraire les caractéristiques fondamentales de Training Data.

La figure 4.4 illustre les différentes étapes présentées ci-dessus réalisées sous Simulink.

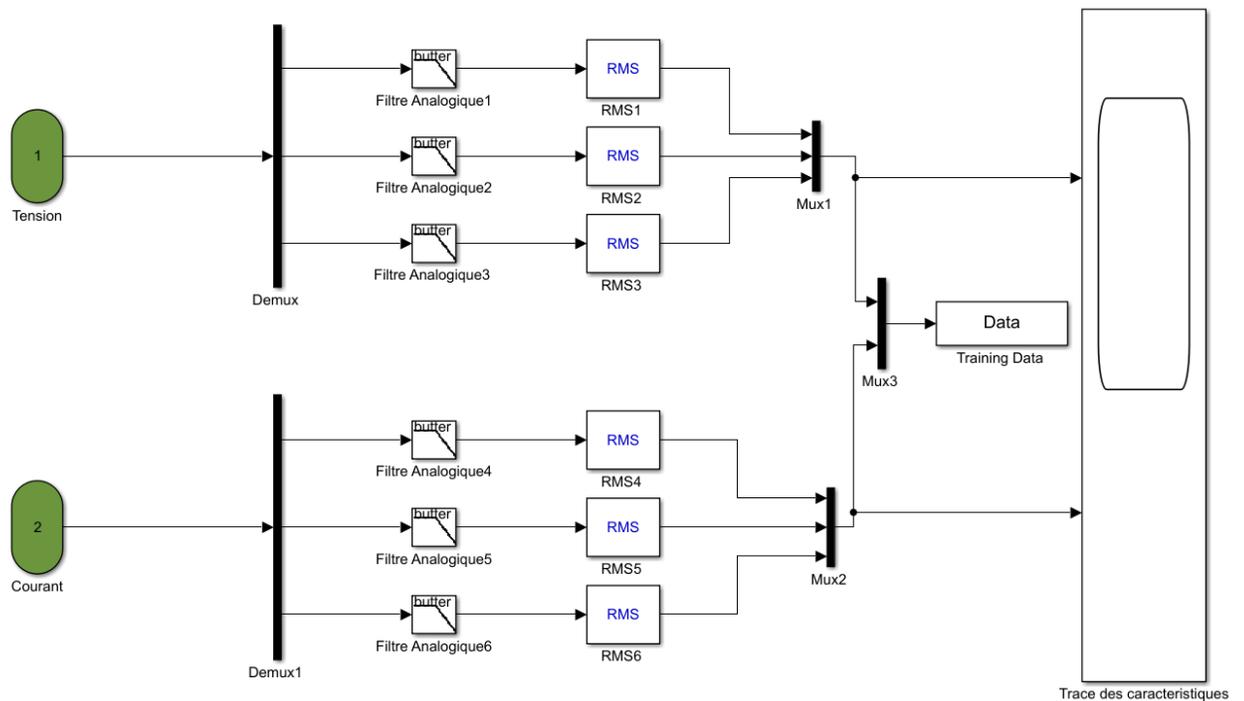


Figure 4.4 : Traitement des signaux de courant et tension.

Les caractéristiques d'entrée obtenues doivent être en plus normalisées dans une plage de 0 à 1. Cette étape peut considérablement augmenter les performances des réseaux neuronaux. Dans ce travail, la normalisation a été effectuée en divisant les composantes de défaut par les composantes de pré défaut ($V_{\text{défaut}}/V_{\text{pré-défaut}}$).

Les réseaux de neurones prennent donc comme entrées ($V_A, V_B, V_C, I_A, I_B, I_C$) après leur traitement, les sorties dépendent de la fonction du réseau neuronal, qui peut être la détection, la classification ou la localisation des défauts dans la ligne de transmission. Le tableau 4-3 donne une idée sur la nature des entrées.

Tableau 4-3 : Exemples d'entrées du réseau de neurones pour différents cas de défaut.

Cas	Entrées en PU						Type de défaut
	VA	VB	VC	IA	IB	IC	
1	0.7093	0.7094	0.7095	0.3536	0.3537	0.3538	Non défaut
2	0.6569	0.7093	0.6939	30.3209	0.8333	0.5859	AG
3	0.6445	0.6558	0.7094	1.2773	55.5789	1.5472	BG
4	0.7093	0.6843	0.7019	0.9190	0.8841	27.1487	CG
5	0.5696	0.6461	0.7068	76.0232	75.8332	0.3535	AB
6	0.6822	0.7209	0.6789	12.8110	0.3541	12.8712	AC
7	0.6370	0.6152	0.7336	0.3546	73.7269	73.6034	BC
8	0.5696	0.6391	0.7005	67.2029	84.8187	0.7738	ABG
9	0.6586	0.6986	0.6789	25.0134	1.0831	21.6207	ACG
10	0.6224	0.6152	0.7213	0.5187	83.9383	63.5406	BCG
11	0.5696	0.6152	0.6789	53.4721	99.3721	49.0701	ABC

4.3 Dataset et entraînement des RNAs

Comme mentionné dans la partie précédente, la base des données a été élaborée en variant et simulant différentes conditions du défaut, telles que la distance entre la source et le défaut, sa résistance et son type, 150 échantillons de chacun des défauts suivants : pas défaut, ligne-terre LT, double ligne LL, double ligne-terre LLT, triphasés LLL ont été simulés à l'aide de Simulink. Un ensemble de données avec un total de 1750 échantillons a été formé et utilisé pour développer les différents modèles de réseau de neurones, soit le détecteur, classificateur et localisateur neuronal.

Le réseau de neurones à rétropropagation a été utilisé pour la détection, classification et 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.

La Dataset élaborée est subdivisée en trois sous-ensembles, 70 % de ces données pour la phase d'entraînement des RNAs, appelée Training Data, 15 % pour la phase de validation et 15 % pour la phase de test. Ces pourcentages peuvent changer d'un problème à l'autre.

La phase de « training » est le processus par lequel le réseau neuronal apprend les données d'entrées en calculant le gradient et en mettant à jour ses poids. Donc training data se constitue des échantillons de données pour ajuster et développer le modèle.

Ensemble de données de validation se constitue des échantillons de données qui sont utilisés pour fournir une évaluation non biaisée de l'ajustement d'un modèle sur l'ensemble de données d'entraînement tout en ajustant les hyperparamètres du modèle. L'évaluation devient plus biaisée à mesure que la compétence sur l'ensemble de données de validation est incorporée dans la configuration du modèle. L'ensemble de validation est fourni au réseau pendant le processus d'entraînement (uniquement les entrées sans les sorties) et l'erreur pendant cette phase est contrôlée tout au long du processus d'entraînement. Lorsque le réseau approche le surapprentissage, l'erreur de validation augmente et lorsque le nombre d'échecs de validation dépasse une valeur prédéfinie, le processus d'entraînement s'arrête pour éviter le surapprentissage des données, le réseau est donc ramené au nombre minimum d'erreurs de validation. Ensemble des données de test se constituent des échantillons de données utilisées pour fournir une évaluation impartiale de l'ajustement du modèle final sur l'ensemble de données d'entraînement. Il n'est pas utilisé pendant le processus d'entraînement, mais sert à tester les performances du réseau formé.

4.4 Démarches pour la protection de la ligne

Après avoir validé et tester les différents modèles de protection de la ligne de transmission à savoir le détecteur, classification et localisateur neuronal. Ces modèles sont donc intégrés dans le système électrique étudié, l'algorithme suivant décrit les différentes étapes pour la protection :

Entrées : Mesure de la tension et courant triphasés ($V_A, V_B, V_C, I_A, I_B, I_C$) à la borne du Source1

Sorties : Détection, classification et localisation du défaut.

Étape 0 : **Démarrer**, initialisation $t=0$

Étape 1 : Prise des 6 valeurs d'entrées ($V_A, V_B, V_C, I_A, I_B, I_C$).

Étape 2 : Effectuer le filtrage anticrénelage et échantillonnage à la fréquence de 2 kHz.

Étape 3 : Application de RMS pour extraire les valeurs fondamentales.

Étape 4 : Normalisation des valeurs.

Étape 5 : Transmettez les six caractéristiques d'entrée au modèle détecteur neuronal ANN et obtenez la sortie.

Étape 6 : **Si** le défaut est non détecté, revenir à l'étape 1 et répéter le processus.

Sinon, envoyer un signal pour déclencher le disjoncteur et procéder aux étapes

Étape 7 : Le classificateur neuronal donne le type du défaut

Étape 8 : Le localisateur donne la distance entre le défaut et la Source1

Étape 9 : **Fin**

4.5 Méthode d'évaluation des modèles neuronaux

Tester le réseau neuronal développé est une étape importante à réaliser avant son application dans l'ensemble du système électrique, cette étape permet de s'assurer de la capacité du réseau neuronal formé à généraliser et produire des résultats souhaités lorsque de nouvelles données lui sont présentées. Il existe plusieurs techniques pour

évaluer les performances d'un réseau de neurones développé, dont quelques-unes sont abordées et utilisées dans ce projet.

L'une de ces techniques est « plotperform » qui consiste à tracer l'erreur en fonction de nombre d'itérations, cette technique permet à suivre l'évolution de l'erreur quadratique moyen et donne une idée sur la façon dont le réseau de neurones apprend pendant chaque phase, entraînement, validation et phase de test, la deuxième technique adoptée est à tracer le meilleur ajustement de régression linéaire « plotregression » entre les sorties du réseau neuronal réel et les cibles souhaitées. L'analyse de la pente de cette droite donne une idée sur le processus d'entraînement, le coefficient de corrélation mesure l'adéquation entre les sorties du réseau de neurones et les cibles souhaitées, la capacité des sorties du réseau neuronal à suivre les valeurs ciblées. Plus ce coefficient est proche de 1, meilleure est la performance du réseau neuronal. Une dernière technique adoptée est de tracer la matrice de confusion qui sert à examiner le nombre réel de cas qui ont été classés positivement par le réseau de neurones, elle permet en quelque sorte de résumer des résultats de prédiction pour un problème particulier de classification. Elle compare les données réelles pour une variable cible à celles prédites (sorties) par un modèle. Les prédictions justes et fausses sont révélées et réparties par classe, ce qui permet de les comparer avec des valeurs définies. Idéalement, ce pourcentage est de 100, ce qui signifie qu'il n'y a pas eu de confusion dans le processus de classification, dans le cas contraire si la matrice de confusion indique des taux de classification très faibles, cela signifie que le réseau neuronal pourrait ne pas être performant [61].

4.6 Analyses des performances du modèle détecteur neuronal

Pour la détection des défauts, différentes topologies des réseaux de neurones multicouches ont été développées et testées. Le choix de la topologie idéale d'un réseau

neuronal dépend de plusieurs facteurs, tel que la taille du réseau, stratégie d'apprentissage employée et la taille de l'ensemble des données d'entraînement.

Le choix de la taille du réseau approprié est très important, il permet non seulement de réduire le temps d'apprentissage, mais aussi d'améliorer considérablement la capacité du réseau neuronal à représenter le problème en question. Il n'existe pas de règle générale qui permet de choisir le nombre de couches cachées et nombre de neurones par couche cachée dans un problème donné.

Après plusieurs essais et une étude approfondie, le réseau de neurones de rétropropagation a été adopté comme topologie adéquate au problème. La technique d'optimisation de Levenberg-Marquardt a été employée pour améliorer les performances de l'algorithme de rétropropagation.

4.6.1 Entraînement du réseau de neurones pour la détection des défauts

Le détecteur neuronal reçoit six entrées ($V_A, V_B, V_C, I_A, I_B, I_C$) et donne une sortie. La sortie du réseau prend une valeur soit 0 indiquant l'absence du défaut ou 1 sa présence. Plusieurs modèles de réseaux de neurones ont été développés en variant le nombre de couches cachées, nombre de neurones dans chaque couche cachée et les fonctions d'activation pour chaque couche cachée. Ces modèles ont été testés dans le but de choisir le meilleur modèle qui permet d'avoir les résultats obtenus les plus proches des résultats ciblés.

Trois modèles sont présentés dans cette section afin de comparer leurs performances, le modèle adopté correspond à celui que son erreur quadratique moyenne proche de la valeur fixée qui est de 10^{-7} .

- **Modèle 1 :**

La figure 4.5 suivante présente les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteinte pendant la meilleure performance de validation.

Ce réseau se constitue de 6 neurones dans la couche d'entrée, 2 couches cachées, 26 neurones dans la première couche cachée, 16 neurones dans la deuxième et un seul neurone dans la couche de sortie, les fonctions de transfert/activation de chaque couche sont logsig-tansig-poslin respectivement. L'erreur quadratique moyenne atteinte à la fin du processus d'entraînement est égale à $6.6 * 10^{-8}$.

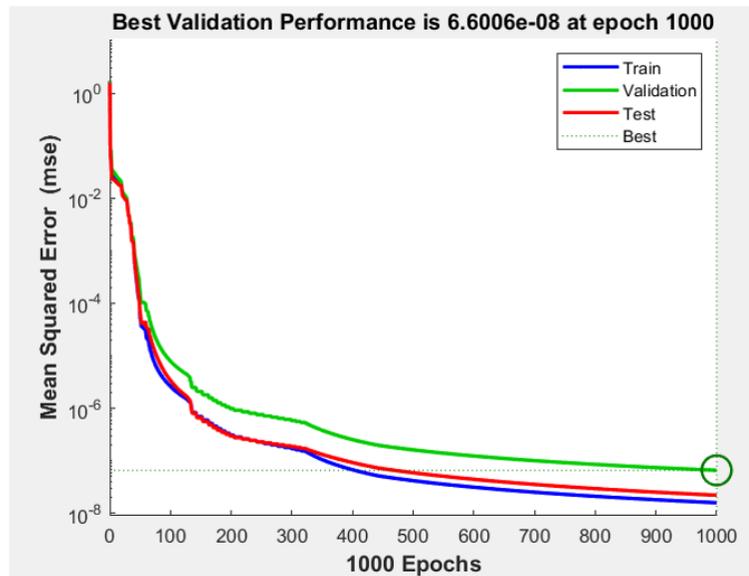


Figure 4.5 : Courbe de performance du détecteur neuronal 6-26-16-1.

- **Modèle 2**

La figure 4.6 suivante présente les courbes d'évolution de performance du deuxième modèle pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteinte pendant la meilleure performance de validation. Ce réseau se constitue

de 6 neurones dans la couche d'entrée, 3 couches cachées, 30 neurones dans la première couche cachée, 25 neurones dans la deuxième, 9 neurones dans la troisième et un seul neurone dans la couche de sortie, les fonctions de transfert/activation de chaque couche sont logsig-tansig-purelin-poslin respectivement. L'erreur quadratique moyenne atteinte à la fin du processus d'entraînement est égale à $8 * 10^{-8}$.

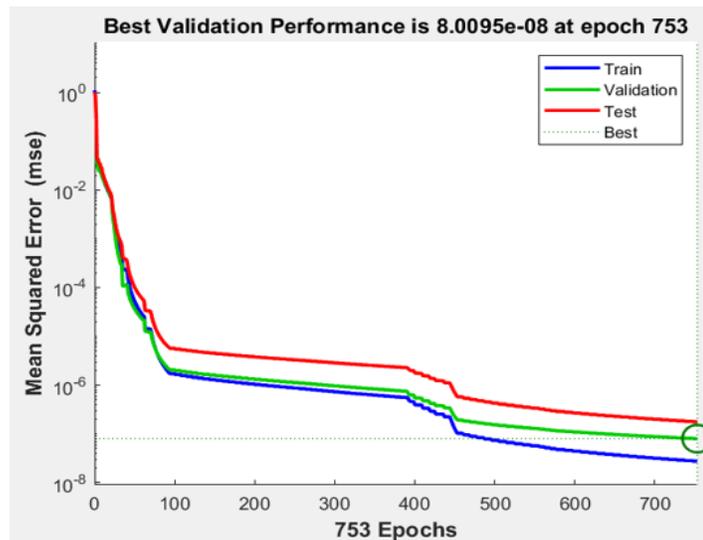


Figure 4.6 : Courbe de performance du détecteur neuronal 6-30-25-9-1.

- Modèle 3

La figure 4.7 suivante présente les courbes d'évolution de performance du deuxième modèle pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteinte pendant la meilleure performance de validation. Ce réseau se constitue de 6 neurones dans la couche d'entrée, 2 couches cachées avec 16 neurones dans la première couche cachée, 5 neurones dans la deuxième et un seul neurone dans la couche de sortie, les fonctions de transfert/activation de chaque couche sont logsig-tansig-purelin respectivement. L'erreur quadratique moyenne atteinte à la fin du processus d'entraînement est égale à $2.56 * 10^{-11}$.

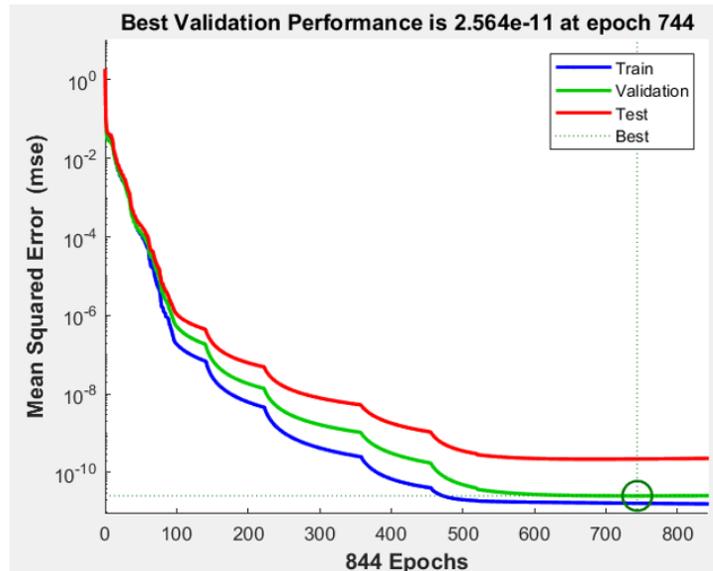


Figure 4.7 : Courbe de performance du détecteur neuronal 6-16-5-1.

Les trois modèles développés démontrent des performances satisfaisantes, les erreurs obtenues à la fin du processus d'apprentissage sont bien inférieures à la valeur fixée au début 10^{-7} , d'après les graphiques ci-dessus, il convient de noter que le modèle 3 montre la meilleure performance pendant la phase d'apprentissage, en plus de sa configuration optimisée, moins de couches cachées et de neurones. D'où le choix du détecteur neuronal.

4.6.2 Évaluation du détecteur neuronal adopté

Dans la section précédente, le réseau de neurones de configuration 6-16-5-1 a été adopté comme le réseau idéal pour la détection des défauts. Dans cette partie, on évalue les performances de ce réseau.

La figure 4.8 présente la meilleure régression linéaire obtenue à la fin de chaque phase, le coefficient de corrélation est égal à 1, ce qui indique une excellente corrélation, presque tous les points sont situés le long de la diagonale, en outre les sorties du réseau

de neurones sont en corrélation avec les valeurs ciblées, d'où le choix du détecteur neuronal adopté.

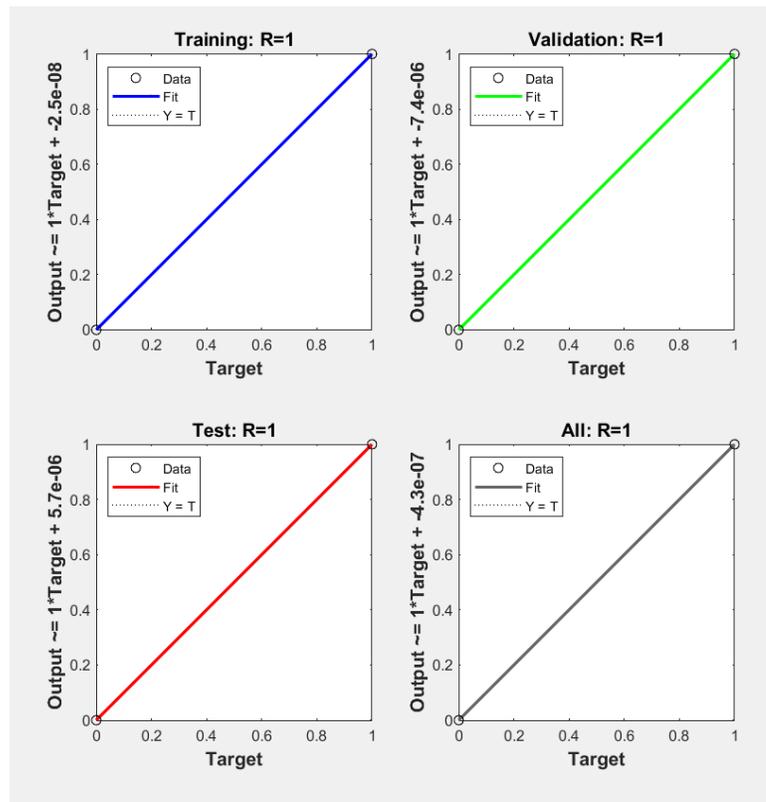


Figure 4.8 : Graphe de régression pour le détecteur neuronal.

La figure 4.9 présente la matrice de confusion pour les trois phases d'entraînement, validation et de test. Les cellules diagonales en vert indiquent le nombre de cas qui ont été correctement classés par le réseau neuronal et les cellules hors diagonale qui sont en rouge indiquent le nombre de cas qui ont été mal classés par le RNA. Le détecteur neuronal adopté permet de classer correctement 100 % l'ensemble de base des données fournies dans chaque phase, il n'y a pas eu de confusion.

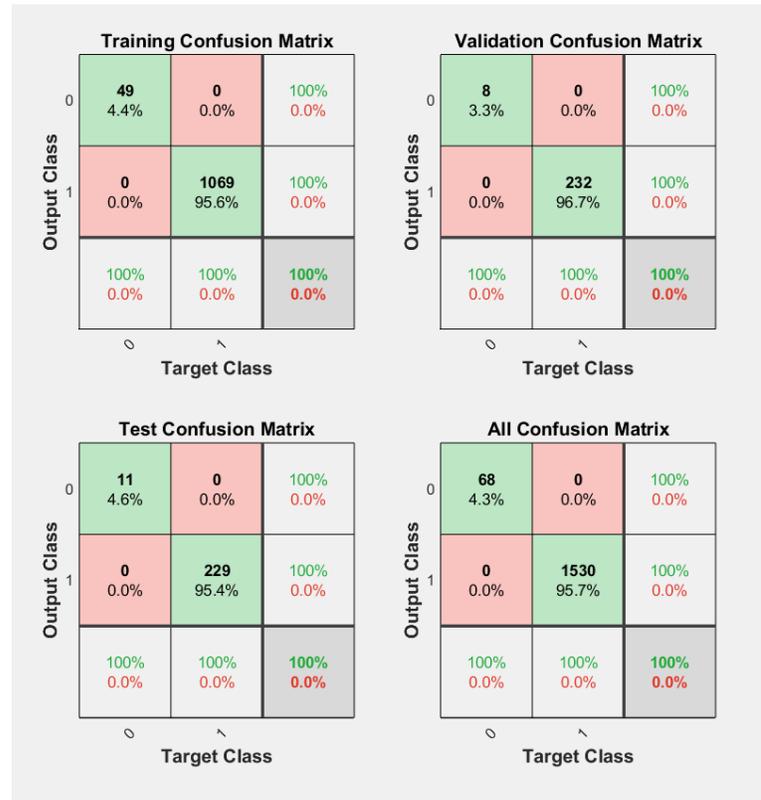


Figure 4.9 : Matrice de confusion du détecteur neuronal.

La structure du détecteur neuronal adopté pour le système électrique étudié est illustrée à la figure 4.10. Il est à noter que ce réseau reçoit 6 entrées dans la couche d'entrée, ces entrées se propagent dans les 2 couches cachées contenant respectivement 16,5 neurones et donne une sortie indiquant la présence ou absence du défaut.

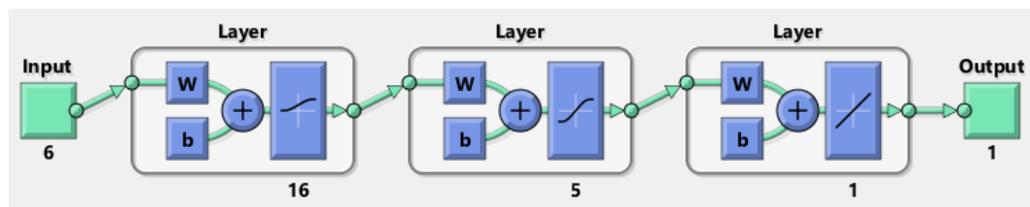


Figure 4.10 : Configuration du détecteur neuronal adopté.

4.7 Analyses des performances du modèle classificateur neuronal

Lorsque le détecteur neuronal détecte la présence du défaut sur la ligne de transmission électrique, la prochaine étape consiste donc à identifier son type et le classer parmi les 10 différents types. Cette section présente les démarches suivies pour le développement du classificateur neuronal. Le même processus qui a été utilisé pour la conception du détecteur neuronal est également suivi pour la conception et le choix du classificateur neuronal. Plusieurs topologies ont été développées et testées, une revue de chaque topologie est proposée dans la section suivante.

4.7.1 Entraînement du réseau de neurones pour la classification des défauts

Quoique l'algorithme de rétropropagation (backpropagation) est lent, il est peut-être utilisé dans 90 % des applications des réseaux de neurones. Il nécessite généralement de petits taux d'apprentissage pour un processus d'apprentissage stable, de sorte que la mise à jour des poids du réseau reste fiable. Certaines techniques visant à améliorer l'algorithme, tel que l'ajout de termes de momentum et du taux d'apprentissage adaptatif, des techniques d'optimisation comme l'algorithme du gradient (gradient descent) et Levenberg-Marquardt peuvent être utilisées. Par l'application de diverses techniques d'amélioration à différentes topologies de réseau de neurones, il a été déterminé que la méthode d'apprentissage la plus appropriée pour le problème de classification était la méthode de rétropropagation basée sur la technique d'optimisation Levenberg-Marquardt.

Le classificateur neuronal comprend lui aussi les six entrées ($V_A, V_B, V_C, I_A, I_B, I_C$) appartenant au même ensemble de base des données élaborée. Ce réseau a quatre sorties, chaque sortie correspond à l'état de chaque phase, soit A, B, C de la ligne de transmission, la 4e sortie correspond à la terre. Ces sorties prennent donc comme valeur soit 0 au cas d'absence de défaut ou 1 indiquant sa présence. Ainsi le réseau de neurones proposé devrait pouvoir distinguer avec précision les 10 différents types de défauts. Le

tableau 4-4 présente les différentes valeurs de sorties désirées ou ciblées correspondantes à chaque type de défaut.

Tableau 4-4 : Sorties désirées du classificateur neuronal.

Phases Type de défaut	Sorties désirées du classificateur neuronal			
	A	B	C	T
Non-Défaut	0	0	0	0
A-T	1	0	0	1
B-T	0	1	0	1
C-T	0	0	1	1
A-B-T	1	1	0	1
A-C-T	1	0	1	1
B-C-T	0	1	1	1
A-B	1	1	0	0
A-C	1	0	1	0
B-C	0	1	1	0
A-B-C	1	1	1	0

Différentes topologies du classificateur neuronal ont été développées et analysées en variant le nombre des couches cachées, nombre de neurones dans chaque couche cachée et les fonctions d'activation de chaque couche cachée. Trois modèles sont donc présentés dans la section suivante afin de comparer leurs performances pour définir le classificateur neuronal le plus performant, l'erreur quadratique moyenne désirée est fixée à la valeur 10^{-4} .

- **Modèle 1 :**

La figure 4.11 suivante présente les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteinte pendant la meilleure performance de validation. Ce réseau se constitue de 6 neurones dans la couche d'entrée, 3 couches cachées, 16 neurones dans la première couche cachée, 12 neurones dans la deuxième, 6 neurones dans la troisième et 4 neurones dans la couche de sortie, les fonctions de transfert/activation des couches cachées et la couche de sortie sont respectivement logsig-tansig-purelin-poslin respectivement. L'erreur quadratique moyenne atteinte à la fin du processus d'entraînement est égale à $1 * 10^{-4}$.

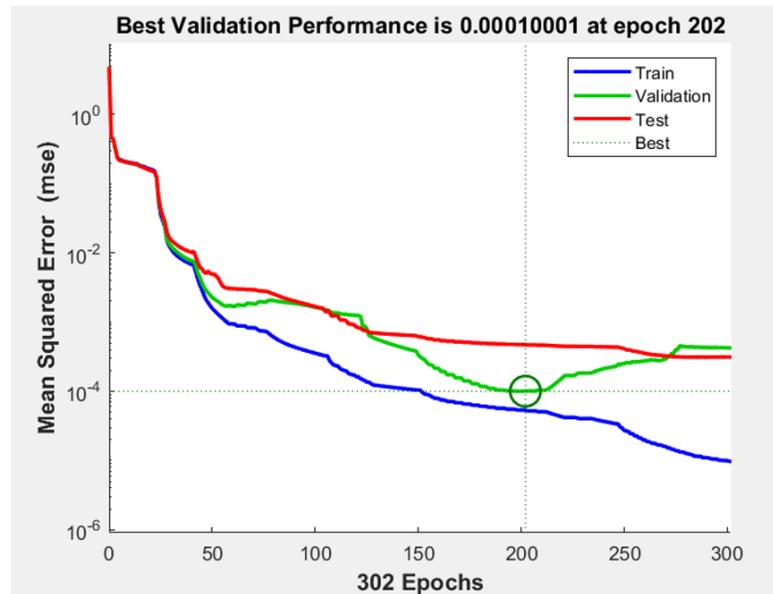


Figure 4.11 : Courbe de performance du classificateur neuronal 6-16-12-6-4.

- **Modèle 2**

La figure 4.12 suivante présente les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteinte pendant la meilleure performance de validation.

Ce réseau se constitue de 6 neurones dans la couche d'entrée, 2 couches cachées, 20 neurones dans la première couche cachée, 12 neurones dans la deuxième et 4 neurones dans la couche de sortie, les fonctions de transfert/activation des couches cachées et la couche de sortie sont respectivement logsig-tansig-poslin respectivement. L'erreur quadratique moyenne atteinte à la fin du processus d'entraînement est égale à $2.79 * 10^{-4}$.

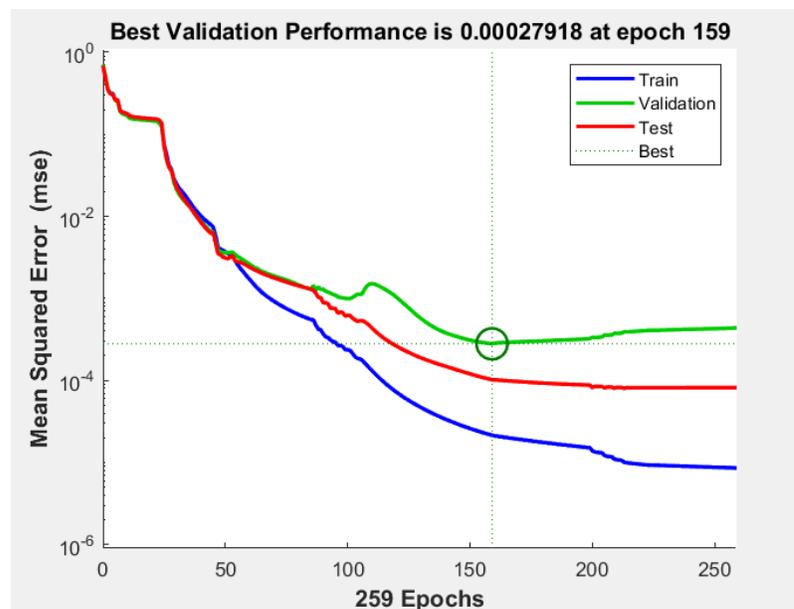


Figure 4.12 : Courbe de performance du classificateur neuronal 6-20-12-4

- Modèle 3

La figure 4.13 suivante présente les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteinte pendant la meilleure performance de validation. Ce réseau se constitue de 6 neurones dans la couche d'entrée, 2 couches cachées, 16 neurones dans la première couche cachée, 6 neurones dans la deuxième et 4 neurones dans la couche de sortie, les fonctions de transfert/activation des couches cachées et de sortie sont respectivement logsig-tansig-purelin respectivement.

L'erreur quadratique moyenne atteinte à la fin du processus d'entraînement est égale à $8.07 * 10^{-5}$, les courbes d'entraînement et de test ont des caractéristiques similaires, ce qui indique un apprentissage efficace.

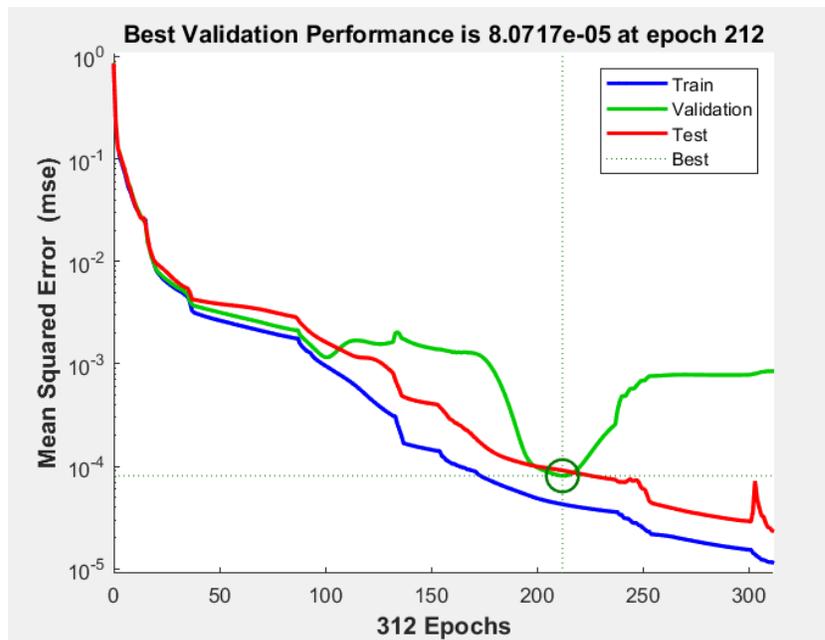


Figure 4.13 : Courbe de performance du classificateur neuronal 6-16-6-4

Les trois modèles développés démontrent des performances satisfaisantes, les erreurs obtenues à la fin du processus d'apprentissage sont proches de la valeur fixée au début 10^{-4} , le 1er et le 2e modèle atteignent presque la même valeur d'erreur à la fin du processus d'apprentissage, la différence réside donc dans la durée requise pour l'apprentissage. D'après les graphiques ci-dessus, il convient de noter que le modèle 3 montre la meilleure performance pendant la phase d'apprentissage, en plus de sa configuration optimisée, moins de couche cachée et de neurones. C'est pourquoi ce réseau a été choisi comme le classificateur idéal des défauts.

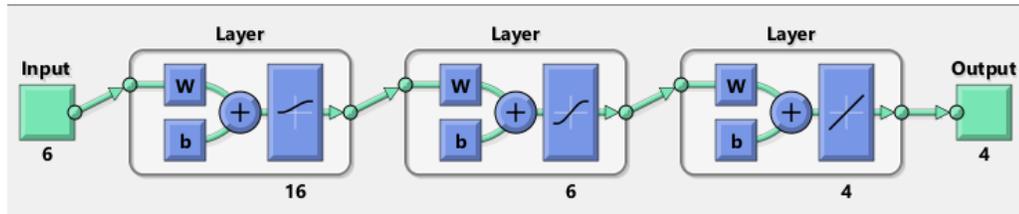


Figure 4.14 : Réseau de neurones adopté pour classification des défauts.

4.7.2 Évaluation du classificateur neuronal adopté

Après avoir choisi la configuration du classificateur neuronal adéquate pour le réseau électrique étudié, ces performances ont été évaluées en analysant la courbe de la meilleure régression linéaire, la matrice de confusion et la courbe de la fonction d'efficacité du récepteur ROC « Receiver Operating Characteristic ».

La figure 4.15 montre le tracé de la meilleure régression linéaire qui relie les sorties désirées ou ciblées aux sorties réelles du classificateur neuronal. Les coefficients de corrélations pour les trois phases, entraînement, validation et test sont d'ordre 0.999 ce qui indique une corrélation satisfaisante entre les deux variables. Les courbes d'apprentissage de chaque division de l'ensemble de données présentent un écart suffisant, ce qui montre que le modèle formé n'est pas sur ajusté. Le classificateur neuronal est donc capable de donner des résultats satisfaisants sous la base des nouvelles données différentes de ceux de la base des données formée au début. La figure 4.16 présente la matrice de confusion pour les trois phases d'entraînement, validation et de test. Les pourcentages de classification obtenue à la fin du processus d'apprentissage sont acceptables.

