

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Ecole Nationale Polytechnique

DEPARTEMENT : GENIE ELECTRIQUE

SPECIALITE : ELECTROTECHNIQUE



Mémoire de fin d'études
En vue de l'obtention du diplôme
D'Ingénieur d'Etat

Thème :

DETECTION, CLASSIFICATION ET
LOCALISATION DES DEFAUTS DANS
LES RESEAUX PAR LES TECHNIQUES
INTELLIGENTES

Proposé et dirigé par :

Dr.Mohamed BOUDOUR

Etudié par :

Karim GUENIFI

Raouf DIREM

Promotion JUIN 2006

Remerciement

*Nous remercions en premier lieu notre dieu de nous donner
La santé et la patience
pour avoir terminer ce travail.*

*Nous remercions particulièrement notre promoteur
Dr. Mohamed Boudour pour nous avoir suivi et soutenu pour
réaliser ce travail. Nous lui exprimons notre gratitude pour sa
disponibilité, ces précieux conseils et pour le soutien qu'il nous
est apportés tout au long de la préparation de ce mémoire.*

*Nos vifs remerciements vont à Monsieur le Président, pour
l'honneur qu'il nous fait et aux membres du jury pour avoir
accepté de corriger et d'évaluer ce travail.*

*Nous tenons également à remercier à tous ceux qui ont participé
de près ou de loin à l'élaboration de ce travail*

*Que tous les professeurs ayant contribué à notre formation
trouvent ici notre profonde reconnaissance*

Karim Guenifi

Raouf Direm

Dédicaces

*Je dédie ce travail à mon père et ma mère à mes frères
et mes sœurs,*

ainsi qu'à mon binôme Karim à toute

la famille 'Direm' et 'Guénifi', à mes amis

et enfin à mes petits :

Imen, Hannane, Mohsen

Et surtout à

la belle Nour El Houda

Raouf

Dédicaces

Je dédie ce travail à mon père et ma mère

et ma sœurs et à toute

la famille

ainsi qu'à mon binôme Raouf , à toute

la famille 'Guenifi et 'Direm', et à tout mes amis.

Karim

Liste des figures

Figure	page
I.1 Schéma fonctionnel d'une protection électrique	3
I.2 Commande de l'ouverture d'un disjoncteur	5
I.3 Schéma bloc des méthodes utilisées dans l'analyse des défauts	7
I.4 Schéma équivalent d'une ligne en défaut	10
I.5 Schéma équivalent d'une ligne triphasée en défaut	15
II.1 Ligne triphasée à deux extrémités avec un défaut en point F	21
II.2 Le schéma monophasé du réseau étudié	22
II.3 Schéma bloc utilisé dans la simulation	23
II.4 Courants $I_a(t), I_b(t), I_c(t)$ à l'état sain	24
II.5 Tensions $V_a(t), V_b(t), V_c(t)$ à l'état sain	24
II.6 Courants $I_a(t), I_b(t), I_c(t)$ en défaut monophasé	25
II.7 Tensions $V_a(t), V_b(t), V_c(t)$ en défaut monophasé	25
II.8 Courants $I_a(t), I_b(t), I_c(t)$ en défaut biphasé	26
II.9 Tensions $V_a(t), V_b(t), V_c(t)$ en défaut biphasé	26
II.10 Courants $I_a(t), I_b(t), I_c(t)$ en défaut triphasé	27
II.11 Tensions $V_a(t), V_b(t), V_c(t)$ en défaut triphasé	27
II.12 Procédure utilisée	28
III.1 Modèle de neurone formel, selon Mc Culloch et Pitts	32
III.2 Perceptron à trois couches	33
III.3 Schéma bloc des trois ANN utilisés dans le Simulink	43
IV.1 Organigramme d'un Algorithme Evolutionnaire	46
IV.2 Chromosome en codage binaire	47
IV.3 Schéma bloc de étapes suivies dans la création des GA	50
IV.4 Schéma bloc utilisé dans la simulation des GANN	58

Liste des Tableaux

Tableau	page
II.1 Résultats de la technique de Fourier	29
II.2 Résultats de la technique de moindres carrés	29
II.1 Erreurs quadratiques moyennes coefficients de corrélation	39
III.2 Résultats de phase de test pour l'ANN de détection	40
III.3 Résultats de phase de test pour l'ANN de classification	40
III.4 Résultats de phase de test pour l'ANN de localisation	41
III.5 Résultats de phase de généralisation pour l'ANN de détection	41
III.6 Résultats de phase généralisation pour l'ANN de classification	42
III.7 Résultats de phase de généralisation pour la localisation	42
II.8 Résultats bloc-ANN	43
IV.1 Les meilleurs individus pour le GA de détection	51
IV.2 Les meilleurs individus pour l'GA de classification	52
IV.3 Les meilleurs individus pour l'GA de localisation	53
IV.4 Phase de test de GANN pour la détection	55
IV.5 Phase de test de GANN pour la classification	55
IV.6 Phase de test de GANN pour la localisation	55
IV.7 Phase de généralisation de GANN pour la détection	56
IV.8 Phase de généralisation de GANN pour la classification	56
IV.9 Phase de généralisation de GANN pour la localisation	57
IV.10 Résultats Bloc-GANN	58

Liste des Symboles et Acronymes

Symboles	ACRONYMES
V_a, V_b, V_c	Les tensions des trois phases a, b et c.
V_{abc1}, V_{abc2}	Vecteur tension de l'extrémité 1 et 2.
V_{fabc}	Vecteur tension de défaut des trois phases a, b et c.
$V_{d(1,2)}, V_{i(1,2)}, V_{h(1,2)}$	Tensions des séquences, directe, inverse et homopolaire, de l'extrémité 1 ou 2.
$I_{d(1,2)}, I_{i(1,2)}, I_{h(1,2)}$	Courants des séquences, directe, inverse et homopolaire, de l'extrémité 1 ou 2.
$\varphi_{Vd(1,2)}, \varphi_{Vi(1,2)}, \varphi_{Vh(1,2)}$	Phases des tensions des séquences, directe, inverse et homopolaire, de l'extrémité 1 ou 2.
$\varphi_{Id(1,2)}, \varphi_{Ii(1,2)}, \varphi_{Ih(1,2)}$	Phases des courants des séquences, directe, inverse et homopolaire, de l'extrémité 1 ou 2.
L	Longueur de la ligne.
x	Distance du défaut.
R_f	Résistance du défaut.
ANN	Réseau neurone artificiel.
GA	Algorithme génétique.
GANN	Réseau neurone artificiel optimisé avec les GA.
S_B	Puissance apparente de base
U_B	Tension de base.
N	Nombre d'échantillons.
ω	Vitesse angulaire.
[pu]	per unit (unité relative).

INTRODUCTION GENERALE.....1**CHAPITRE I *Techniques d'analyse des défauts***

I.1 Introduction	3
I.2 Généralités sur la protection électrique	3
I.2.1 Rôle de la protection électrique	3
I.2.2 Schéma fonctionnel d'une protection électrique	3
I.2.3 Les éléments les plus importants dans une protection électrique	4
I.2.3.1 Relais	4
I.2.3.2 Disjoncteur	4
I.2.4 Qualités que doit présenter un système de protection	4
I.2.5 grandeurs utilisées dans la détection des défauts	5
I.2.6 types de protection des lignes	5
I.2.6.1 Protection par fonction	6
I.2.6.1.1 Protection par relais différentiel	6
I.2.6.1.2 Protection par relais de comparaison de phase	6
I.2.6.1.3 protection par relais ampèremétrique (ou de surintensité)	6
I.2.6.1.4 Protection par relais de distance	6
I.2.6.2 Protection par technologie	6
I.2.6.2.1 Protection électromécanique	6
I.2.6.2.2 Protection électronique (ou statique)	6
I.2.6.2.3 Protection numérique	7
I.3 Méthodes utilisées dans l'analyse des défauts	7
I.3.1 Méthodes utilisées dans la détection	7
I.3.2 Méthodes utilisées dans la classification	8
I.3.3 Méthodes de localisation des défauts	8
I.3.3.1 Méthode des phaseurs	9
I.3.3.1.1 Méthodes numériques d'estimation des phaseurs	9
I.3.3.1.2 Algorithmes de localisation basés sur les données d'une extrémité....	10
I.3.3.1.3 Algorithmes de localisation basés sur les données de deux extrémités.	11
I.3.3.2 Méthode des équations différentielles	13
I.3.3.2.1 Modèle à paramètres concentrés (lumped parameter model)	13
I.3.3.2.2 Modèle à paramètres distribués (distributed parameter model)	14
I.3.3.3 Méthode de propagation des ondes	15
I.4 Conclusion.....	16

CHAPITRE II *Estimation des phaseurs et localisation des défauts*

II.1 Introduction	17
II.2 Estimation des phaseurs	17
II.2.1 Analyse de Fourier	17
II.2.2 La méthode des moindres carrés	17
II.3 Localisation des défauts par les phaseurs	20
II.4 Application de l'algorithme sur un réseau de transport	22
II.4.1 Résultats de simulation du réseau en état sain	24
II.4.2 Résultats de simulation du réseau en défaut.....	25
II.4.2.1 Défaut monophasé (A-terre)	25

II.4.2.2 Défaut biphasé (A-B-terre)	26
II.4.2.3 Défaut triphasé (A-B-C-terre)	27
II.4.3 Résultats de l'algorithme de localisation	28
II.4.4 Interprétation des résultats	29
II.5 Conclusion.....	30

CHAPITRE III *Application des réseaux de neurones*

III.1 Introduction.....	31
III.2 Réseaux de neurones artificiels	31
III.2.1 Définition	31
III.2.2 Neurones formels	31
III.2.3 Architecture	32
III.2.4 Grands types de réseaux	33
III.2.4.1 Perceptrons multicouches.....	33
III.2.4.2 Réseaux de Kohonen.....	33
III.2.4.2.1 VQ (Vector Quantization).....	34
III.2.4.2.2 SOM (Self Organizing Map).....	34
III.2.4.2.3 LVQ (Learning Vector Quantization).....	34
III.2.4.3 Réseaux de Hopfield.....	34
III.2.4.4 Réseaux à Résonance Adaptative (ART).....	34
III.2.4.5 Réseau à fonction radiale (RBF).....	34
III.2.5 Etapes de la conception d'un réseau de neurone	35
III.2.5.1 Choix et préparation des échantillons	35
III.2.5.2 Elaboration de la structure du réseau	35
III.2.5.3 Apprentissage	35
III.2.5.4 Validation et tests de généralisation	35
III.3 Application de ANN dans la protection numérique.....	36
III.4 Application de ANN sur notre modèle.....	36
III.4.1 Génération d'ensemble d'apprentissage	37
III.4.1.1 Ensemble d'apprentissage utilisé pour la détection.....	37
III.4.1.2 Ensemble d'apprentissage utilisé pour la classification.....	37
III.4.1.3 Ensemble d'apprentissage utilisé pour la localisation.....	38
III.4.2 Conception du réseau de neurones.....	38
III.4.3 Phase de test.....	40
III.4.4 Phase de généralisation	41
III.4.5 Interprétation des résultats.....	42
III.4.6 Implantation dans Simulink.....	42
III.5 Conclusion.....	44

CHAPITRE IV *Optimisation des ANN par les GA*

IV.1 Introduction	45
IV.2 Principe des algorithmes génétiques	45
IV.3 Etapes d'un algorithme génétique	47
IV.3.1 Codage des chromosomes	47
IV.3.2 Initialisation de la population	47
IV.3.3 Fonction d'évaluation	47

SOMMAIRE

IV.3.4 Méthodes de sélection	48
IV.3.5 Opérateurs génétiques de reproduction	48
IV.4 Choix des paramètres d'un algorithme génétique	48
IV.5 Applications de l'algorithme génétique dans la protection électrique	48
IV.6 Application des GA pour optimiser les entrées des ANN.....	49
IV.6.1 Création des GA	49
IV.6.1.1 Génération d'une population initiale.....	49
IV.6.1.2 Codages des individus.....	49
IV.6.1.3 Evaluation de la fonction d'adaptation.....	49
IV.6.1.4 Sélection.....	50
IV.6.1.5 Croisement	50
IV.6.1.6 Critère d'arrêt.....	50
IV.6.2 Résultats de programmation.....	50
IV.6.3 Phase de test	54
IV.6.4 Phase de généralisation	56
IV.6.5 Interprétation des résultats.....	57
IV.6.6 Implantation dans Simulink.....	57
IV.7 Conclusion	59
CONCLUSION GENERALE.....	60
REFERENCES BIBLIOGRAPHIQUE.....	62

Introduction générale

Les investissements humains et matériels affectés aux réseaux électriques sont énormes. Pour cela, le réseau électrique doit répondre à trois exigences essentielles : stabilité, économie et surtout continuité du service.

Les lignes de transport d'énergie électrique constituent une partie essentielle d'un réseau électrique qui doit assurer la continuité de l'alimentation en électricité aux consommateurs. Ce qui n'est pas toujours le cas, car ces lignes de transport sont souvent exposés à des incidents ou défauts qui peuvent interrompre ce service et engendrer des pertes financières importantes pour les industriels et des désagréments pour les simples consommateurs.

La majorité des défauts sont dus à des courts-circuits causés souvent par la foudre, la pluie ou les surtensions créées par l'ouverture et la fermeture des disjoncteurs. Ces courts-circuits pouvant être permanents, il est ainsi nécessaire de les détecter et localiser avec précision pour réparer et restaurer l'alimentation dès que possible. C'est pour cela que l'on utilise des dispositifs de protection qui assurent le bon fonctionnement des lignes de transports [4].

Depuis l'entrée sur le marché des relais numériques programmables ces quinze dernières années pour la protection électrique, plusieurs algorithmes ont été développés afin de rendre ces relais plus performants aussi bien sur leur rapidité de fonctionnement que sur leur précision.

Depuis quelques années, l'application des systèmes intelligents à la protection numérique tels les réseaux de neurones artificiels (ANN), l'algorithme génétique (GA),... a connu un intérêt particulier par les chercheurs, aussi bien dans l'université que dans l'industrie [12,20].

Notre travail traite de l'application de deux méthodes intelligentes : ANN et GA pour l'analyse des défauts (Détection, Classification et Localisation) survenant dans les lignes de transport d'énergie électrique [13].

Le premier chapitre définira les concepts de base relatifs à la protection et les différentes méthodes utilisées dans l'analyse des défauts survenant dans les lignes de transports électriques.

Le deuxième chapitre portera sur la simulation et la programmation des défauts par un algorithme conventionnel qui est celui des moindres carrés pour l'estimation des phaseurs.

Dans le troisième chapitre, les réseaux de neurones artificiels sont utilisés pour la détection, la classification et la localisation des défauts moyennant la base de données déterminée dans le deuxième chapitre.

Finalement, l'algorithme génétique est utilisé dans le quatrième chapitre pour optimiser le choix des variables d'état représentant les entrées des réseaux de neurones construits préalablement.

Nous terminerons ce travail par une conclusion générale résumant les principaux résultats obtenus et les perspectives pour les travaux ultérieurs.

I.1 Introduction

Avant d'aborder les différentes méthodes utilisées dans l'analyse des défauts qui apparaissent sur les lignes de transport d'énergie électrique, nous allons définir les principaux concepts de la protection électrique.

I.2 Généralités sur la protection électrique

I.2.1 Rôle de la protection électrique

Lorsqu'un défaut ou une perturbation se produit sur un réseau électrique, il est indispensable de mettre hors tension l'élément ou la partie du réseau en défaut à l'aide des dispositifs de protection. Ces derniers auront pour rôle de limiter les dégâts causés par l'arc électrique, et d'éviter les répercussions du défaut sur le fonctionnement normal de réseau [1].

I.2.2 Schéma fonctionnel d'une protection électrique

La protection électrique par relais est destinée à débrancher l'élément endommagé dans le système électrique et à signaler l'apparition des régimes de fonctionnement anormaux des éléments du réseau. La protection électrique agit comme un système autonome installé sur les éléments du réseau (lignes, transformateurs,...etc.) et schématisé par la Figure I.1.

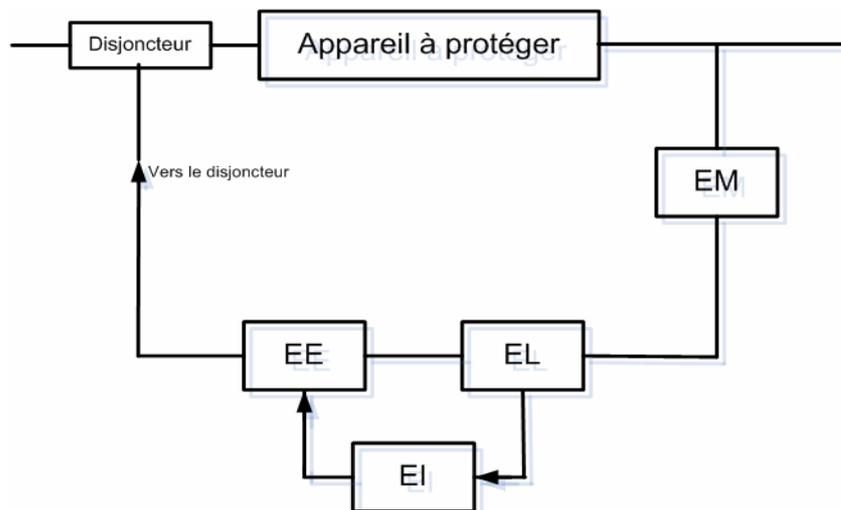


Figure I.1 Schéma fonctionnel d'une protection électrique.

Le schéma fonctionnel de toute protection électrique comprend les éléments suivants :

- **EM**: élément de mesure qui contrôle l'état de l'élément à protéger.
- **EL** : élément logique qui élabore un signal logique pour les conditions de fonctionnement de la protection.

- **EE** : élément exécutif qui forme un signal de débranchement du disjoncteur.
- **EI** : élément d'indication qui informe le personnel sur l'état de la protection [2].

I.2.3 Eléments importants dans une protection électrique

Dans un dispositif de protection électrique les éléments les plus importants sont :

I.2.3.1 Relais

Le relais est un dispositif automatique qui commence à fonctionner sous l'action d'une grandeur d'entrée. On distingue deux types de relais [2] :

- **Les relais à contacts électromagnétiques.**
- **Les relais sans contacts**

I.2.3.2 Disjoncteur

Le disjoncteur est un appareil qui peut interrompre des courants importants, qu'il s'agisse du courant normal ou des courants de défaut. Il peut donc être utilisé comme un gros interrupteur, commandé sur place par un bouton-poussoir ou télécommandé. Par ailleurs, le disjoncteur ouvre un circuit automatiquement dès que le courant qui le traverse dépasse une valeur prédéterminée. Quand il sert à interrompre les forts courants de court-circuit, il joue le rôle d'un fusible avec un fonctionnement plus sûr et on n'a pas besoin de le remplacer après chaque coupure. Le schéma de la Figure I.2 montre la commande de l'ouverture d'un disjoncteur.

Les types de disjoncteurs les plus répandus sont [3]:

- **les disjoncteurs à l'huile.**
- **les disjoncteurs à air comprimé.**
- **les disjoncteurs au gaz SF₆.**
- **les disjoncteurs à vide.**

I.2.4 Qualités d'un système de protection

Pour que la protection soit adéquate, il faut qu'elle remplisse les conditions suivantes [1]:

- Rapidité de fonctionnement.
- Sélectivité.
- Stabilité.
- Sûreté de fonctionnement

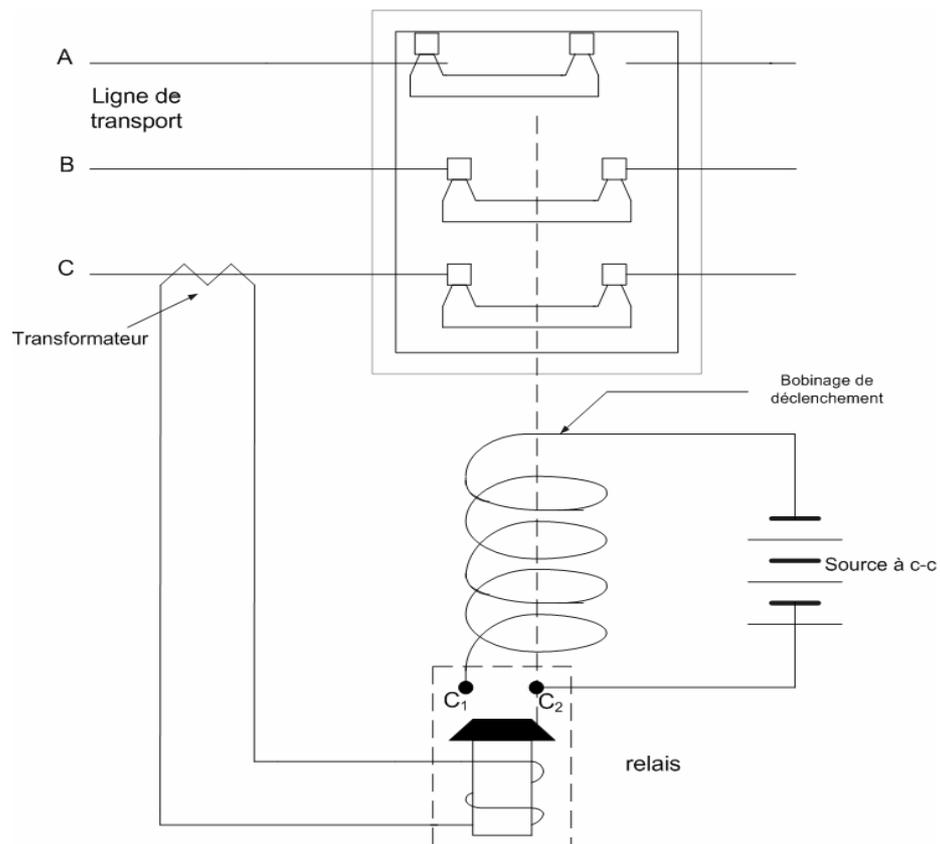


Figure I.2 Commande de l'ouverture d'un disjoncteur.

I.2.5 Grandeurs utilisées dans la détection des défauts

Parmi les rôles importants des dispositifs de protection : la détection des défauts apparaissent sur un réseau. Pour cela, ces dispositifs sont rendus sensibles à la variation de l'une au moins des caractéristiques physiques ou électriques du réseau parmi lesquelles on cite les suivantes [1]:

- La tension.
- L'intensité du courant.
- La fréquence.
- La vitesse de variation de l'une de ces quantités.

I.2.6 Types de protection des lignes

Dans un système de transport d'énergie électrique, les lignes sont les éléments les plus exposés aux différentes perturbations à cause de plusieurs facteurs (exemple : le vent, la glace, la neige, le jet de sel, les oiseaux, les avions, les automobiles,...etc....). Pour maintenir le fonctionnement normal du système, il faut équiper les lignes par des relais de protection et des disjoncteurs. D'après le type du relais utilisé, on peut caractériser deux types de protection :

I.2.6.1 Protection par fonction

I.2.6.1.1 Protection par relais différentiel

Cette protection est basée essentiellement sur la mesure de la différence géométrique de deux courants (ou tensions). D'après le principe de mesure, on distingue deux types [1]:

- **Protection ampèremétrique différentielle longitudinale**
- **Protection ampèremétrique différentielle transversale**

I.2.6.1.2 Protection par relais de comparaison de phase

Ce type de relais est basé sur la comparaison des phases des deux courants : l'angle de phase du courant entrant et celui sortant de l'élément à protéger [1].

I.2.6.1.3 protection par relais ampèremétrique (ou de surintensité)

Les relais utilisés dans ce type de protection fonctionnent quand l'intensité du courant qui les traverse dépasse la valeur admissible (nominale). Ils peuvent être alimentés par le courant d'une phase, ou par une composante symétrique (inverse ou homopolaire) du courant [1].

I.2.6.1.4 Protection par relais de distance

La protection par relais de distance est basée sur le principe de mesure de la distance entre l'emplacement du relais et le point de défaut. Lorsque celle-ci est supérieure à la valeur pré-réglée, le relais fonctionne [1].

I.2.6.2 Protection par technologie

I.2.6.2.1 Protection électromécanique

Un relais électromécanique se compose de deux parties : l'une est fixe et l'autre est mobile, entre lesquelles s'exerce une force (ou un couple) d'origine mécanique ou thermique ou électromagnétique. La partie mobile est solidaire d'un contact qui se déplace par rapport au circuit d'utilisation (exemple : le circuit de disjoncteur). Le mouvement de cette partie mobile sert à fermer ou ouvrir le circuit d'utilisation. Cette protection est relativement abandonnée parce qu'elle est caractérisée par un temps de fonctionnement très élevé, une grande consommation d'énergie et un grand prix de revient [4].

I.2.6.2.2 Protection électronique (ou statique)

Cette protection est basée sur des relais statiques dont les circuits de mesure et de commutation sont généralement à base de composants semi-conducteurs : transistors, diodes,

thyristors,...etc. Le parcours du signal d'état depuis les capteurs des grandeurs (physiques ou électriques) jusqu'à la prise de décision (le fonctionnement de la protection ou pas) s'effectue dans des modules entièrement électroniques propres à chaque fonction. Cette protection est caractérisée par une construction simple, un temps de déclenchement très court et une grande précision [4].