Le 3e facteur dans le processus d'évaluer les performances du classificateur neuronal adopté consiste à tracer la courbe de la fonction d'efficacité du récepteur ROC, comme montré dans la figure 4.17. Cette fonction d'évaluation est surtout utilisée dans le cas du problème de classification binaire, elle trace la caractéristique opérationnelle du récepteur pour chaque classe de sortie. Plus les courbes s'approchent du bord gauche

et supérieur du graphique, meilleure est la classification. Les courbes ROC sont donc des traces entre les taux de vrai positifs (taux de classification positive) et les taux de faux positifs (taux de classification incorrecte) du classificateur neuronal. Par conséquent, le classificateur neuronal adopté donne une courbe ROC idéale avec des taux positifs réels de 100 %. Par conséquent, le classificateur neuronal choisi permet d’avoir des performances satisfaisantes.

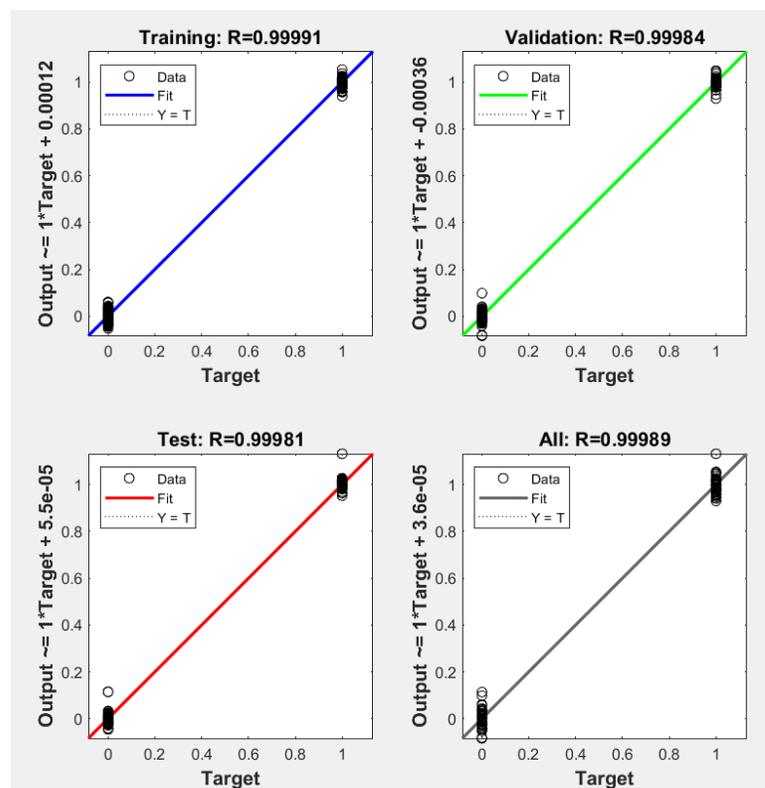


Figure 4.15 : Graphe de régression pour le classificateur neuronal.



Figure 4.16 : Matrice de confusion du classificateur neuronal.

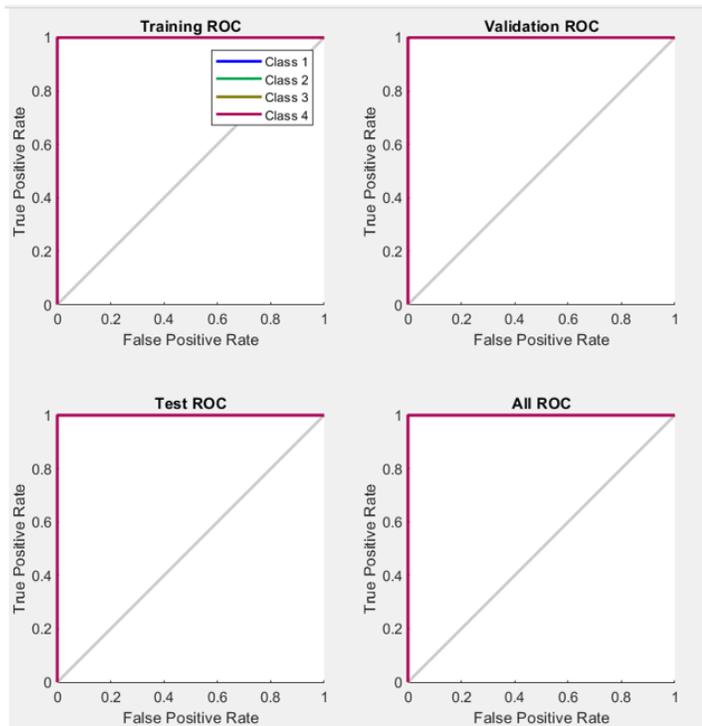


Figure 4.17 : La courbe de la fonction d'efficacité du récepteur ROC.

4.8 Analyses des performances du modèle localisateur neuronal

Pour protéger les lignes de transmission des dégâts catastrophiques qu'un défaut peut causer, il faut isoler la partie défectueuse une fois un défaut détecté. En effet, la localisation précise du défaut, permet d'économiser le temps nécessaire pour vérifier physiquement la ligne. La classification permet d'identifier le type de défaut pour prendre une décision sur la façon de l'éliminer. Cette section présente une revue sur la conception et le développement d'un localisateur du défaut basé sur les réseaux de neurones artificiels pour le système électrique étudié. Différentes topologies du réseau de neurones ont été développées et testées pour choisir un localisateur neuronal ayant le taux d'erreur le plus petit.

4.8.1 Entraînement du réseau de neurones pour la localisation des défauts

Les réseaux de neurones de type feedforward ont été encore une fois adoptés pour développer les localisateurs neuronaux en raison de leurs simplicités, facilité de les mettre en œuvre avec un temps d'entraînement réduit. Le localisateur neuronal n'est pas un modèle de classification comme le détecteur et classificateur neuronal du défaut qui permet de donner une sortie binaire. En effet, il s'agit plutôt de calculer la valeur exacte de l'emplacement du défaut par rapport à un terminal, c'est donc un modèle de régression.

Par conséquent, la fonction d'ajustement « Fitting » est utilisée pour ajuster les sorties du localisateur neuronal, Levenberg-Marquardt a été adoptée comme fonction d'apprentissage.

Les caractéristiques d'entrées sont toujours les six valeurs triphasées de tension et courant après leur traitement ($V_A, V_B, V_C, I_A, I_B, I_C$). Le localisateur neuronal doit donc avoir une seule sortie indiquant la distance entre l'emplacement du défaut détecté et la source 1. Ci-dessous trois modèles sont donc présentés afin de comparer leurs

performances pour choisir le localisateur neuronal du défaut le plus approprié, l'objectif est d'atteindre une erreur quadratique moyenne de 0,1.

- Modèle 1

Ce premier modèle se constitue de 6 neurones dans la couche d'entrée, 4 couches cachées, 30 neurones dans la première couche cachée, 16 neurones dans la deuxième, 6 neurones dans la troisième, 3 dans la quatrième et un neurone dans la couche de sortie, la fonction d'activation pour ces quatre couches cachées est tansig et purelin pour la couche de sortie. La figure 4.18 présente les courbes d'évolution de performance du réseau 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 $1.95 * 10^{-2}$.

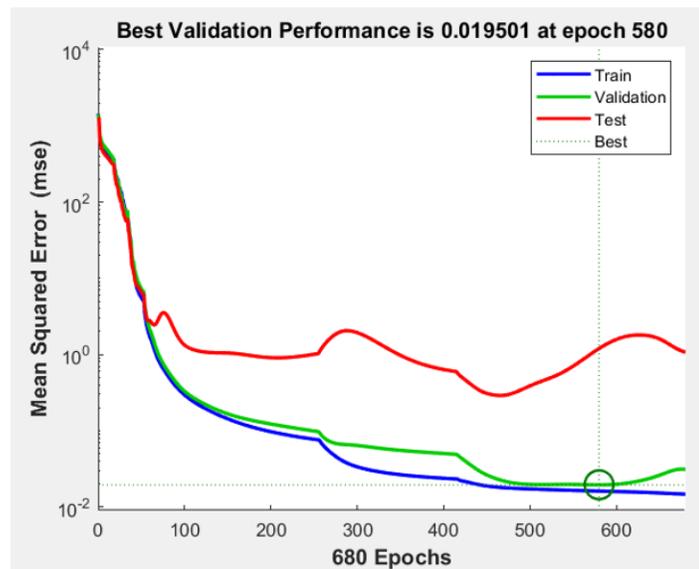


Figure 4.18 : Courbe de performance du localisateur neuronal 6-30-16-6-3-1.

- Modèle 2

La figure 4.19 présente les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test. Elles représentent l'erreur quadratique moyenne en fonction du temps pendant le processus d'apprentissage. Ce réseau se constitue de 6 neurones dans la couche d'entrée, 2 couches cachées, 25 neurones dans la première couche cachée, 3 neurones dans la deuxième et 1 neurone dans la couche de sortie.

L'erreur quadratique moyenne atteinte à la fin du processus d'entraînement est égale à 0.24369, les trois courbes ont des caractéristiques similaires, ce qui indique un apprentissage efficace.

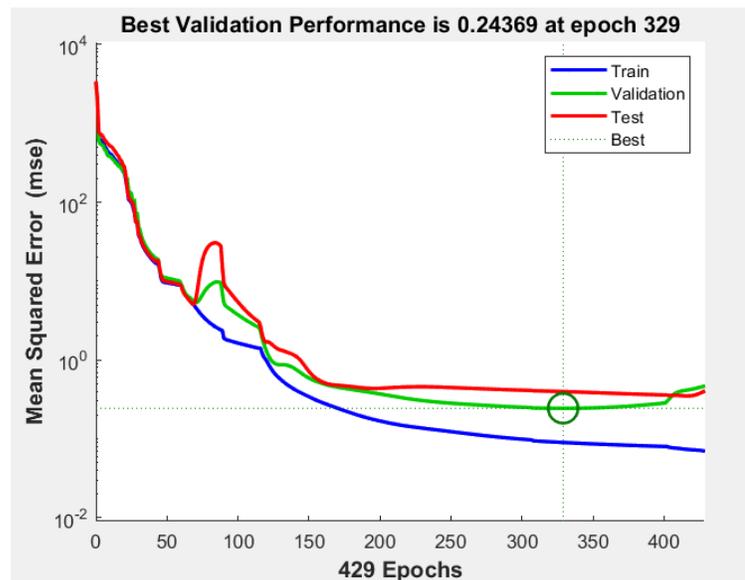


Figure 4.19 : Courbe de performance du localisateur neuronal 6-20-3-1.

- Modèle 3

La figure 4.20 présente les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test. Elles représentent l'erreur quadratique moyenne en fonction du temps pendant le processus d'apprentissage. Ce réseau se

constitue de 6 neurones dans la couche d'entrée, 3 couches cachées, 16 neurones dans la première couche cachée, 9 neurones dans la deuxième, 3 neurones dans la troisième et 1 neurone dans la couche de sortie. L'erreur quadratique moyenne atteinte à la fin du processus d'entraînement est égale à $6.019 * 10^{-6}$.

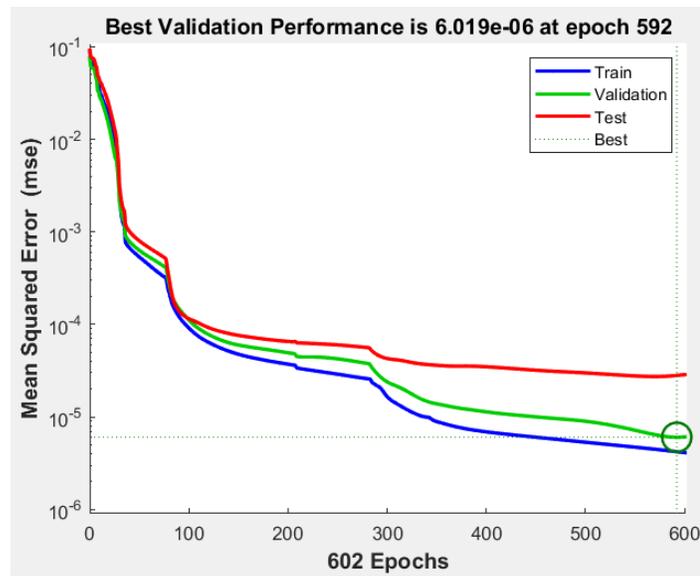


Figure 4.20 : Courbe de performance du localisateur neuronal 6-16-9-3-1.

D'après les graphiques présentés pour les trois modèles du localisateur neuronal, il convient de noter que des performances satisfaisantes ont été obtenues pendant la phase d'apprentissage par le troisième modèle. L'erreur quadratique moyenne EQM obtenue est égale à $6.019 * 10^{-6}$ qui est inférieur à la valeur 0.1 fixée comme objectif. Par conséquent, le modèle 3 est adopté pour la localisation du défaut.

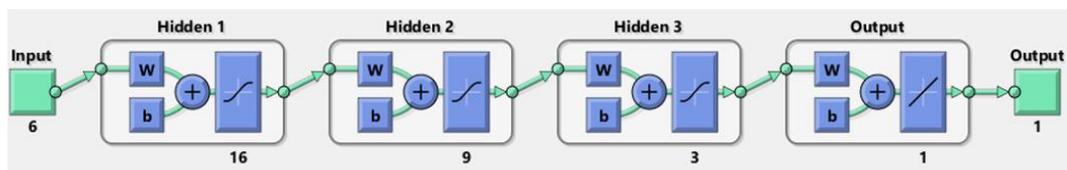


Figure 4.21 : Réseau de neurones adopté pour la localisation des défauts.

4.8.2 Évaluation du localisateur neuronal adopté

Le localisateur neuronal choisi (avec configuration 6-16-9-3-1) démontre des performances excellentes pendant la phase d'apprentissage, par ailleurs l'évaluation de l'efficacité de ce réseau a été analysée en traçant la courbe de meilleure régression linéaire entre les sorties du localisateur neuronal et les valeurs ciblées réelles pendant les trois phases d'entraînement, validation et test. Ce graphe est représenté dans la figure 4.22, la valeur du coefficient de corrélation pendant les trois phases d'apprentissage est d'ordre 0.9999, ce qui indique une excellente corrélation entre les sorties et les valeurs réelles. Un autre facteur pour évaluer l'efficacité du localisateur neuronal choisi est de le tester sur un nouvel ensemble de données (juste les entrées) et de calculer l'erreur entre les sorties réelles (distances réelles) et les sorties du localisateur neuronal (distances prédites).

Le tableau 4.5 illustre les pourcentages d'erreurs dans la localisation des défauts en fonction de type de défauts et résistance du défaut. Les valeurs de résistances choisies pour tester le réseau de neurones ne font pas partie de l'ensemble de données pour l'entraînement élaboré au début du chapitre. Il est noté que l'erreur moyenne dans la localisation des défauts n'est que de 0,213. Par conséquent, le localisateur neuronal choisi a démontré sa capacité à généraliser et à réagir d'une manière appropriée aux nouvelles données.

À noter : Les courbes d'évaluation des modèles conçus pour la détection, classification et localisation sont présentées dans l'Annexe A.

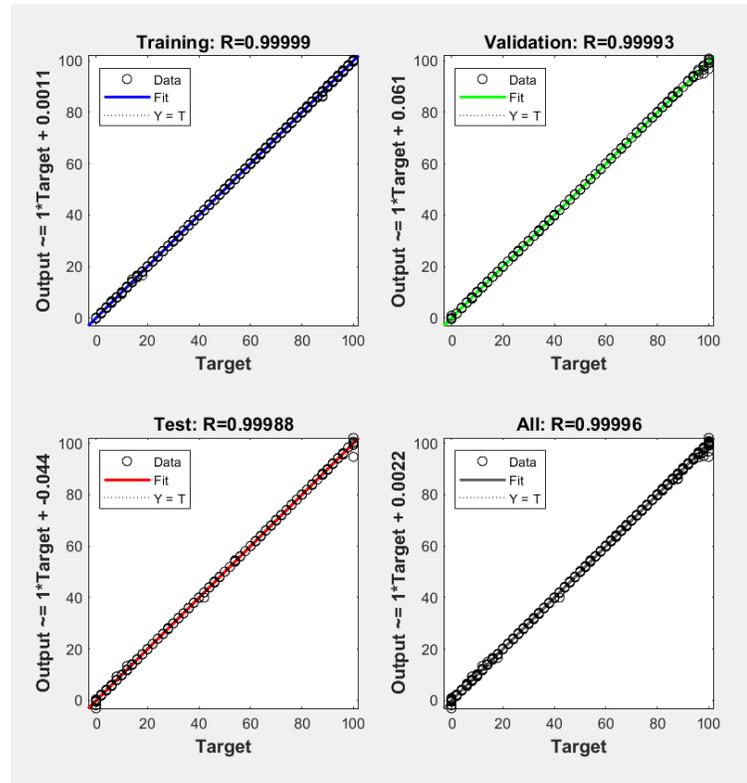


Figure 4.22 : Graphe de régression pour le localisateur neuronal.

Tableau 4-5 : Comparaison entre sorties réelles et sorties prédites par le localisateur neuronal.

Type de défaut	Résistance de défaut Ω	Distance réelle km	Distance prédite km	Erreur en %
A-G	0.5	15	14.8	0.2
	14	17	17.2	0.2
	46	59	59.05	0.05
B-G	1.5	94	94.12	0.12
	23	27	27.05	0.05
	66	62	61.92	0.08
C-G	0.4	26	26.04	0.04
	13	13	12.95	0.05
	55	82	82.23	0.23

Type de défaut	Résistance de défaut Ω	Distance réelle km	Distance prédite km	Erreur en %
A-B-G	3	17	18.96	1.96
	17	3	2.66	0.34
	24	19	19.07	0.07
B-C-G	2	1	1.16	0.16
	16	53	53.8	0.8
	29	71	70.94	0.06
C-A-G	4	89	88.9	0.1
	0.7	29	28.91	0.09
	69	15	15.14	0.14
A-B	78	67	66.98	0.02
	12	14	13.85	0.15
	27	22	22.18	0.18
B-C	96	19	19	0
	14	38	38.8	0.8
	35	45	44.93	0.07
C-A	41	75	75.01	0.01
	0.4	83	82.79	0.21
	12	5	5.03	0.03
A-B-C	1.4	7	6.89	0.11
	9	99	98.95	0.05
	100	77	77.03	0.03

4.9 Application des modèles conçus sur le système proposé

Après avoir développé et évalué les performances des trois modèles de réseaux de neurones pour la détection, classification et localisation des défauts, ces derniers sont regroupés dans un bloc appelé « relais ANN » comme illustré dans la figure 4.23, c.-à-d. relais à base des réseaux de neurones, ce relais est capable d'indiquer la présence ou absence du défaut, identifier son type et donner son emplacement dans la ligne par

rapport au terminal 1 (Source triphasée 1). Le bus de mesure enregistre en temps réel les valeurs de courant et tension triphasés. Le relais se base donc sur ces derniers après avoir passé par le système de traitement et extraction des caractéristiques fondamentales illustré dans la figure annexe B pour prédire les résultats.

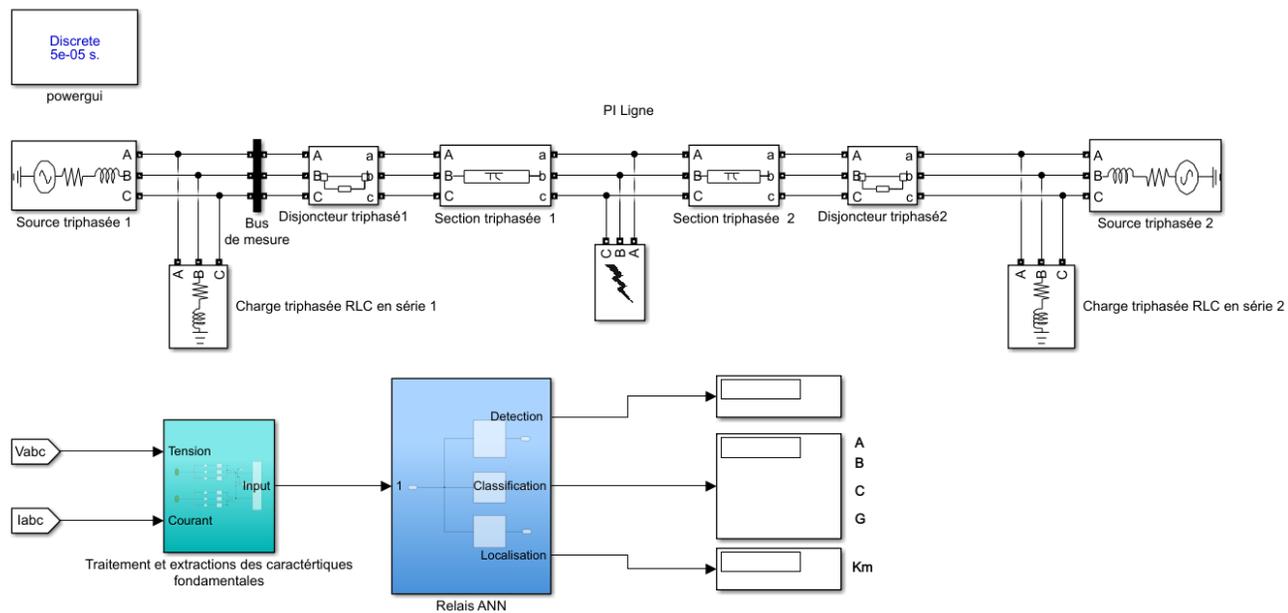


Figure 4.23 : Modèle de protection en temps réel du système électrique proposé.

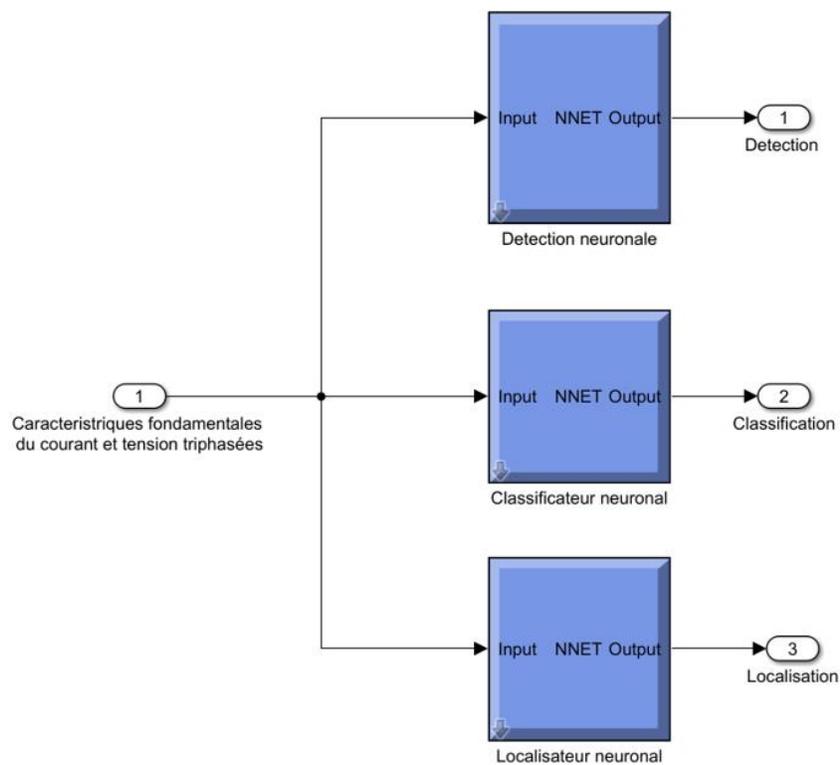


Figure 4.24 : Bloc Relais ANN.

Un défaut entre la phase B et la terre est appliqué pendant 30 ms entre l'instant 0.03 s et 0.06 s, la figure 4.25 présente la forme d'onde du courant triphasé et la réponse du détecteur neuronal en temps réels, ce dernier prend la valeur 1 toute la durée du défaut et même pendant la phase d'élimination du défaut. La figure 4.26 montre les formes d'onde de courant et tensions triphasés après leur traitement pendant le défaut B-G, c.-à-d. après avoir être normalisées, filtrées et converties en valeur RMS. Ces signaux constituent ensuite les entrées pour le détecteur de défauts, les résultats de simulation obtenus montrent l'efficacité du détecteur neuronal à indiquer la présence ou l'absence du défaut.

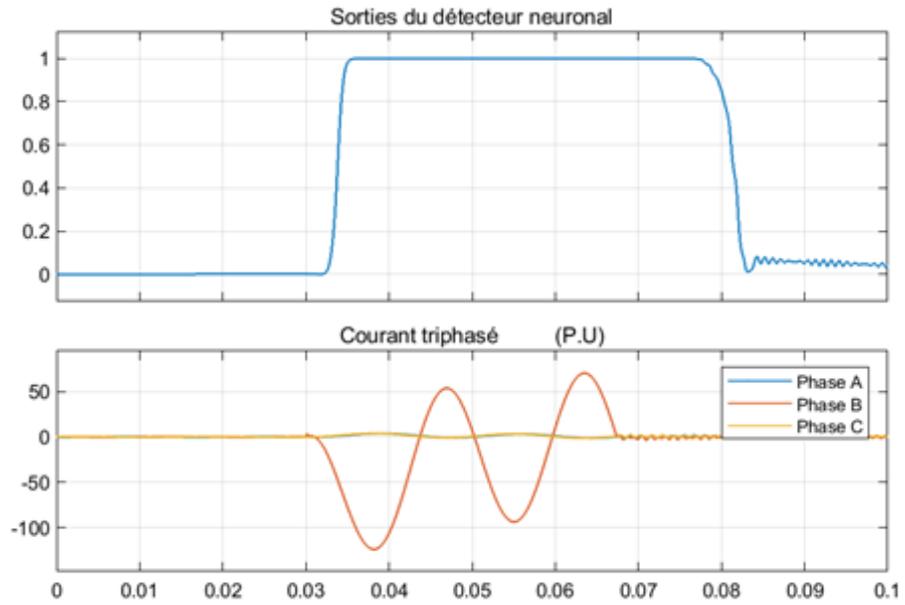


Figure 4.25 : Forme d'onde de courant et réponse du détecteur neuronal lors d'un défaut B-G.

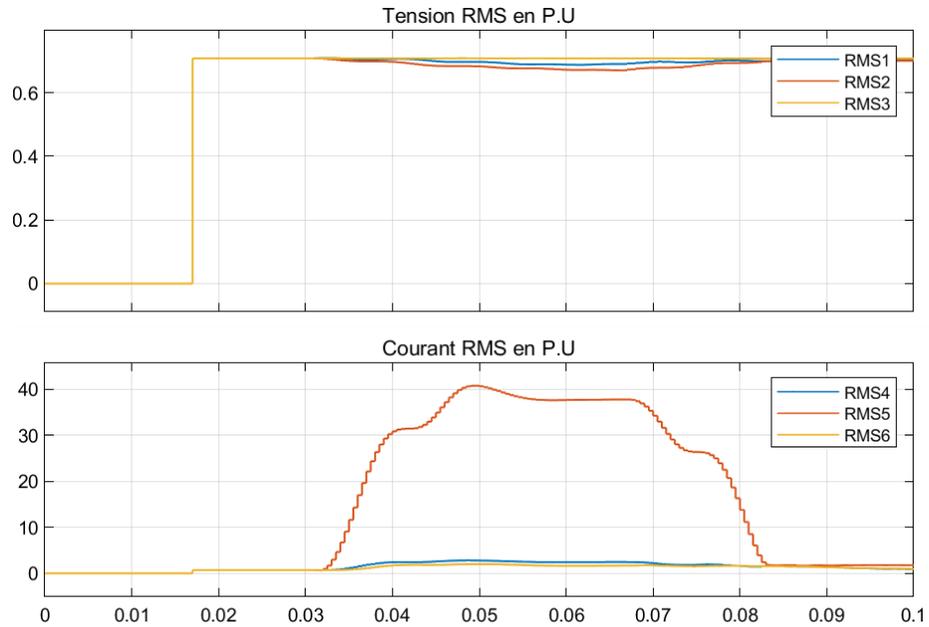


Figure 4.26 : Formes d'ondes de courant et tensions après leur traitement.

Pour la même durée, différents types de défauts ont été simulés pour tester davantage le détecteur neuronal. Figure 4.27, figure 4.28 et figure 4.29 présentent la forme d'onde du courant et la réponse de ce détecteur avant et pendant le défaut : un défaut de type Ligne-Ligne, défaut Ligne-Ligne-Terre et défaut triphasé Ligne-Ligne-Ligne.

Comme constaté, le détecteur neuronal a démontré sa capacité à identifier correctement les différents types de défauts. Un détecteur à base de réseaux de neurones constitue donc une meilleure solution pour la reconnaissance des formes, comme dans ce cas : les défauts.

La précision du détecteur neuronal dépend en grande partie des données d'apprentissage « Training Data », l'amélioration et l'optimisation de cet ensemble des données peuvent améliorer davantage les performances des réseaux de neurones.

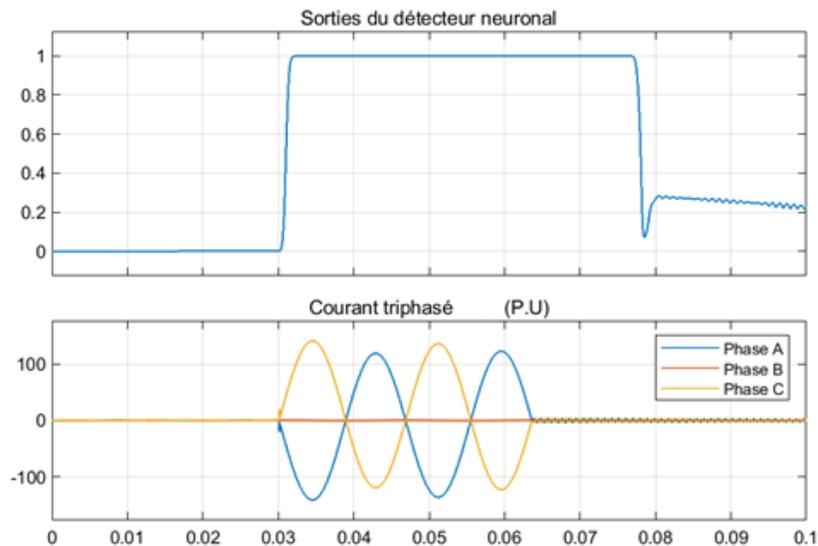


Figure 4.27 : Forme d'onde de courant et réponse du détecteur neuronal lors d'un défaut A-C.

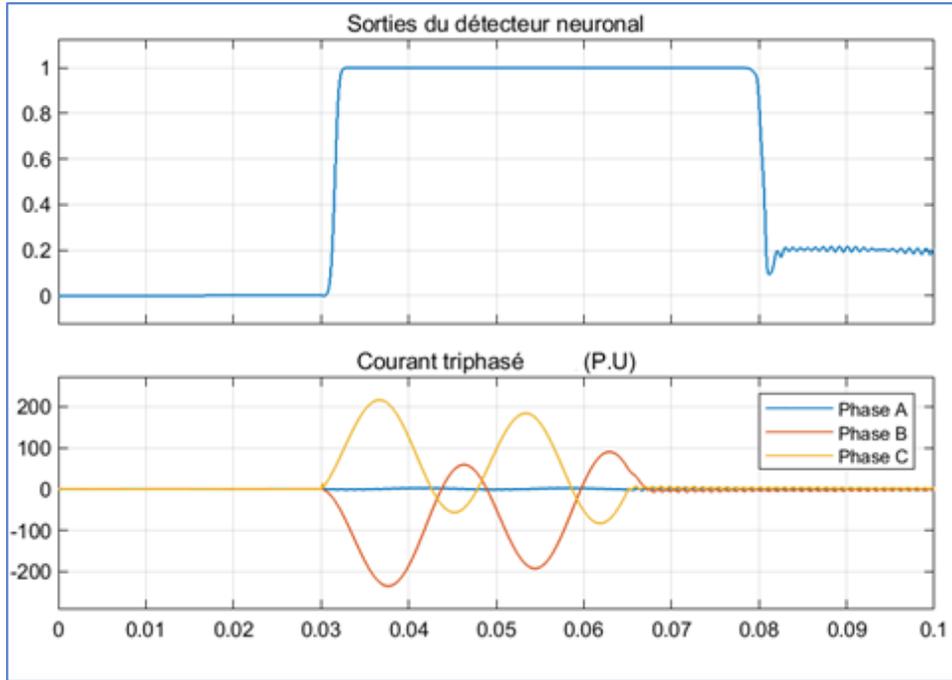


Figure 4.28 : Forme d'onde de courant et réponse du détecteur neuronal lors d'un défaut B-C-G.

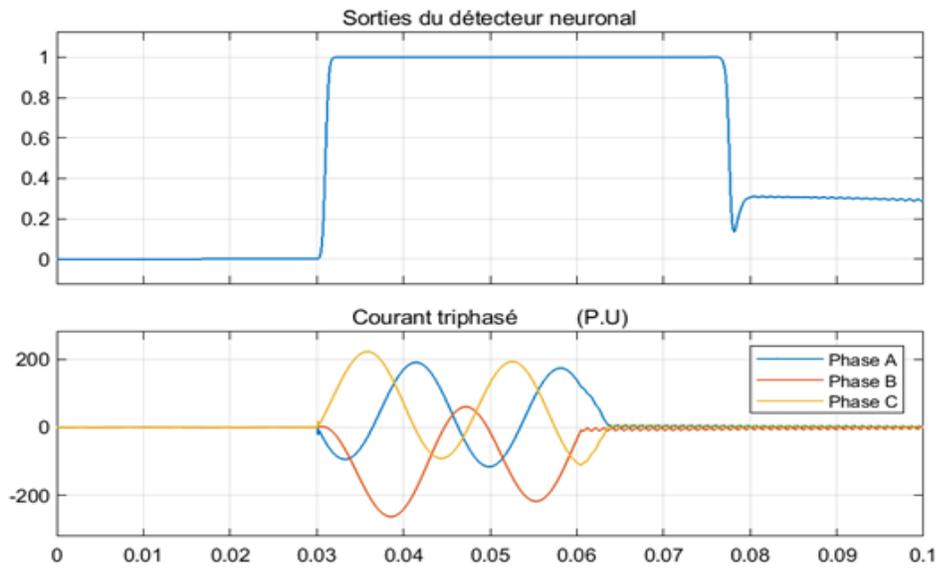


Figure 4.29 : Forme d'onde de courant et réponse du détecteur neuronal lors d'un défaut A-B-C.

4.10 Relais à base de réseaux de neurones

Comme indiqué dans la partie précédente, les trois modèles conçus pour la protection de ligne de transmission « réseau électrique étudié », à savoir : détecteur, classificateur et le localisateur des défauts à base du réseau de neurones ont été regroupé dans un seul modèle « bloc relais ANN », ce relais prend les valeurs de courant et tension triphasés comme entrées, après leur traitement, donne 6 sorties, la 1^{re} indique la présence ou l'absence du défaut, les 4 sorties qui suivent sont réservées pour identifier son type et la dernière sortie donne son emplacement dans la ligne de transmission par rapport à la source triphasée 1.

Il est à noter que le localisateur neuronal donne la position du défaut après quelques millisecondes approximativement 10 ms, après le régime transitoire du défaut.

La figure 4.30 présente la réponse du relais pour un défaut appliqué entre la phase A et la terre G à 77 km de la source triphasée 1 avec une résistance de défaut 0.5 Ω . Le relais indique le type et l'emplacement approximatif du défaut afin que l'ingénieur de contrôle de ligne envoie ces informations aux travailleurs de maintenance pour aller directement à la position de défaut pour l'éliminer en fonction de son type, cela permet d'éviter de vérifier physiquement le 100 km de la ligne pour le défaut.

Différents cas (figure 4.31, figure 4.32, figure 4.33) ont été simulés pour évaluer l'efficacité du relais conçu pour la protection de ligne de transmission.

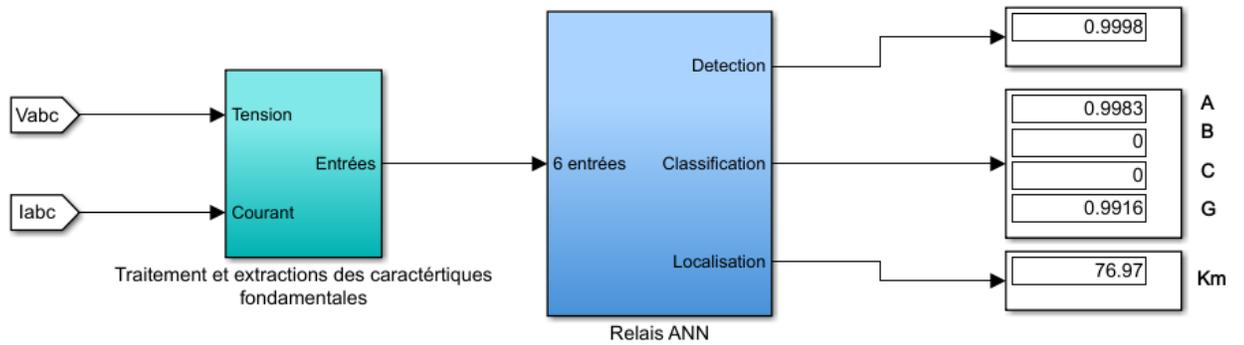


Figure 4.30 : Réponse de relais pour un défaut A-G à 77 km de Source 1.

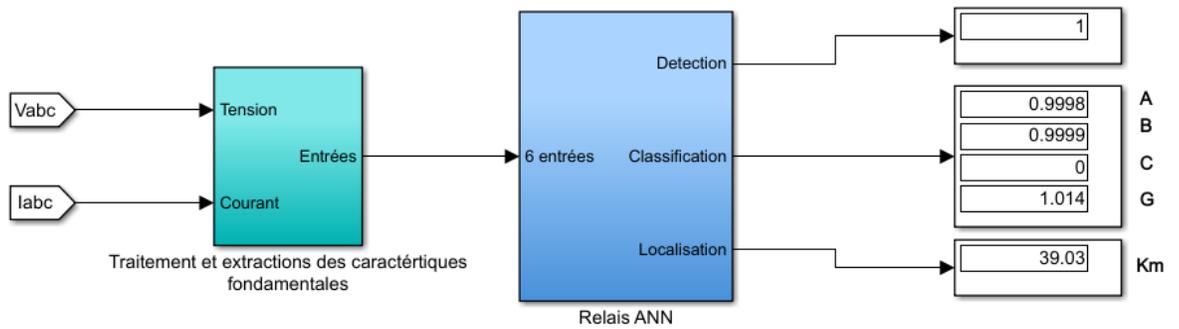


Figure 4.31 : Réponse de relais pour un défaut A-B-G à 39 km de Source 1 avec $R_f = 10 \Omega$.

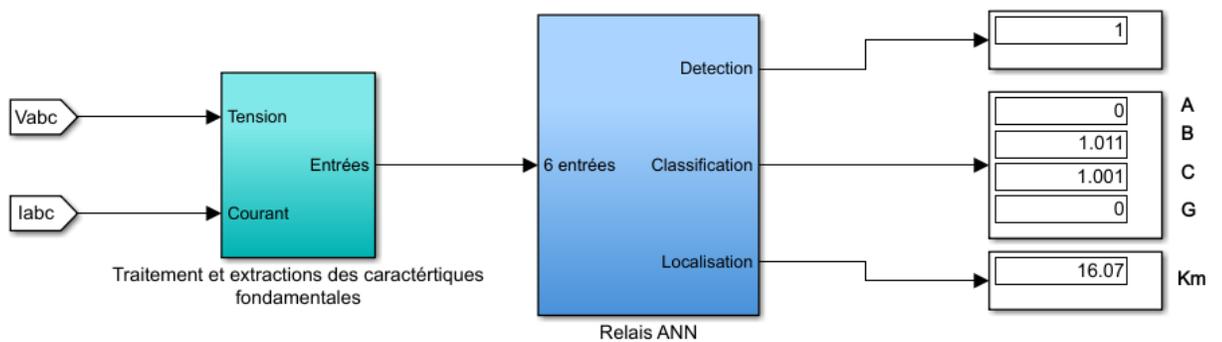


Figure 4.32 : Réponse de relais pour un défaut B-C à 16 km de Source 1 avec $R_f = 24 \Omega$.

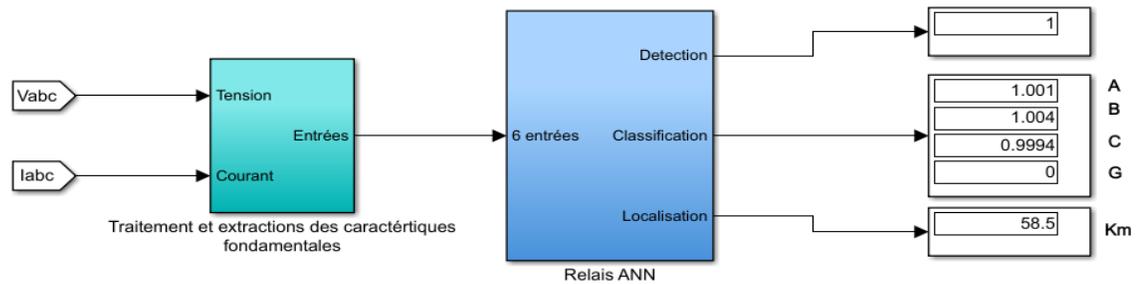


Figure 4.33 : Réponse de relais pour un défaut A-B-C à 58 km de Source 1 avec $R_f = 0.7 \Omega$.

D'après les résultats obtenus et simulés, les réseaux de neurones ont démontré leurs efficacités à détecter, classifier et localiser les défauts dans une ligne de transmission électrique, ces modèles sont capables de généraliser les cas sous une base d'entraînement et réagir d'une manière appropriée aux nouveaux évènements. Ils sont donc insensibles aux changements. Par conséquent, ils sont fortement recommandés pour la protection des systèmes électriques.

4.11 Conclusion

Ce chapitre a présenté les démarches de conception du système de protection pour le réseau électrique proposé, ce système se compose d'un détecteur neuronal capable d'indiquer la présence ou l'absence du défaut, d'un classificateur neuronal pour identifier son type et d'un localisateur neuronal indiquant l'emplacement du défaut dans la ligne de transmission par rapport à la source1. Les résultats présentés démontrent l'efficacité des réseaux de neurones à réaliser les tâches demandées dans un délai très court, facilitant par la suite aux ingénieurs des lignes de transmission à éliminer les défauts et évitant les dommages catastrophiques.

Pour tester davantage leurs efficacités, les réseaux de neurones artificiels ont été appliqués à un système plus compliqué que le système proposé ci-dessus, c'est d'ailleurs l'objectif du chapitre suivant.

CHAPITRE 5

IDENTIFICATION DES DÉFAUTS DANS UN SYSTÈME À DEUX LIGNES PARALLÈLES PAR RNA

Après avoir testé les performances des réseaux de neurones à détecter, classifier et localiser les défauts dans un système électrique simple à une ligne, même méthodologie présentée dans le chapitre précédent est suivie pour concevoir un système de protection à base des réseaux de neurones pour un réseau électrique avec deux lignes parallèles.

5.1 Modélisation du système de lignes de transport proposé

Le modèle de réseau électrique triphasé considéré est simulé sous l'environnement MATLAB/Simulink. Il s'agit de deux lignes parallèles de 735 kV, une de 30 km et la deuxième de 20 km, transmettent une puissance de 3000 MW d'une centrale de production (12 générateurs de 350 MVA) à un réseau équivalent ayant un niveau de court-circuit de 20 GVA. Ce modèle (figure 5.1) est inspiré d'un réseau d'Hydro-Québec trouvé sur Mathworks avec quelques changements au niveau des lignes pour l'adapter au problématique du sujet. La centrale de production est simulée avec une machine synchrone simplifiée (réactance subtransitoire de 0,22 pu). La machine est connectée au réseau de transmission par un transformateur Wye-Delta de 13,8 kV/735 kV.

Les deux lignes parallèles sont modélisées en Π (Pi) avec mêmes paramètres. Chaque ligne est compensée en dérivation par deux réacteurs de dérivation de 200 Mvars chacun, connectés aux extrémités de la ligne, des disjoncteurs, deux appareils de mesure M1 et M2, un bloc pour le traitement des signaux et extraction des caractéristiques fondamentales pour les tensions triphasées V_{abc} et les courants triphasés I_{abc} , les composants de ce bloc sont présentés dans la figure A de l'Annexe A.

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. Les paramètres de ce modèle sont spécifiés en Annexe A.

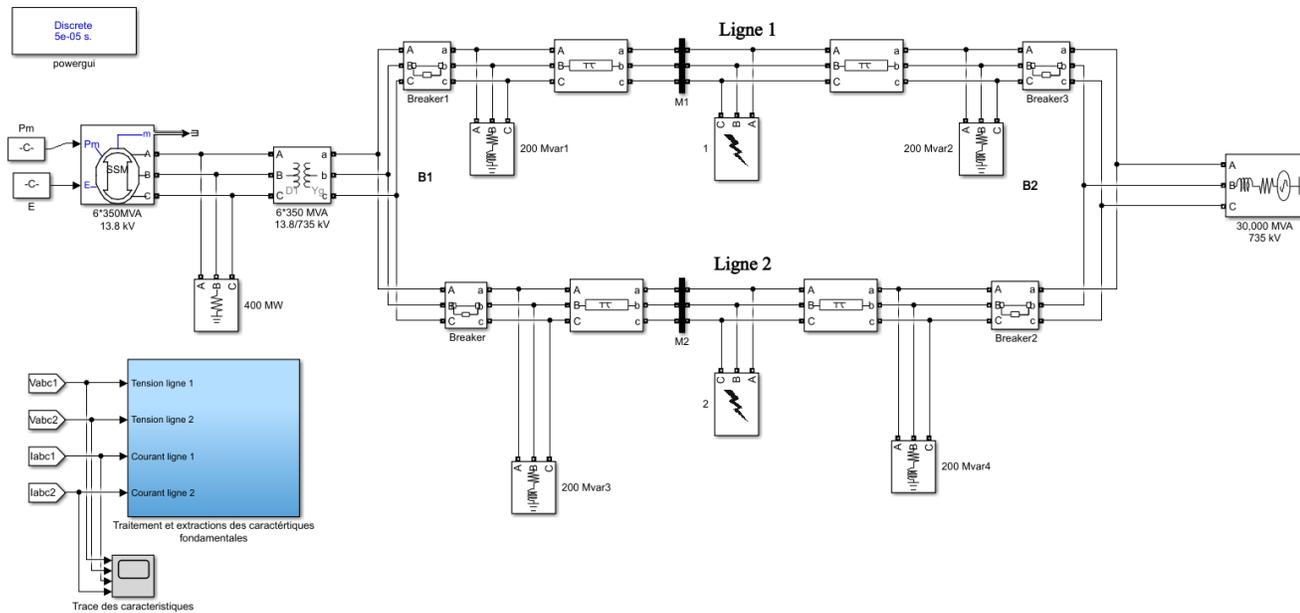


Figure 5.1 : Modèle du système électrique proposé.

Les formes d'onde de tension et de courant triphasés ont été générées et échantillonnées à une fréquence de 20 kHz. Une réduction de la taille globale du réseau de neurones artificiels RNA améliore sa performance, ce qui peut être réalisé en optimisant l'extraction des caractéristiques. En procédant ainsi, toutes les informations importantes et pertinentes présentes dans les formes d'onde des signaux de tension et de courant peuvent être utilisées efficacement. La figure 5.2 présente les formes d'ondes de tensions et courants des deux lignes obtenues dans le cas du non-défaut, la figure 5.3 présente le cas du défaut de type phase B- Terre dans ligne 1, la figure 5.4 présente le cas du défaut de type double phases A-B Terre dans ligne 2, le défaut est appliqué entre la période 0.3s et 0.4s. On suppose ici que le défaut se produit seulement dans une ligne à la fois.

On remarque que si un défaut est appliqué sur une ligne, l'autre ligne est aussi affectée automatiquement. D'où la nécessité de localiser avec précision l'emplacement du défaut. Le modèle proposé ci-dessus est proche au cas réel d'un réseau électrique complet, qui peut comporter plusieurs lignes et points de raccordement.

Dans ce chapitre, deux approches pour la détection, classification et localisation des défauts sont analysées, la première est de concevoir trois modèles de réseaux de neurones pour les différentes trois tâches, la deuxième est de développer un seul modèle de réseau de neurones pour effectuer toutes les tâches, une évaluation de tous les modèles est détaillée dans les parties suivantes et une comparaison est faite à la fin.

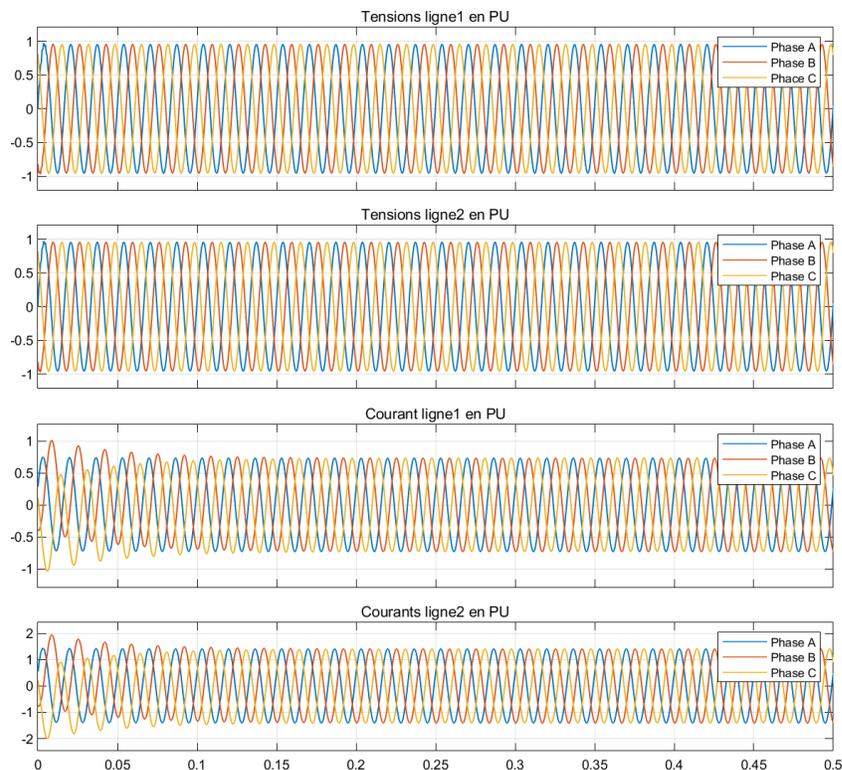


Figure 5.2 : Formes d'onde de tension et de courant du système étudié au cas de non-défaut.

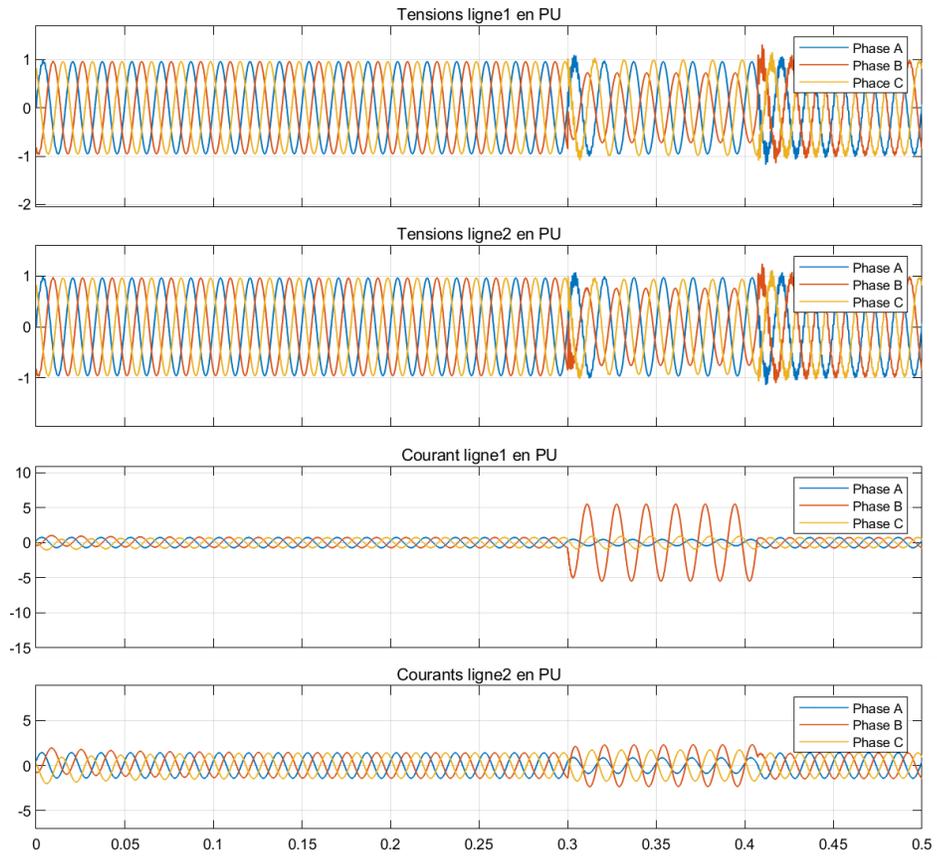


Figure 5.3 : Formes d'onde de tension et de courant pour un défaut entre la phase B et terre dans la ligne1

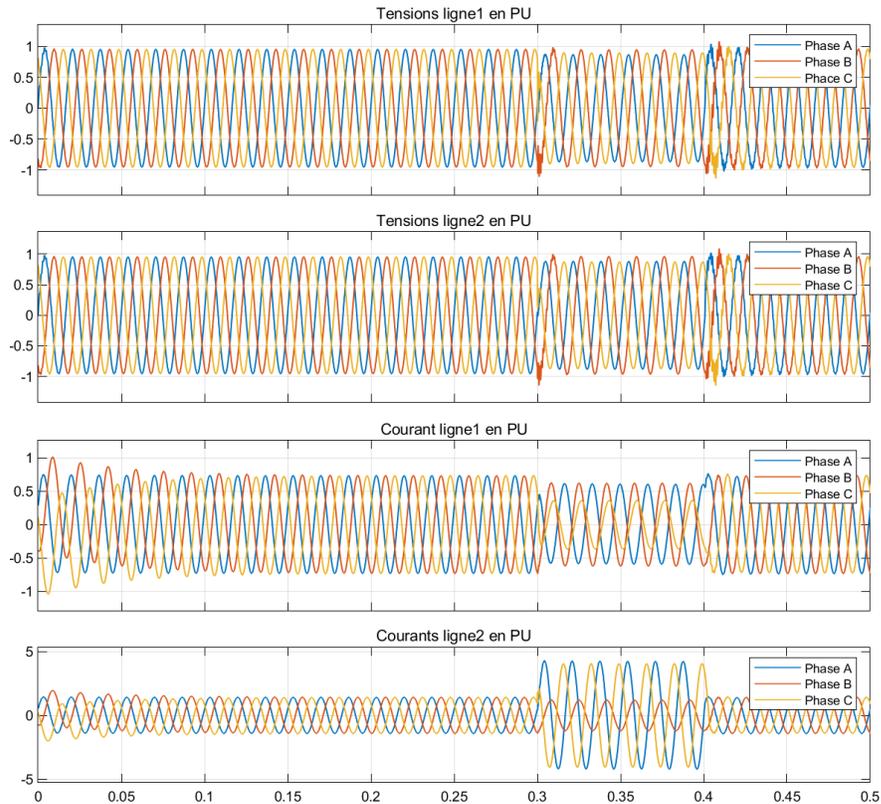


Figure 5.4 : Formes d'onde de tension et de courant pour un défaut entre les phases A-B et terre dans la ligne 2.

5.2 Base des données d'entraînement/Training Data

Le traitement des signaux et extraction des données se font par le même bloc développé dans le chapitre précédent, cette fois-ci les entrées des réseaux de neurones sont les courants et tensions triphasées de chaque ligne ($V_{A1}, V_{B1}, V_{C1}, V_{A2}, V_{B2}, V_{C2}, I_{A1}, I_{B1}, I_{C1}, I_{A2}, I_{B2}, I_{C3}$). Les données obtenues sont filtrées, échantillonnées et finalement traitées pour extraire les tensions et courants fondamentaux. La sortie dépend de la fonction du modèle développé.

Comme mentionné dans la partie précédente, la base des données a été élaborée en variant et simulant différentes conditions du défaut, telles que la distance entre le

transformateur et le défaut, sa résistance et son type, le tableau 5-1 résume les paramètres variés pour Dataset.

Tableau 5-1 : Paramètres pour la génération de Dataset.

Localisation de défaut L_f (km)	Ligne 1	Pas de 3km sur 30km
	Ligne 2	Pas de 2km sur 20km
Résistance de défaut R_f (Ω)	Ligne 1	0.25, 1, 10, 25, 50
	Ligne 2	0.5, 0.75, 15, 25,60
Types de défaut	Ligne 1	Non défaut, A-G, B-G, C-G, A-B, B-C, A-C.
	Ligne 2	Non-défaut, A-B-G, B-C-G, A-C-G, ABC

Un ensemble de données avec un total de 1750 échantillons a été formé et utilisé pour développer les différents modèles de réseau de neurones, soit le détecteur, classificateur et localisateur neuronal.

Le réseau de neurones à rétropropagation a été utilisé pour la détection, classification et 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. La Dataset élaborée est subdivisée en trois sous-ensembles, 70 % de ces données pour la phase d'entraînement des RNAs, appelée Training Data, 15 % pour la phase de validation et 15 % pour la phase de test. Ces pourcentages peuvent changer d'un problème à l'autre.

5.3 Conception des trois modèles : détecteur, classificateur et localisateur neuronal

5.3.1 Entraînement du réseau de neurones pour la détection des défauts

Le détecteur neuronal reçoit douze entrées ($V_{A1}, V_{B1}, V_{C1}, V_{A2}, V_{B2}, V_{C2}, I_{A1}, I_{B1}, I_{C1}, I_{A2}, I_{B2}, I_{C3}$) et comporte deux sorties. La 1re sortie du réseau prend une

valeur soit 0 indiquant l'absence du défaut ou 1 sa présence, la deuxième sortie indique la zone au quelle le défaut s'est produit, elle prend soit 1 correspondante à la ligne 1 ou 2 correspondante à la ligne 2. Plusieurs modèles de réseaux de neurones ont été développés en variant le nombre de couches cachées, nombre de neurones dans chaque couche cachée et les fonctions d'activation pour chaque couche cachée. Ces modèles ont été testés dans le but de choisir le meilleur modèle qui permet d'avoir les résultats obtenus les plus proches des résultats ciblés.

Trois modèles sont présentés dans cette section afin de comparer leurs performances, le modèle adopté correspond à celui que son erreur quadratique moyenne proche de la valeur fixée qui est de 10^{-5} .

- **Modèle 1 :**

La figure 5.5 suivante présente les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteinte pendant la meilleure performance de validation. Ce réseau se constitue de 12 neurones dans la couche d'entrée, 3 couches cachées, 16 neurones dans la première couche cachée, 9 neurones dans la deuxième, 3 neurones dans la troisième et deux neurones dans la couche de sortie, les fonctions de transfert/activation de chaque couche sont logsig-tansig-logsig-purelin respectivement. L'erreur quadratique moyenne atteinte à la fin du processus d'entraînement est égale 0.033.

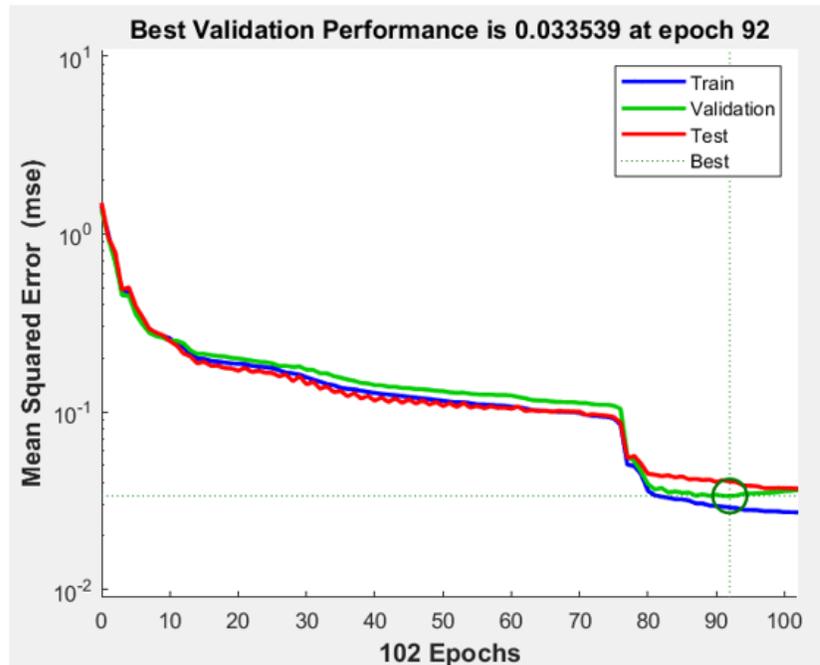


Figure 5.5 : Courbe de performance du détecteur neuronal 12-16-9-3-2.

- **Modèle 2**

La figure 5.6 suivante présente les courbes d'évolution de performance du deuxième modèle pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteinte pendant la meilleure performance de validation. Ce réseau se constitue de 12 neurones dans la couche d'entrée, 2 couches cachées, 14 neurones dans la première couche cachée, 6 neurones dans la deuxième et deux neurones dans la couche de sortie, les fonctions de transfert/activation de chaque couche sont logsig-tansig-purelin respectivement. L'erreur quadratique moyenne atteinte à la fin du processus d'entraînement est égale à $1.56 * 10^{-4}$.

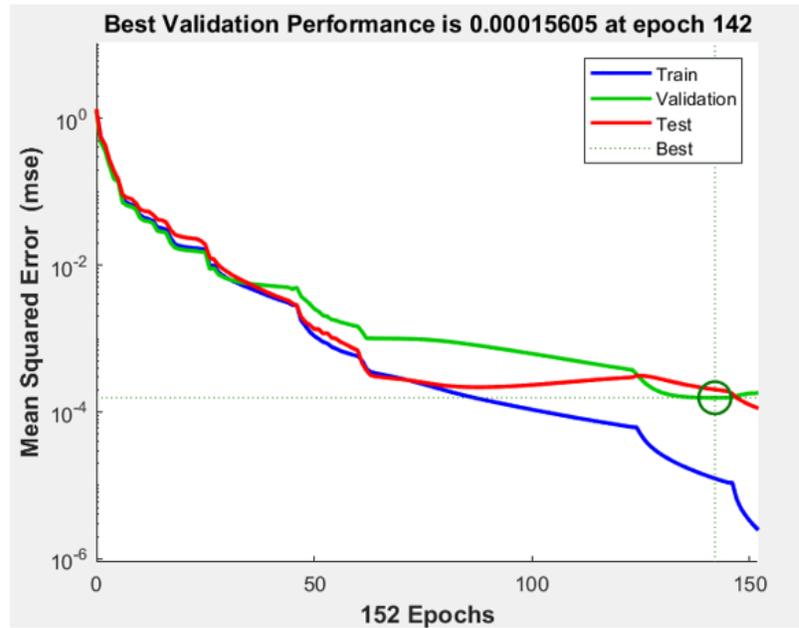


Figure 5.6 : Courbe de performance du détecteur neuronal 12-14-6-2.

- **Modèle 3**

La figure 5.7 suivante présente les courbes d'évolution de performance du deuxième modèle pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteinte pendant la meilleure performance de validation. Ce réseau se constitue de 12 neurones dans la couche d'entrée, 2 couches cachées, 32 neurones dans la première couche cachée, 16 neurones dans la deuxième et deux neurones dans la couche de sortie, les fonctions de transfert/activation de chaque couche sont logsig-tansig-purelin respectivement. L'erreur quadratique moyenne atteinte à la fin du processus d'entraînement est égale à $1.07 * 10^{-6}$.

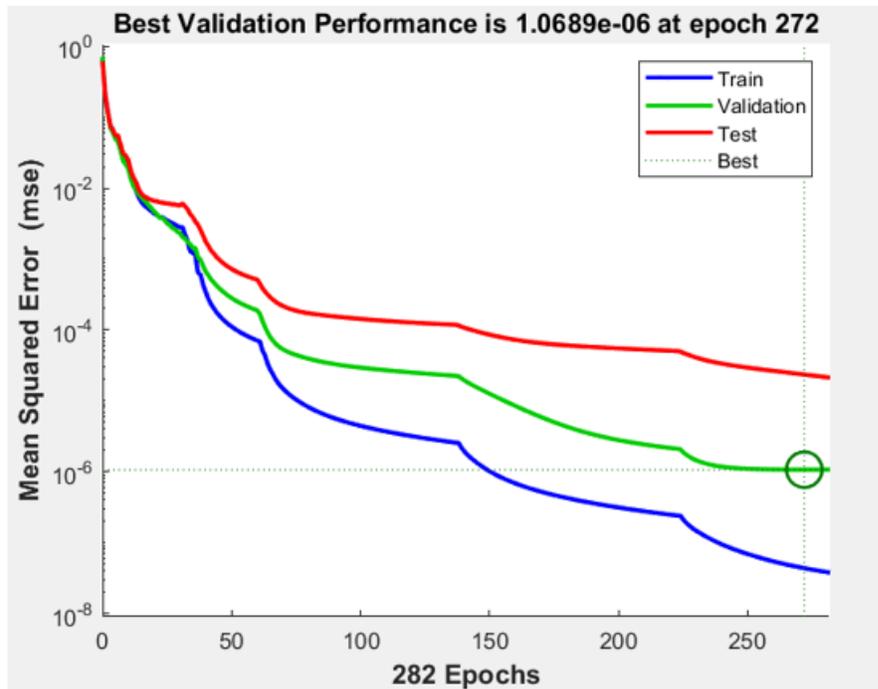


Figure 5.7 : Courbe de performance du détecteur neuronal 12-32-16-2.

Les trois modèles développés démontrent des performances satisfaisantes, le modèle 3 atteint à la fin du processus d'apprentissage une erreur inférieure à l'erreur fixée au début. En outre, le graphe de la meilleure régression linéaire obtenue à la fin de chaque phase (figure 5.8) pour ce modèle montre un coefficient de corrélation égale à 1, ce qui indique une excellente corrélation, presque tous les points sont situés le long de la diagonale, en outre les sorties du réseau de neurones sont en corrélation avec les valeurs ciblées, d'où le choix du détecteur neuronal adopté.

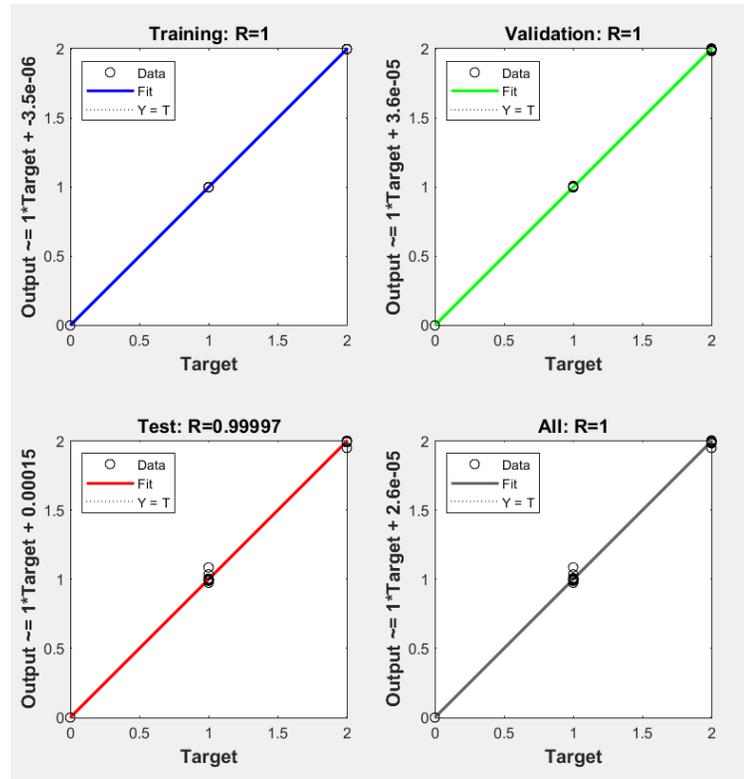


Figure 5.8 : Graphe de régression pour le détecteur neuronal.

5.3.2 Entraînement du réseau de neurones pour la classification des défauts

Après savoir développer le détecteur neuronal des défauts pour le nouveau réseau électrique proposé, la prochaine étape est de les classifier selon leurs types, dans cette partie le classificateur neuronal est entraîné à reconnaître les défauts de types phase-terre et double phase pour la ligne1 et le type double-phase-terre et triphasé pour la ligne2.

Le classificateur neuronal reçoit lui aussi douze entrées ($V_{A1}, V_{B1}, V_{C1}, V_{A2}, V_{B2}, V_{C2}, I_{A1}, I_{B1}, I_{C1}, I_{A2}, I_{B2}, I_{C3}$) et comporte 8 sorties. Ce réseau a huit sorties, les quatre premiers correspondent à l'état des phases de la ligne1 avec la terre et les quatre restant pour la ligne2.

L'algorithme de rétropropagation (backpropagation) est encore employé pour l'apprentissage avec Levenberg-Marquardt pour l'optimisation.

Plusieurs modèles de réseaux de neurones ont été développés en variant le nombre de couches cachées, nombre de neurones dans chaque couche cachée et les fonctions d'activation pour chaque couche cachée. Ces modèles ont été testés dans le but de choisir le meilleur modèle qui permet d'avoir les résultats obtenus les plus proches des résultats ciblés. Le tableau suivant présente les différentes valeurs de sorties désirées ou ciblées correspondantes à chaque type de défaut.

Tableau 5-2 : Sorties désirées du classificateur neuronal.

Phases Types de défaut	Sorties désirées du classificateur neuronal							
	Ligne 1				Ligne 2			
	A	B	C	T	A	B	C	T
Non-Défaut	0	0	0	0	0	0	0	0
A-T	1	0	0	1	0	0	0	0
B-T	0	1	0	1	0	0	0	0
C-T	0	0	1	1	0	0	0	0
A-B-T	0	0	0	0	1	1	0	1
A-C-T	0	0	0	0	1	0	1	1
B-C-T	0	0	0	0	0	1	1	1
A-B	1	1	0	0	0	0	0	0
A-C	1	0	1	0	0	0	0	0
B-C	0	1	1	0	0	0	0	0
A-B-C	0	0	0	0	0	1	1	0

Trois modèles sont donc présentés dans la section suivante afin de comparer leurs performances pour définir le classificateur neuronal le plus performant, l'erreur quadratique moyenne désirée est fixée à la valeur 10^{-4} .

- **Modèle 1 :**

La figure 5.9 présente les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteinte pendant la meilleure performance de validation. Ce réseau se constitue de 12 neurones dans la couche d'entrée, 3 couches cachées, 25 neurones dans la première couche cachée, 12 neurones dans la deuxième, 6 neurones dans la troisième et 8 neurones dans la couche de sortie, les fonctions de transfert/activation des couches cachées et la couche de sortie sont respectivement logsig-tansig-logsig-purelin respectivement. L'erreur quadratique moyenne atteinte à la fin du processus d'entraînement est égale à $5.8 * 10^{-3}$.

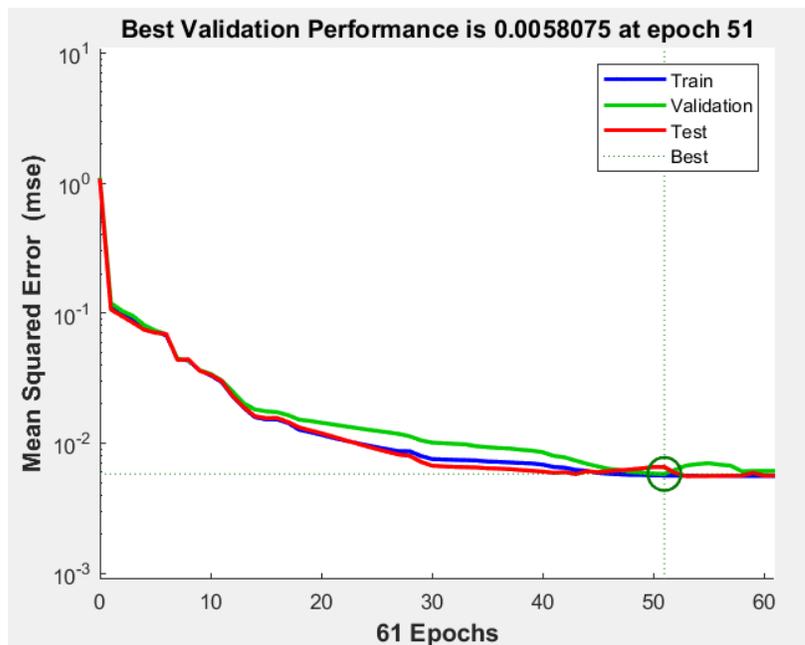


Figure 5.9 : Courbe de performance du classificateur neuronal 12-25-12-6-8.