I.2.6.2.3 Protection numérique

La protection numérique est une protection sophistiquée basée sur le traitement de signal. Les signaux analogiques issus des transformateurs de mesure seront convertis en grandeurs numériques par l'intermédiaire d'un convertisseur analogique – numérique. Cette conversion permet de stocker ces données dans des mémoires et les traiter par un microprocesseur en utilisant les différents programmes de détection, classification et localisation des défauts [5].

I.3 Méthodes utilisées dans l'analyse des défauts

L'analyse des défauts qui apparaissent dans les lignes de transport d'énergie électrique comporte trois étapes essentielles représentées par la Figure I.3.

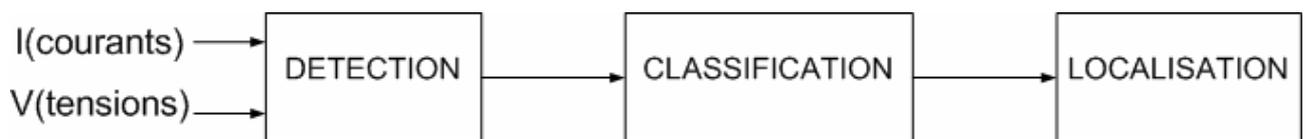


Figure I.3 Schéma bloc des méthodes utilisées dans l'analyse des défauts

I.3.1 Méthodes utilisées dans la détection

Parmi les méthodes proposées dans la littérature et utilisées dans la détection des défauts, nous citerons les suivantes :

- La méthode présentée dans la référence [6] est basée sur la comparaison entre deux échantillons successifs d'un même signal (courant ou tension). Lorsque la différence entre eux atteint un seuil prédéterminé, on conclut directement qu'il y a un défaut sur la phase qui correspond au signal traité.
- Lorsque le courant de défaut d'une phase est différent de zéro, on conclut directement que cette ligne est le siège d'un défaut qui peut être détecté en utilisant l'indicateur T_n calculé à partir des échantillons du courant issus des deux extrémités de la ligne [7]. Les valeurs de T_n sont comparées à la valeur prédéterminée T pour le système à l'état sain. Si la valeur de T_n est supérieure à T , donc la ligne est en défaut.

- Les méthodes intelligentes ont été largement utilisées dans ce domaine [8-10]. Parmi lesquelles, nous citerons la détection par les réseaux de neurones artificiels 'ANN' (détaillée en Chapitre III).

I.3.2 Méthodes utilisées dans la classification

Parmi les méthodes utilisées dans la classification, nous résumerons les suivantes:

- La méthode présentée dans la référence [7] est basée sur le calcul des indicateurs $J_{n,m}$ ($m = a, b, c, g$) à l'état sain avant défaut et après défaut. Selon cette méthode, pour classifier les défauts, une comparaison est effectuée entre les nouvelles valeurs de $J_{n,m}$ et leurs valeurs prédéterminées.
- De tous les algorithmes intelligents, les ANN sont les plus utilisés (voir Chapitre III) dans le domaine de classification des défauts [11-13].
- La logique floue (FL) a été appliquée par plusieurs chercheurs tels J. Mendel en 1995 [12], J. Vittal Reddy en 2005 [14], pour la classification des défauts survenants dans les lignes aériennes. L'algorithme de classification est basé sur 6 paramètres essentiels qui sont les arguments et amplitudes des composantes fondamentales des courants. Un tableau établissant pour chaque type de défaut 5 différentes valeurs correspondantes est élaboré. Ces 5 variables seront les entrées de notre système flou [12, 14-16].
- A cause de la variété des problèmes rencontrés dans les réseaux électriques, plusieurs chercheurs ont essayé de combiner les ANN et les FL. Cette combinaison diffère d'un travail à un autre : La logique floue est utilisée pour optimiser les paramètres d'apprentissage des ANN et améliorer la sortie représentant le type de défaut [17, 18]. Une autre approche consiste à utiliser les neurones flous (par exemple : entrée du neurone flou et poids non flou ou entrée non flou et poids flou) [19].
- Les algorithmes génétiques (GA) sont aussi appliqués à l'optimisation des entrées du réseau neuronal (voir Chapitre IV) et à l'optimisation des poids synaptiques des ANN [20].
- D'autres méthodes hybrides consistant à combiner les trois systèmes intelligents (FL, ANN, GA) ont été appliquées avec toutefois des résultats mitigés [17].

I.3.3 Méthodes de localisation des défauts

La première utilisation d'un microprocesseur dans la protection électrique (utilisation des relais numériques) était en 1969 par G.D. Rockefeller. A nos jours, plusieurs algorithmes proposés dans ce nouveau domaine servent à localiser les défauts apparents dans les réseaux électriques. On peut distinguer ces algorithmes suivant trois catégories:

- **La première catégorie**

Ces algorithmes sont les plus répandus et sont basés sur l'utilisation des phaseurs en régime permanent, calculés à partir des données issues d'une ou des deux extrémités de la ligne.

- **La deuxième catégorie**

Ces algorithmes ont comme principe l'utilisation des équations différentielles dans le modèle du réseau de transport.

- **La troisième catégorie**

Ces algorithmes utilisent le principe de propagation des ondes offrant des avantages considérables, surtout pour les longues lignes [4].

I.3.3.1 Méthode des phaseurs

Cette méthode très utilisée, est basée sur l'estimation des phaseurs d'état en régime permanent, moyennant les données d'une ou de deux extrémités.

I.3.3.1.1 Méthodes numériques d'estimation des phaseurs

Les phaseurs sont estimés à partir des valeurs échantillonnées des tensions et des courants, issues des extrémités de la ligne. Il y a plusieurs méthodes pour calculer les paramètres des phaseurs, les plus importantes sont :

- **Analyse de Fourier**

C'est une méthode très rapide qui est basé sur le traitement de signal [21]. Cette partie fera l'objet de plus de détails dans le chapitre suivant.

- **Méthode de Prony**

Cette méthode estime le signal de défaut par une somme de fonctions élémentaires caractérisées chacune par quatre paramètres dits 'paramètres de Prony'. La méthode utilisée pour la détermination des paramètres est détaillée dans la référence [22]. Cette méthode est très employée dans le domaine des protections numériques, puisque elle assure l'estimation des phaseurs avec une grande précision.

- **Méthode de moindres carrés**

C'est une méthode qui est très utilisée dans le domaine de la protection électrique [4] pour sa précision de calcul (voir Chapitre II).

- **Méthode du filtre de Kalman**

Le filtre de Kalman est un ensemble d'équations mathématiques qui donnent une solution récursive de la méthode des moindres carrés. Il diffère des autres algorithmes de filtrage utilisés dans l'estimation des phaseurs du fait que ses coefficients de gain sont en fonction du temps [25].

Malgré que cette technique offre plusieurs avantages dans la rapidité et la précision de calcul, elle a plusieurs inconvénients comme la difficulté d'identifier les composantes apériodiques. [26]

I.3.3.1.2 Algorithmes de localisation basés sur les données d'une extrémité

Considérant le modèle de la ligne en défaut schématisé dans la Figure I.4.

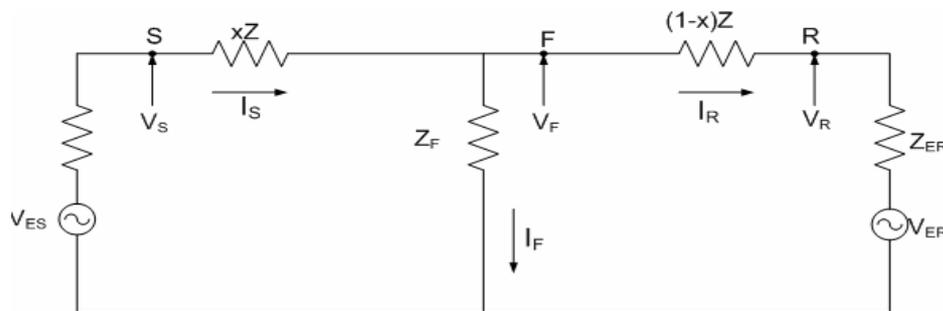


Figure I.4 Schéma équivalent d'une ligne en défaut

Avec : S , R et F désignent respectivement la source, le récepteur et le défaut de la ligne.

V_S , V_R et V_F sont les tensions de la source, du récepteur et du défaut de la ligne.

I_S , I_R et I_F sont les courants de la source, du récepteur, et du défaut de la ligne.

x est la distance de défaut.

Z est l'impédance de la ligne.

Z_{ES} , Z_{ER} sont les impédances équivalentes de Thévenin.

V_{ES} , V_{ER} sont les tensions équivalentes de Thévenin.

Parmi les algorithmes basés sur une seule extrémité, la technique développée dans la référence [21] par Takagi et al supposent que les impédances et les résistances mutuelles entre les phases sont négligeables, et l'impédance de défaut est une résistance égale à R_F . La distance de défaut x est donnée par l'équation suivante :

$$x = \frac{\text{Im}(V_S I_S^{**})}{\text{Im}(Z I_S^{**})} \quad (\text{I.1})$$

Sachant que : I_S^{**} est le conjugué de courant de défaut superposé donné dans [21].

D'autres algorithmes de localisation de défaut sont basés sur les données d'une extrémité utilisant comme principe les composantes symétriques comme l'algorithme présenté dans la référence [21]. L'avantage principal de l'application des composantes symétriques est dans le découplage de notre système qui permet d'obtenir trois équations découplées et de déduire la valeur de x .

Il y a un autre algorithme basé aussi sur les composantes symétriques présenté dans la référence [24], et qui définit la distance x par la relation suivante :

$$x = \frac{s_1.V_{s1} + s_2.V_{s2} + s_0.V_{s0}}{s_1(V_{rs1} + V'_{rs1}) + s_2V_{rs2} + s_0V_{rs0}} - e_r \quad (\text{I.2})$$

Tel que : e_r est le terme d'erreur due à la résistance du défaut donné dans la référence [24].

$$\begin{cases} V_{rs1} = I_1.Z_1 \\ V_{rs2} = I_2.Z_{1s} \\ V_{rs0} = I_0.Z_{0s} + I_{02}.Z_{0m} \end{cases}$$

$$V'_{rs1} = I'_{1s}.Z_{1s} \quad (\text{I.3})$$

$$\begin{cases} I_1 = I_{1s} - I'_{1s} \\ I_2 = I_{2s} \\ I_0 = I_{0s} \end{cases} \quad (\text{I.4})$$

Sachant que :

V_{s1}, V_{s2}, V_{s0} sont les tensions de phase des séquences au relais.

I_{1s}, I_{2s}, I_{0s} sont les courants de phase des séquences au relais.

I'_{1s} est le Courant pré-défaut.

Z_{1s}, Z_{0s} sont Les impédances de la ligne.

s_0, s_1 et s_2 sont des coefficients qui prennent les valeurs : 0, 1, -1, a , $-a$, a et a^2 .

Avec :

$$a = -0.5 + j 0.866 \quad (\text{I.5})$$

N.B.: Les modes 0, 1 et 2 correspondent respectivement aux séquences homopolaire, directe et inverse.

I.3.3.1.3 Algorithmes de localisation basés sur les données de deux extrémités

Ces algorithmes peuvent être classés en deux catégories :

- Algorithmes basés sur les données non synchronisées issues de deux extrémités de la ligne
- Algorithmes basés sur les données synchronisées issues de deux extrémités de la ligne.

Nous supposons que la ligne en défaut a le même schéma équivalent de la figure I.4 précédente. Dans la première catégorie, la tension de défaut a deux valeurs : V_F et V'_F qui ont la même amplitude avec un déphasage δ tel que :

$$V_F = V'_F e^{j\delta} \quad (\text{I.6})$$

Plusieurs algorithmes sont proposés, parmi lesquels nous citons :

- L'algorithme présenté dans la référence [21] utilisant les données non synchronisées des deux extrémités de la ligne et leur schéma équivalent inverse. L'application de la loi de Kirchhoff sur les tensions inverses permet de calculer la valeur de x .
- L'algorithme présenté dans la référence [4] utilise aussi les données non synchronisées des deux extrémités de la ligne. La valeur de x est donnée par la relation suivante:

$$x = \frac{\text{Re}(V_S) \cdot \sin \delta + \text{Im}(V_S) \cdot \cos \delta - \text{Im}(V_R) + C_4}{C_1 \cdot \sin \delta + C_2 \cdot \cos \delta + C_4} \quad (\text{I.7})$$

Les valeurs des coefficients C_1 , C_2 et C_4 sont données dans la référence [4].

Pour la deuxième catégorie, plusieurs algorithmes proposés sont basés sur l'utilisation des échantillons synchronisés par 'GPS' (Global Positioning system of Satellite), et sur les paramètres distribués de la ligne où est négligé l'effet de la capacité shunt et de la conductance. La ligne est considérée homogène pour simplifier le modèle utilisé.