- **Modèle 2**

La figure 5.10 présente les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteinte pendant la meilleure performance de validation. Ce réseau se constitue de 12 neurones dans la couche d'entrée, une couche cachée contenant 15 neurones et 8 neurones dans la couche de sortie, les fonctions de transfert/activation de la couche cachée et la couche de sortie sont respectivement logsig-purelin respectivement. L'erreur quadratique moyenne atteinte à la fin du processus d'entraînement est égale à 1.3×10^{-3} .

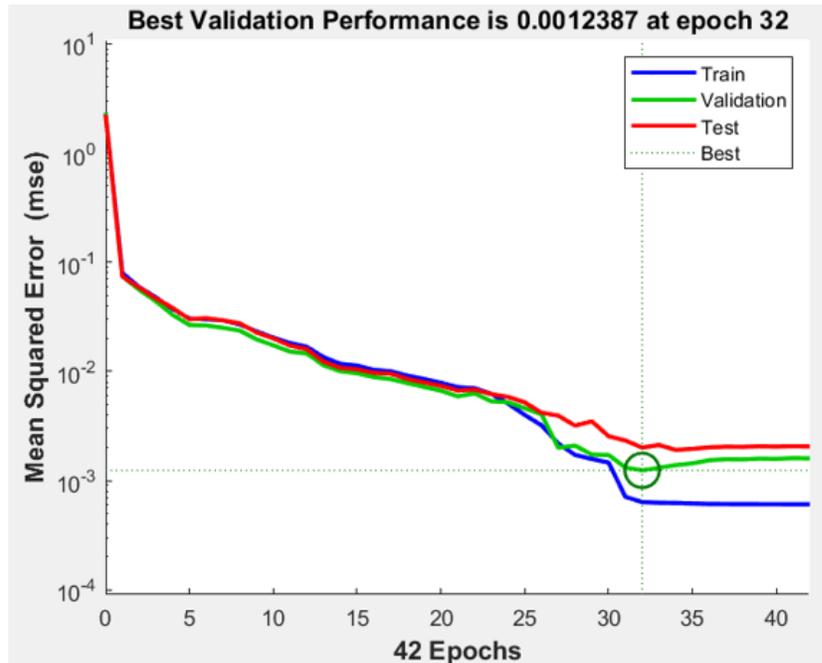


Figure 5.10 : Courbe de performance du classificateur neuronal 12-15-8.

- **Modèle 3**

La figure 5.11 présente les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteinte pendant la meilleure performance de validation.

Ce réseau se constitue de 12 neurones dans la couche d'entrée, 2 couches cachées, 30 neurones dans la première couche cachée, 16 neurones dans la deuxième et 8 neurones dans la couche de sortie, les fonctions de transfert/activation des couches cachées et de sortie sont respectivement logsig-tansig-purelin respectivement. L'erreur quadratique moyenne atteinte à la fin du processus d'entraînement est égale à $1.57 * 10^{-5}$, les courbes d'entraînement et de validation ont des caractéristiques similaires, ce qui indique un apprentissage efficace.

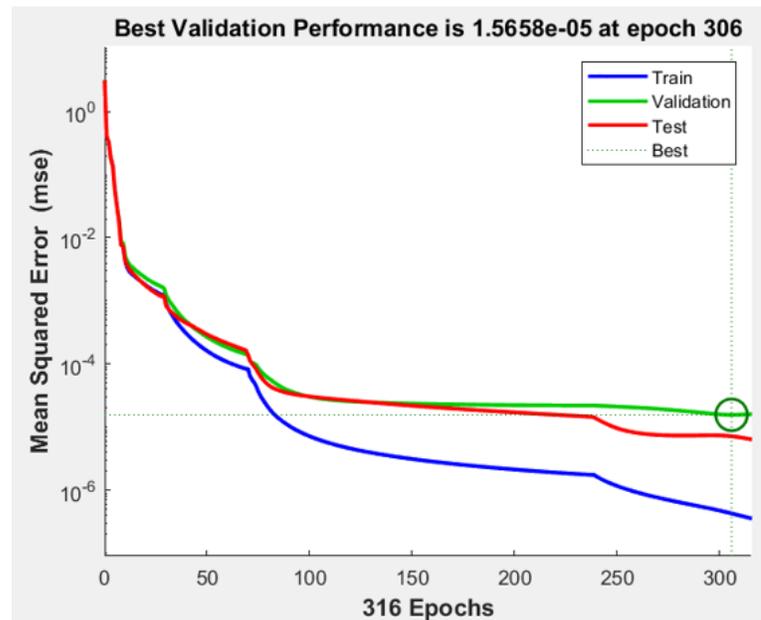


Figure 5.11 : Courbe de performance du classificateur neuronal 12-30-16-8.

Les trois modèles développés démontrent des performances satisfaisantes, les erreurs obtenues à la fin du processus d'apprentissage sont proches. D'après les graphiques ci-dessus, il convient de noter que le modèle 3 montre la meilleure performance pendant la phase d'apprentissage. En plus, la courbe de meilleure régression linéaire présentée dans la figure 5.12, le coefficient de corrélation pour la phase d'entraînement est égale à 1, ce qui montre que les sorties du classificateur neuronal suivent parfaitement et linéairement les sorties désirées.

La courbe de la fonction d'efficacité du récepteur ROC présentée dans la figure 5.13 montre une meilleure classification atteinte avec ce modèle, chaque courbe de chaque classe alignée avec le bord gauche et supérieur du graphique. Par conséquent, le modèle 3 est adopté comme le classificateur neuronal donnant une courbe ROC idéale avec des taux positifs réels de 100 %.

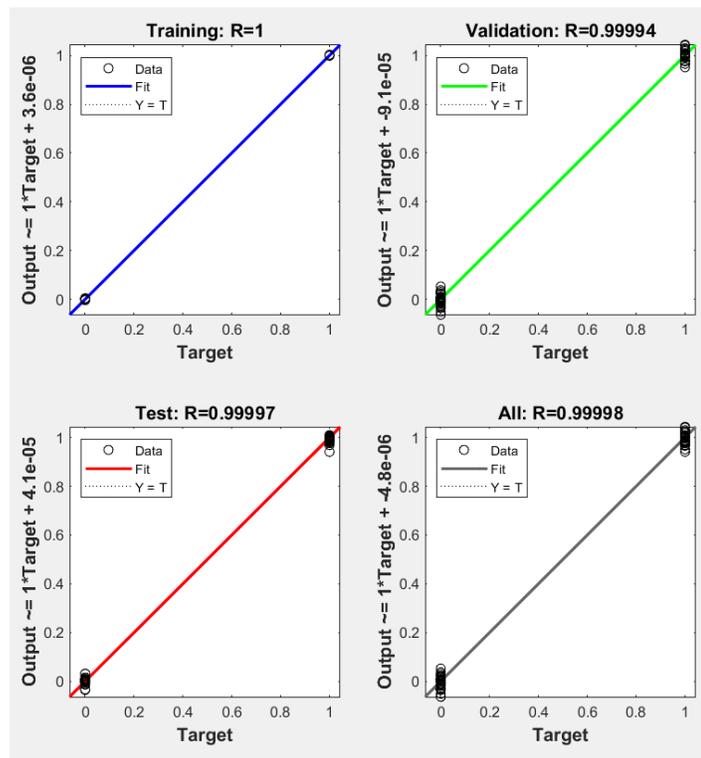


Figure 5.12 : Graphe de régression pour le classificateur neuronal.

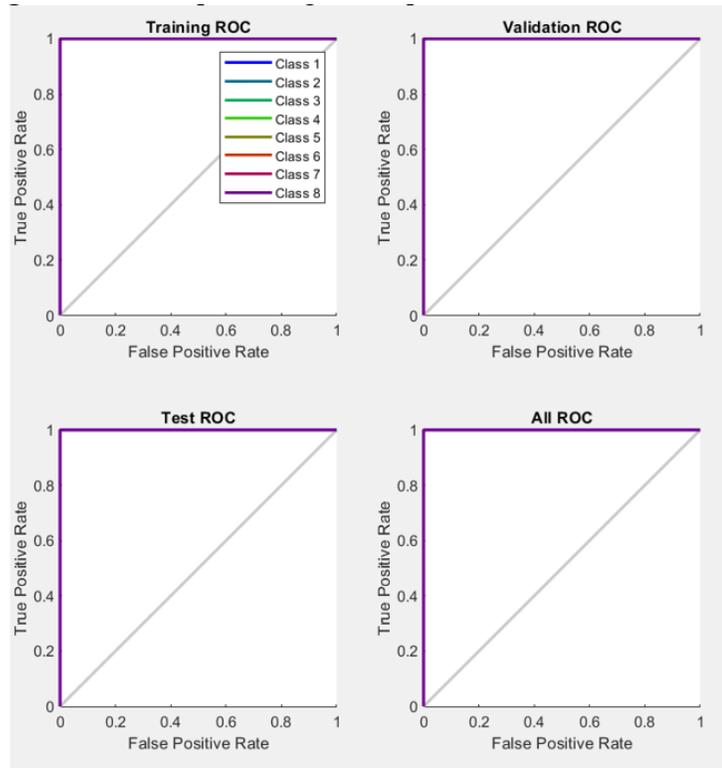


Figure 5.13 : La courbe de la fonction d'efficacité du récepteur ROC.

5.3.3 Entraînement du réseau de neurones pour la localisation des défauts

La localisation précise permet de faciliter aux ingénieurs la prise de décision et éviter de vérifier physiquement la ligne pour l'emplacement de défaut, le localisateur neuronal permet donc d'isoler directement la partie défectueuse. Même démarche de conception du détecteur et localisateur neuronal est suivie pour développer le localisateur neuronal.

Le localisateur neuronal reçoit lui aussi douze entrées ($V_{A1}, V_{B1}, V_{C1}, V_{A2}, V_{B2}, V_{C2}, I_{A1}, I_{B1}, I_{C1}, I_{A2}, I_{B2}, I_{C2}$) et donne 2 sorties. La 1ère indique l'emplacement du défaut dans ligne1 et la 2ème pour la ligne2.

Trois modèles sont donc présentés dans la section suivante afin de comparer leurs performances pour définir le localisateur neuronal le plus performant.

- **Modèle 1**

La figure 5.14 présente les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteint pendant la meilleure performance de validation. Ce réseau se constitue de 12 neurones dans la couche d'entrée, 2 couches cachées, 16 neurones dans la première couche cachée, 4 neurones dans la deuxième et 2 neurones dans la couche de sortie, les fonctions de transfert/activation des couches cachées et de sortie sont respectivement logsig-tansig-purelin respectivement. L'erreur quadratique moyenne atteint à la fin du processus d'entraînement est égale à 0.70.

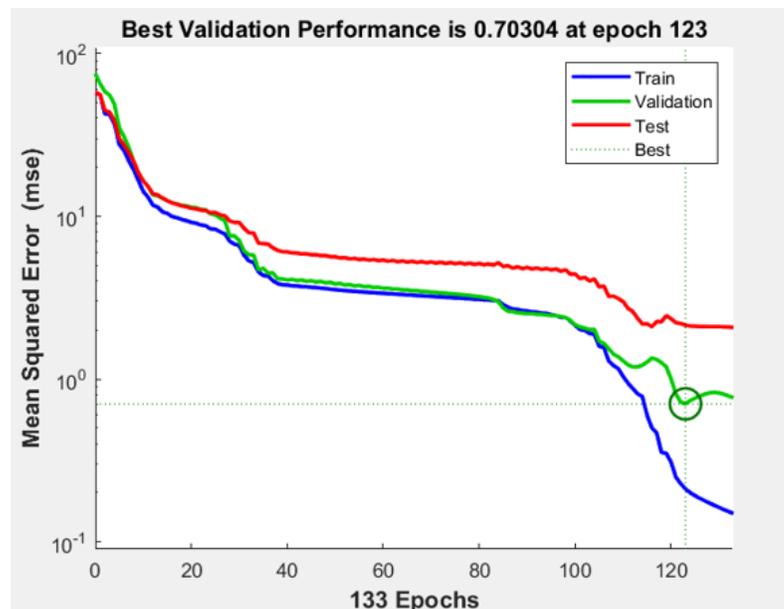


Figure 5.14 : Courbe de performance du localisateur neuronal 12-16-4-2.

- **Modèle 2**

La figure 5.15 présente les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteint pendant la meilleure performance de validation.

Ce réseau se constitue de 12 neurones dans la couche d'entrée, 2 couches cachées, 16 neurones dans la première couche cachée, 9 neurones dans la deuxième et 2 neurones dans la couche de sortie, les fonctions de transfert/activation des couches cachées et de sortie sont respectivement logsig-tansig-purelin respectivement. L'erreur quadratique moyenne atteint à la fin du processus d'entraînement est égale à 0.20. On peut constater que ce modèle est similaire au modèle 1, même nombre de couche cachée et nombre de neurones dans la 1ère couche cachée, une augmentation de neurone dans la 2ème couche cachée a permis de réduire l'erreur quadratique de 0.5.

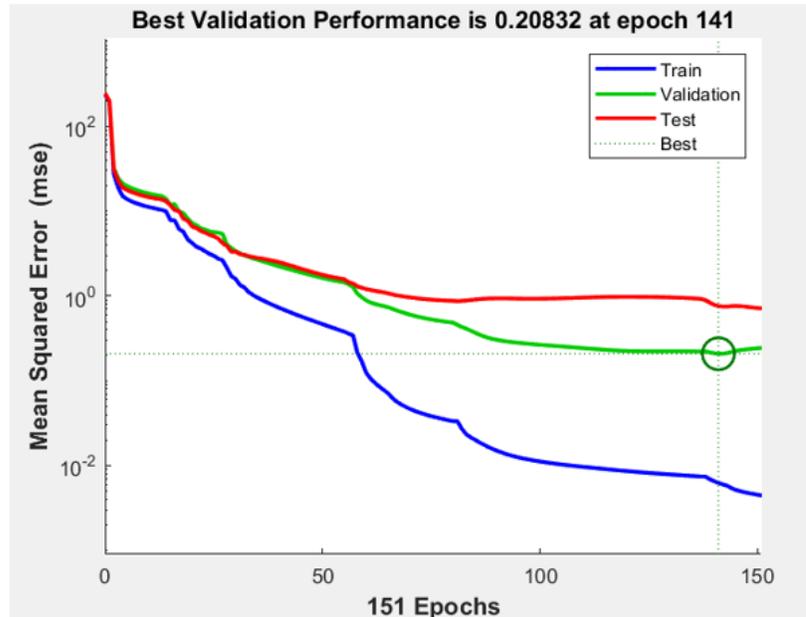


Figure 5.15 : Courbe de performance du localisateur neuronal 12-16-9-2.

- Modèle 3

La figure 5.16 présente les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteinte pendant la meilleure performance de validation. Ce réseau se constitue de 12 neurones dans la couche d'entrée, 3 couches cachées, 32 neurones dans la première couche cachée, 16 neurones dans la deuxième, 4 neurones dans la troisième et 2 neurones dans la couche

de sortie, les fonctions de transfert/activation des couches cachées et de sortie sont respectivement logsig-tansig-logsig-purelin respectivement. L'erreur quadratique moyenne atteint à la fin du processus d'entraînement est égale à 0.13.

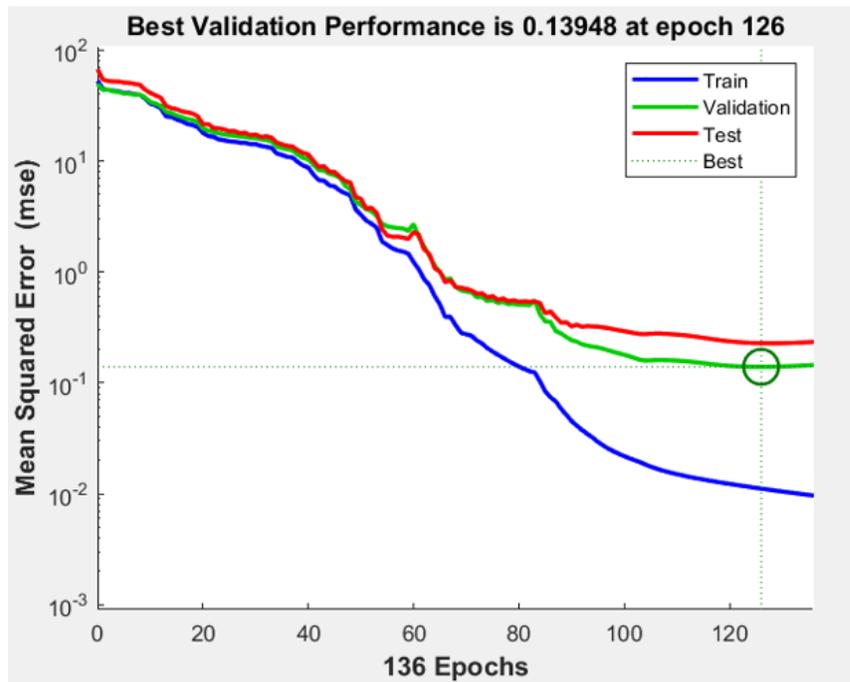


Figure 5.16 : Courbe de performance du localisateur neuronal 12-32-16-4-2.

Ce modèle permet d'atteindre l'erreur le plus petit, de plus le graphe de la meilleure régression linéaire (figure 5.17) montre des coefficients de corrélation pendant les trois phases d'ordre de 0.999, ce qui prouve une meilleure performance atteinte par ce modèle, d'où le choix du localisateur neuronal.

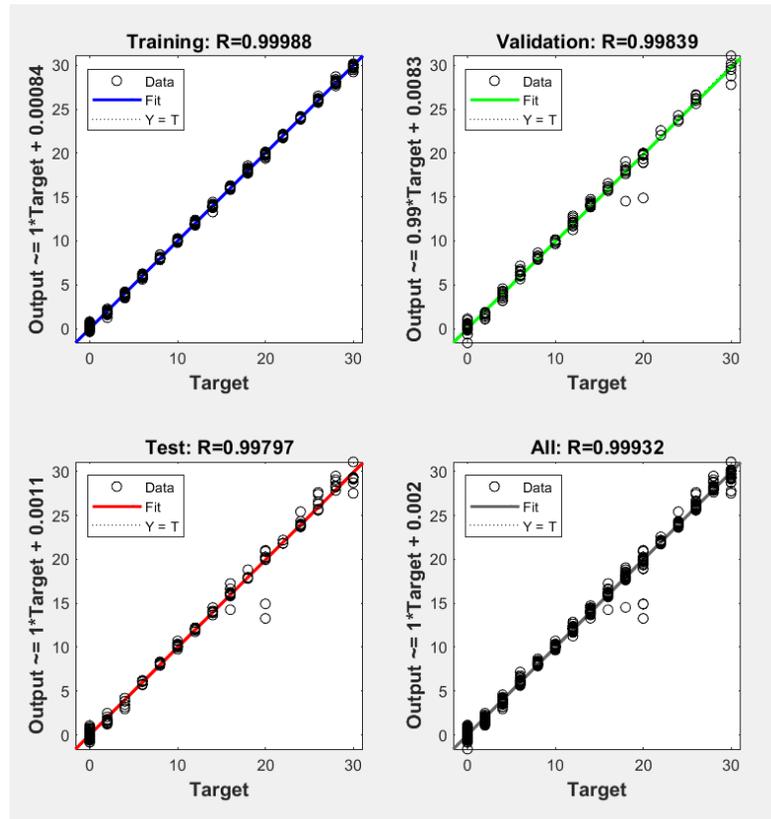


Figure 5.17 : Graphe de régression pour le localisateur neuronal.

Le tableau 5-3 illustre les pourcentages d'erreurs dans la localisation des défauts en fonction de type de défauts et résistance du défaut. Les valeurs de résistances choisies pour tester le réseau de neurones ne font pas parties de l'ensemble de données pour l'entraînement élaboré au début du chapitre. Il est noté que l'erreur moyenne dans la localisation des défauts ne dépasse pas 0.213. Par conséquent, le localisateur neuronal choisi a démontré sa capacité à généraliser et à réagir d'une manière appropriée aux nouvelles données.

Tableau 5-3 : Comparaison entre sorties réelles et sorties prédites par le localisateur neuronal.

Ligne	Type de défaut	Résistance de défaut Ω	Distance réelle km	Distance prédite km	Erreur
Ligne 1	A-G	0.5	2	1.87	0.13
		8	10	9.93	0.07
		40	15	15.2	0.2
	B-G	0.75	4	3.89	0.11
		9	7	6.77	0.23
		21	12	11.94	0.06
	C-G	2	5	5.96	0.04
		5	9	8.9	0.1
		17	25	25.06	0.06
	A-B	1.5	6	6.7	0.7
		6	13	13.05	0.05
		14	17	17.27	0.27
	B-C	2.5	19	18.7	0.3
		8	20	19.88	0.12
		13	29	28.73	0.27
	C-A	4	0.5	0.55	0.05
		9	11	10.93	0.07
		12	15	15.05	0.05
Ligne 2	A-B-T	0.25	1	1.4	0.4
		7	5	5.03	0.03
		10	13	13.24	0.24
	B-C-T	3	3	2.88	0.12
		14	7	7.1	0.1
		29	11	11.02	0.02
	C-A-T	100	5	4.95	0.05
		45	9	8.99	0.01
		50	19	18.92	0.08
	A-B-C	16	17	16.99	0.01
		20	20	19.78	0.22
		80	7	6.92	0.08

5.4 Conception d'un modèle neuronal : détecteur, classificateur et localisateur neuronal

Dans cette partie, la conception d'un seul modèle neuronal est considérée comme une nouvelle approche, ce modèle sera capable à la fois d'indiquer la présence ou l'absence du défaut, identifier son type et localiser son emplacement soit par rapport à la ligne 1 ou la ligne 2, cette méthode est par la suite comparée à la méthode adoptée dans la section précédente.

Ce nouveau modèle reçoit lui aussi les mêmes 12 entrées ($V_{A1}, V_{B1}, V_{C1}, V_{A2}, V_{B2}, V_{C2}, I_{A1}, I_{B1}, I_{C1}, I_{A2}, I_{B2}, I_{C2}$) et donne 12 sorties, chaque sortie correspond à un état donné (voir le tableau 5-4). L'algorithme de rétropropagation (backpropagation) est encore employé pour l'apprentissage avec Levenberg-Marquardt pour l'optimisation.

Plusieurs modèles de réseaux de neurones ont été développés en variant le nombre de couches cachées, nombre de neurones dans chaque couche cachée et les fonctions d'activation pour chaque couche cachée. Ces modèles ont été testés dans le but de choisir le meilleur modèle qui permet d'avoir les résultats obtenus les plus proches des résultats ciblés.

Tableau 5-4 : Sorties du réseau de neurones et leurs correspondants états.

Sortie	État
1	Détection du défaut (0/1)
2	Zone du défaut (ligne1=1 ou ligne2=2)
3	État de phase A de la ligne1 (0/1)
4	État de phase B de la ligne1 (0/1)
5	État de phase C de la ligne1 (0/1)
6	État de phase G de la ligne1 (0/1)
7	État de phase A de la ligne2 (0/1)

Sortie	État
8	État de phase B de la ligne2 (0/1)
9	État de phase C de la ligne2 (0/1)
10	État de phase G de la ligne2 (0/1)
11	Position du défaut dans la ligne 1
12	Position du défaut dans la ligne 2

Cinq principaux modèles sont présentés et comparés afin de choisir le modèle le plus approprié au réseau électrique adopté.

- **Modèle 1**

Ce premier modèle se constitue de 12 neurones dans la couche d'entrée, une seule couche cachée contenant 30 neurones et une couche de sortie concernant 12 neurones, les fonctions d'activation de la couche cachée et la couche de sortie sont respectivement logsig-purelin. Les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test sont présentées à la figure 5.18 et indiquent l'erreur moyenne atteinte à la fin de la phase d'apprentissage, qui est égale à 0,14. La figure 5.19 illustre la meilleure régression linéaire, le coefficient de corrélation est d'ordre de 0,99 ce qui démontre les performances de ce modèle.

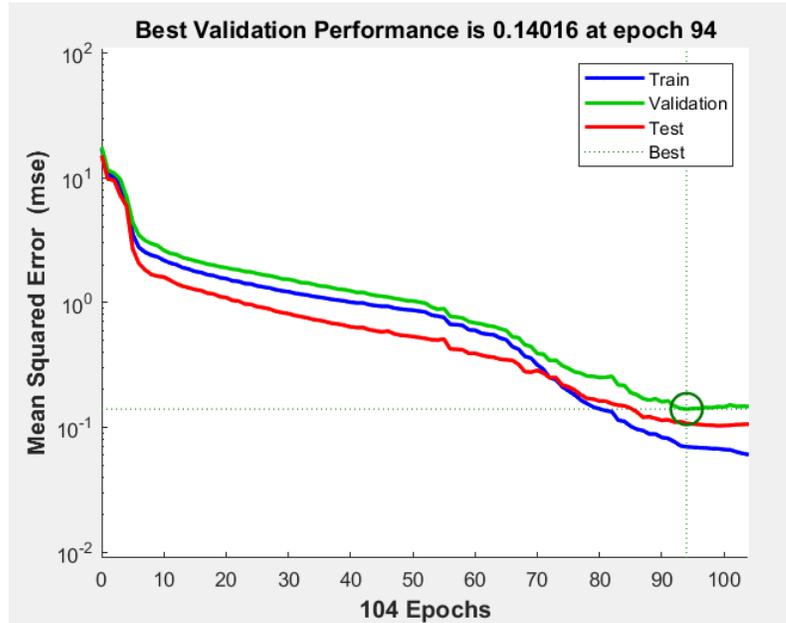


Figure 5.18 : Courbe de performance du réseau neuronal 12-30-12.

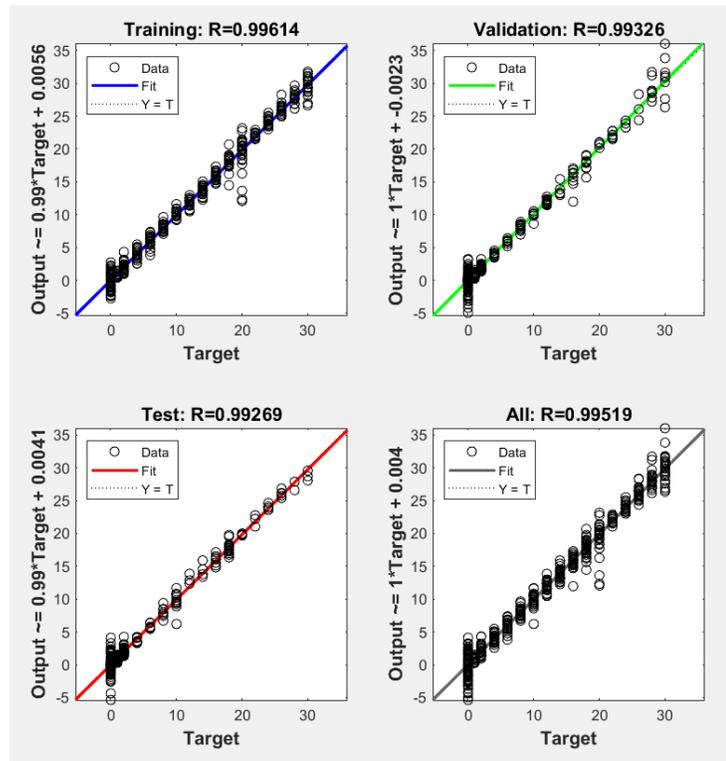


Figure 5.19 : Graphe de régression pour le réseau neuronal 12-30-12.

- **Modèle 2**

Ce premier modèle se constitue de 12 neurones dans la couche d'entrée, trois couches cachées, 30 neurones dans la première couche cachée, 20 neurones dans la deuxième, 5 neurones dans la troisième et une couche de sortie concernant 12 neurones, les fonctions d'activation des couches cachées et la couche de sortie sont respectivement logsig-tansig-poslin-purelin. Les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test sont présentées à la figure 5.20 et indiquent l'erreur moyenne atteinte à la fin de la phase d'apprentissage, qui est égale à 0,1 de même ordre que l'erreur moyenne atteint par le modèle 1, mais ce modèle atteint cette erreur plus rapidement. La figure 5.21 illustre la meilleure régression linéaire, le coefficient de corrélation est d'ordre de 0,99 ce qui démontre les performances de ce modèle.

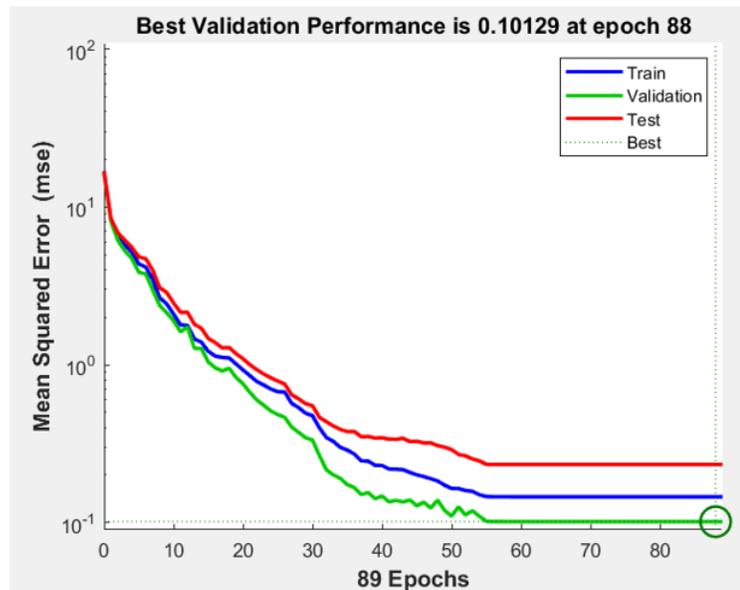


Figure 5.20 : Courbe de performance du réseau neuronal 12-32-20-5-12.

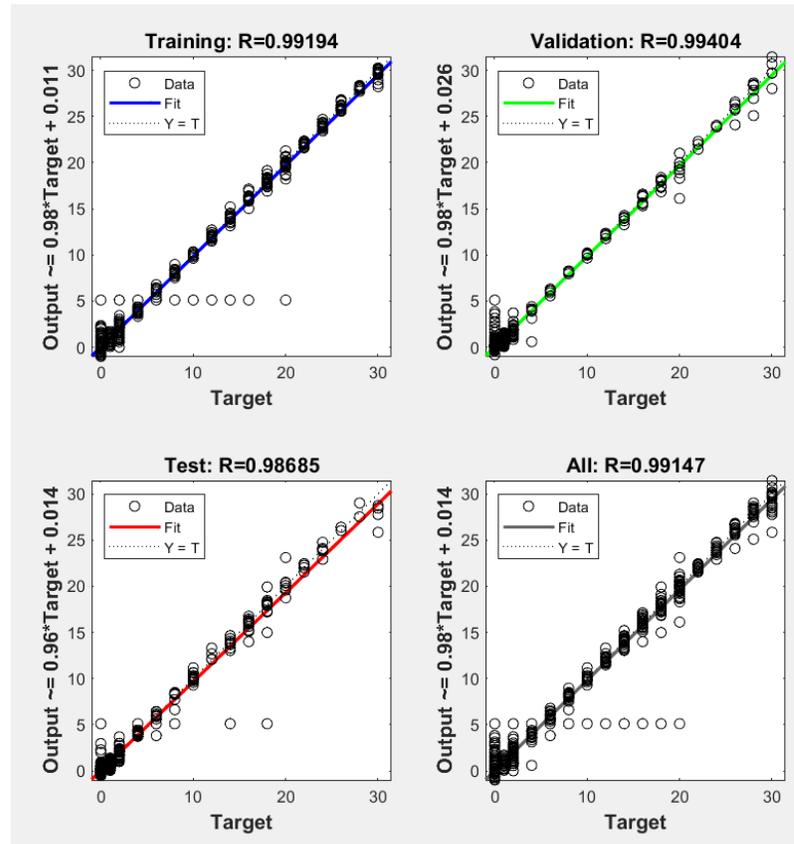


Figure 5.21 : Graphe de régression pour le réseau neuronal 12-32-20-5-12.

- Modèle 3

Ce premier modèle se constitue de 12 neurones dans la couche d'entrée, quatre couches cachées, 30 neurones dans la première couche cachée, 26 neurones dans la deuxième, 16 neurones dans la troisième, 4 dans la quatrième et une couche de sortie concernant 12 neurones, les fonctions d'activation des couches cachées et la couche de sortie sont respectivement logsig-tansig-logsig-logsig-purelin. Les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test sont présentées à la figure 5.22 et indiquent l'erreur moyenne atteinte à la fin de la phase d'apprentissage, qui est égale à 0,037. La figure 5.23 illustre la meilleure régression linéaire, le coefficient de corrélation est d'ordre de 0,99 ce qui démontre les performances de ce modèle.

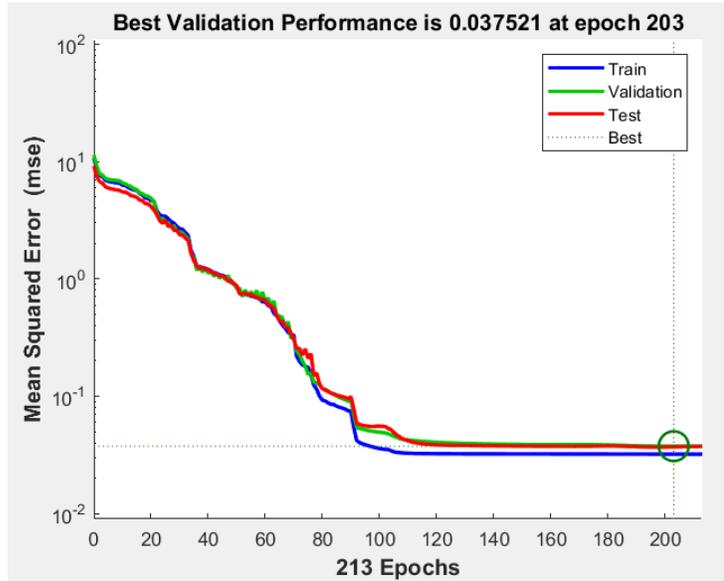


Figure 5.22 : Courbe de performance du réseau neuronal 12-30-26-16-4-12.

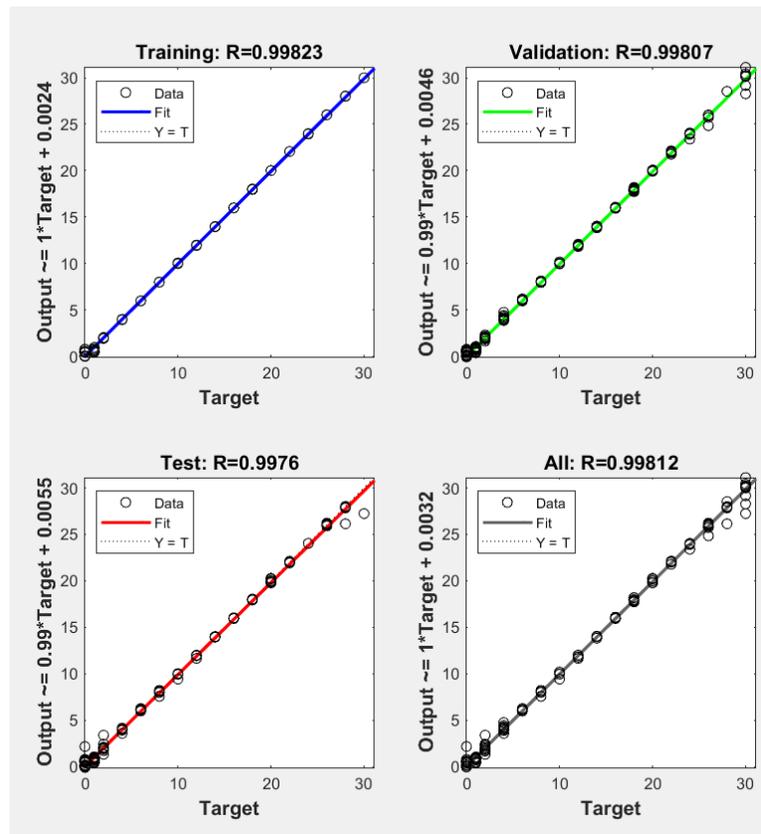


Figure 5.23 : Graphe de régression pour le réseau neuronal 12-32-26-16-4-12.

- **Modèle 4**

Ce premier modèle se constitue de 12 neurones dans la couche d'entrée, deux couches cachées, 27 neurones dans la première couche cachée, 15 neurones dans la deuxième et une couche de sortie concernant 12 neurones, les fonctions d'activation des couches cachées et la couche de sortie sont respectivement logsig-logsig-purelin. Les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test sont présentées à la figure 5.24 et indiquent l'erreur moyenne atteinte à la fin de la phase d'apprentissage, qui est égale à de 0,019. La figure 5.25 illustre la meilleure régression linéaire, le coefficient de corrélation est d'ordre de 0,999 ce qui démontre les performances de ce modèle.

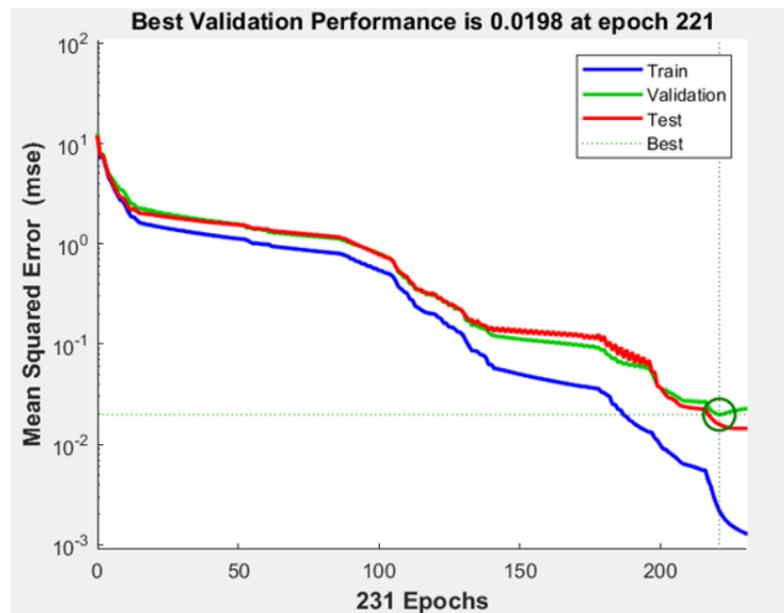


Figure 5.24 : Courbe de performance du réseau neuronal 12-27-15-12.

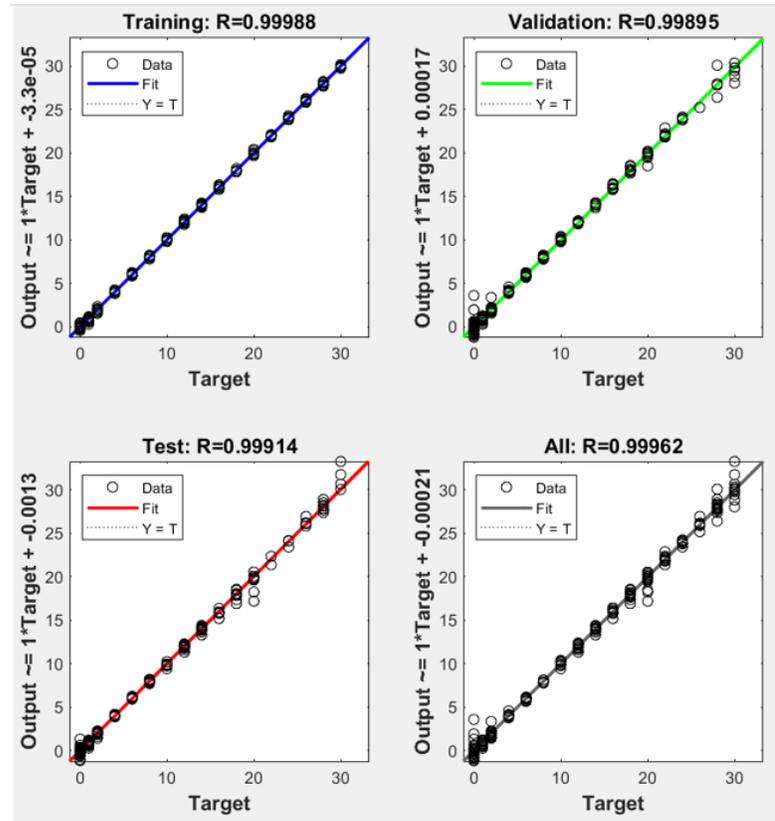


Figure 5.25 : Graphe de régression pour le réseau neuronal 12-27-15-12.

- Modèle 5

Ce premier modèle se constitue de 12 neurones dans la couche d'entrée, deux couches cachées, 31 neurones dans la première couche cachée, 16 neurones dans la deuxième et une couche de sortie concernant 12 neurones, les fonctions d'activation des couches cachées et la couche de sortie sont respectivement logsig-tansig-purelin. Les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test sont présentées à la figure 5.26 et indiquent l'erreur moyenne atteinte à la fin de la phase d'apprentissage, qui est égale à 0,002. La figure 5.27 illustre la meilleure régression linéaire, le coefficient de corrélation est d'ordre de 0,99977 ce qui démontre les performances de ce modèle.

Les modèles développés ont montré des performances satisfaisantes, que ce soit au niveau d'apprentissage et erreur quadratique moyenne atteinte ou le coefficient de corrélation. Le modèle 5 est choisi comme le modèle le plus approprié pour réaliser les tâches souhaitées, car il atteint le taux d'erreur le plus faible compare aux autres modèles.

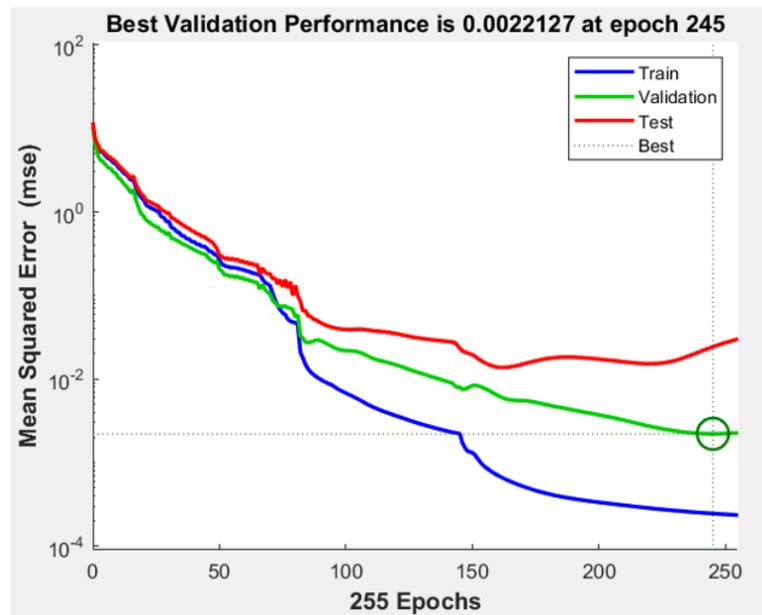


Figure 5.26 : Courbe de performance du réseau neuronal 12-31-16-12.

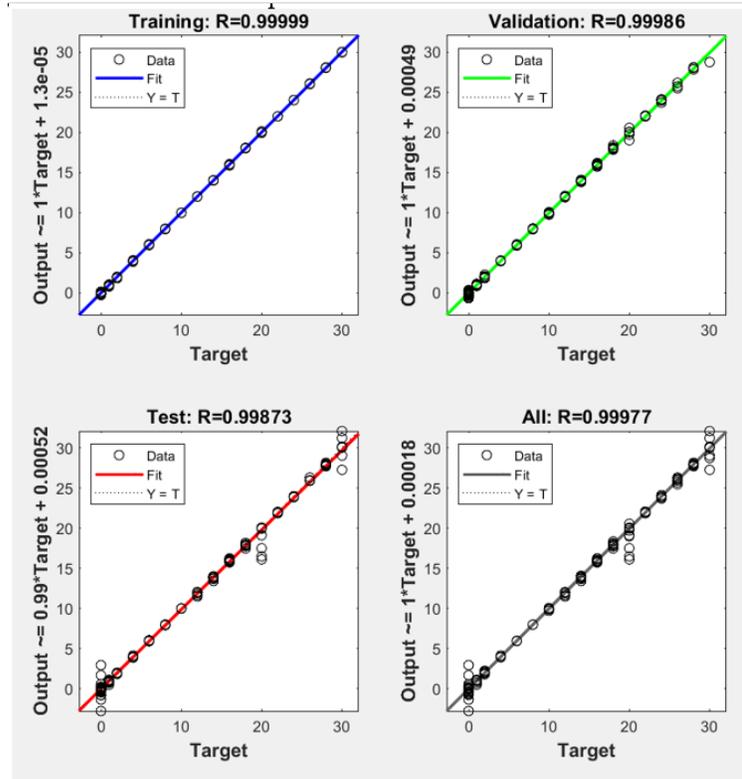


Figure 5.27 : Graphe de régression pour le réseau neuronal 12-31-16-12.

5.5 Application des modèles conçus sur le système proposé

Après avoir développé les différents modèles pour les deux approches proposées, la première qui consiste à concevoir trois modèles neuronaux différents pour les trois tâches de détection, classification et localisation des défauts dans les deux lignes parallèles, la deuxième approche est basée sur la conception d'un seul modèle neuronale capable de réaliser les trois tâches énumérées ci-dessus. Il convient de rappeler que nous supposons que le défaut ne se produit pas simultanément dans les deux lignes. Ces deux approches sont donc appliquées au réseau électrique proposé, à deux lignes parallèles, en considérant les mêmes conditions afin de comparer les résultats obtenus.

- **Approche 1**

Les appareillages de mesures, placés dans chaque ligne, prennent en temps réels les valeurs triphasées de courants et de tensions, V_{abc1} et I_{abc1} sont les valeurs de courants et tensions triphasées de la ligne 1, V_{abc2} et I_{abc2} sont les valeurs de courants et tensions triphasées de la ligne 2. Ces derniers sont donc traités avant d'être envoyés au bloc relais à réseaux de neurones artificiels, qui est constitué des trois modèles neuronaux comme montré dans la figure 5.29, ce relais donne par la suite 3 réponses, la 1^{re} indique l'absence ou la présence du défaut et indique aussi la zone où le défaut s'est produit, la 2^e réponse consiste à identifier son type, c'est-à-dire les phases en défaut tandis que la dernière réponse est réservée à préciser son emplacement, tout ce cela est illustré dans la figure 5.28.

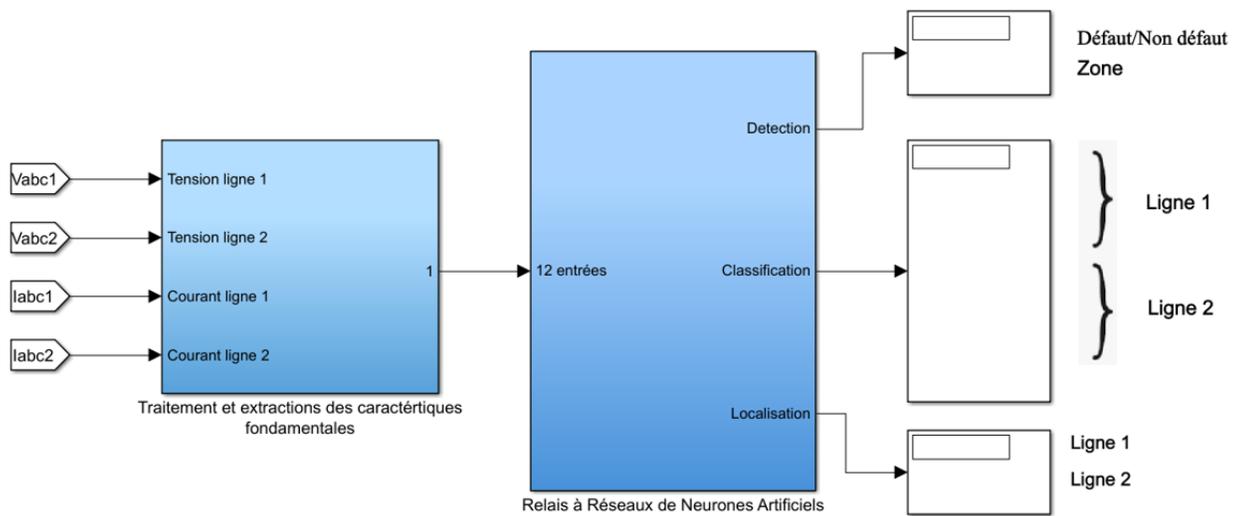


Figure 5.28 : Ensemble de blocs de protection pour l'approche 1.

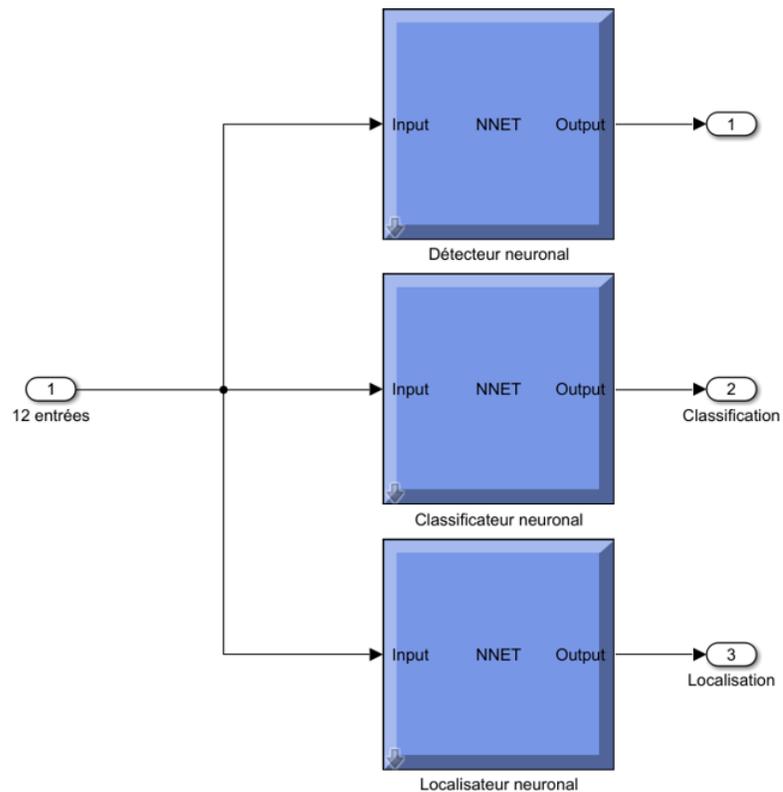


Figure 5.29 : Composants du bloc relais à réseaux de neurones artificiels.

- **Approche 2**

Mêmes démarches décrites pour l'approche est appliqué pour cette approche, mais le bloc de relais est constitué d'un seul modèle neuronal donnant 12 réponses, comme montré dans la figure 5.30, le tableau 5-4 montre les différentes significations de chaque réponse.

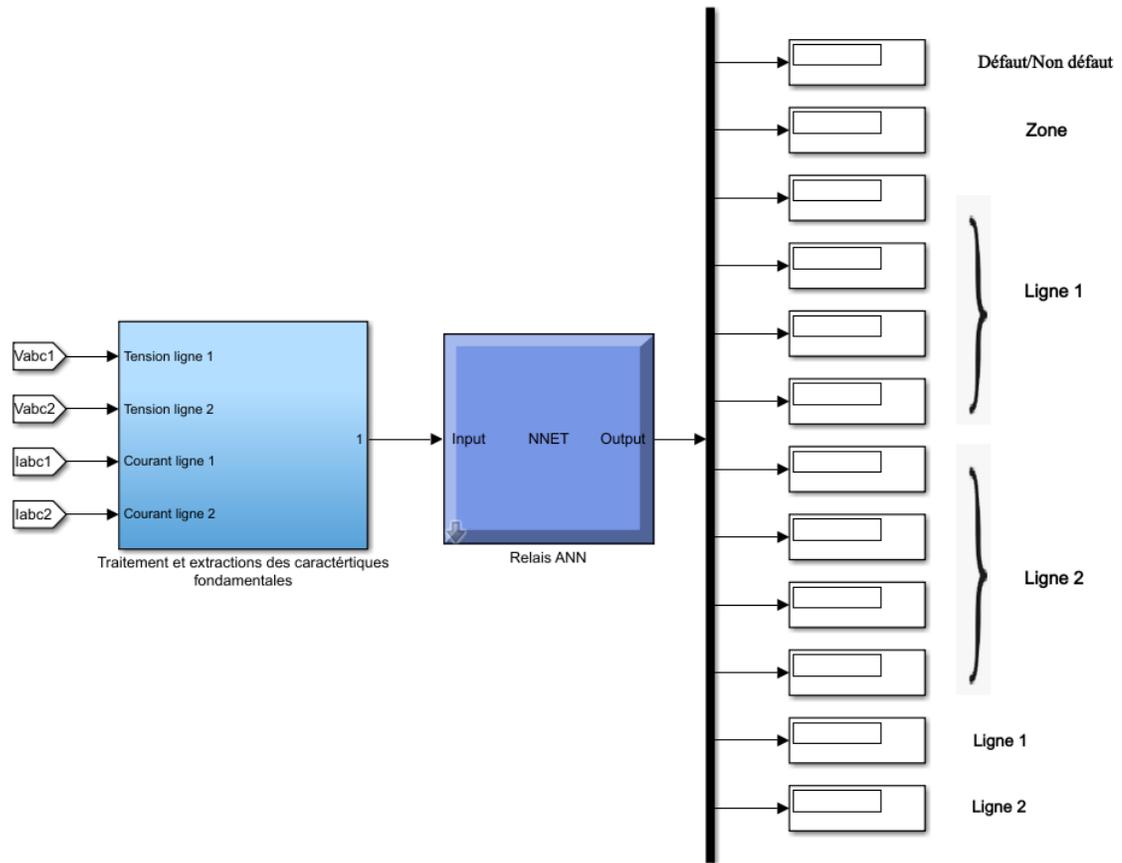


Figure 5.30 : Ensemble de blocs de protection pour l'approche2.

Différentes conditions sont donc appliquées au réseau électrique à deux lignes, ce dernier est associé aux blocs de protection proposés dans les deux approches, les résultats obtenus sont donc présentés et discutés.

i. Cas d'un défaut dans la ligne 1

- Défaut phase A-Terre à 6 km du terminal

Un défaut de type phase A-Terre est appliqué à 6 km du terminal de la ligne 1, avec une résistance du défaut de 9Ω , les résultats obtenus à la fin de la simulation pour l'approche 1 et l'approche 2 sont présentés respectivement dans la figure 5.31 et 5.32.

En ce qui concerne la partie de détection et localisation, on remarque que les deux approches donnent presque les mêmes réponses, la différence réside dans la classification, l'approche 1 est plus précise pour indiquer les phases en défaut que l'approche 2.

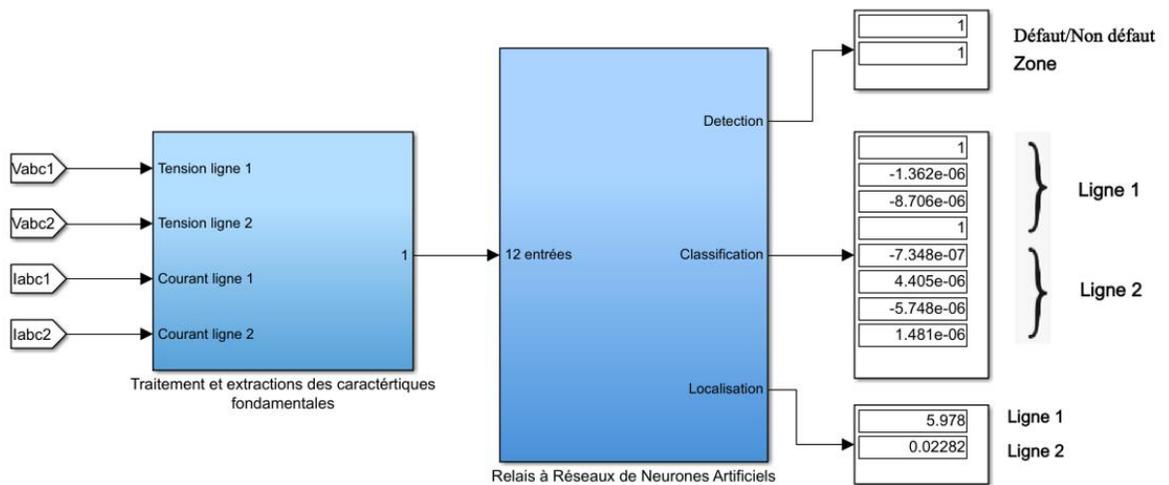


Figure 5.31 : Résultats obtenus par l'approche 1 pour un défaut de type phase A-Terre à 6 km du terminal de la ligne 1.

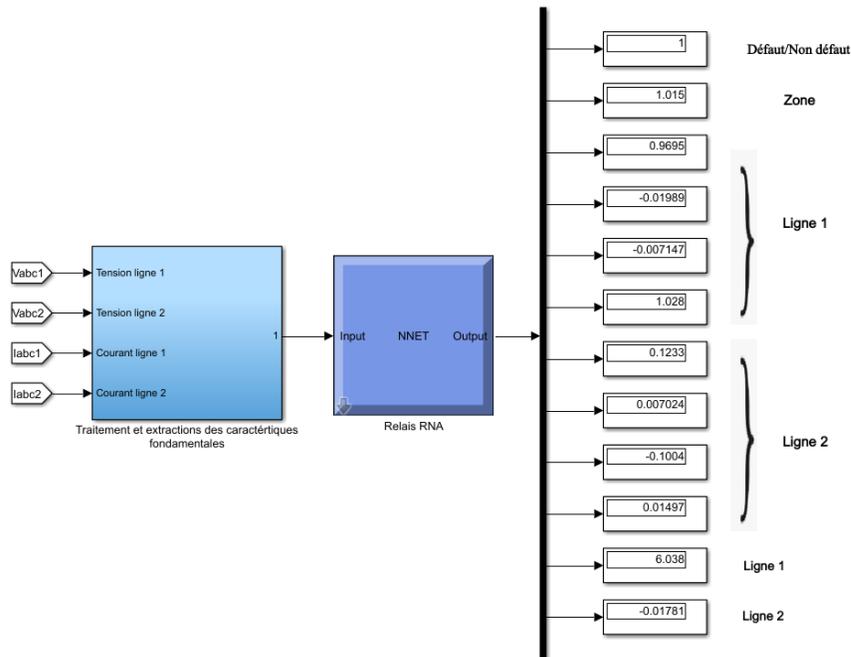


Figure 5.32 : Résultats obtenus par l'approche 2 pour un défaut de type phase A-Terre à 6 km du terminal de la ligne 1.

- Défaut phase C-Terre à 17 km du terminal

Un défaut de type phase C-Terre est appliqué à 17 km du terminal de la ligne 1, avec une résistance du défaut de 20Ω , les résultats obtenus à la fin de la simulation pour l'approche 1 et l'approche 2 sont présentés respectivement dans la figure 5.33 et 5.34. Cette fois-ci, l'approche 1 donne des résultats plus précis pour la détection, classification et localisation du défaut.

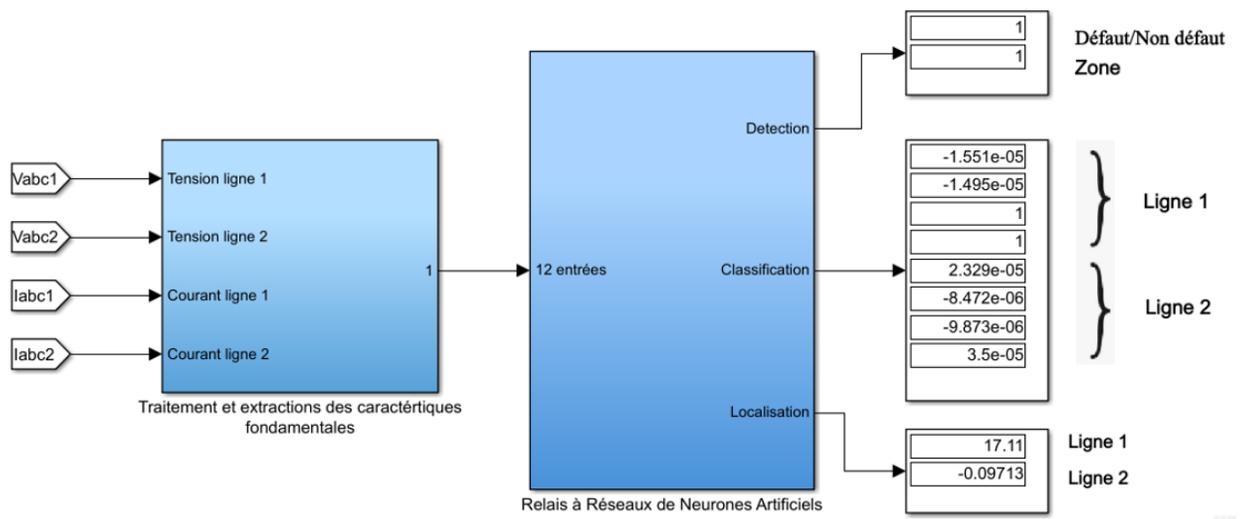


Figure 5.33 : Résultats obtenus par l'approche 1 pour un défaut de type phase C-Terre à 17 km du terminal de la ligne 1.

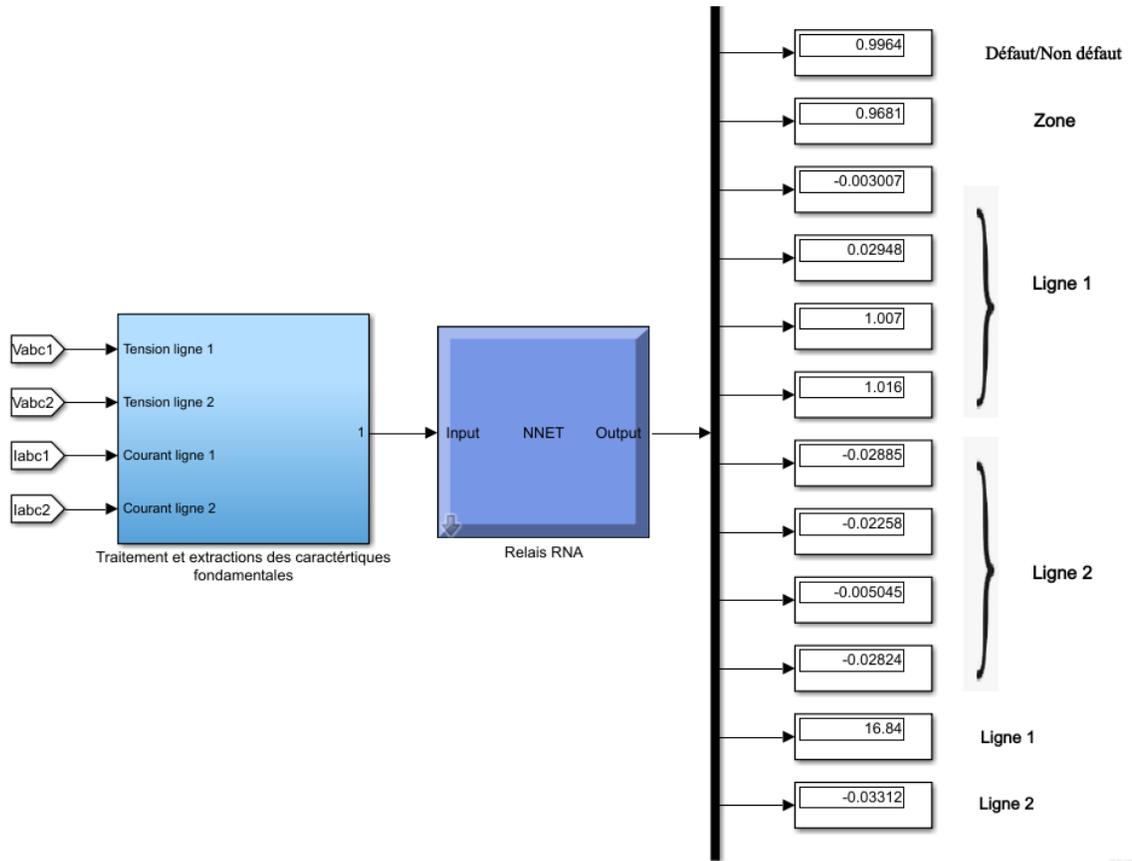


Figure 5.34 : Résultats obtenus par l'approche 2 pour un défaut de type phase C-Terre à 17 km du terminal de la ligne 1.

- Défaut double phase B-C à 29 km du terminal

Un défaut de type double phase B-C est appliqué à 29 km du terminal de la ligne 1, avec une résistance du défaut de 60Ω , les résultats obtenus à la fin de la simulation pour l'approche 1 et l'approche 2 sont présentés respectivement dans la figure 5.35 et 5.36.

Dans ce cas, l'approche 2 donne des résultats plus précis dans le cas de détection et localisation, la classification est plus précise avec l'approche 1.

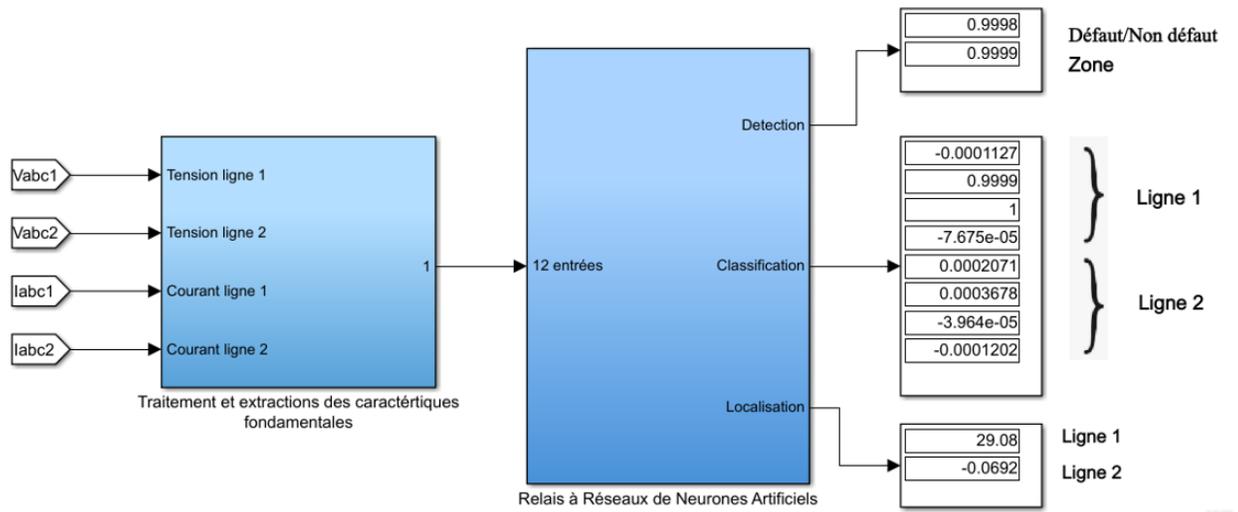


Figure 5.35 : Résultats obtenus par l'approche 1 pour un défaut de type double phase B-C à 29 km du terminal de la ligne 1.

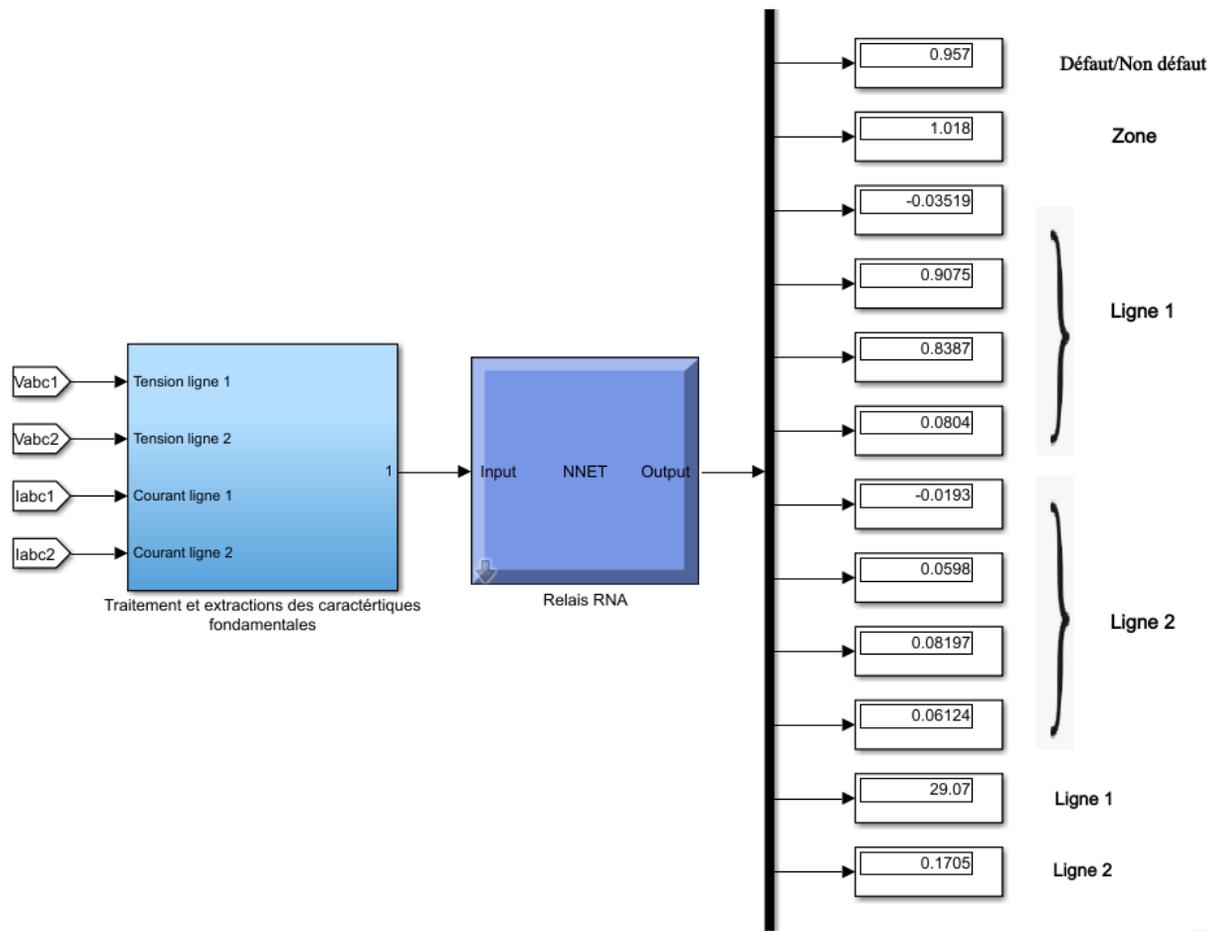


Figure 5.36 : Résultats obtenus par l'approche 2 pour un défaut de type double phase B-C à 29 km du terminal de la ligne 1.

ii. Cas d'un défaut dans la ligne 2

- Défaut double phase A-B-Terre à 5 km du terminal

Un défaut de type double phase A-B-Terre est appliqué à 5 km du terminal de la ligne 2, avec une résistance du défaut de 1Ω , les résultats obtenus à la fin de la simulation pour l'approche 1 et l'approche 2 sont présentés respectivement dans la figure 5.37 et 5.38.

Dans ce cas l'approche 2 est plus précise à donner la position du défaut tandis que l'approche 1 est plus efficace pour la détection et classification.

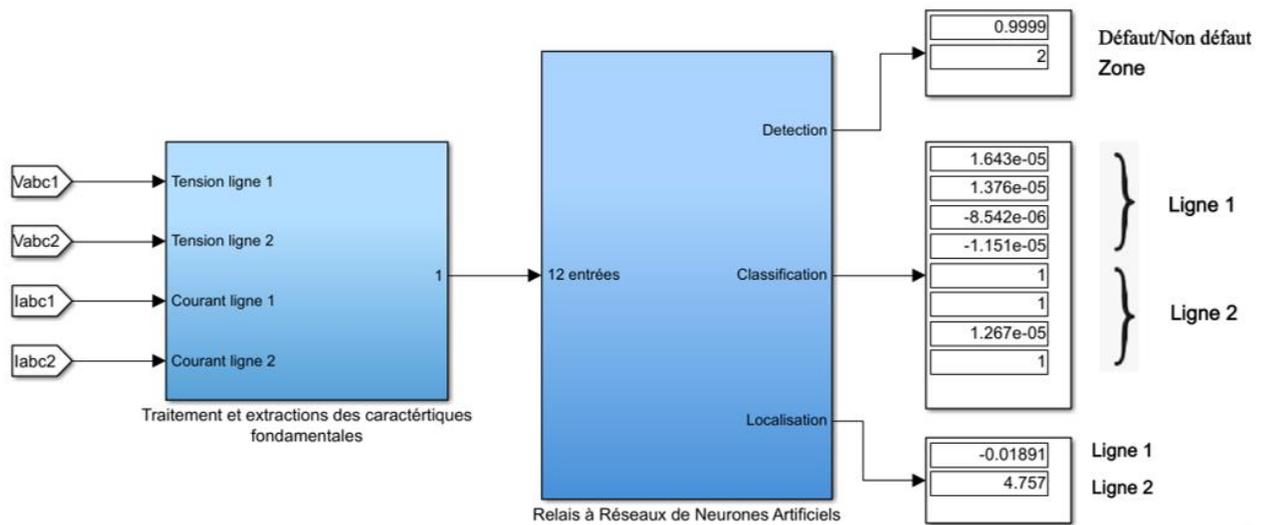


Figure 5.37 : Résultats obtenus par l'approche 1 pour un défaut de type double phase A-B-Terre à 5 km du terminal de la ligne 2.