Soit le schéma suivant qui représente un défaut sur une ligne triphasée :

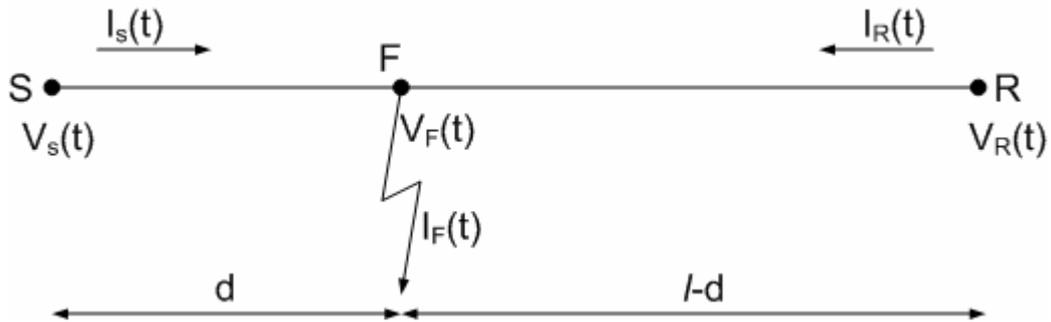


Figure I.5 Schéma équivalent d'une ligne triphasée en défaut

Les algorithmes les plus importants sont :

- Le travail proposé dans la référence [7] permet de déterminer la valeur de la distance x donnée par la formule suivante :

$$x = \frac{\sum_{n=2}^{N+1} \langle \Delta V_n, \varphi_n \rangle}{\sum_{n=2}^{N+1} \langle \varphi_n, \varphi_n \rangle} \quad (\text{I.8})$$

Avec: ΔV_n : vecteur représentant les écarts des tensions échantillonnées.

φ_n : vecteur qui est en fonction des écarts des courants échantillonnés.

$\langle \cdot, \cdot \rangle$ dénote le produit scalaire entre ces deux vecteurs.

- L'étude présentée dans la référence [21] basée sur la méthode des moindres carrés nous donne l'expression suivante permettant d'estimer la distance x :

$$x = -(A^T A)^{-1} (A^T B) \quad (\text{I.9})$$

Tels que : A et B sont des matrices des tensions et courants définis dans la référence [21].

L'exposant T dénote la matrice transposée.

I.3.3.2 Méthode des équations différentielles

Dans cette méthode, on peut utiliser deux modèles différents de la ligne de transport :

- Modèle à paramètres concentrés (lumped parameter model).
- Modèle à paramètres distribués (distributed parameter model).

I.3.3.2.1 Modèle à paramètres concentrés

Ce modèle néglige la conductance g , la capacité c , et la dérivée partielle du courant $i(t)$ par rapport à la position x en considérant l'équation suivante :

$$v_x(t) - v_s(t) = xri(t) + lx \left[\frac{di(t)}{dt} \right] \quad (\text{I.10})$$

Avec : $v_s(t)$ est la tension à l'extrémité de la ligne.

$v_x(t)$ est la tension à la position x de la ligne.

$i(t)$ est le courant mesuré sur la ligne.

- L'algorithme de la référence [27] se base sur la transformée de Laplace et de l'intégrale trapézoïdale pour estimer le courant à l'extrémité de la ligne. La distance de défaut est par la suite estimée grâce à la relation suivante :

$$x = \frac{V(s)}{\tilde{I}(s)[r + sl]} \quad (\text{I.11})$$

Avec : $V(s)$ est la transformée de Laplace pour la tension à l'extrémité de la ligne.

$\tilde{I}(s)$ est la transformée de Laplace pour la valeur estimée du courant à l'extrémité de la ligne (par l'intégrale trapézoïdale).

r , et l sont respectivement la résistance et l'inductance linéiques de la ligne.

- Pour l'algorithme de la référence [4], l'utilisation de la transformation de Fourier permet d'estimer la distance de défaut x qui a comme expression :

$$x = \bar{i}_1 \cdot S_i - \bar{i}_2 \cdot C_0 \quad (\text{I.12})$$

Avec : \bar{i}_1 et \bar{i}_2 sont respectivement les parties réelle et imaginaire du courant $i(t)$

S_i et C_0 sont des variables identifiées dans la référence [4].

I.3.3.2 Modèle à paramètres distribués

Ce modèle comprend deux équations différentielles de premier ordre où les tensions et les courants sont en fonction du temps t et de la position x .

$$\begin{aligned} -v_x(x,t) &= li_t(x,t) + ri(x,t) \\ -i_x(x,t) &= cv_t(x,t) + gv(x,t) \end{aligned} \quad (\text{I.13})$$

Avec : l , r , c , et g sont respectivement l'inductance, la résistance, la capacité, et la conductance par unité de longueur.

$v_x(x,t)$ et $i_x(x,t)$ sont les tensions et les courants.

x et t des indices indiquant les dérivés partielles par rapport à la position et le temps.

Pour ce modèle, plusieurs algorithmes sont proposés pour estimer la distance de défaut. La référence [21] permet de résoudre les équations différentielles à l'aide de la méthode qui utilise les conditions aux limites des tensions et des courants, dans les extrémités de la ligne, pour estimer la

distance de défaut. Lorsque la tension obtenue pour une position x est nulle ou est inférieure à la valeur minimale des valeurs à l'état normale, il y a apparition d'un défaut sur la ligne. Pour les lignes triphasées, la forme matricielle suivante est utilisée :

$$\begin{aligned} [V] &= L[I_t] + R[I] \\ [I_x] &= C[V_x] \end{aligned} \quad (\text{I.14})$$

Avec : $[V]$ et $[I]$ sont les vecteurs de tension et de courant pour les trois phases.

L , C et R sont les matrices inductance, capacité et résistance de la ligne triphasée.

Les indices x et t désignent les dérivés partielles par rapport à la position et le temps.

Pour la résolution des équations précédentes, la transformation modale est utilisée pour découpler le réseau et éliminer le couplage entre les phases. Puis la distance de défaut est estimée à partir des tensions obtenues.

I.3.3.3 Méthode de propagation des ondes

Cette méthode ne nécessite pas la résolution des équations aux dérivées partielles. Dans cette approche, la résistance r et la conductance g sont négligées puisqu'on considère la propagation d'ondes le long d'une ligne sans pertes. Une telle simplification est appropriée pour les longues lignes à haute tension.

En utilisant les ondes incidentes S_F et les ondes réfléchies S_B des ondes électromagnétiques, les expressions de la tension et de courant sont données par :

$$V(x, t) = \frac{1}{2}(S_F(t - \chi x) + S_B(t + \chi x)) \quad (\text{I.15})$$

$$i(x, t) = \frac{1}{2Z_0}(S_F(t - \chi x) - S_B(t + \chi x)) \quad (\text{I.16})$$

Où : $Z_0 = \sqrt{L/C}$: est l'impédance caractéristique de la ligne, $\chi = \eta^{-1}$ et $\eta^2 = LC$.

D'après les conditions aux limites à l'extrémité source de la ligne $V(0, t) = V_s(t)$ et $i(0, t) = i_s(t)$, on trouve :

$$\begin{aligned} S_F &= V(t) + Z_0 i(t) \\ S_B &= V(t) - Z_0 i(t) \end{aligned} \quad (\text{I.17})$$

Pour la localisation du défaut, seules les composantes transitoires des ondes sont utilisées. Les ondes mobiles apparaissent dans la ligne de transport après chaque changement brusque des tensions et courants. Lors de la survenance d'un défaut, la tension au point de défaut chute et

produit deux ondes se propageant en arrière (vers la source) et en avant (vers le récepteur) à l'endroit du défaut avec la même vitesse η^{-1} .

Ces ondes en se propageant ne changent pas leurs formes jusqu'à ce qu'elles atteignent une discontinuité dans la ligne (les discontinuités sont dans les deux extrémités source et récepteur et à l'endroit du défaut).

La distance de défaut x et la vitesse de propagation sont liées par la relation :

$$\Delta t = 2\eta^{-1}.x \quad (\text{I.18})$$

Le calcul du temps écoulé est facile à déterminer si l'impulsion injectée et sa réflexion ont des puissances suffisamment grandes. Cependant, les ondes provoquées par un défaut peuvent avoir une faible puissance, particulièrement si le défaut se produit quand la tension instantanée à l'endroit du défaut est proche de zéro. Dans ce cas, le calcul de ce temps exige l'utilisation des méthodes de traitement de signal telle que la technique de corrélation [23].

Malgré que cette méthode soit indépendante de la structure du réseau et des équipements de protection, son utilisation dans le domaine de localisation des défauts est limitée à cause de :

- la présence des réflexions multiples qui peuvent donner des résultats erronés.
- la fréquence d'échantillonnage est très élevée, ce qui augmente le temps de calcul [21].

I.4 Conclusion

Dans ce chapitre, nous avons cité quelques généralités sur la protection électrique et les différentes étapes d'analyse des défauts qui apparaissent sur les lignes de transports d'énergie électrique ainsi que les techniques utilisées dans la détection, classification et localisation des défauts.

L'approche des phaseurs étant l'approche la plus utilisée, dans la suite de ce travail, nous allons l'utiliser pour l'analyse des défauts.

II.1 Introduction

Dans ce chapitre, nous allons étudier une méthode conventionnelle basée sur les données synchronisées issues de deux extrémités de la ligne à protéger, en utilisant l'approche des phaseurs. Cette méthode contient les deux étapes suivantes:

- *La première étape* : l'estimation des phaseurs.
- *La deuxième étape* : l'estimation de la distance de défaut en utilisant les phaseurs estimés

II.2 Estimation des phaseurs

Comme nous avons mentionné précédemment, le phaseur est un nombre complexe qui caractérise une période d'un signal donné et qui peut être estimé par plusieurs méthodes :

II.2.1 Analyse de Fourier

Pour un signal donné $y(t)$ l'estimation de la partie réelle et imaginaire de son phaseur \bar{Y} pendant une période donnée, est définie par la relation suivante [21] :

$$\begin{aligned} \operatorname{Re}\{\bar{Y}\} &= f_s \sum_{n=0}^{N-1} y\left(\frac{n}{Nf_0}\right) \cos(2\pi n/N) \\ \operatorname{Im}\{\bar{Y}\} &= f_s \sum_{n=0}^{N-1} y\left(\frac{n}{Nf_0}\right) \sin(2\pi n/N) \end{aligned} \quad (\text{II.1})$$

Tel que : N est le nombre d'échantillons qui est égal au rapport entre la fréquence d'échantillonnage f_s et la fréquence du système f_0 .

A partir de la relation précédente, on peut déduire l'amplitude et la phase du phaseur estimé en appliquant les relations suivantes :

$$|\bar{Y}| = \sqrt{\operatorname{Re}\{\bar{Y}\}^2 + \operatorname{Im}\{\bar{Y}\}^2} \quad (\text{II.2})$$

$$\operatorname{Arg}(\bar{Y}) = \arctan\left(\frac{\operatorname{Im}\{\bar{Y}\}}{\operatorname{Re}\{\bar{Y}\}}\right) \quad (\text{II.3})$$

Donc le phaseur \bar{Y} du signal $y(t)$ est donné par la relation suivante :

$$\bar{Y} = |\bar{Y}| \exp(j\operatorname{Arg}(\bar{Y})) \quad (\text{II.4})$$

II.2.2 La méthode des moindres carrés

Soit le système des tensions triphasées suivant :

$$\begin{cases} V_a(t) = V_a \cos(\omega t + \phi_a) \\ V_b(t) = V_b \cos(\omega t + \phi_b) \\ V_c(t) = V_c \cos(\omega t + \phi_c) \end{cases} \quad (\text{II.5})$$

Les phaseurs du système précédent peuvent être exprimés par la relation suivante :

$$\begin{cases} \overline{V}_a = V_a \exp(j\phi_a) \\ \overline{V}_b = V_b \exp(j\phi_b) \\ \overline{V}_c = V_c \exp(j\phi_c) \end{cases} \quad (\text{II.6})$$

On peut écrire l'équation (II.5) sous la forme suivante :

$$V_i(t) = \text{Re}\{\overline{V}_i e^{j\omega t}\} = \frac{1}{2} [\overline{V}_i e^{j\omega t} + \overline{V}_i^* e^{-j\omega t}] \quad (\text{II.7})$$

Sachant que :

$$i = a, b, c.$$

et : \overline{V}_i^* est le conjugué de \overline{V}_i .

On peut écrire l'équation précédente sous la forme discrète suivante :

$$V(t_N) = \frac{1}{2} [\overline{V}_N e^{j\omega t_N} + \overline{V}_N^* e^{-j\omega t_N}] \quad (\text{II.8})$$

Avec : $t_N = N \cdot \Delta t$

Δt est la période d'échantillonnage.

N est le nombre d'échantillons.

\overline{V}_N est le phaseur de la grandeur temporelle $V(t_N)$ qui a l'expression suivante ;

$$\overline{V}_N = V_r + jV_i \quad (\text{II.9})$$

Où : V_r et V_i sont les deux parties réelle et imaginaire de phaseur \overline{V}_N .