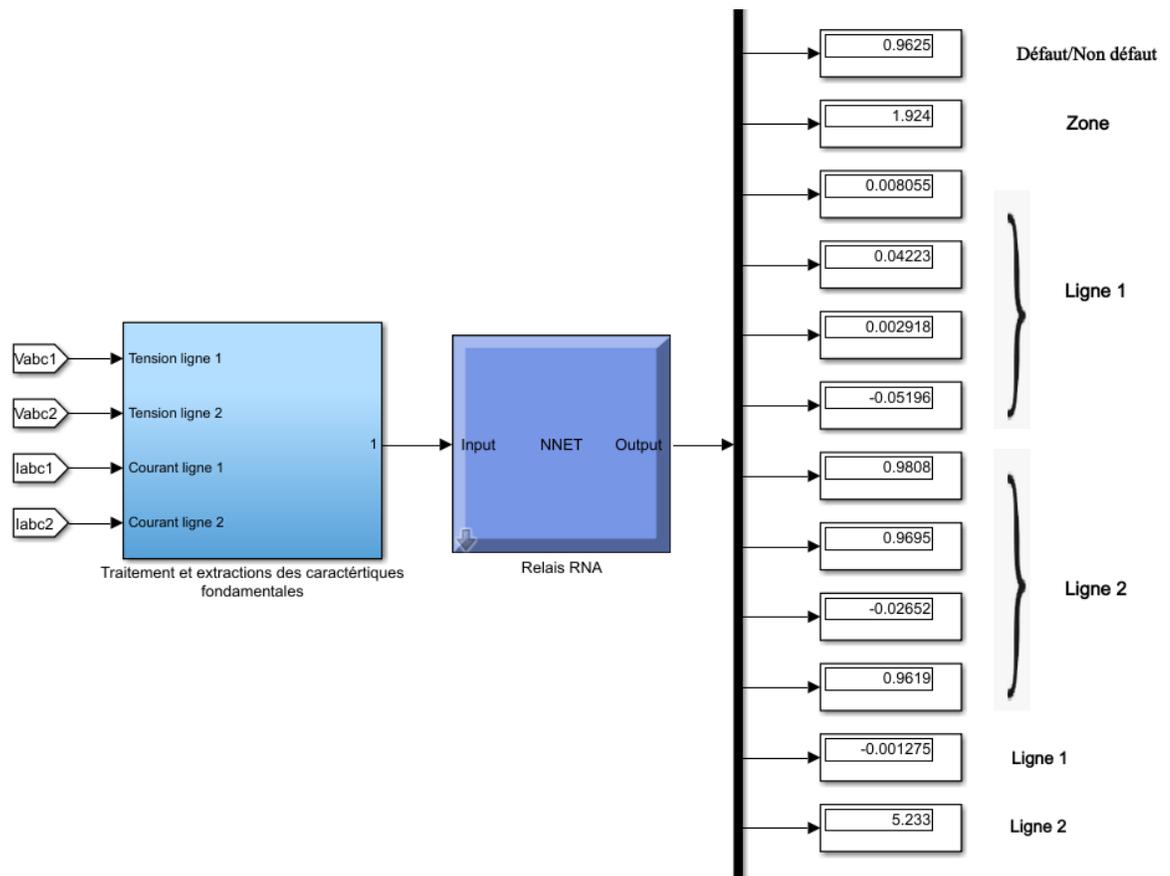


Figure 5.38 : Résultats obtenus par l'approche 2 pour un défaut de type double phase A-B-Terre à 5 km du terminal de la ligne 2.

- Défaut double phase B-C-Terre à 13 km du terminal

Un défaut de type double phase B-C-Terre est appliqué à 13 km du terminal de la ligne 2, avec une résistance du défaut de 20Ω , les résultats obtenus à la fin de la simulation pour l'approche 1 et l'approche 2 sont présentés respectivement dans la figure 5.39 et 5.40.

L'approche 1 donne des résultats plus précis dans ce cas.

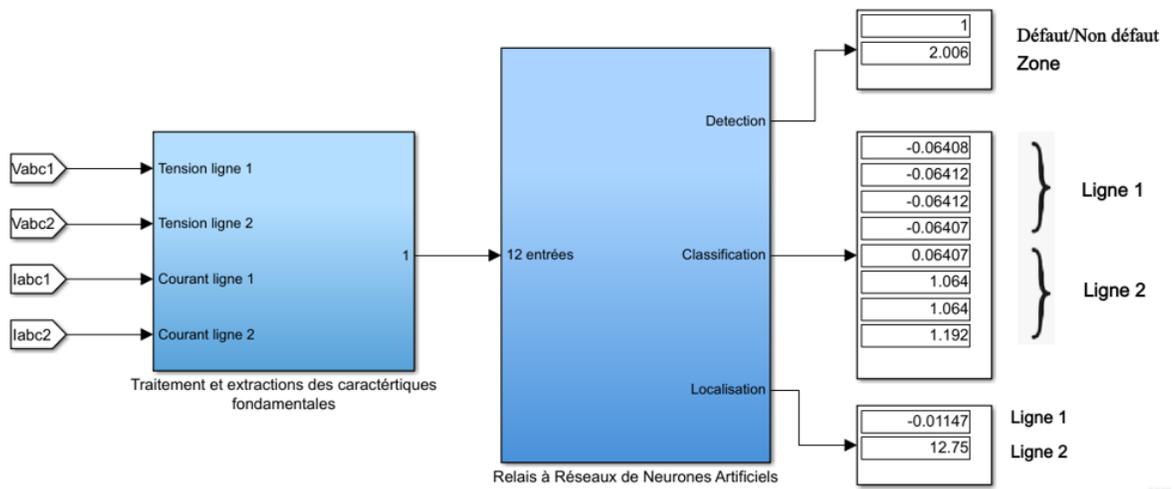


Figure 5.39 : Résultats obtenus par l'approche 1 pour un défaut de type double phase B-C-Terre à 13 km du terminal de la ligne 2.

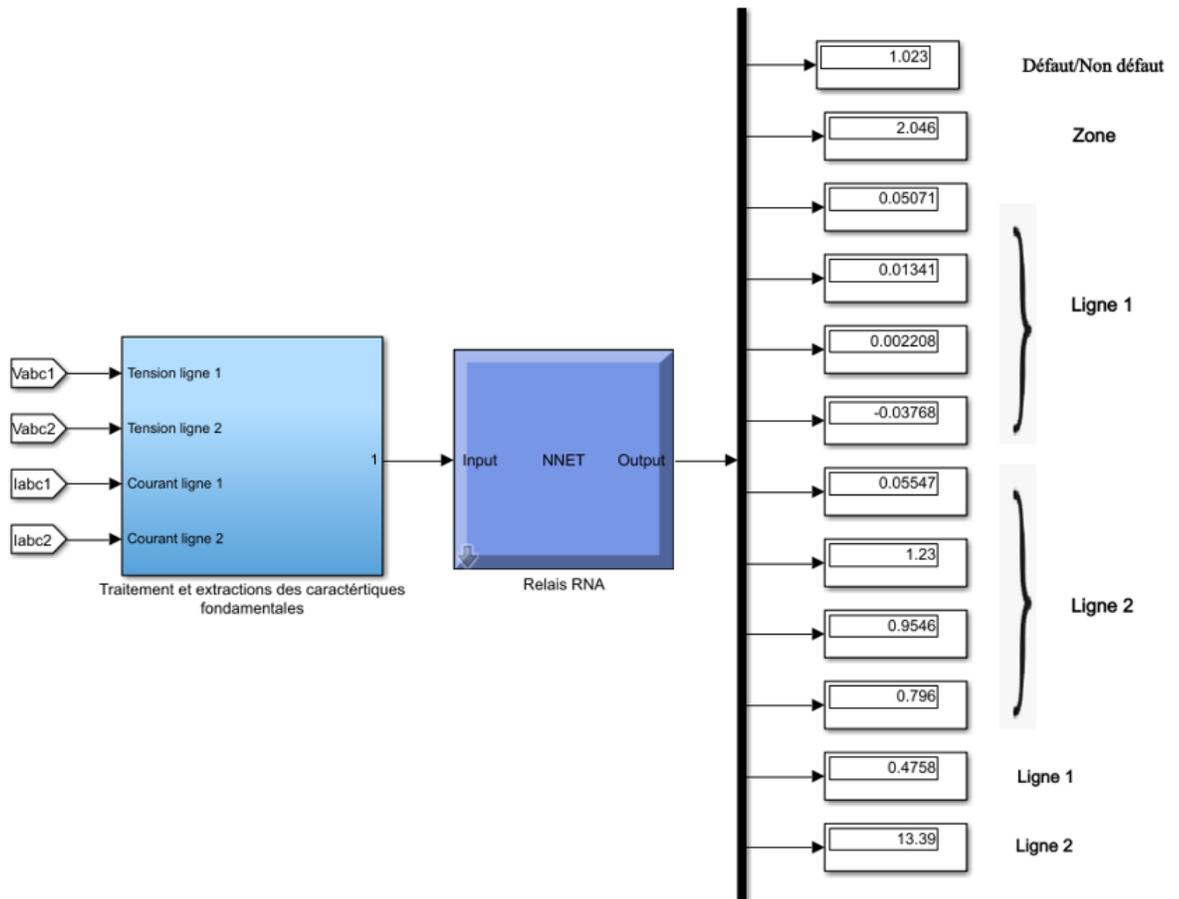


Figure 5.40 : Résultats obtenus par l'approche 2 pour un défaut de type double phase B-C-Terre à 13 km du terminal de la ligne 2.

- Défaut triphasé A-B-C-Terre à 20 km du terminal

Un défaut de type triphasé A-B-C est appliqué à 20 km du terminal de la ligne 2 (l'extrémité de la ligne 2), avec une résistance du défaut de 45Ω , les résultats obtenus à la fin de la simulation pour l'approche 1 et l'approche 2 sont présentés respectivement dans la figure 5.41 et 5.42.

L'approche 1 donne des résultats plus précis dans ce cas.

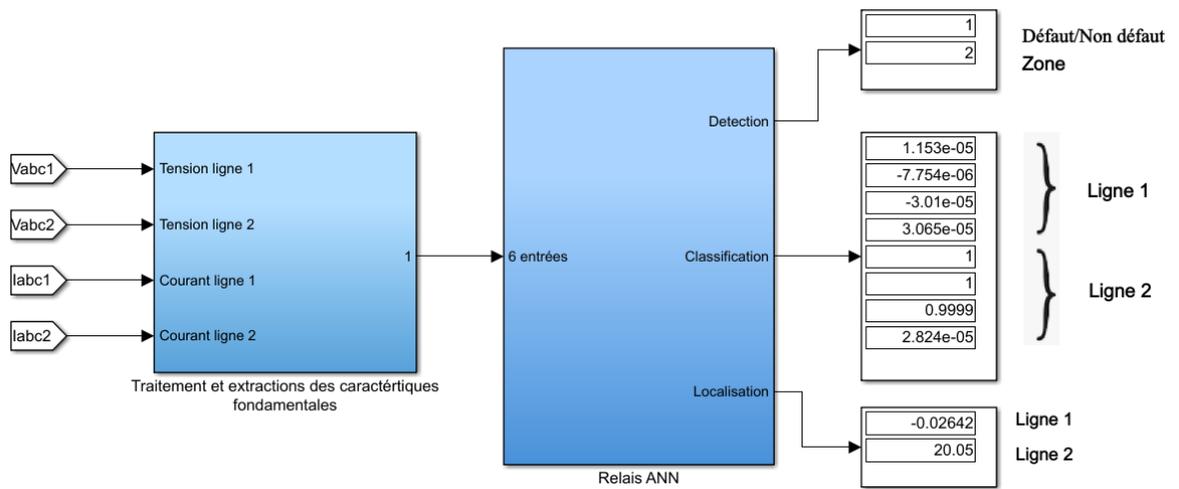


Figure 5.41 : Résultats obtenus par l'approche 1 pour un défaut de type triphasé A-B-C à 20 km du terminal de la ligne 2.

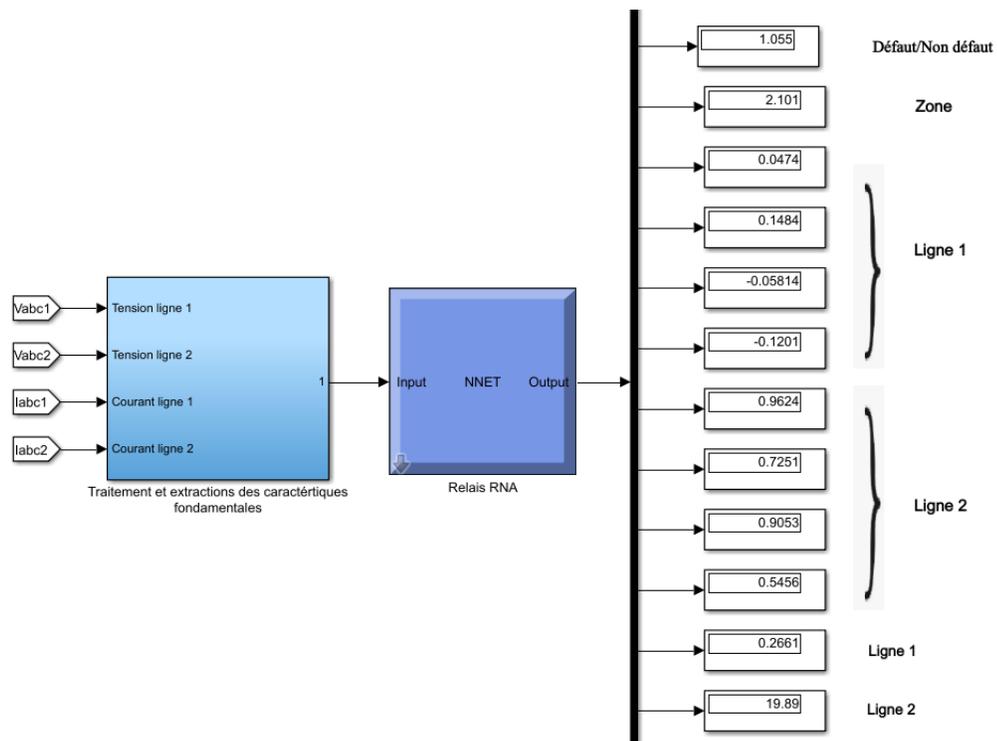


Figure 5.42 : Résultats obtenus par l'approche 2 pour un défaut de type triphasé A-B-C à 20 km du terminal de la ligne 2.

5.6 Conclusion

Dans ce chapitre, un réseau électrique plus compliqué est considéré pour bien tester l'efficacité des réseaux de neurones, il s'agit de deux lignes en parallèle, deux approches sont proposées et développées afin de pouvoir protéger les deux lignes en parallèle, la 1^{re} consiste à concevoir trois modèles neuronaux pour la détection, classification et localisation, regroupés dans un bloc relais, la 2^e s'agit de développer directement un relais basé sur un seul modèle neuronal. Les résultats de simulation des deux méthodes sont présentés et comparés, on remarque que les résultats sont proches et ils ont presque le même temps de réponse. Le choix de la méthode dépend de l'application désirée, si la problématique est concentrée plus sur la détection et localisation, l'approche 2 est plus appropriée parce qu'il est moins encombrant de développer un seul réseau de neurones, si l'objectif est concentré sur l'identification du type du défaut, la méthode 1 est plus précise à indiquer les phases en défaut.

CHAPITRE 6

DÉTECTION ET ISOLATION DE LA ZONE DÉFECTUEUSE PAR LE RELAIS INTELLIGENT POUR MISE EN OEUVRE D'UNE PROTECTION EN TEMPS RÉEL

La protection du système électrique, en général, est nécessaire pour détecter toute condition anormale qui peut nuire au bon fonctionnement du système, isoler le nombre minimum de dispositifs dans le but de ramener le système à son état de fonctionnement normal le plus rapidement possible afin d'éviter des dommages catastrophiques assurant par la suite la sécurité du personnel et les biens matériels.

Une nouvelle mise en œuvre en temps réel d'un isolateur de défauts a été réalisée sur le modèle de ligne de transmission proposé dans le 4^{ème} chapitre, présenté dans la figure 6.1. La ligne de 100 km est considérée comme une série de deux lignes de 50 km chacune afin de bien contrôler les deux disjoncteurs, la sélectivité entre les deux est donc basée sur l'emplacement du défaut, si le défaut est plus proche de la source triphasée 1, c'est-à-dire il s'est produit dans la section triphasée 1 de 50 km, le relais intelligent conçu va donc envoyé un signal au générateur des signaux de déclenchement, les composants de ce bloc sont spécifiés dans l'Annexe A-3, ce générateur est utilisé pour créer l'impulsion nécessaire à la commande du disjoncteur, par conséquent, le disjoncteur 1 va être ouvert afin de protéger la charge triphasée RLC en série numéro 1 des surintensités dangereuses causées par le défaut. En d'autres termes, au cas de l'occurrence du défaut, le relais intelligent commande le disjoncteur le plus proche de l'emplacement du défaut à être ouvert, coupant par la suite le courant triphasé et isolant la partie défectueuse jusqu'à élimination de ce dernier.

Le bloc disjoncteur nécessite un signal d'amplitude 0 pour être ouvert et un signal d'amplitude supérieure à 0 pour fermer le disjoncteur. Le modèle de système de protection intelligente mis en œuvre en temps réel est présenté à la figure 6.1, les formes d'onde de tension et de courant ont été mesurées et envoyées au bloc de traitement du signal, où la composante fondamentale a été extraite et introduite dans le sous-système de réseau neuronal (Relais ANN). Ce relais intelligent produit le résultat approprié, avec 0 pour l'absence du défaut et 1 au cas de sa présence, indiquant aussi sa position sur la ligne.

Lorsqu'il n'y a pas de défauts, la sortie du relais ANN (Artificial Neural Network) est 0 et l'impulsion à envoyer au disjoncteur est 1, pour le maintenir fermé. Lorsqu'un défaut est introduit, la sortie du relais ANN est égale à 1 et l'impulsion à envoyer au disjoncteur est égale à 0, pour l'ouvrir et assurer ainsi une action de protection.

Deux blocs de mesure « Bus de mesure 1 » et « Bus de mesure 2 » sont placés en aval des deux charges pour observer leurs états instantanés, le bloc « Bus de mesure » sert à prendre les mesures nécessaires pour le bloc de relais ANN. Toutes les valeurs prises sont en PU (Per-Unit).

Différents types de défauts, avec des conditions de défaut et des distances de défaut variables, ont été appliqués pour démontrer l'action de déclenchement intelligente prise par le système de protection développé.

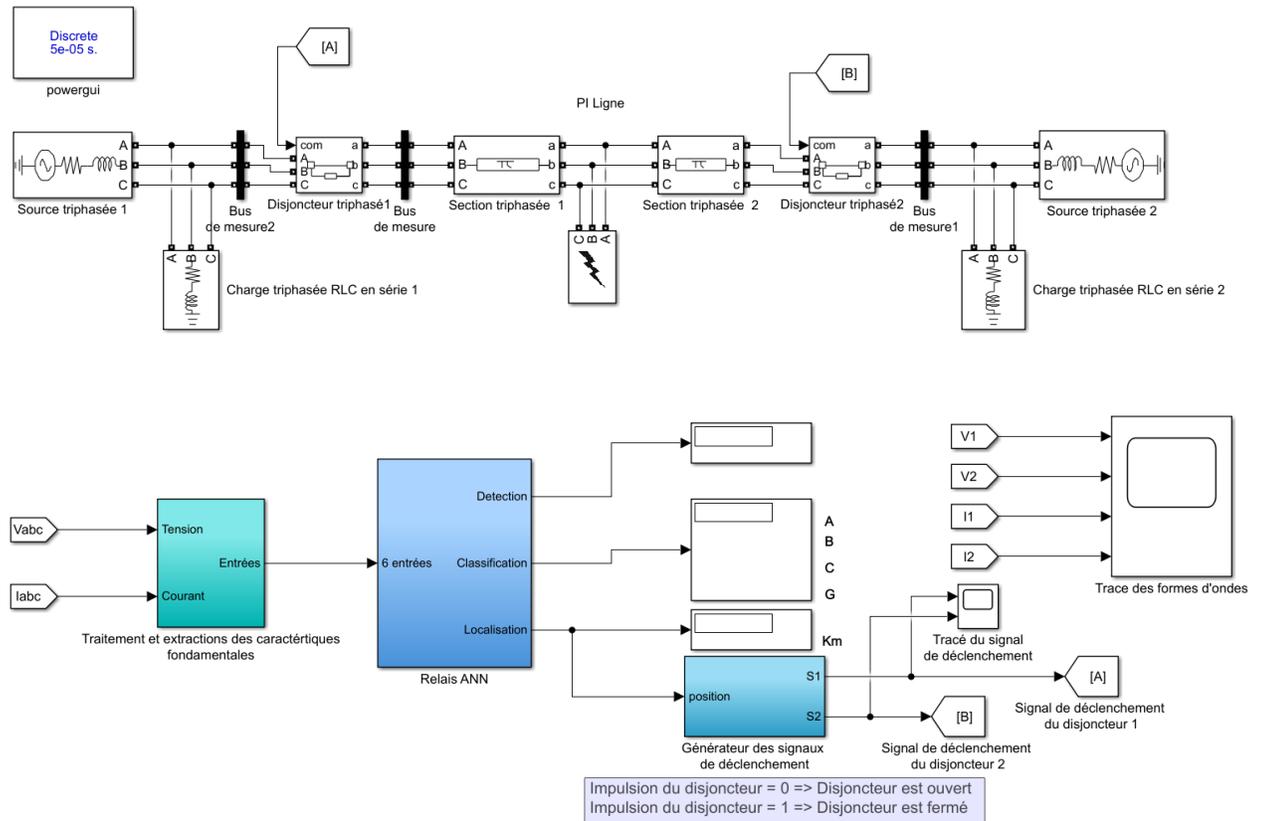


Figure 6.1 : Modèle de protection intelligent en temps réel basé sur le réseau de neurones artificiels

6.1 Défaut monophasé à la terre

Un défaut monophasé à la terre a été appliqué à $t = 0.03$ s. Deux cas de défaut sont présentés pour tester la sélectivité entre les deux disjoncteurs.

Les figures 6.2 et 6.3 montrent respectivement les formes d'onde de tension et de courant instantanés et le signal de déclenchement envoyé au disjoncteur dans le cas d'un défaut monophasé de type phase B-Terre à 26 km de la source triphasée1. Le générateur des signaux de déclenchement produit un signal 0 pour le disjoncteur 1 à l'instant $t = 0.043$ s, c'est à dire 13 ms après l'occurrence du défaut. Après

l'élimination du défaut, les formes d'onde de courant sont nulles et les formes d'onde de tension deviennent normales pour la ligne1 (section triphasé1 de 50 km). La ligne 2 reste en défaut jusqu'à une décision est prise de la part des ingénieurs. La ligne 1 a été protégée du défaut en quelques millisecondes.

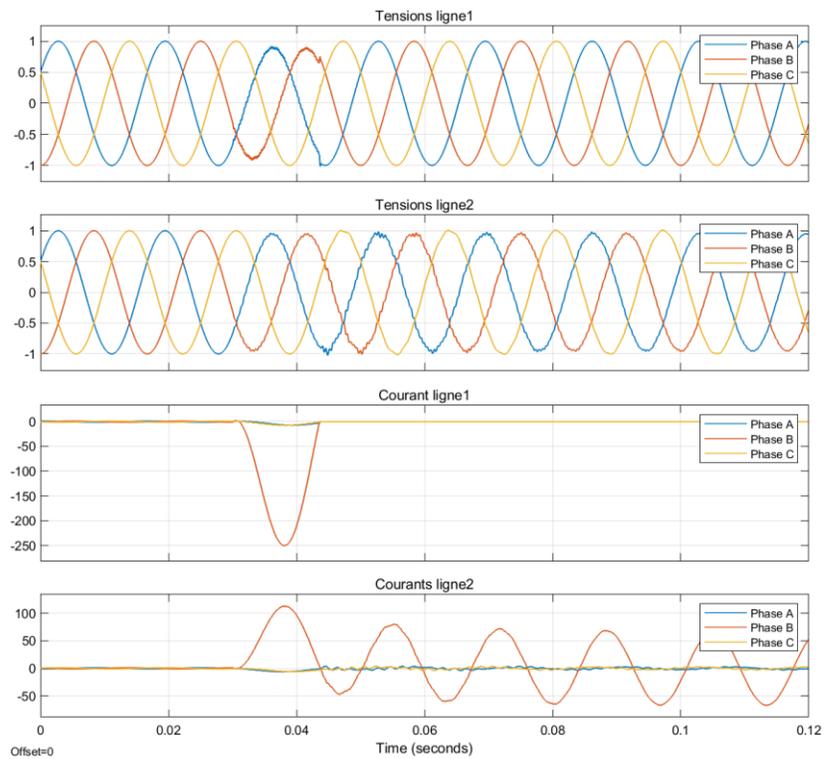


Figure 6.2 : Formes d'ondes au cas d'un défaut phase B-Terre à 26 km.

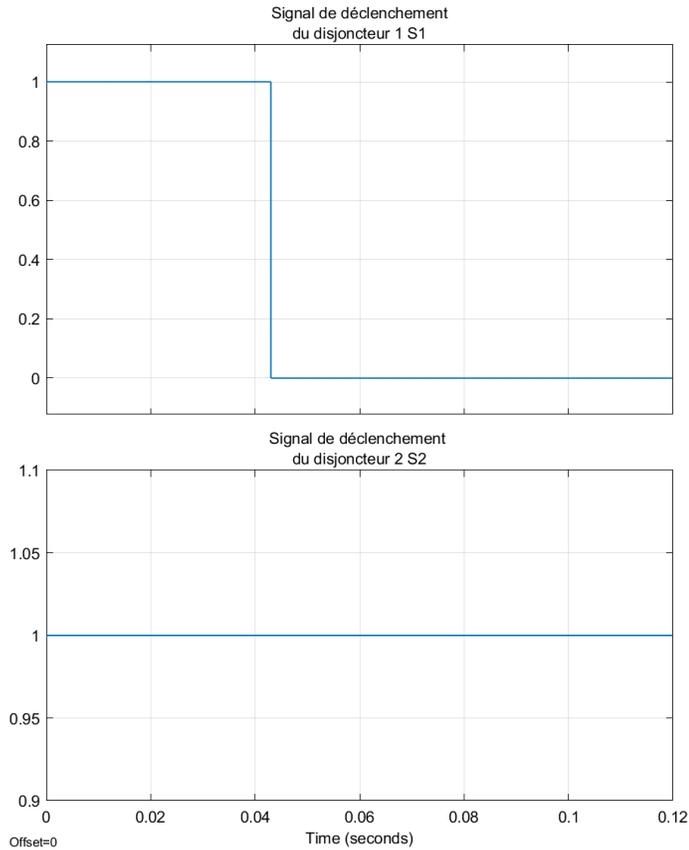


Figure 6.3 : Signaux de déclenchement au cas d'un défaut phase B-Terre à 26 km. Les figures 6.4 et 6.5 montrent respectivement les formes d'onde de tension et de courant instantanés et le signal de déclenchement envoyé au disjoncteur dans le cas d'un défaut monophasé de type phase A-Terre à 63 km de la source triphasée1. Le générateur des signaux de déclenchement produit un signal 0 pour le disjoncteur 1 à l'instant $t = 0.06$ s , c'est à dire 30 ms après l'occurrence du défaut. Après l'élimination du défaut, les formes d'onde de courant sont nulles et les formes d'onde de tension deviennent normales pour la ligne2 (section triphasé2 de 50 km de source2).

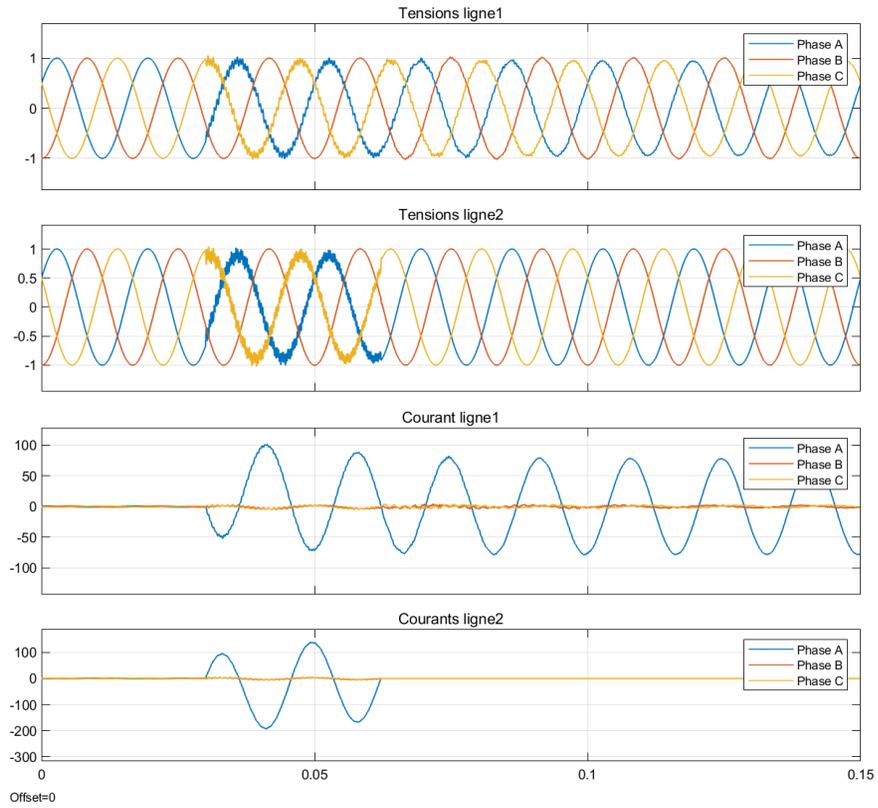


Figure 6.4 : Formes d'ondes au cas d'un défaut phase A-Terre à 63 km.

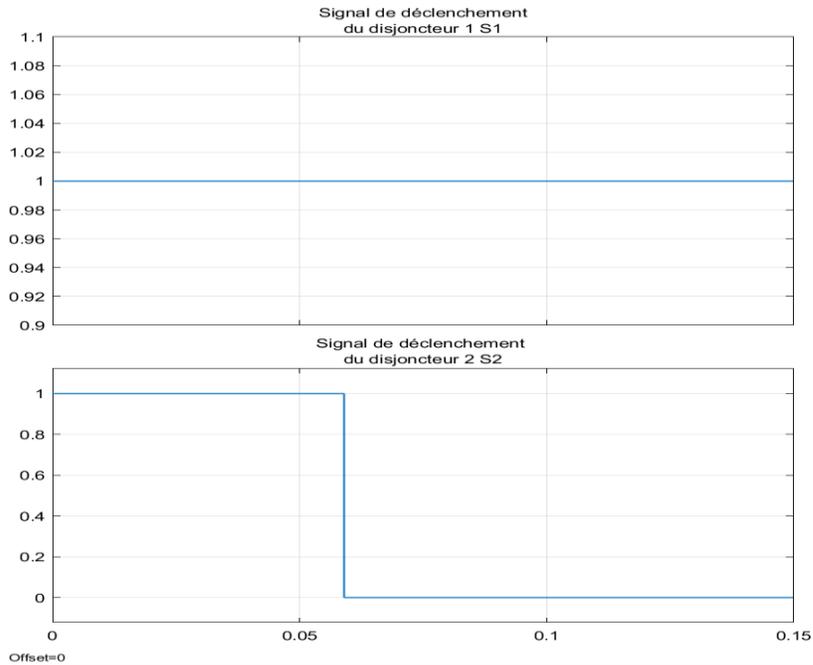


Figure 6.5 : Signaux de déclenchement au cas d'un défaut phase A-Terre à 63 km.

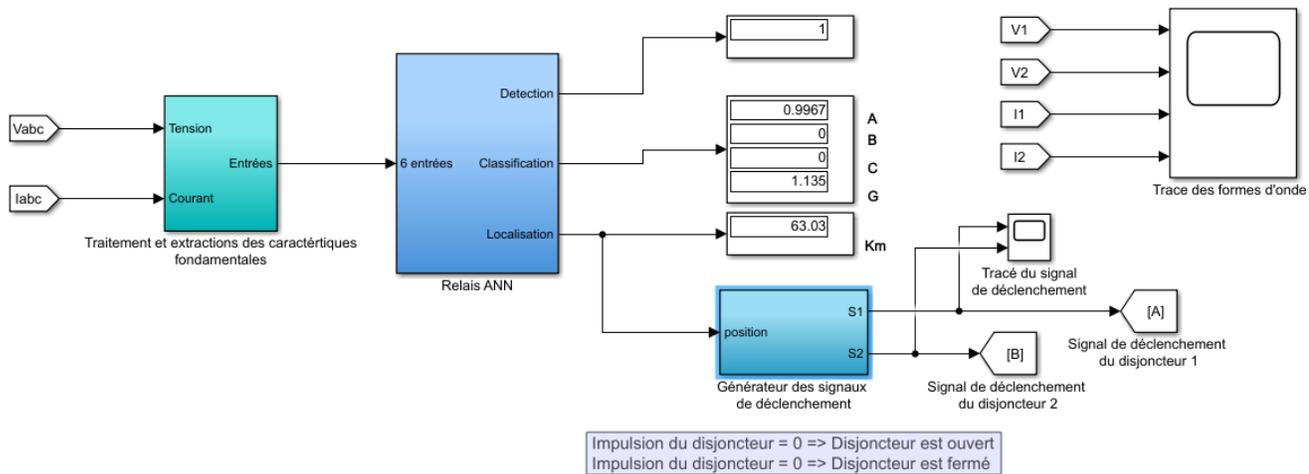


Figure 6.6 : Résultats de simulation obtenue au cas d'un défaut de type phase A-terre à 63 km.

6.2 Défaut double phase

Un défaut double phase (phase-phase) a été appliqué à $t = 0.03$ s. Deux cas de défaut sont présentés pour tester la sélectivité entre les deux disjoncteurs. Les figures 6.7 et 6.8 montrent respectivement les formes d'onde de tension et de courant instantanés et le signal de déclenchement envoyé au disjoncteur dans le cas d'un défaut monophasé de type double phase A-B à 43 km de la source triphasée 1.

Le générateur des signaux de déclenchement produit un signal 0 pour le disjoncteur 1 à l'instant $t = 0.11$ s, c'est à dire 80 ms après l'occurrence du défaut. Le courant dans la 1ère section devient donc nul alors que la tension reprend sa valeur normale, l'isolation de la section 1 est donc réalisée automatiquement.

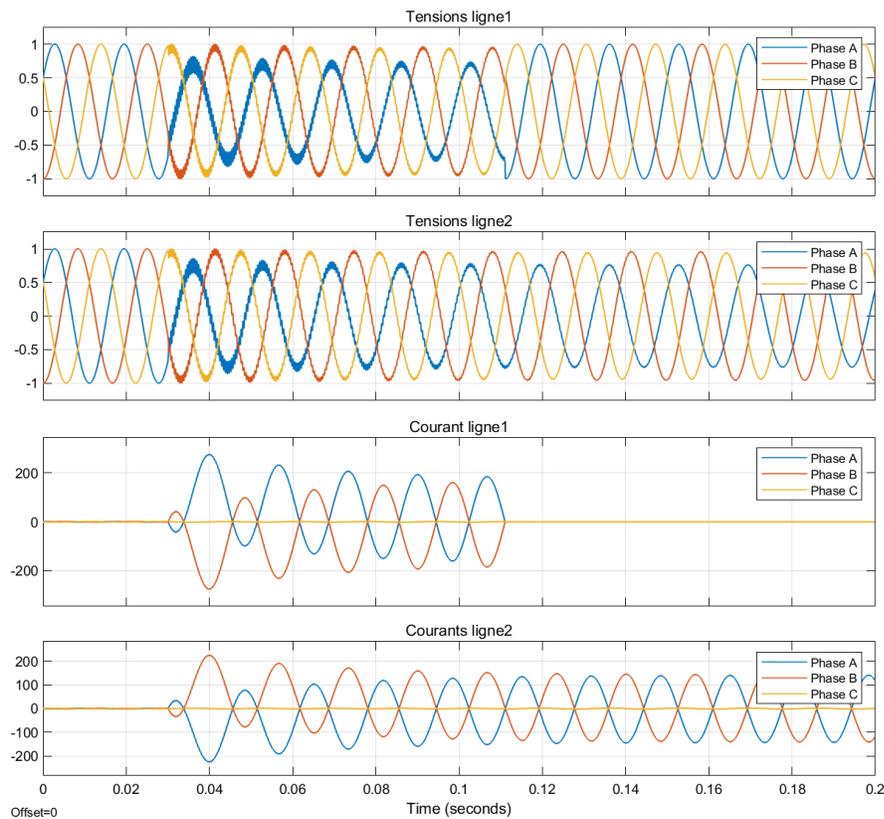


Figure 6.7 : Formes d'ondes au cas double phases A-B à 43 km.

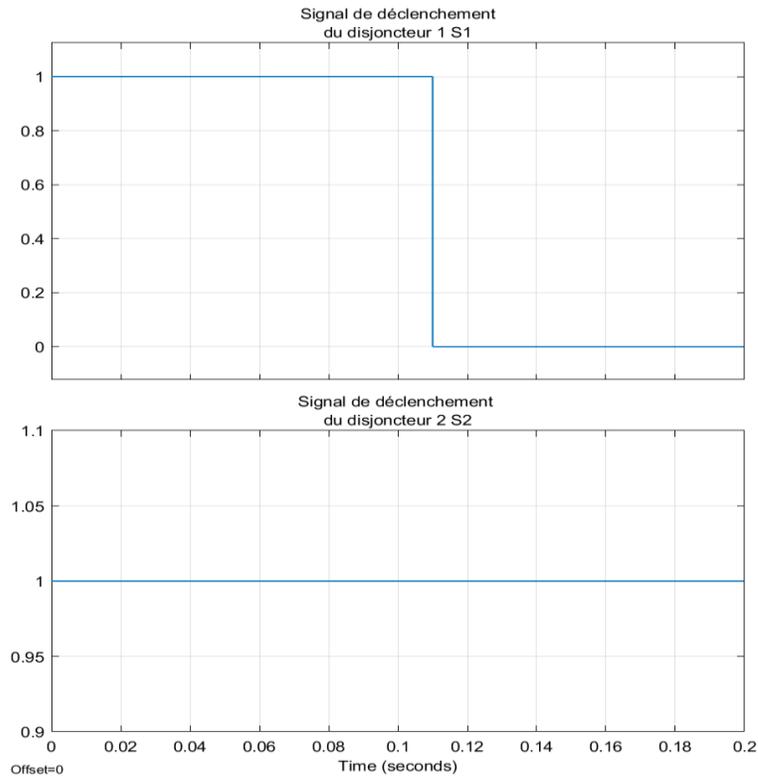


Figure 6.8 : Signaux de déclenchement au cas double phases A-B à 43 km.

Les figures 6.9 et 6.10 montrent respectivement les formes d'onde de tension et de courant instantanés et le signal de déclenchement envoyé au disjoncteur dans le cas d'un défaut monophasé de type double phase B-C à 75 km de la source triphasée1. Le courant dans la 2ème section devient donc nul alors que la tension reprend sa valeur normale après 29 ms de l'occurrence du défaut, l'isolation de la section 2 est donc réalisée automatiquement.

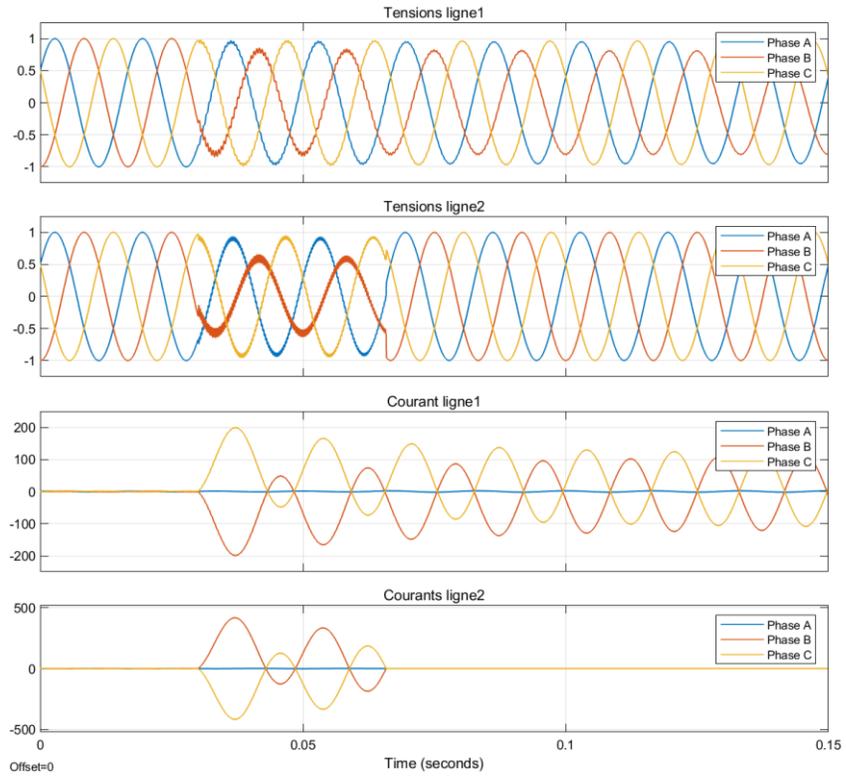


Figure 6.9 : Formes d'ondes au cas double phases B-C à 75 km

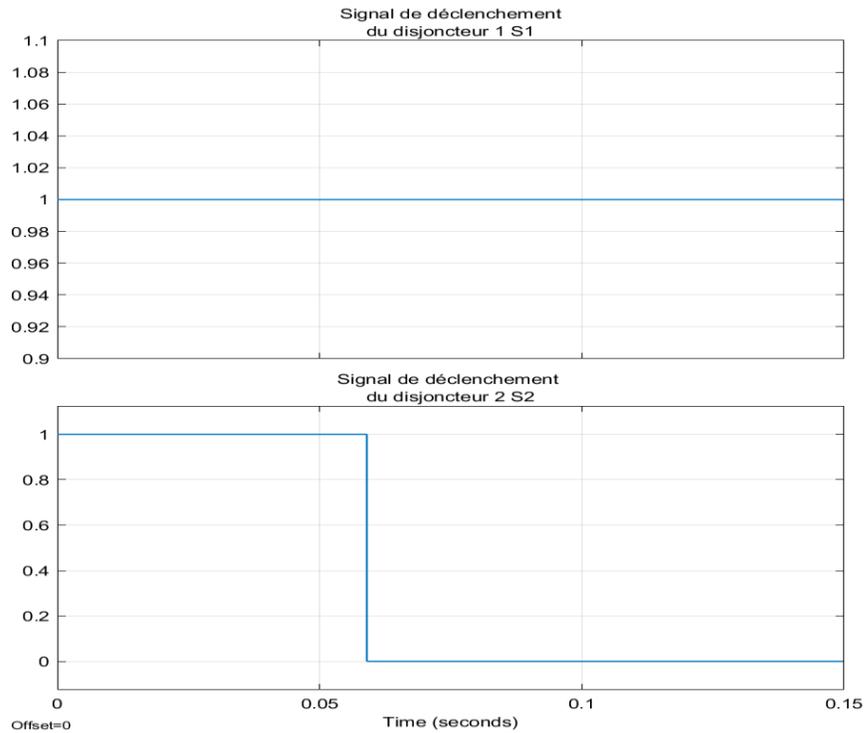


Figure 6.10 : Signaux de déclenchement au cas double phases B-C à 75 km.

6.3 Défaut double phase à la terre

Un défaut double phase à la terre (phase-phase-terre) a été appliqué à $t = 0.03$ s. Deux cas de défaut sont présentés pour tester la sélectivité entre les deux disjoncteurs.

Les figures 6.11 et 6.12 montrent respectivement les formes d'onde de tension et de courant instantanés et le signal de déclenchement envoyé au disjoncteur dans le cas d'un défaut monophasé de type double phases à la terre A-C-Terre à 40 km de la source triphasée¹. Le générateur des signaux de déclenchement produit un signal 0 pour le disjoncteur 1 à l'instant $t = 0.16$ s, c'est à dire 0,13 s après l'occurrence du défaut. Le courant dans la 1ère section devient donc nul alors que la tension reprend sa valeur normale, l'isolation de la section 1 est donc réalisée automatiquement.

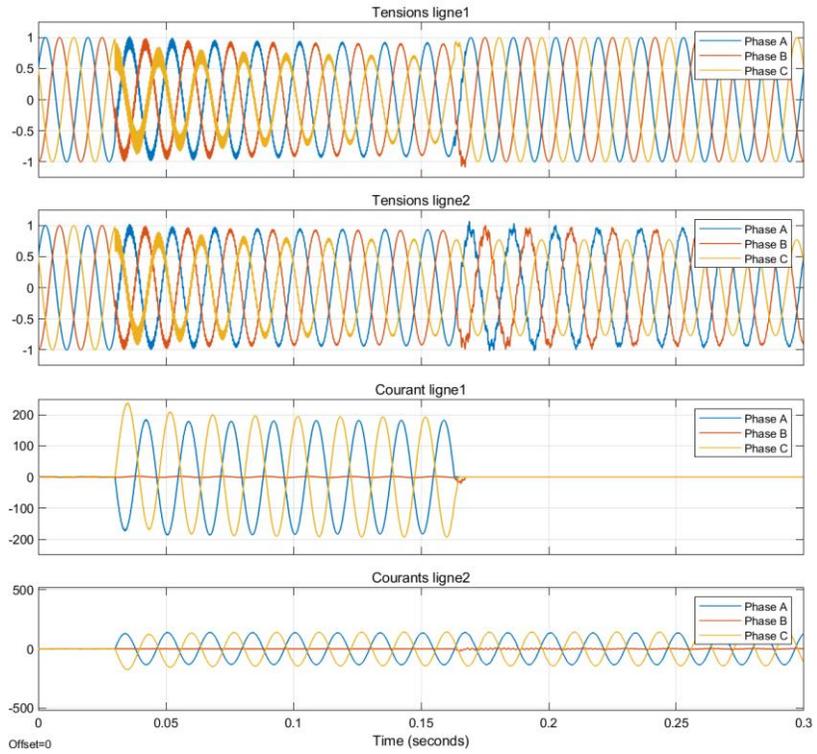


Figure 6.11 : Formes d'ondes au cas double phases à la terre A-C-Terre à 40 km.

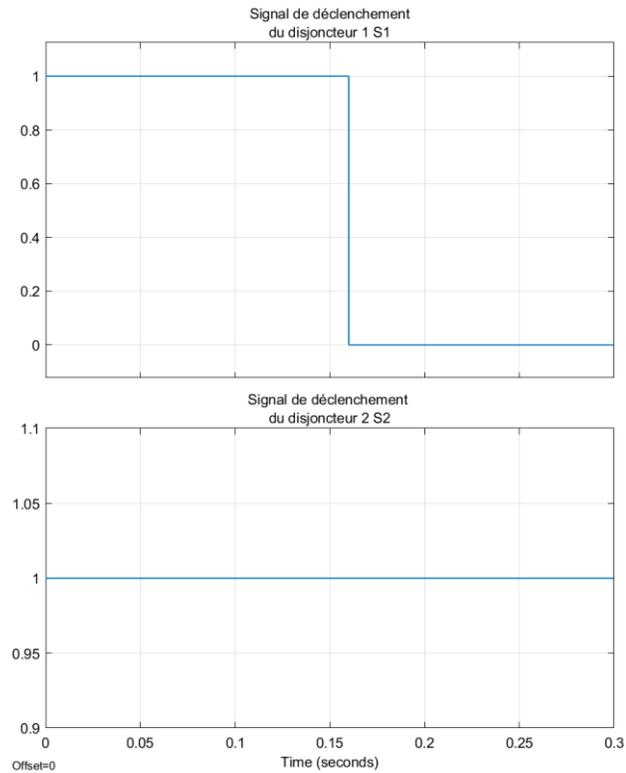


Figure 6.12 : Signaux de déclenchement au cas double phases à la terre A-C-Terre à 40 km.

Les figures 6.13 et 6.14 montrent respectivement les formes d'onde de tension et de courant instantanés et le signal de déclenchement envoyé au disjoncteur dans le cas d'un défaut monophasé de type double phase à la terre B-C-Terre à 87 km de la source triphasée¹. Le courant dans la 2ème section devient donc nul alors que la tension reprend sa valeur normale après 30 ms de l'occurrence du défaut, l'isolation de la section 2 est donc réalisée en quelques millisecondes.

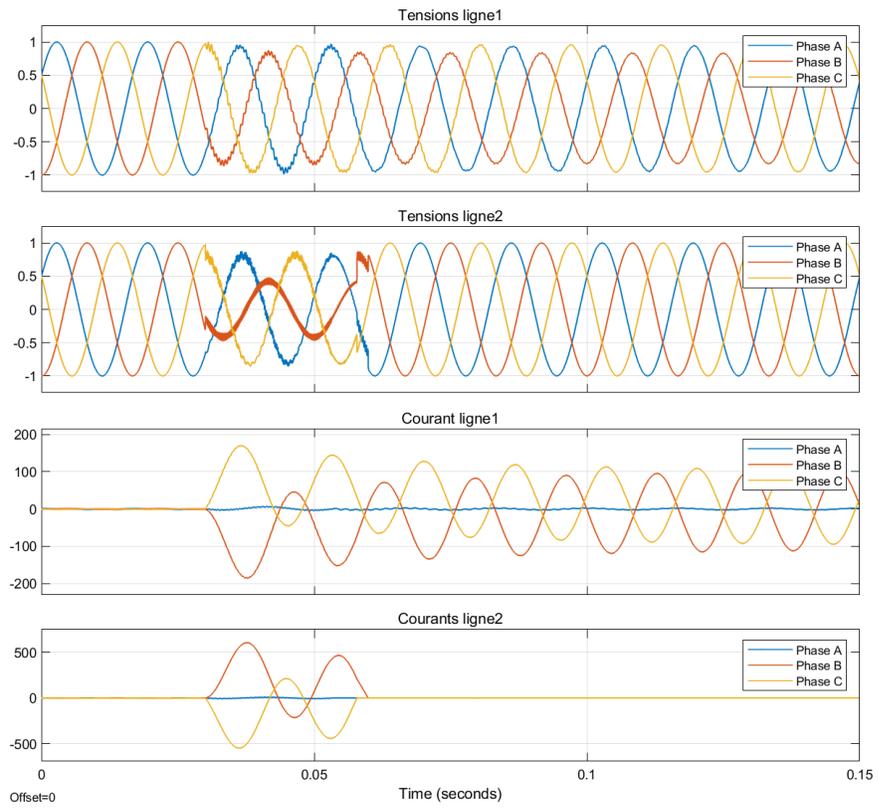


Figure 6.13 : Formes d'ondes au cas double phase à la terre B-C-Terre à 87 km.

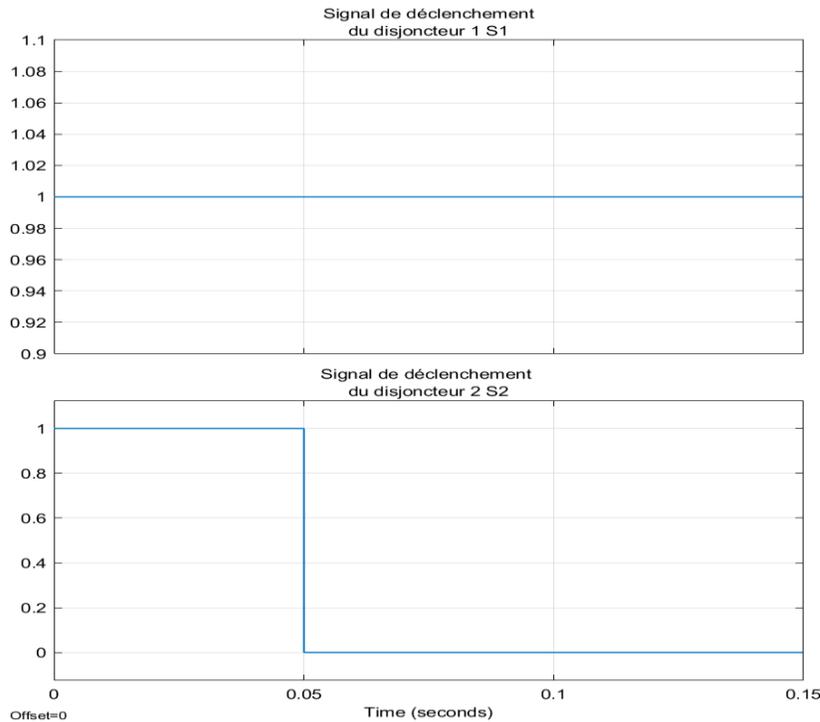


Figure 6.14 : Signaux de déclenchement au cas double phase à la terre B-C-Terre à 87 km.

6.4 Défaut triphasé

Un défaut triphasé (phase-phase-phase) a été appliqué à $t = 0.03$ s. Deux cas de défaut sont présentés pour tester la sélectivité entre les deux disjoncteurs.

Les figures 6.15 et 6.16 montrent respectivement les formes d'onde de tension et de courant instantanées et le signal de déclenchement envoyé au disjoncteur dans le cas d'un défaut monophasé de type triphasé A-B-C à 13 km de la source triphasée¹. Le générateur des signaux de déclenchement produit un signal 0 pour le disjoncteur 1 à l'instant $t = 0.05$ s, c'est à dire 0,02 s après l'occurrence du défaut. Le courant dans la 1ère section devient donc nul alors que la tension reprend sa valeur normale, l'isolation de la section 1 est donc réalisée automatiquement.

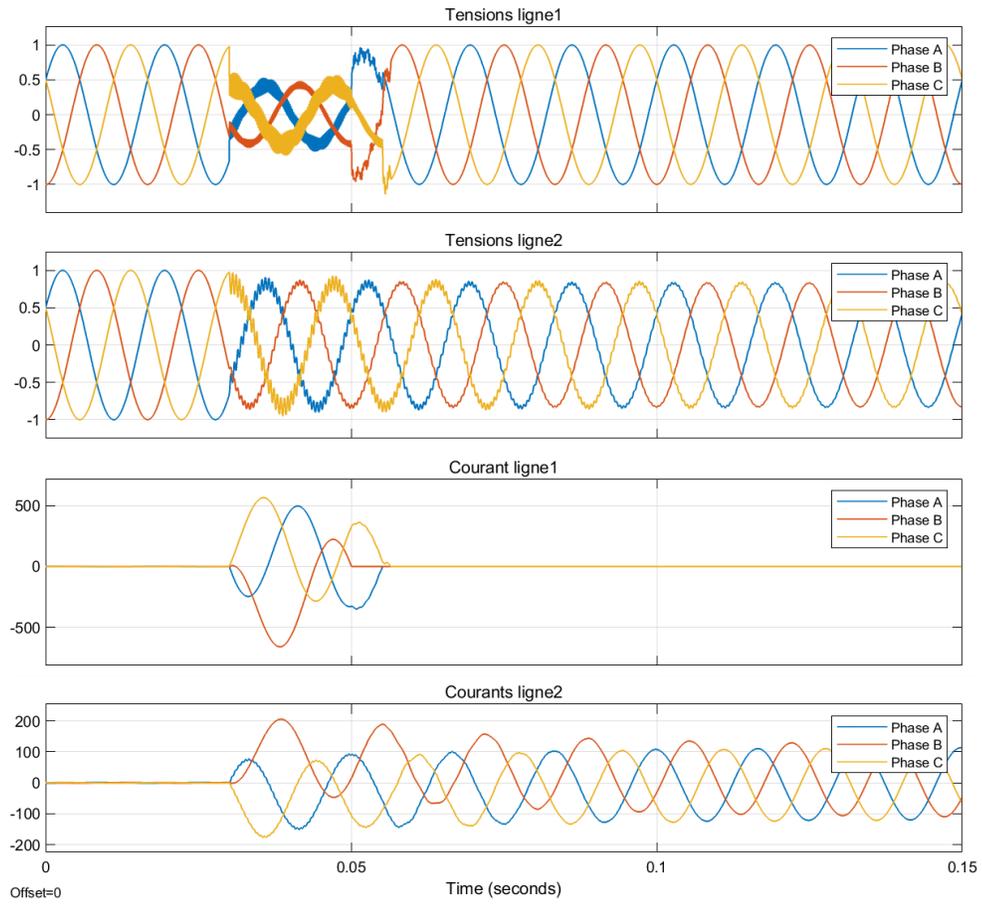


Figure 6.15 : Formes d'ondes au cas triphasé A-B-C à 13 km.

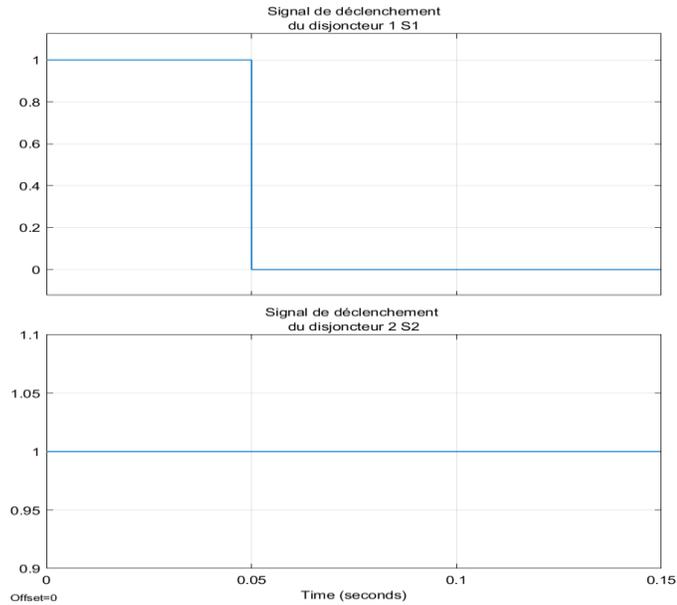


Figure 6.16 : Signaux de déclenchement au cas triphasé A-B-C à 13 km.

Les figures 6.17 et 6.18 montrent respectivement les formes d'onde de tension et de courant instantanés et le signal de déclenchement envoyé au disjoncteur dans le cas d'un défaut triphasé A-B-C à 99 km de la source triphasée numéro 1. L'action d'isolation de la section 2 est prise à l'instant 0.06s c'est-à-dire 30 ms après le défaut.

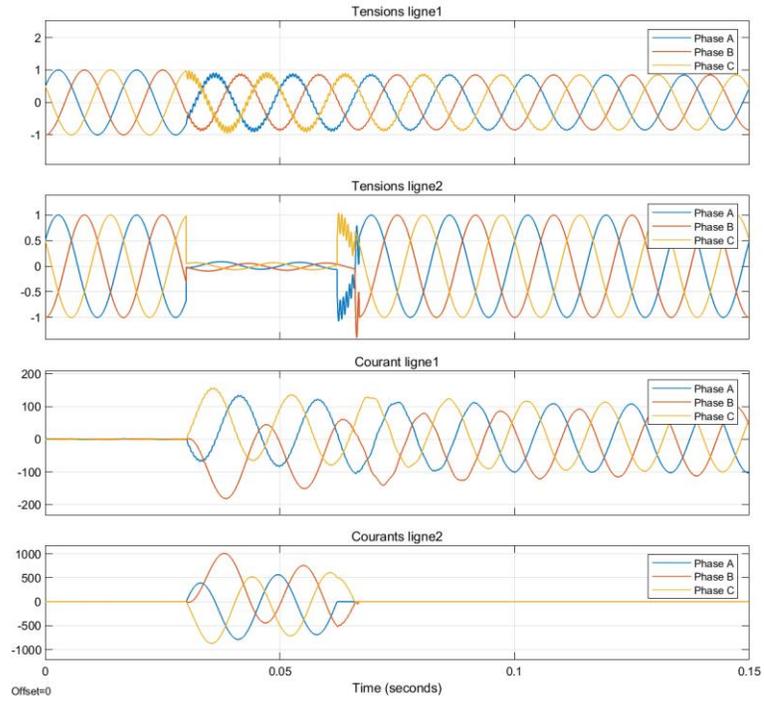


Figure 6.17 : Formes d'ondes au cas triphasé A-B-C à 99 km.

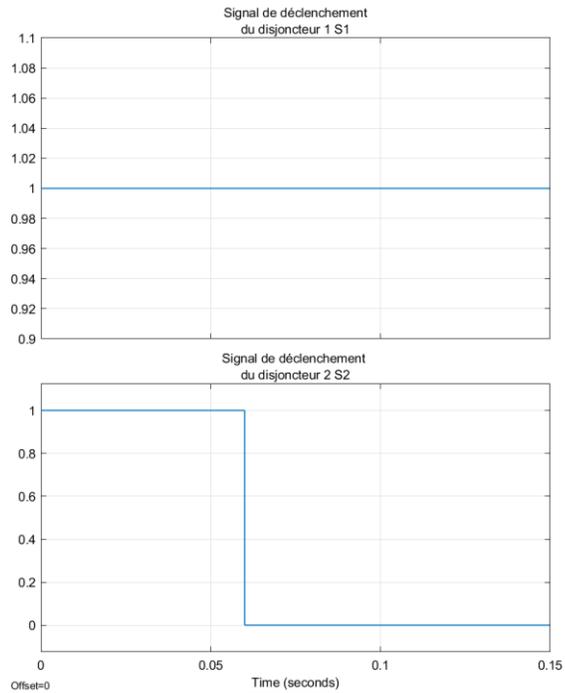


Figure 6.18 : Signaux de déclenchement au cas triphasé A-B-C à 99 km.

6.5 Conclusion

Les résultats présentés ci-dessus montrent que le modèle de système de protection mis en œuvre fonctionne en temps réel avec une grande fiabilité et protège la ligne de transmission pour tout type défauts. Ce système intelligent basé sur les réseaux de neurones artificiels est capable d'isoler automatiquement la section défectueuse en quelques millisecondes, ne dépassant pas 80 ms, en envoyant un signal de déclenchement du disjoncteur le plus proche du défaut.

La position du défaut a été calculée avec une grande précision, ce qui signifie que l'autoréparation et la restauration plus rapide sont possibles. La caractéristique remarquable de ce nouveau système de relais est que les réseaux neuronaux peuvent être amenés à apprendre des situations dans lesquelles ils sont mis en œuvre. Grâce à une nouvelle conception des réseaux neuronaux, ce système de relais intelligent peut être adapté à des situations où des énergies renouvelables intermittentes ou des micro réseaux sont présents.

CONCLUSION

Les lignes de transport électrique représentent un élément nécessaire et indisponible dans le réseau électrique, permettant d'acheminer l'énergie électrique aux clients. En plus, leurs câbles ne sont pas isolés et sont directement exposés à des conditions atmosphériques sévères, ce qui font d'eux plus susceptibles d'être sujettes à l'apparition de défauts, ces derniers peuvent causer des dommages catastrophiques s'ils ne sont pas éliminés rapidement.

Ce travail a étudié la possibilité de concevoir un système de protection intelligent des lignes de transmission basé sur les réseaux de neurones artificiels. Les méthodes employées utilisent les tensions de phase et les courants de phase (mis à l'échelle par rapport à leurs valeurs pré défaut) comme entrées des réseaux de neurones. La topologie de réseaux de neurones feedforward à back-propagation a été utilisée voire la simplicité de sa mise en œuvre.

Pour tester la fiabilité des réseaux de neurones à résoudre la problématique, deux modèles de réseau électrique ont été proposés et étudiés.

Pour le premier modèle, un relais intelligent se composant de trois blocs neuronaux a été développé. Ce relais est capable de détecter la présence ou l'absence du défaut, identifier son type et indiquer son emplacement par rapport à la source triphasée numéro 1. En cas du défaut, ce relais envoie un signal de déclenchement au disjoncteur le plus proche du défaut pour s'ouvrir et isoler par la suite la partie défectueuse, en protégeant par conséquent la charge des surintensités dangereuses.

Pour le deuxième modèle, deux méthodes ont été proposées et analysées. La première méthode est la même proposée pour le 1^{er} modèle, la 2^{ème} est de concevoir un relais

basé sur un seul réseau de neurones capable d'indiquer l'absence ou la présence du défaut, en indiquant aussi sur quelle ligne, son type et sa position par rapport à la source.

Plusieurs types de défauts, à savoir les défauts monophasés à la terre « phase-terre », biphasé « phase-phase », double phase à la terre « phase-phase-terre » et défauts triphasés « phase-phase-phase » ont été pris en considération dans ce travail. Les résultats de simulation obtenus ont prouvé des performances satisfaisantes atteintes par tous les réseaux neuronaux proposés. Le choix de la taille du réseau de neurones (c.-à-d. nombre de couches cachées et nombre de neurones par couche cachée) varie en fonction de l'application ciblée. L'importance de choisir la configuration la plus appropriée du réseau de neurones artificiels, afin d'obtenir les meilleures performances, a été soulignée dans ce rapport.

L'outil utilisé à cette fin est Matlab/Simulink, les bibliothèques « SimPowerSystems » et « Deep Learning Toolbox » ont été exploitées.

Il a été démontré, dans la revue de littérature, que les réseaux de neurones artificiels constituent un outil excellent de détection, classification et localisation précise des défauts des lignes de transmission. La présente étude a également confirmé son application et le fait que de bons résultats de performance peuvent être obtenus.

Le relais intelligent est un composant très utile pour la protection qui permet de donner un support aux ingénieurs qui œuvrent dans la conception et la supervision des lignes de transport d'énergie électrique,

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

- Les modèles neuronaux conçus peuvent être implémentés dans des microchips (microprocesseur) pour créer un système automatisé pour le diagnostic des défauts dans un système réel.
- Grâce à une nouvelle conception de réseau neuronal, ce système de relais intelligent peut être adapté aux situations où il existe des énergies renouvelables intermittentes ou des micro-réseaux.
- Monter un relais intelligent bidirectionnel pour les réseaux électriques,
- Développer un relais intelligent pour les réseaux électriques de basse tension.

Article publié : Alilouch Raghda et Slaoui-Hasnaoui Fouad, "**Intelligent Relay Based on Artificial Neural Networks ANN for Transmission Line**," 2022 IEEE 9th International Conference on Sciences of Electronics, Technologies of Information and Telecommunications (SETIT), 2022, pp. 468-473, doi: 10.1109/SETIT54465.2022.9875449.

Article soumis pour la publication : Alilouch Raghda, Slaoui Hasnaoui Fouad et Georges Semaan, "**Intelligent fault locator and zone isolation for transmission line**" ID 426, Proc. of the International Conference on Electrical, Computer, Communications and Mechatronics Engineering (ICECCME) 16-18 November 2022, Maldives (accepté).

Article en cours de préparation pour publication : Alilouch Raghda, Slaoui Hasnaoui Fouad et Georges Semaan, "**Intelligent relay based on ANN and fault isolator for parallel line**" à publier dans un journal spécialisé.

ANNEXE A

COURBES DES PERFORMANCES ET PARAMÈTRES

Projet 1

- Courbe d'évaluation des modèles neuronal conçus.
- i. Détecteur neuronal
 - a. **Modèle 1 : 6-26-16-1**

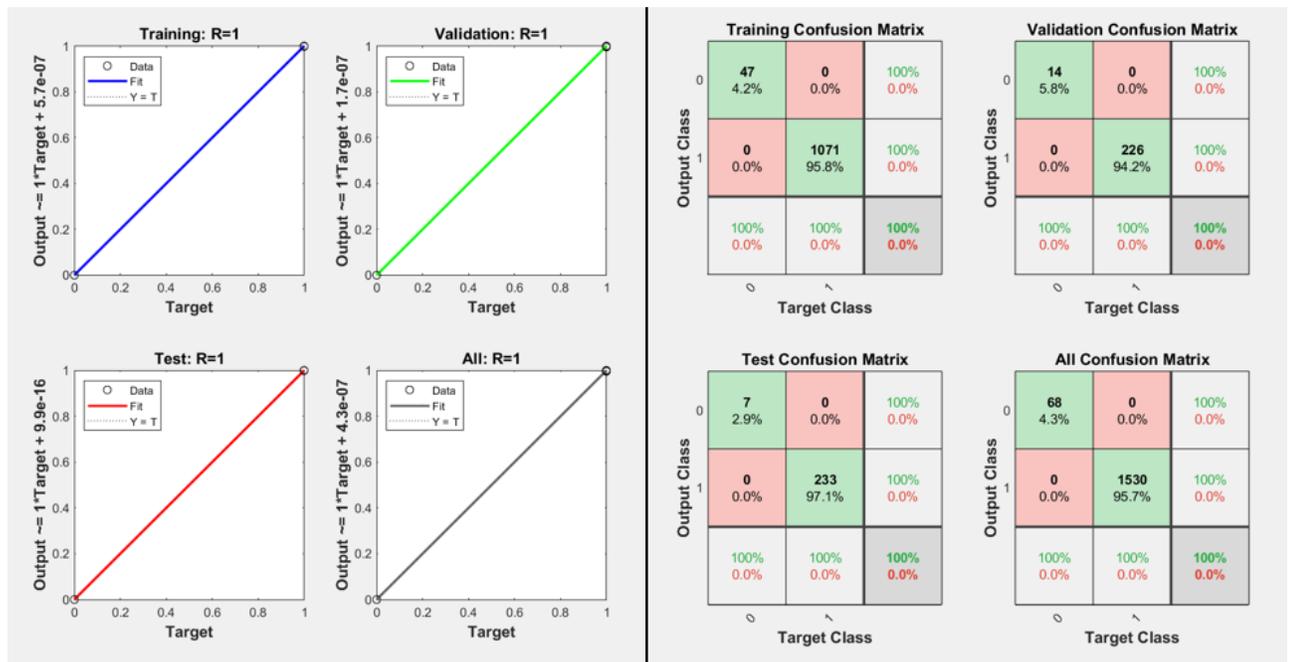


Figure A-1 : Graphe de régression et matrice de confusion pour le détecteur neuronal du modèle 1.

b. **Modèle 2** : 6-30-25-9-1

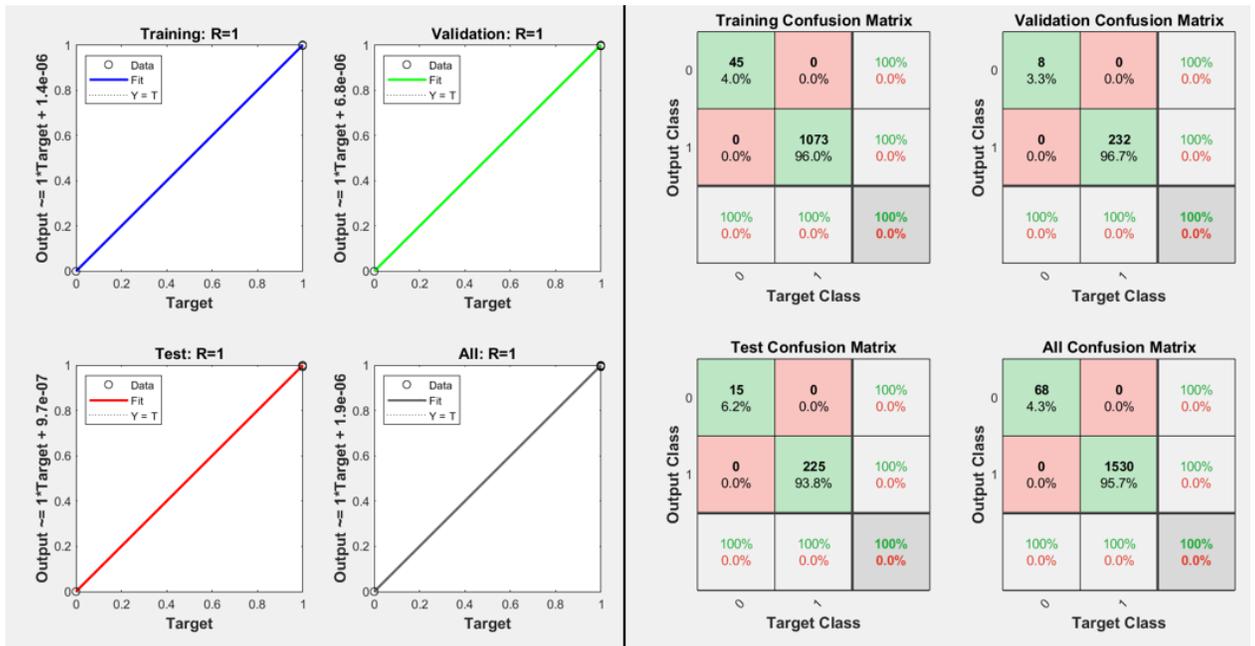


Figure A-2 : Graphe de régression et matrice de confusion pour le détecteur neuronal du modèle 2.

ii. **Classificateur neuronal**

a. **Modèle 1** : 6-16-12-6-4

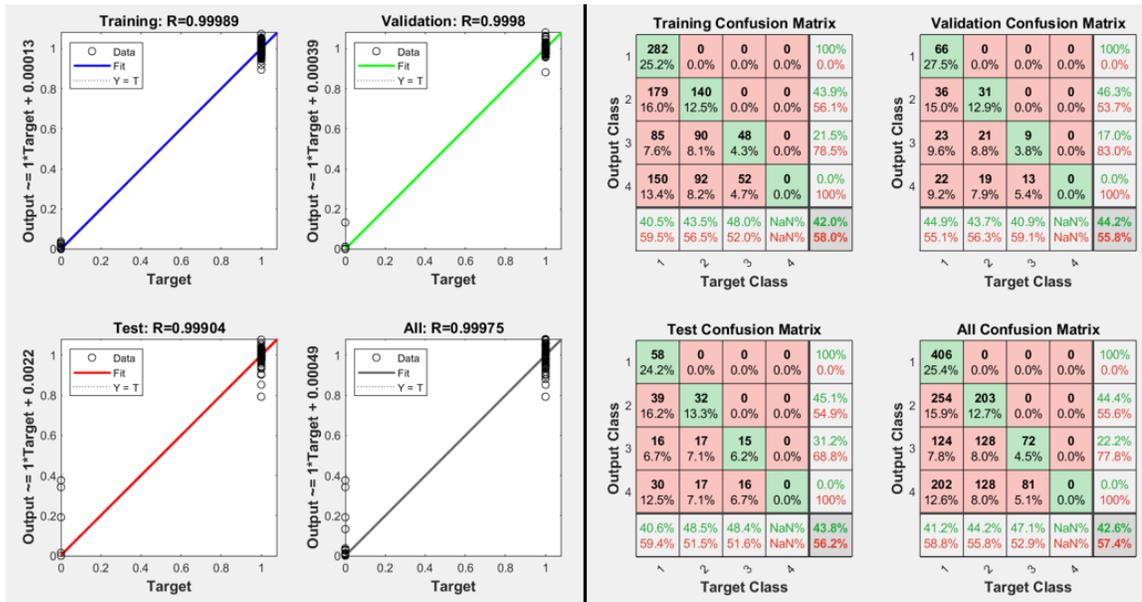


Figure A-3 : Graphe de régression et matrice de confusion pour le détecteur neuronal du modèle 1.