On remplace \overline{V}_N par sa nouvelle expression dans l'équation (II.8), et après simplification, on obtient

l'équation suivante :

$$V(t_N) = V_r \left(\frac{e^{jN\omega\Delta t} + e^{-jN\omega\Delta t}}{2} \right) - V_i \left(\frac{e^{jN\omega\Delta t} - e^{-jN\omega\Delta t}}{2} \right) \quad (\text{II.10})$$

On aura donc :

$$V(t_N) = V_r \cos(N\omega\Delta t) - V_i \sin(N\omega\Delta t) \quad (\text{II.11})$$

Pour chaque instant $t_k \in [0, t_N]$ on peut écrire:

$$V(t_k) = V_r \cos(k\omega\Delta t) - V_i \sin(k\omega\Delta t) \quad (\text{II.12})$$

L'équation précédente peut être exprimée sous la forme matricielle suivante :

$$\begin{bmatrix} V(t_1) \\ \vdots \\ V(t_k) \\ \vdots \\ V(t_N) \end{bmatrix} = \begin{bmatrix} \cos(\omega\Delta t) & -\sin(\omega\Delta t) \\ \cos(k\omega\Delta t) & -\sin(k\omega\Delta t) \\ \cos(N\omega\Delta t) & -\sin(N\omega\Delta t) \end{bmatrix} * \begin{bmatrix} V_r \\ V_i \end{bmatrix} \Leftrightarrow [D] = [F] * [T] \quad (\text{II.13})$$

Avec : N est le nombre d'échantillons.

En utilisant la méthode des moindres carrés, on peut facilement estimer les composantes V_r, V_i du vecteur $[T]$ par l'expression [4] :

$$[T] = ([F]^t \cdot [W][F])^{-1} \cdot [F]^t \cdot [W][D] \quad (\text{II.14})$$

Avec : $[F]^t$ est la matrice transposée de $[F]$.

$[W]$ est une matrice identité de dimension $(N \times N)$.

Après simplification, on obtient :

$$[F]^t [W][F] = \begin{bmatrix} \sum_{k=1}^{k=N} \cos^2 k\omega\Delta t & -\sum_{k=1}^{k=N} \cos k\omega\Delta t \cdot \sin k\omega\Delta t \\ -\sum_{k=1}^{k=N} \cos k\omega\Delta t \cdot \sin k\omega\Delta t & \sum_{k=1}^{k=N} \sin^2 k\omega\Delta t \end{bmatrix} \quad (\text{II.15})$$

On pose que :

$$\begin{cases} A = \sum_{k=1}^{k=N} \sin^2 k\omega\Delta t \\ B = \sum_{k=1}^{k=N} \cos k\omega\Delta t \cdot \sin k\omega\Delta t \\ C = \sum_{k=1}^{k=N} \cos^2 k\omega\Delta t \end{cases} \quad (\text{II.16})$$

On aura donc :

$$[F]^t \cdot [W][F] = \begin{bmatrix} C & -B \\ -B & A \end{bmatrix} \Leftrightarrow ([F]^t \cdot [W][F])^{-1} = \frac{1}{A \cdot C - B^2} \begin{bmatrix} A & B \\ B & C \end{bmatrix} \quad (\text{II.17})$$

Après les simplifications des parties restantes de l'équation (II.14):

$$[F]^t \cdot [W][D] = \begin{bmatrix} \sum_{k=1}^{k=N} V_k \cos k\omega\Delta t \\ -\sum_{k=1}^{k=N} V_k \sin k\omega\Delta t \end{bmatrix} \quad (\text{II.18})$$

En posant:

$$\begin{cases} F_c = \sum_{k=1}^{k=N} V_k \cos k\omega\Delta t \\ F_s = \sum_{k=1}^{k=N} V_k \sin k\omega\Delta t \end{cases} \quad (\text{II.19})$$

On aura donc :

$$[F]^t \cdot [W] \cdot [D] = \begin{bmatrix} F_c \\ -F_s \end{bmatrix} \tag{II.20}$$

La nouvelle expression de vecteur $[T]$ sera :

$$[T] = \frac{1}{A.C - B^2} \begin{bmatrix} A & B \\ B & C \end{bmatrix} * \begin{bmatrix} F_c \\ -F_s \end{bmatrix} \tag{II.21}$$

$$[T] = \frac{1}{A.C - B^2} \begin{bmatrix} A.F_c - B.F_s \\ B.F_c - C.F_s \end{bmatrix} \tag{II.22}$$

Les valeurs estimées des parties réelle et imaginaire du phaseur \overline{V}_N seront :

$$V_r = \frac{1}{A.C - B^2} (A.F_c - B.F_s) \tag{II.23}$$

$$V_i = \frac{1}{A.C - B^2} (B.F_c - C.F_s) \tag{II.24}$$

Pour calculer le module et la phase du phaseur \overline{V}_N , on utilise les relations développées dans la première méthode de Fourier [4]. Les méthodes d'estimation précédentes, sont valables pour l'estimation des phaseurs des courants et des tensions.

A l'aide des deux méthodes précédentes, nous sommes arrivés à estimer un nombre complexe dit 'phaseur' à partir d'échantillons d'un signal sinusoïdal pendant une période donnée. Ces méthodes sont utiles dans le domaine de la protection électrique puisqu'elles transforment les systèmes sinusoïdaux en des systèmes complexes faciles à traiter à l'aide des méthodes numériques.

II.3 Localisation des défauts par les phaseurs

Parmi les algorithmes utilisés, dans la localisation des défauts basés sur les données synchronisées des deux extrémités de la ligne par l'approche des phaseurs, nous avons opté pour l'algorithme des moindres carrés [4].

Soit le schéma suivant qui représente une ligne triphasée à deux extrémités avec un défaut au point F :

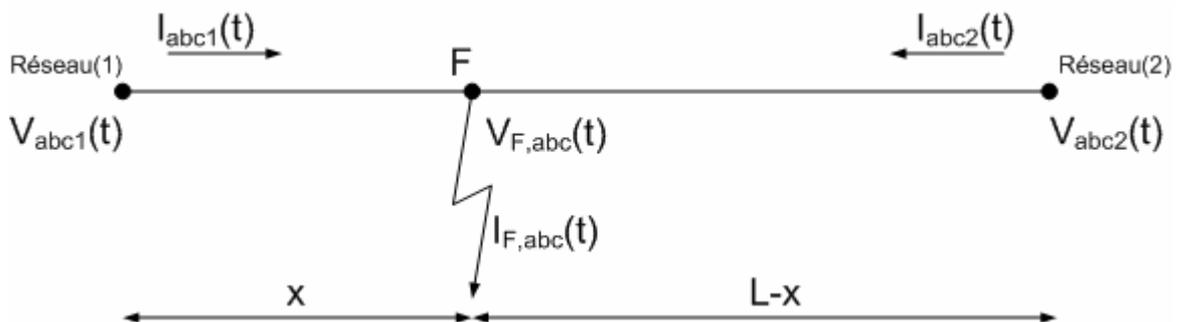


Figure II.1 Ligne triphasée à deux extrémités avec un défaut en point F

Comme première étape, on suppose que les échantillons des courants et des tensions issus des deux extrémités de la ligne sont synchronisés.

A partir de la première extrémité, l'équation suivante est définie :

$$V_{abc1} = V_{Fabc} + x.Z_{abc}.I_{abc1} \quad (\text{II.25})$$

Et à partir de la deuxième extrémité on peut tirer l'équation suivante :

$$V_{abc2} = V_{Fabc} + (L - x).Z_{abc}.I_{abc2} \quad (\text{II.26})$$

Sachant que :

Z_{abc} est la matrice impédance de la ligne par unité de longueur.

V_{Fabc} est le vecteur tension du défaut.

x est la distance de défaut par rapport au relais de la première extrémité.

La soustraction des deux équations précédentes donne :

$$V_{abc1} - V_{abc2} + L.Z_{abc}.I_{abc2} = x.Z_{abc}.(I_{abc1} + I_{abc2}) \quad (\text{II.27})$$

L'équation précédente peut s'écrire sous la forme matricielle suivante :

$$[y] = x.[m] \Leftrightarrow Y = x.M \quad (\text{II.28})$$

Avec Y, M des vecteurs, leurs éléments sont définis par:

$$\begin{cases} y_j = V_{j1} - V_{j2} + L. \sum_{i=a,b,c} Z_{ji} I_{i2} \\ m_j = \sum_{i=a,b,c} Z_{ji} (I_{i1} + I_{i2}) \\ j = a, b, c \end{cases} \quad (\text{II.29})$$

Les valeurs temporelles des tensions et des courants sont remplacées dans l'équation (II.28) par les phaseurs estimés de ces signaux. Un système de trois équations complexes indépendantes du temps est ainsi obtenu et développé en six équations réelles avec une seule inconnue qui est la distance de défaut x .

$$Y = M.x \Leftrightarrow Y - M.x = 0 \quad (\text{II.30})$$

Donc on aura :

$$(Y - M.x)^*(Y - M.x) = 0 \quad (\text{II.31})$$

Avec l'exposant (*) dénotant la matrice transposée conjuguée.

Sachant que :

$$(A.B)^* = B^*.A^* \quad (\text{II.32})$$

En appliquant la propriété précédente sur l'équation II.31 et après les simplifications on obtient :

$$Y^*.Y - x^*.M^*.Y - Y^*.M.x + x^*.M^*.M.x = 0 \quad (\text{II.33})$$

En réarrangeant l'équation précédente :

$$Y^* . Y - x^* . M^* . Y - x^* . M^* . Y + x^* . M^* . M . x = 0 \quad (\text{II.34})$$

De l'équation II.30 on aura l'équation suivante :

$$Y^* . Y = (M . x)^* . M . x \Leftrightarrow Y^* . Y = x^* . M^* . M . x \quad (\text{II.35})$$

En remplaçant l'équation précédente dans l'équation II.34 et en divisant par rapport à x^* , on obtient l'équation suivante :

$$- 2M^* . Y + 2M^* . M . x = 0 \quad (\text{II.36})$$

L'expression suivante de la distance de défaut est enfin donnée par :

$$x = (M^* . M)^{-1} . M^* . Y \quad (\text{II.37})$$

II.4 Application de l'algorithme sur un réseau de transport

Nous avons appliqué la méthode précédente pour la localisation des défauts apparaissant sur une ligne triphasée qui relie deux générateurs dans le réseau représenté sur la figure II.2.



Figure II.2 Le schéma monophasé du réseau étudié

Les caractéristiques du réseau étudié sont les suivantes :

- Deux générateurs de 35 GVA/400 kV avec une fréquence de 60Hz.
- Deux jeux de barre J_1, J_2 .
- Tension de base $U_B = 400$ kV, puissance de base $S_B = 100$ GVA.
- Une ligne triphasée de T.H.T de longueur $L=128$ km ayant comme matrice impédance la matrice Z_{abc} suivante :

$$Z_{abc} = \begin{bmatrix} 0.1465 + 1.4405i & 0.0864 + 0.5801i & 0.0864 + 0.5801i \\ 0.0864 + 0.5801i & 0.1465 + 1.4405i & 0.0864 + 0.5801i \\ 0.0864 + 0.5801i & 0.0864 + 0.5801i & 0.1465 + 1.4405i \end{bmatrix} \quad \left(\frac{\text{Ohm}}{\text{km}} \right)$$

Nous avons simulé le réseau précédent sur l'environnement MATLAB-Simulink en utilisant le bloc présenté sur la figure II.3.

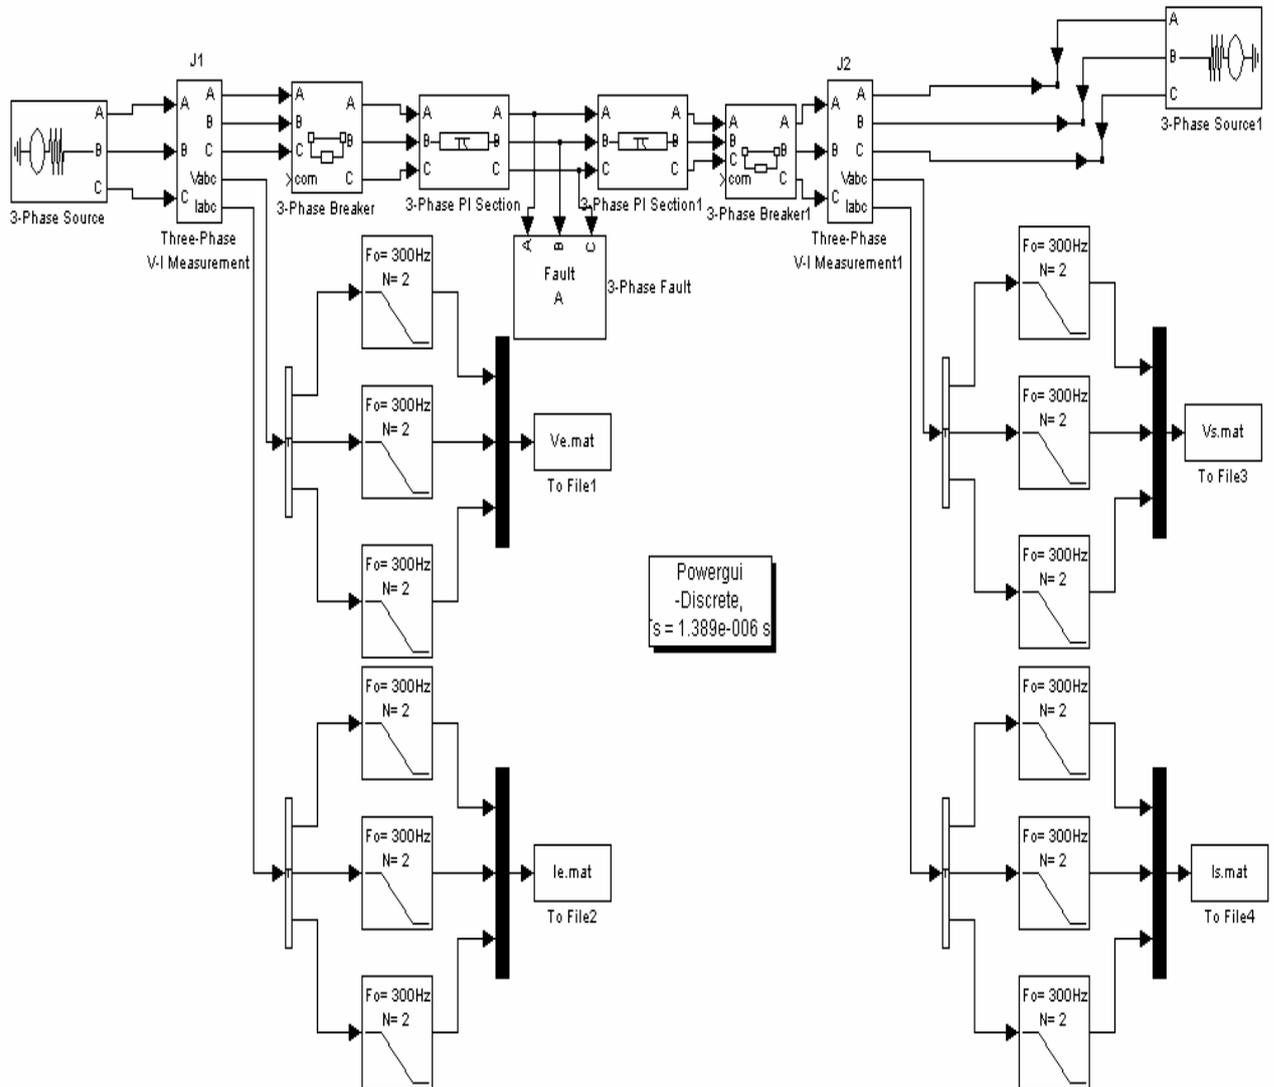


Figure II.3 Schéma bloc utilisé dans la simulation

Trois types de défauts à la terre (monophasé, biphasé et triphasé) sont simulés pour une distance de 64 km et pour un niveau de charge nominal de 35 GVA avec une résistance de défaut $R_f = 10\Omega$. Pour l'intervalle [0.1 0.16] s, le défaut survient à l'instant 0.12 s.

II.4.1 Résultats de simulation du réseau en état sain

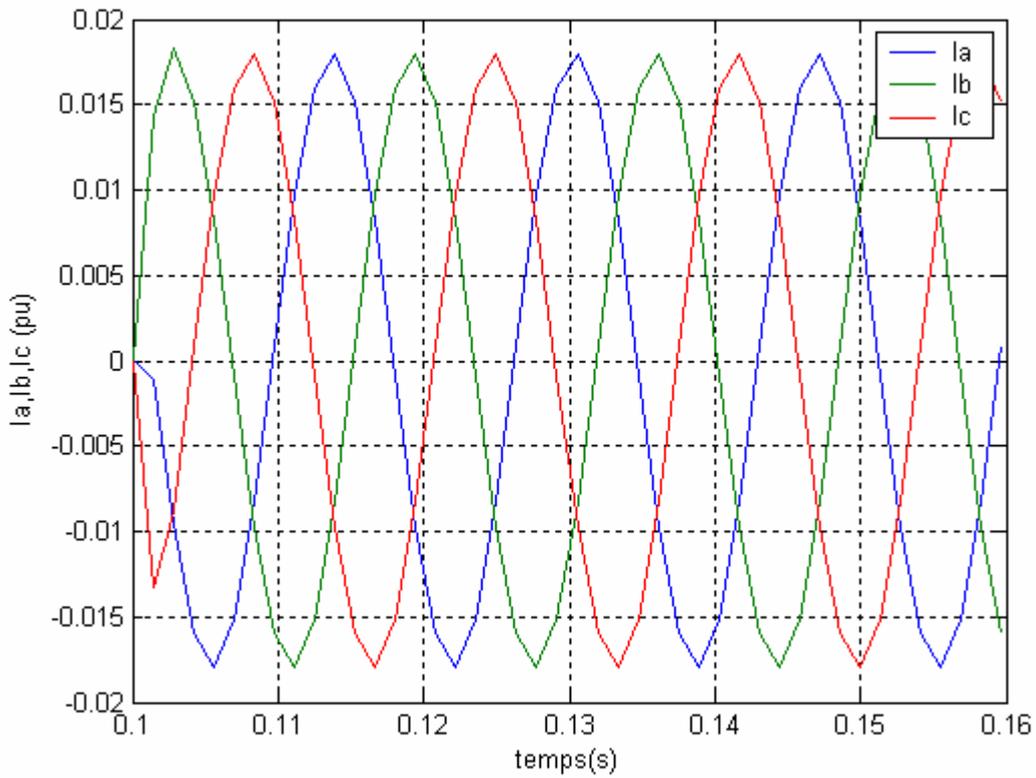


Figure II.4 courants $I_a(t), I_b(t), I_c(t)$ à l'état sain

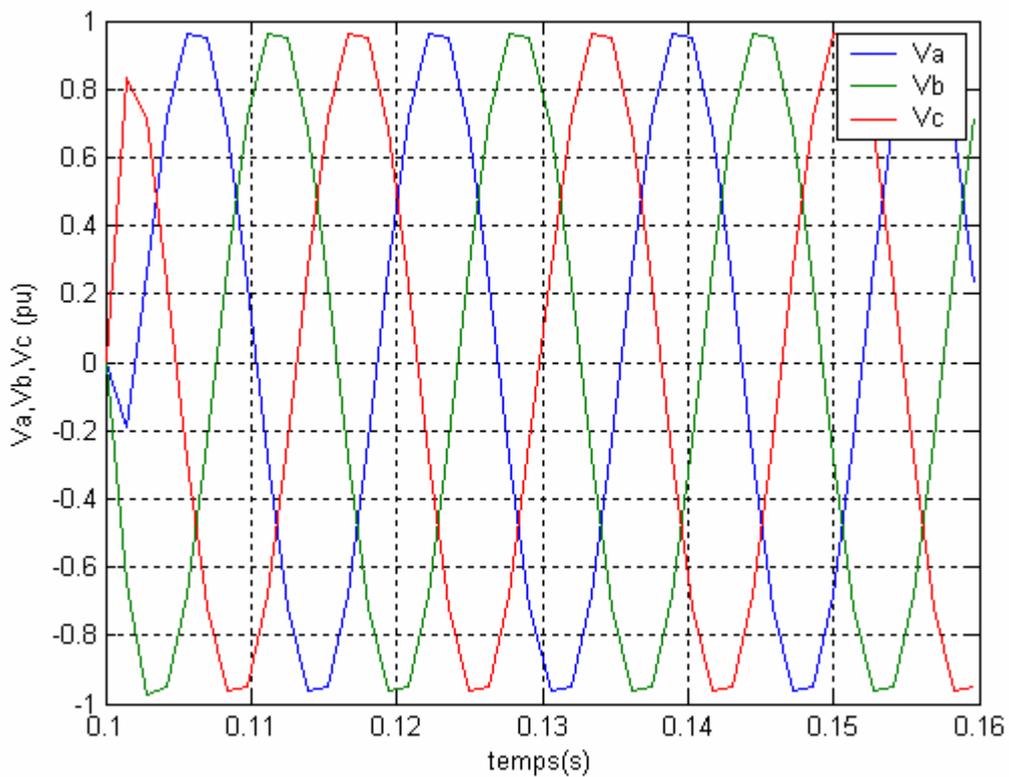


Figure II.5 Tensions $V_a(t), V_b(t), V_c(t)$ à l'état sain

II.4.2 Résultats de simulation du réseau en défaut

II.4.2.1 Défaut monophasé (A-terre)

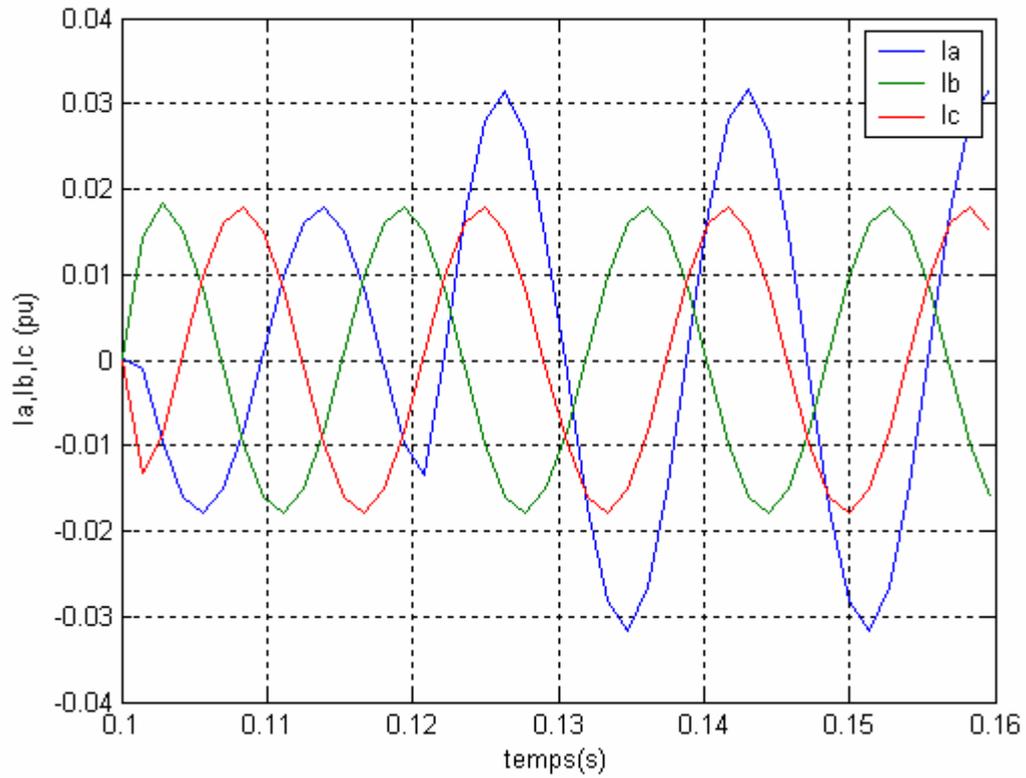


Figure II.6 Courants $I_a(t), I_b(t), I_c(t)$ en défaut monophasé

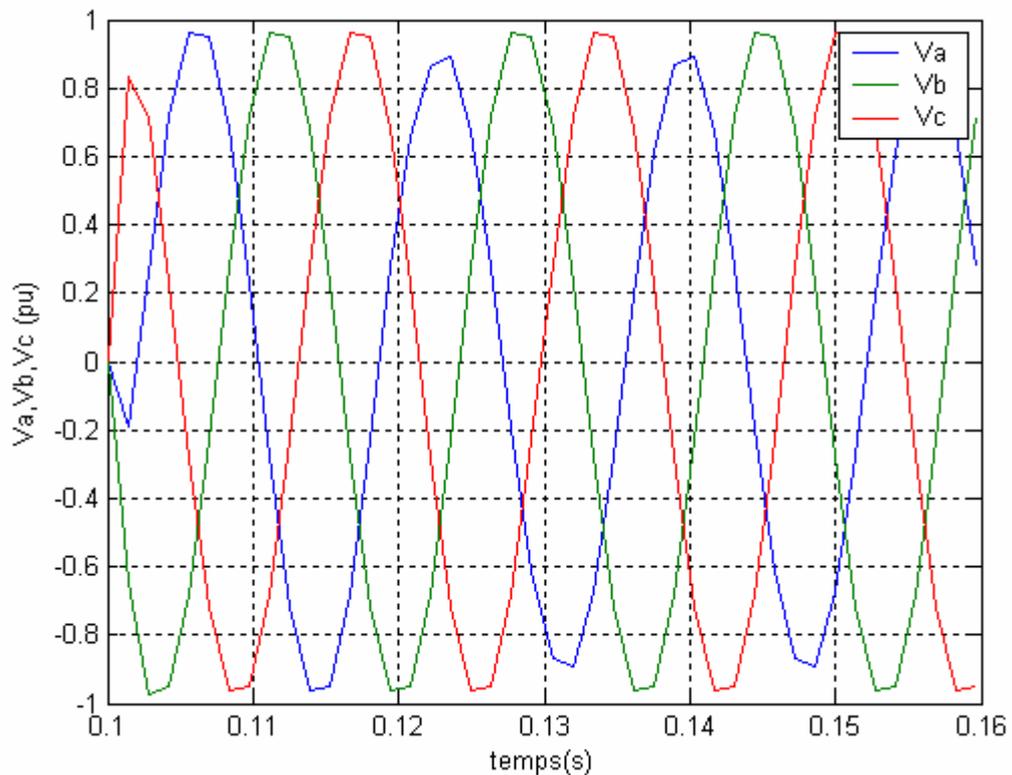


Figure II.7 Tensions $V_a(t), V_b(t), V_c(t)$ en défaut monophasé

II.4.2.2 Défaut biphasé (A-B-terre)