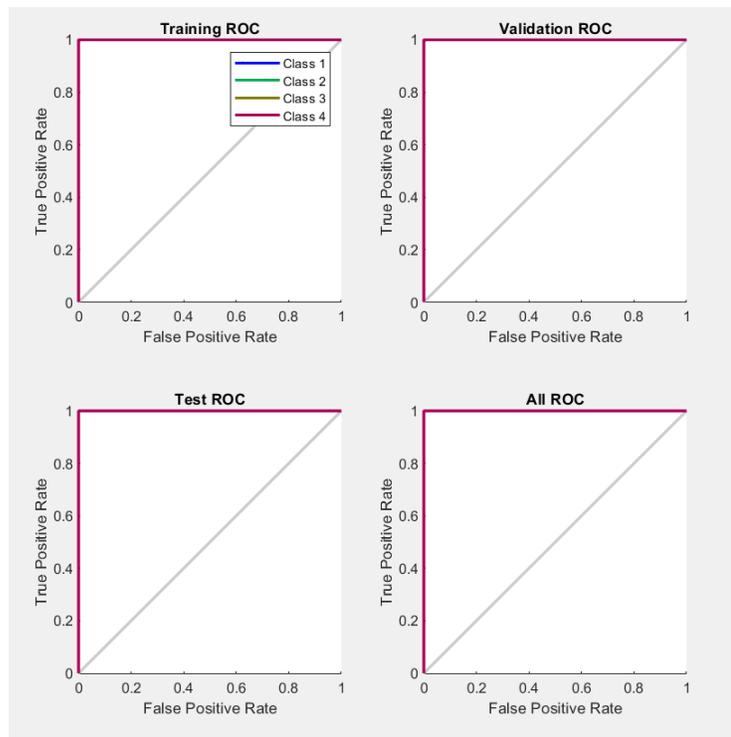


Figure A-4 : La courbe de la fonction d'efficacité du récepteur ROC du modèle 1.

b. Modèle 2 : 6-20-12-4

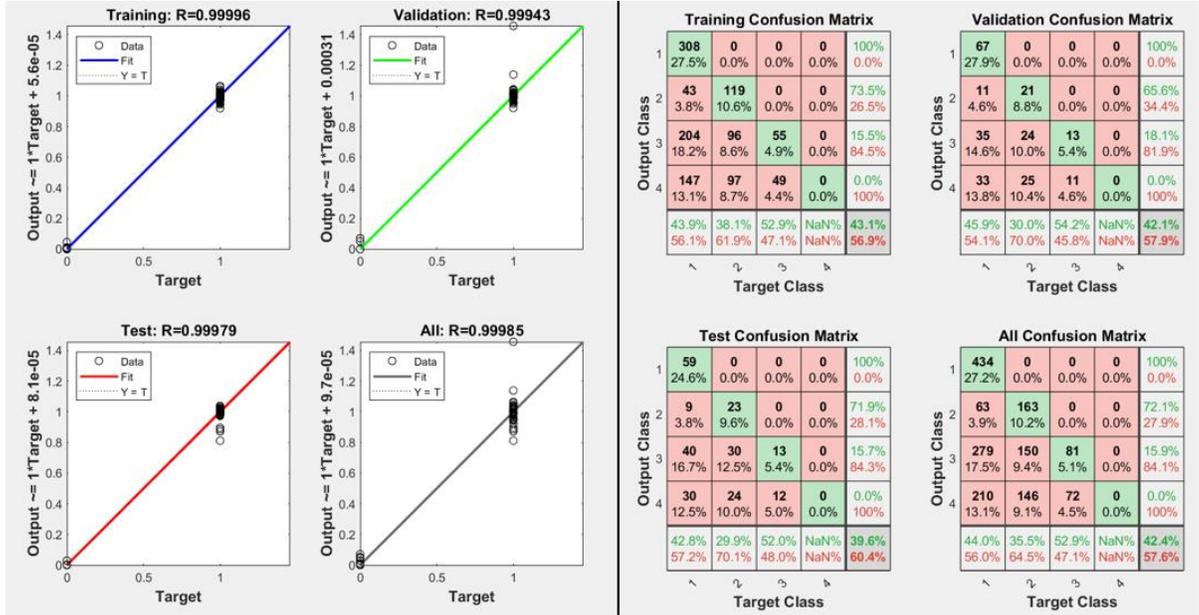


Figure A-5 : Graphe de régression et matrice de confusion pour le détecteur neuronal du modèle 2.

iii. Localisateur neuronal

a. Modèle 1 : 6-30-16-6-3-1.

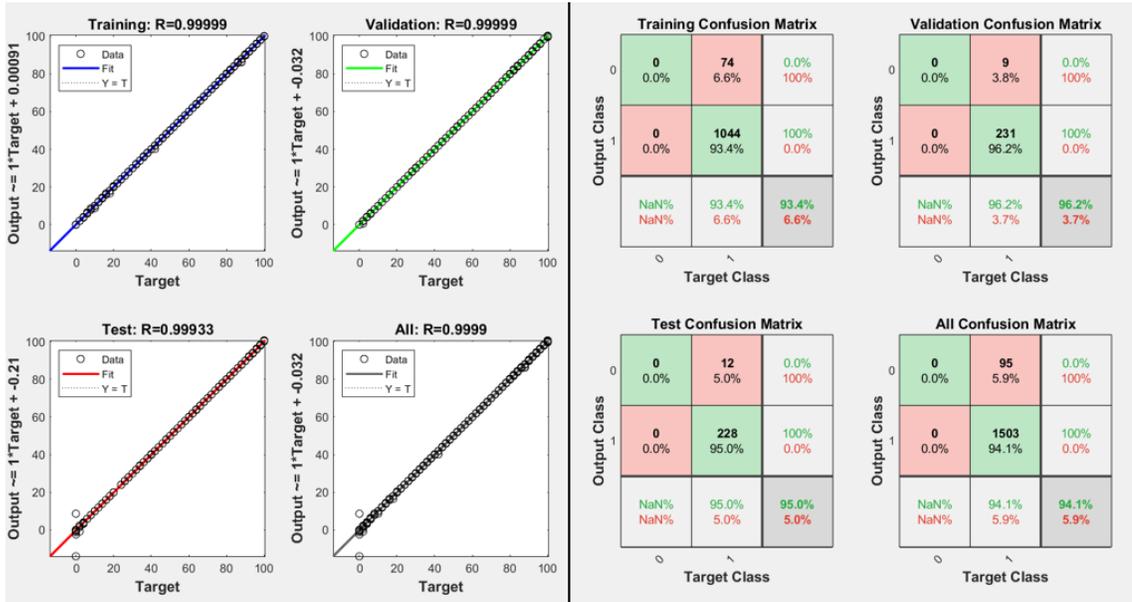


Figure A-6 : Graphe de régression et matrice de confusion pour le détecteur neuronal du modèle 1.

a. Modèle 2 : 6-20-3-1.

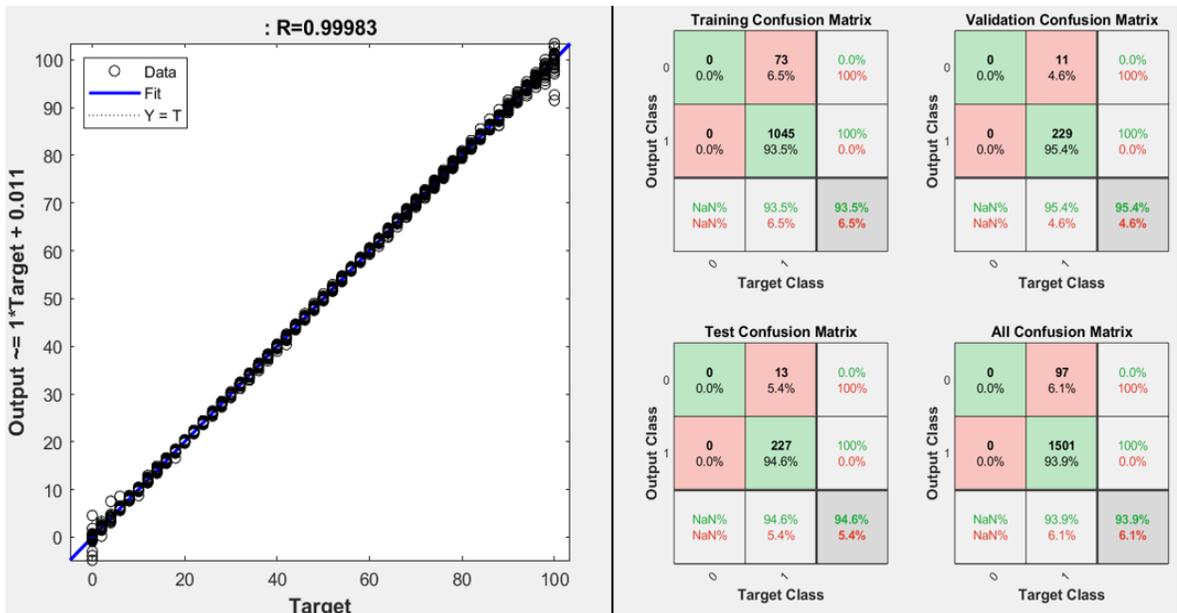


Figure A-7 : Graphe de régression et matrice de confusion pour le détecteur neuronal du modèle 2.

Projet 2

Tableaux des paramètres des composants du réseau électrique.

Tableau A-1 : Paramètres de machine synchrone

Spécifications	Valeurs	
La puissance mécanique fournie à la machine Pm en PU	0.721809 PU	
L'amplitude des tensions internes du bloc E	1.01132 V	
Puissance apparente nominale Pn (VA)	$6 \cdot 350 \cdot 10^6$ VA	
Fréquence fn (Hz)	60 Hz	
Tension efficace ligne à ligne Vn (V).	$13.8 \cdot 10^3$ V	
L'inertie H	Infinie (en seconde)	
Facteur d'amortissement (Kd)	0 (PU de couple)/(PU de vitesse)	
Nombre de paires de pôles (p)	2	
Résistance interne en PU	0.01466	
Réactance interne en PU	0.22	
Conditions initiales	Écart de vitesse initial dw(% de la valeur nominale)	0
	L'angle du rotor (degrés)	1.43122
	L'amplitude du courant de ligne ia,ib,ic en PU	[0.716215 ; 0.716215 ; 0.716215]
	Les angles de phase pha,phb,phc (degrés)	[-3.34575 ; -123.346 ; 116.654]

Tableau A-2 : Paramètres du transformateur.

Spécifications		Valeurs
Puissance et fréquence nominales [Pn(VA) , fn(Hz)]		$[6*350*10^6 , 60]$
Primaire	Configuration	Delta
	Tension nominale phase à phase V1 RMS.	$13.8*10^3$ Vrms
	Résistance	0.002 PU
	Inductance de fuite	0.08 PU
Secondaire	Configuration	Yg
	Tension nominale phase à phase V2 RMS.	$735*10^3$ Vrms
	Résistance	0.002 PU
	Inductance de fuite	0.08 PU
Résistance de magnétisation Rm		500 PU
Inductance de magnétisation Lm		500 PU

Tableau A-3 : Paramètres de lignes.

Spécifications	Valeurs	Unités
Longueur	$L1 = 30 , L2 = 20$	Km
Résistance de séquence positive (système direct)	0.01165	Ω/km
Résistance de séquence zéro (système homopolaire)	0.2676	Ω/km
Inductance de séquence positive	0.8679	mH/km
Inductance homopolaire	3.008	mH/km
Capacité de séquence positive	13.41	nF/km
Capacité de séquence zéro	8.57	nF/km

Tableau A-4 : Paramètres de source triphasé

Spécifications	Valeurs	Unités
Configuration	Yg	
Tension interne phase à phase	$735 * 0.98865 * 10^3$	Vrms
Fréquence	60	Hz
Angle de phase de la phase A	-2.0892	Degré
Niveau de court-circuit triphasé à la tension de base	30	Géga VA
Tension de base	$735 * 10^3$	Vrms
Rapport X/R	10	

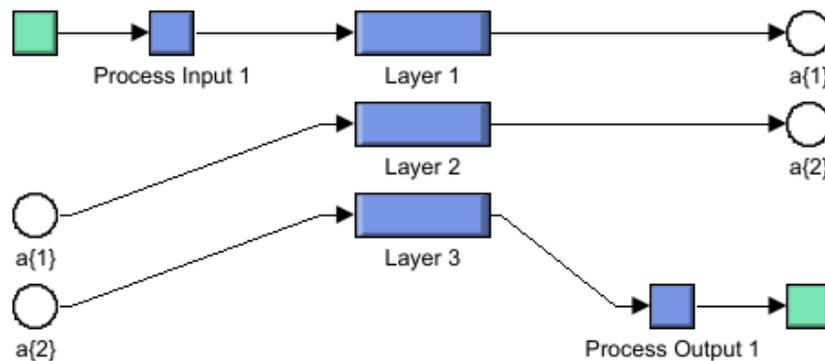


Figure A-9 : Structure du réseau de neurones dans Simulink

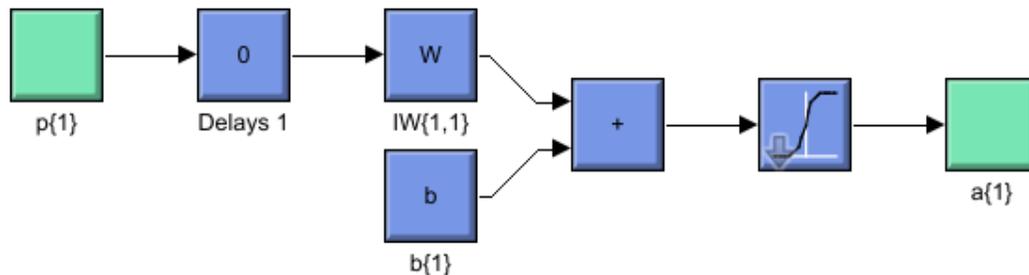


Figure A-10 : Structure d'une couche cachée dans Simulink.

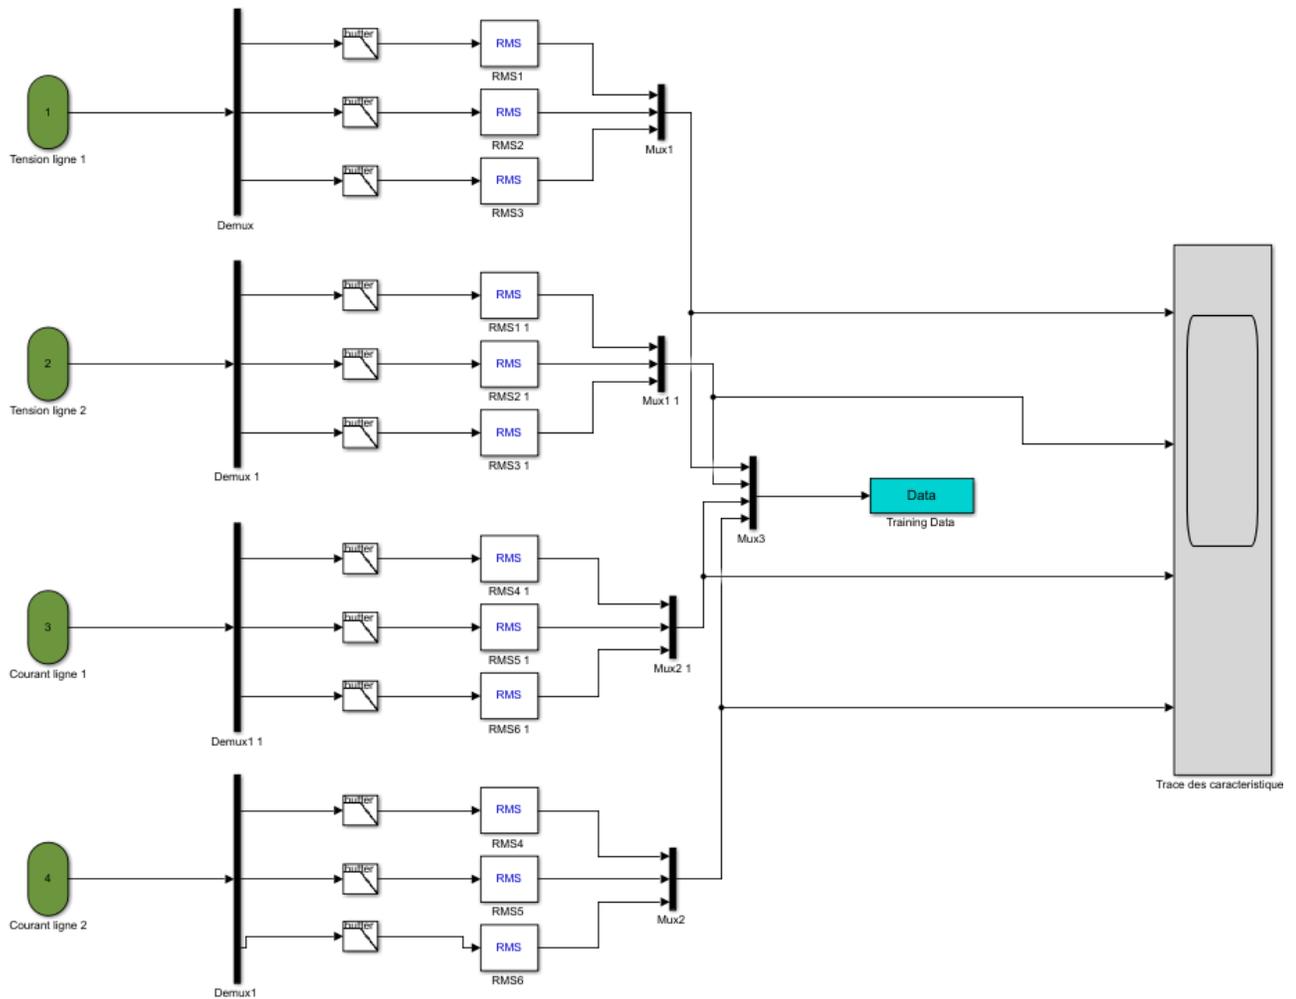


Figure A-8 : Bloc de traitement des signaux et extractions des caractéristiques fondamentales du projet 2.

ANNEXE B

EXPLOITATION DE LA BASE DES DONNÉES

La base des données générée à partir des simulations est élaborée dans le fichier Excel, la figure ci-dessous montre une capture d'écran d'une partie de la base des données pour le projet 1

	A	B	C	D	E	F	G	H	I	J	K	L
1	Va	Vb	Vc	Ia	Ib	Ic	Yd	Ya	Yb	Yc	Yg	Yp
2	0	0	0	0	0	0	0	0	0	0	0	0
3	0.7082	0.7082	0.7082	0.7363	0.7363	0.7363	0	0	0	0	0	0
4	0.6694	0.7082	0.6990	47.7680	1.2078	0.7803	1	1	0	0	1	42
5	0.7027	0.6547	0.7082	1.7450	70.4393	2.6051	1	0	1	0	1	20
6	0.7082	0.6728	0.6401	2.1852	1.7579	81.7845	1	0	0	1	1	32
7	0.4538	0.6342	0.6217	158.3571	149.8915	1.9931	1	1	1	0	1	32
8	0.5605	0.7065	0.5566	177.1720	4.1435	149.4580	1	1	0	1	1	12
9	0.6428	0.5212	0.6538	0.7861	115.9847	109.6329	1	0	1	1	1	50
10	0.5822	0.6358	0.7194	95.9463	95.4407	0.7362	1	1	1	0	0	40
11	0.6825	0.6758	0.5837	73.3230	0.7362	73.3857	1	1	0	1	0	84
12	0.7370	0.5572	0.6035	0.7363	132.8811	132.3232	1	0	1	1	0	20
13	0.5734	0.5734	0.5734	121.3081	121.3054	121.3078	1	1	1	1	0	34

Pour importer cette base dans l'espace du travail « workspace » de MATLAB, on clique sur « Import Data » dans l'onglet « Home », puis on sélectionne le fichier Excel à importer aussi que le type des données « Matrice numérique ».

Après avoir importé la base des données dans l'espace du travail de MATLAB, on crée les matrices des données d'entrée et de sorties désirées, qui vont par la suite être les entrées et les sorties des réseaux de neurones conçus.

BIBLIOGRAPHIE

- [1] J. I. Murari Mohan Saha, Eugeniusz Rosolowski, *Fault Location on Power Networks (Power Systems)*. Springer, 2010.
- [2] M. S. S. R. Sanjay Kumar K, Dr. V. Venkatesh, "Artificial Neural Network Based Method for location and classification of faults on a transmission lines," *International Journal of Scientific and Research Publications*, vol. 4, no. 6, June 2014.
- [3] R. Resmi, V. Vanitha, E. Aravind, B. R. Sundaram, C. R. Aswin, and S. Harithaa, "Detection, Classification and Zone Location of Fault in Transmission Line using Artificial Neural Network," in *2019 IEEE International Conference on Electrical, Computer and Communication Technologies (ICECCT)*, 20-22 Feb. 2019 2019, pp. 1-5.
- [4] C. Pothisarn and A. Ngaopitakkul, "Discrete wavelet transform and back-propagation neural networks algorithm for fault classification on transmission line," in *2009 Transmission & Distribution Conference & Exposition: Asia and Pacific*, 26-30 Oct. 2009 2009, pp. 1-4.
- [5] 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.
- [6] M. Jamil, S. K. Sharma, and R. Singh, "Fault detection and classification in electrical power transmission system using artificial neural network," *SpringerPlus*, vol. 4, no. 1, p. 334, 2015/07/09 2015.
- [7] Z. M. H. A. Y. Hatata , S. S. Eskander, "Transmission Line Protection Scheme for Fault Detection, Classification and Location Using ANN," *International journal of Modern Engineering Research (IJMER)*, vol. 6, no. 8, 2016.
- [8] K. Chen, C. Huang, and J. He, "Fault detection, classification and location for transmission lines and distribution systems: a review on the methods," *High Voltage*, vol. 1, no. 1, pp. 25-33, 2016.
- [9] S. Ekici, S. Yildirim, and M. Poyraz, "A transmission line fault locator based on Elman recurrent networks," *Applied Soft Computing*, vol. 9, no. 1, pp. 341-347, 2009/01/01/ 2009.
- [10] E. Koley, A. Jain, A. S. 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 (ICCCT-2011)*, 15-17 Sept. 2011 2011, pp. 100-103.
- [11] M. F. M. Othman, M.; Linkens, D.A., "Transmission lines fault detection, classification and location using an intelligent power system stabiliser," in

- Proceedings of the 2004 IEEE International Conference, pp. 360-365 Vol.1, , April 2004.
- [12] T. Dhadbanjan, U. J. Shenoy, and H. Ashageetha, Neural Network Approach for Fault Location in Unbalanced Distribution Networks with Limited Measurements. 2006, p. 8 pp.
- [13] S. Das, S. Santoso, A. Gaikwad, and M. Patel, "Impedance-based Fault Location in Transmission Networks: Theory and Application," IEEE Access, vol. 2, pp. 1-1, 01/01 2014.
- [14] J. Mora-Flòrez, J. Meléndez, and G. Carrillo-Caicedo, "Comparison of impedance based fault location methods for power distribution systems," Electric Power Systems Research, vol. 78, no. 4, pp. 657-666, 2008/04/01/ 2008.
- [15] K. Zimmerman and D. Costello, "Impedance-based fault location experience," in 58th Annual Conference for Protective Relay Engineers, 2005., 5-7 April 2005 2005, pp. 211-226.
- [16] L. Aoyu, X. Dong, S. Shi, and W. Bin, "A novel current travelling wave based single-ended fault location method for locating single-phase-to-ground fault of transmission line," in 2015 50th International Universities Power Engineering Conference (UPEC), 1-4 Sept. 2015 2015, pp. 1-6, doi: 10.1109/UPEC.2015.7339950.
- [17] G. Ma, L. Jiang, K. Zhou, and G. Xu, "A Method of Line Fault Location Based on Traveling Wave Theory," International Journal of Control and Automation, vol. 9, pp. 261-270, 02/28 2016.
- [18] P. S. 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.
- [19] M. Geethanjali and K. S. priya, "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, 4-6 June 2009 2009, pp. 1-7.
- [20] 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.
- [21] P. Nonyane, "The Application of Artificial Neural Networks to Transmission Line Fault Detection and Diagnosis," Master, University of South Africa, 2016.
- [22] A. Oonsivilai and S. Saichoomdee, "Appliance of recurrent neural network toward distance transmission lines protection," in TENCON 2009 - 2009 IEEE Region 10 Conference, 23-26 Jan. 2009 2009, pp. 1-4.
- [23] L. Teklić, B. Filipović-Grčić, and I. Pavičić, Artificial Neural Network Approach for Locating Faults in Power Transmission System. 2013.

- [24] S. Vasilic and M. Kezunovic, "Fuzzy ART neural network algorithm for classifying the power system faults," *IEEE Transactions on Power Delivery*, vol. 20, no. 2, pp. 1306-1314, 2005.
- [25] N. Zhang and M. Kezunovic, "Transmission Line Boundary Protection Using Wavelet Transform and Neural Network," *IEEE Transactions on Power Delivery*, vol. 22, no. 2, pp. 859-869, 2007.
- [26] 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)*, 2-4 July 2019 2019, pp. 1-6, doi: 10.1109/ICCAD46983.2019.9037950.
- [27] A. Isa and C. Sourkounis, "Development of Artificial Neural Network and Adaptive Neuro-Fuzzy Inference System Based Techniques and Algorithms for Protection of Transmission Line," in *IECON 2019 - 45th Annual Conference of the IEEE Industrial Electronics Society*, 14-17 Oct. 2019 2019, vol. 1, pp. 2144-2147, doi: 10.1109/IECON.2019.8927811.
- [28] C. Liu, F. Zhuo, and F. Wang, "Fault Diagnosis of Commutation Failure Using Wavelet Transform and Wavelet Neural Network in HVDC Transmission System," *IEEE Transactions on Instrumentation and Measurement*, vol. 70, 2021, doi: 10.1109/TIM.2021.3115574.
- [29] H. Kaur and M. Kaur, "Fault Classification in a Transmission Line Using Levenberg Marquardt Algorithm Based Artificial Neural Network," *Advances in Intelligent Systems and Computing*, 2019.
- [30] A. P. V. T. Rishmek C. Kachhadiya "DETECTION AND CLASSIFICATION OF FAULTS FOR ELECTRICAL TRANSMISSION LINE USING ANN," *International Journal For Technological Research In Engineering*, vol. 3, no. 9, 2016.
- [31] B. B. R. Chothani N.G, Desai A. K, A, "New Algorithm for Coordination of Relay and Auto-Reclosure in 220 kV Transmission System," presented at the Annual IEEE India Conference,, Dec 2013.
- [32] A. S. Shaeboub A, Hu N, Gu F,, "Detection and diagnosis of motor stator faults using electric signals from variable speed drives," presented at the Automation and Computing 21st International Conference, 2015.
- [33] N. D. Tleis, *Power systems modelling and fault analysis : theory and practice*, Amsterdam ;: Elsevier/Newnes, 2008.
- [34] "IEEE Recommended Practice for Protection and Coordination of Industrial and Commercial Power Systems (IEEE Buff Book)," *IEEE Std 242-2001 (Revision of IEEE Std 242-1986) [IEEE Buff Book]*, pp. 1-710, 2001.
- [35] K.-P. Brand and I. De Mesmaeker, "Power System Protection," in *Handbook of Electrical Power System Dynamics: John Wiley and Sons, Inc.*, 2013, pp. 737-785.
- [36] S. H. Horowitz and A. G. Phadke, *Power System Relaying* (no. 1). Wiley/Research Studies Press, , 2008, pp. 115-118.

- [37] A. J. Ebha K, Thoke A.S, Abhinav J, Subhojit G,, "Detection and Classification of Faults on Six Phase Transmission Line Using ANN," presented at the International Conference on Computer & Communication Technology, 2011.
- [38] A. Yadav and Y. Dash, "An Overview of Transmission Line Protection by Artificial Neural Network: Fault Detection, Fault Classification, Fault Location, and Fault Direction Discrimination," *Advances in Artificial Neural Systems*, vol. 2014, p. 230382, 2014/12/28 2014.
- [39] R. R. Samii, H. Raoufi, and N. Moslemi, "Effect of two-circuit lines on unbalanced distribution systems," 16th Electrical Power Distribution Conference, pp. 1-5, 2011.
- [40] H. Kunlun, C. Zexiang, and L. Yang, "Study on protective performance of HVDC transmission line protection with different types of line fault," 07/01 2011.
- [41] V. N. Vapnik, "An overview of statistical learning theory," *IEEE Transactions on Neural Networks*, vol. 10, no. 5, pp. 988-999, 1999.
- [42] D. Sharples, V. Asaro, M. Pozzuoli, and B. Kasztenny, *DISTANCE RELAYS AND CAPACITIVE VOLTAGE TRANSFORMERS BALANCING SPEED AND TRANSIENT OVERREACH* (presentation). 2018.
- [43] O. E. Obi, O. A. Ezechukwu, and C. N. Ezema, "Enhanced Real Time and Off-Line Transmission Line Fault Diagnosis Using Artificial Intelligence," *Asian Journal of Computing and Engineering Technology*, no. 1, pp. 1-22%V 1, 2016-12-15 2016.
- [44] K. Moloji, Y. Hamam, and J. A. Jordaan, "Fault Pattern Recognition in Power Distribution Integrated Network with Renewable Energy Source," in 2020 5th International Conference on Renewable Energies for Developing Countries (REDEC), 29-30 June 2020 2020, pp. 1-6.
- [45] E. Rosolowski, P. Balcerek, M. M. Saha, J. Izykowski, and P. Pierz, "A New Method of Selection Between Faulty and Healthy Circuits in Series Compensated Parallel Lines with Use of One-End Current Measurements. 2016, pp. 7.-7 .
- [46] P. Pierz, M. M. Saha, E. Rosolowski, J. Izykowski, and P. Balcerek, "Fault location on double-circuit transmission line with series capacitor compensation at both ends. 2014, pp. 6.2.1-6.2.1.
- [47] M. Saha, J. Izykowski, and E. Rosolowski, "Fault Location on Power Networks," 2009.
- [48] "IEEE Guide for Determining Fault Location on AC Transmission and Distribution Lines," *IEEE Std C37.114-2014* (Revision of IEEE Std C37.114-2004), pp. 1-76, 2015.
- [49] M. Silva, M. Oleskovicz, and D. V. Coury, "A fault locator for transmission lines using traveling waves and wavelet transform theory. 2004, pp. 212-215 Vol.1.
- [50] M. Tolun, S. Sahin, and K. Oztoprak, "Expert Systems," 2016.

- [51] H. Kumamoto, K. Ikenchi, K. Inoue, and E. J. Henley, "Application of expert system techniques to fault diagnosis," *The Chemical Engineering Journal*, vol. 29, no. 1, pp. 1-9, 1984/08/01/ 1984.
- [52] C. J. Kim and B. d. Russell, "Classification of faults and switching events by inductive reasoning and expert system methodology," *IEEE Transactions on Power Delivery*, vol. 4, no. 3, pp. 1631-1637, 1989.
- [53] W. W. L. Keerthipala, W. Huisheng, and W. Chan Tat, "On-line testing of a fuzzy-neuro based protective relay using a real-time digital simulator," in *2000 IEEE Power Engineering Society Winter Meeting. Conference Proceedings (Cat. No.00CH37077)*, 23-27 Jan. 2000 2000, vol. 3, pp. 1917-1922 vol.3.
- [54] M. Oleskovicz, D. V. Coury, and R. K. Aggarwal, "A complete scheme for fault detection, classification and location in transmission lines using neural networks," in *2001 Seventh International Conference on Developments in Power System Protection (IEE)*, 9-12 April 2001 2001, pp. 335-338, doi: 10.1049/cp:20010168.
- [55] M. Sanaye-Pasand and H. Khorashadi-Zadeh, "Transmission Line Fault Detection & Phase Selection using ANN," 01/01 2003.
- [56] T. S. Dillon and D. Niebur, "Neural networks applications in power systems," 1996.
- [57] K. Suzuki, *ARTIFICIAL NEURAL NETWORKS – ARCHITECTURES AND APPLICATIONS*. 2013.
- [58] R. Dubey, S. Samantaray, and B. Panigrahi, "An Extreme Learning Machine based Fast and Accurate Adaptive Distance Relaying Scheme," *International Journal of Electrical Power & Energy Systems*, vol. 73, pp. 1002-1014, 07/07 2015.
- [59] P. Gupta and R. N. Mahanty, "Artificial Neural Network based Fault Classifier and Locator for Transmission Line Protection," 2016, vol. 11, no. Issue 04 (April 2015)

International Journal of Engineering Research and Development.

- [60] Y. Menchafou, Z. Mustapha, M. Habibi, and H. El Markhi, "Nouvelle méthode de localisation des défauts dans les systèmes de distribution de l'énergie électrique," presented at the Conference: The Fifth Workshop on Information technologies and CommunicationAt: Faculty of Dher El Mahraz, Fez, Morocco, 2013.
- [61] M. H. B. Howard B.Demuth, Martin T.Hagan, *Deep Learning Toolbox™, User's guide*. The MathWorks, 2021.
- [62] N. G. K, J. Raj, and L. R. Chandran, "Transmission Line Monitoring and Protection with ANN aided Fault Detection, Classification and Location," in *2021 2nd International Conference on Smart Electronics and Communication (ICOSEC)*, 7-9 Oct. 2021 2021, pp. 883-889, doi: 10.1109/ICOSEC51865.2021.9591911.

- [63] M. R. Bishal, S. Ahmed, N. M. Molla, K. M. Mamun, A. Rahman, and M. A. A. Hysam, "ANN Based Fault Detection & Classification in Power System Transmission line," in 2021 International Conference on Science & Contemporary Technologies (ICSCT), 5-7 Aug. 2021 2021, pp. 1-4, doi: 10.1109/ICSCT53883.2021.9642410.
- [64] N. A. M. Leh, F. M. Zain, Z. Muhammad, S. A. Hamid, and A. D. Rosli, "Fault Detection Method Using ANN for Power Transmission Line," in 2020 10th IEEE International Conference on Control System, Computing and Engineering (ICCSCE), 21-22 Aug. 2020 2020, pp. 79-84, doi: 10.1109/ICCSCE50387.2020.9204921.
- [65] S. Upadhyay, S. R. Kapoor, and R. Choudhary, "Fault Classification and Detection in Transmission Lines Using ANN," in 2018 International Conference on Inventive Research in Computing Applications (ICIRCA), 11-12 July 2018 2018, pp. 1029-1034, doi: 10.1109/ICIRCA.2018.8597294.