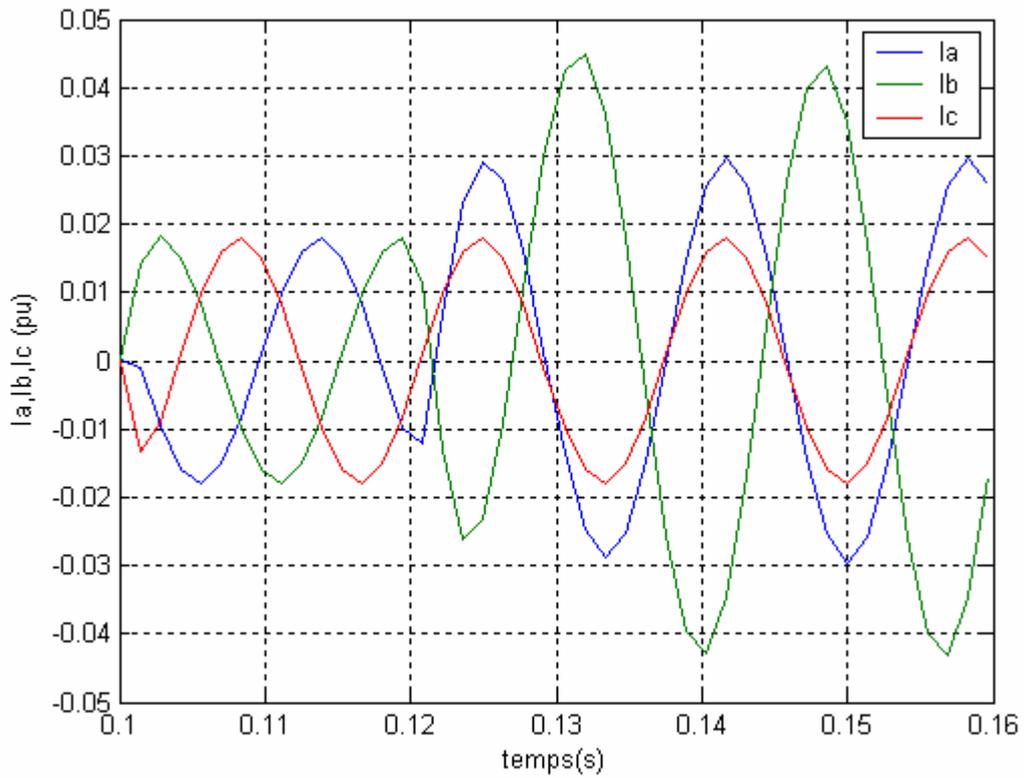


Figure II.8 Courants $I_a(t), I_b(t), I_c(t)$ en défaut biphasé.

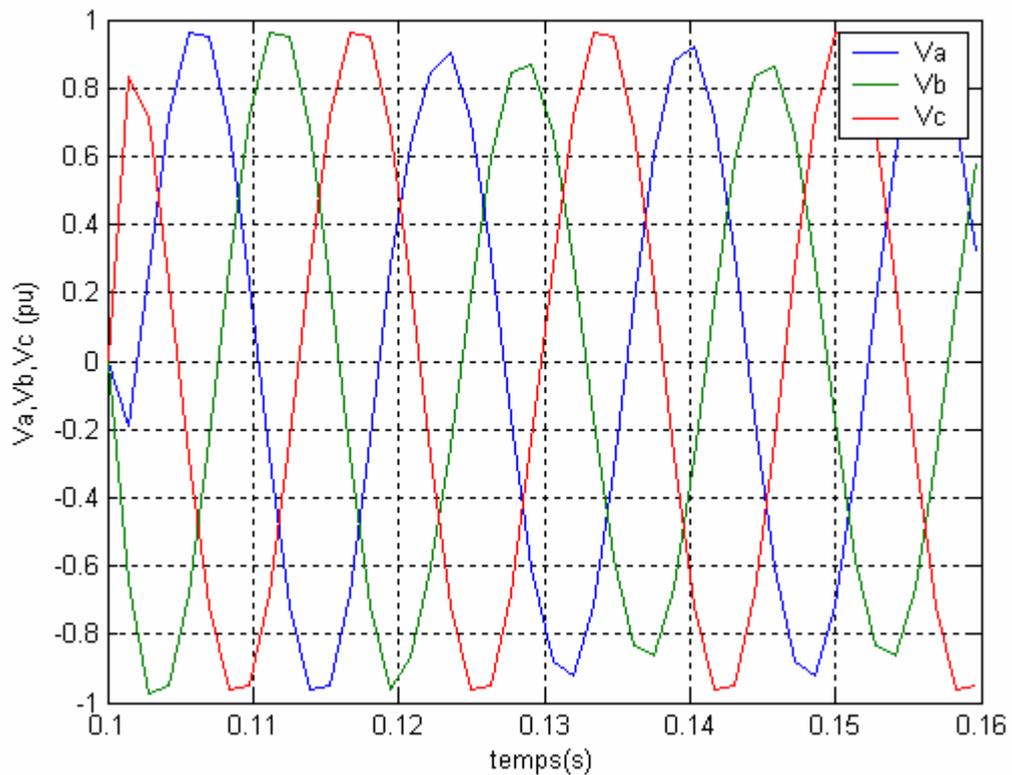


Figure II.9 Tensions $V_a(t), V_b(t), V_c(t)$ en défaut biphasé

II.4.2.3 Défaut triphasé (A-B-C-terre)

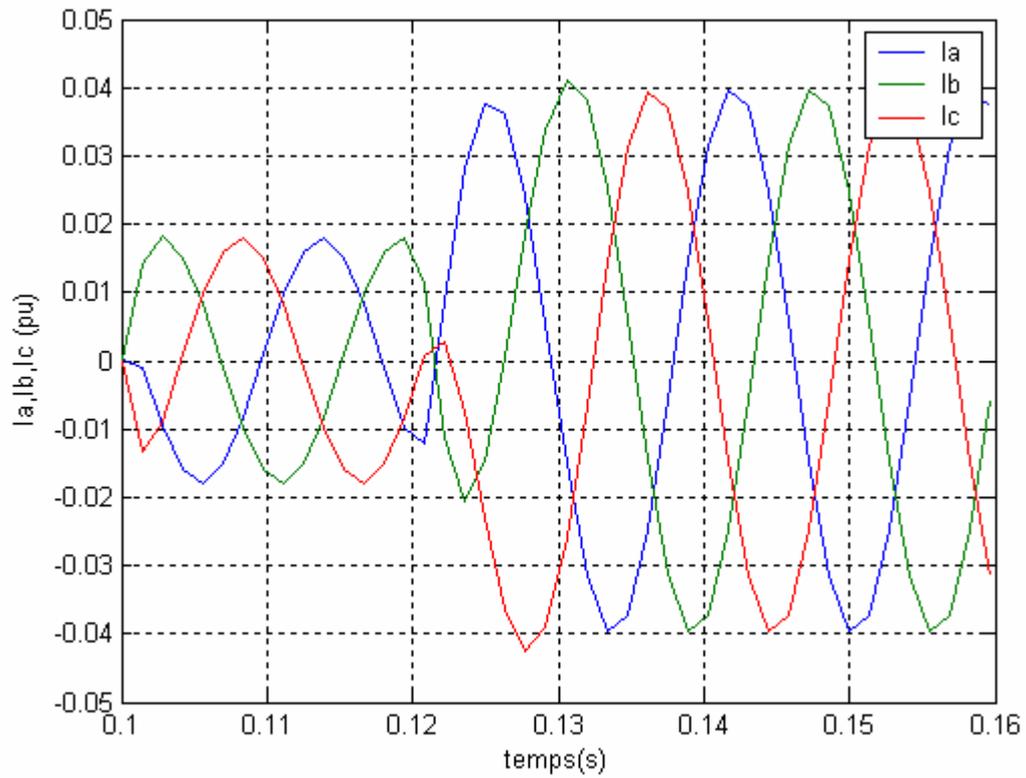


Figure II.10 Courants $I_a(t), I_b(t), I_c(t)$ en défaut triphasé

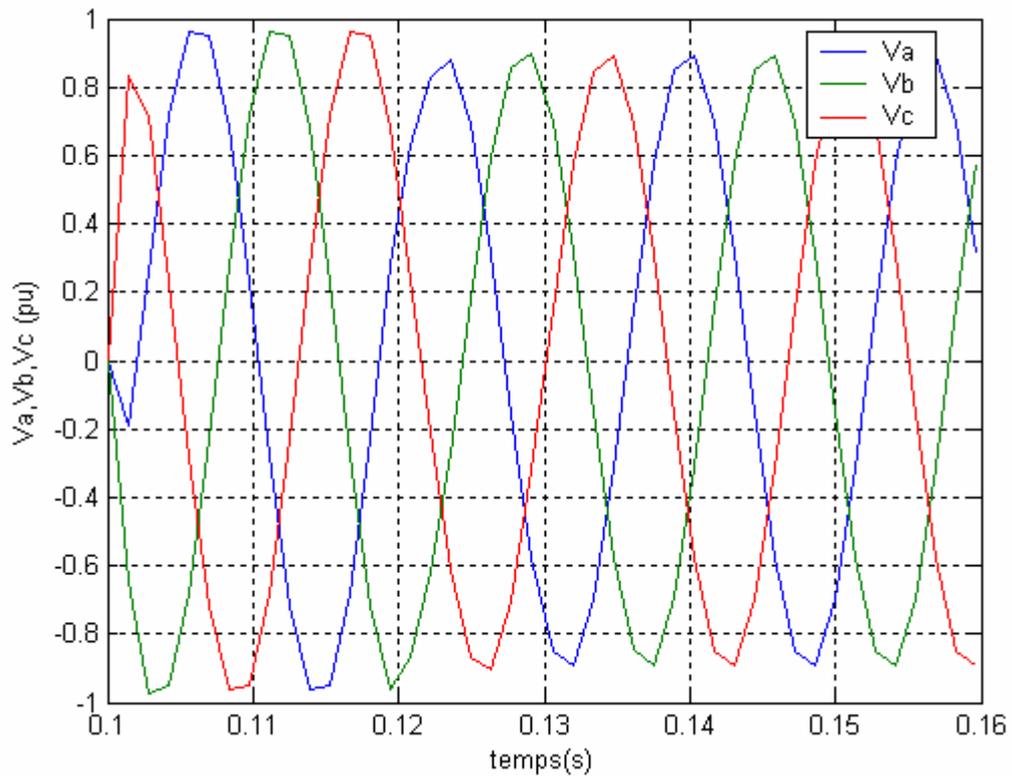


Figure II.11 Tensions $V_a(t), V_b(t), V_c(t)$ en défaut triphasé

II.4.3 Résultats de l'algorithme de localisation

Nous avons échantillonné les signaux obtenus aux deux extrémités de la ligne en utilisant un bloc spécial dans la bibliothèque de Simulink, puis nous avons traité ces échantillons par un programme élaboré sous l'environnement MATLAB, basé sur l'algorithme étudié précédemment. Les phaseurs des signaux échantillonnés sont ainsi obtenus et la distance de défaut estimée. La figure II.12 montre l'organigramme du programme élaboré.

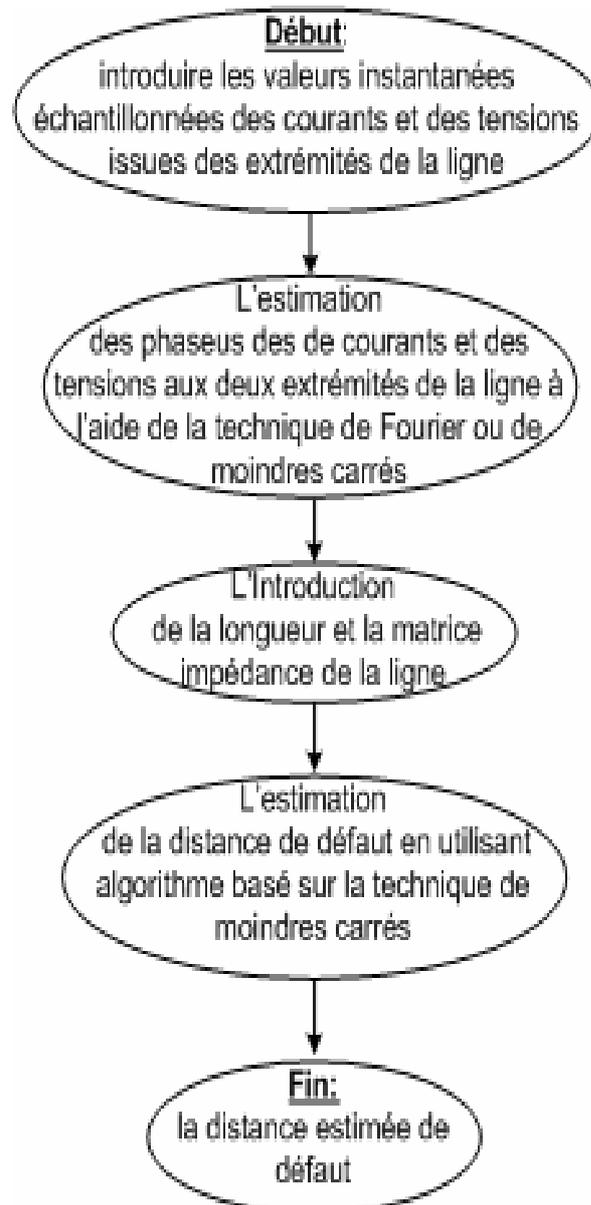


Figure II.12 Procédure utilisée

Trois types de des défauts à la terre (monophasé, biphasé et triphasé) sont simulés pour une distance de 64 km, pour différents niveaux de charge et différents résistance de défaut R_f , en utilisant les deux techniques, pendant l'intervalle $[0 \quad 0.5]s$. Le défaut survient à l'instant 0.35 s.

- *En utilisant la technique de Fourier :*

Tableau II.1 Résultats de la technique de Fourier

Type de défauts	Niveaux de charges en (GVA)	Distances estimées en (km) pour $R_f = 0.01\Omega$	Distances estimées en (km) pour $R_f = 0.035\Omega$
Monophasé	20	86.670	37.667
	35	85.225	37.652
	40	88.133	88.124
Biphasé	20	62.896	62.907
	35	62.939	62.939
	40	62.977	62.986
Triphasé	20	63.969	64.046
	35	63.917	64.003
	40	63.949	64.040

- *En utilisant la technique de moindres carrés*

Tableau II.2 Résultats de la technique de moindres carrés

Type de défauts	Niveaux de charges en (GVA)	Distances estimées en (km) pour $R_f = 0.01\Omega$	Distances estimées en (km) pour $R_f = 0.035\Omega$
Monophasé	20	60.013	59.956
	35	59.814	59.755
	40	59.769	59.709
Biphasé	20	61.762	61.1706
	35	61.846	61.178
	40	61.863	61.1799
Triphasé	20	61.836	61.785
	35	61.917	61.859
	40	61.933	61.873

II.4.4 Interprétation des résultats

D'après les tableaux II.1 et II.2 la précision des deux techniques mentionnées dépend de la résistance de défaut, du type de défaut et du niveau de charge.

Les résultats donnés par la méthode des moindres carrés, varient peu en fonction de la résistance de défaut et du niveau de charge, comparativement à celui donnés par la méthode de Fourier.

Pour une même valeur de la résistance de défaut R_f , nous constatons que la méthode des moindres carrés, donne des résultats meilleurs que la méthode de Fourier, cette constatation est d'autant plus visible pour les défauts monophasés.

II.5 Conclusion

La précision de la méthode conventionnelle étudiée dans ce chapitre dépend des phaseurs estimés. Plusieurs paramètres influent sur l'estimation des phaseurs comme la résistance de défaut, le type de défaut, le niveau de charge.

Pour remédier au problème de calcul (le temps, l'effort, ...etc.), on se rabat sur les réseaux de neurones qu'on va utiliser dans le chapitre suivant pour la détection, la classification et la localisation en utilisant les phaseurs estimés par les moindres carrés.

III.1 Introduction

De nombreux travaux ont été effectués dans le cadre du développement des systèmes intelligents, dont certains inspirés de réseaux de neurones biologiques. Des chercheurs de différents horizons ont défini et construit des ANN (Artificial Neural Network) pour résoudre des problèmes aussi variés que la reconnaissance de formes, la prévision, l'optimisation, les mémoires associatives ou le contrôle.

La recherche dans le domaine des ANN a vécu trois périodes d'intense activité. La première, dans les années 1940 est liée aux travaux de McCulloch et Pitts. La seconde, durant les années 1960 avec les travaux de Rosenblatt sur le perceptron et le théorème de convergence ainsi que les travaux de Minsky et Papert démontrant les limites du perceptron mono-couche. Le creux de la vague dura environ 20 ans, jusqu'au début des années 1980, avec l'approche proposée par Hopfield et l'algorithme de rétro-propagation dans le cadre des Perceptrons Multi-Couches (PMC) proposé pour la première fois par Werbos, réinventé par la suite plusieurs fois avant d'être popularisé par Rumelhart et al. en 1986 [28, 29].

Avant d'aborder la construction des réseaux de neurones pour l'analyse des défauts, nous allons donner brièvement les principales définitions et notions de base d'un réseau de neurone.

III.2 Réseaux de neurones artificiels

III.2.1 Définition

Inspirés des réseaux de neurones biologiques, un réseau de neurones est un système composé de plusieurs unités de calcul simples fonctionnant en parallèle, dont la fonction est déterminée par la structure du réseau, la solidité des connexions, et l'opération effectuée par les éléments ou nœuds(neurones) [29].

III.2.2 Neurones formels

Mc Culloch et Pitts introduisirent un modèle de neurone formel en tant qu'unité (à seuil) de calcul [30]. Ce neurone formel représenté par la Figure III.1, calcule une somme pondérée de ses n entrées x_1, \dots, x_n et renvoie 1 si la somme est supérieure à un certain seuil θ , 0 sinon. Mathématiquement, cela revient à écrire [29] :

$$y = f\left(\sum_{j=1}^n w_j x_j - \theta\right) \quad (\text{III.1})$$

Où : f est la fonction seuil, et w_j est le poids de la connexion associée à la $j^{\text{ème}}$ entrée.

Pour des raisons de simplification des notations, on considère le seuil $-\theta$ comme un poids w_0 et on augmente de 1 la taille du vecteur d'entrée en posant $x_0 = 1$ [29,30].

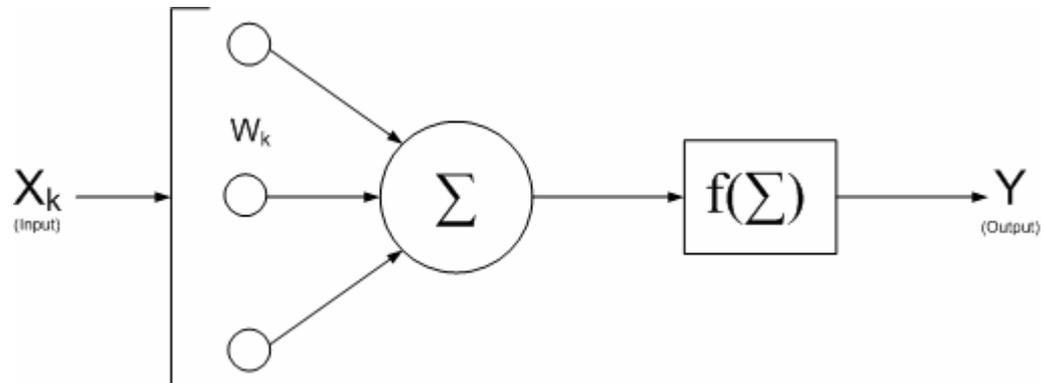


Figure III.1 *Modèle de neurone formel, selon Mc Culloch et Pitts*

Les sigmoïdes sont de loin les fonctions les plus utilisées dans les ANN. La fonction logistique est définie par :

$$g(x) = \frac{1}{1 + e^{-\beta x}} \quad (\text{III.2})$$

Où β est le paramètre de pente de la sigmoïde.

Les fonctions d'activations [29] les plus utilisées sont :

- seuil
- linéaire par morceau
- sigmoïde
- Gaussienne

III.2.3 Architecture

L'exemple le plus simple de réseau de neurones est souvent donné par le perceptron multicouches (PMC) [31]. Dans un perceptron, plusieurs couches contenant des neurones sont connectées entre elles de l'entrée vers la sortie. Afin d'illustrer un peu ces propos, le dessin suivant de la Figure III.2 représente le schémas type d'un perceptron à trois couches :

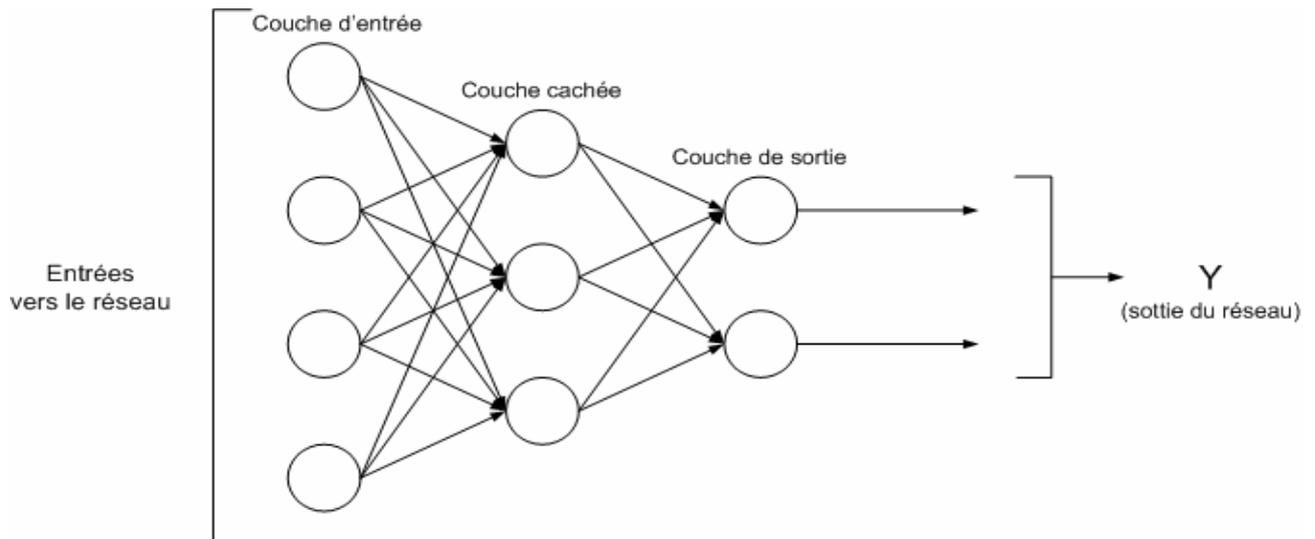


Figure III.2 *Perceptron à trois couches*

- Couche d'entrées : c'est la couche des neurones d'entrée, les neurones du réseau qui perçoivent les données du problème.
- Couche cachée : les neurones cachés qui ne sont ni à l'entrée ni à la sortie du réseau. les neurones cachés n'ont aucun lien direct avec l'utilisateur.
- Couche de sorties : un sous-ensemble de neurones dont l'activation sera interprétée comme la réponse du réseau, ce sont les neurones de sortie [33].

III.2.4 Grands types de réseaux

Il existe plusieurs types de réseaux de neurones pour plusieurs applications, parmi lesquels nous citerons les plus connus et les plus utilisés :

III.2.4.1 *Perceptrons multicouches*

La structure est relativement simple : une couche d'entrée, une couche de sortie et une ou plusieurs couches cachées (Figure III.2). Chaque neurone n'est relié qu'aux neurones des couches précédentes donc ces réseaux ne possèdent pas de connexions intra-couches, et les connexions inter-couches (pouvant être complètes ou pas) se font uniquement dans le sens de la propagation du signal. La fonction d'activation utilisée est en générale une somme pondérée. Le développement de l'algorithme d'apprentissage par rétropropagation a rendu ces réseaux très populaires, tant chez les chercheurs que chez les utilisateurs des ANN [29,32].

III.2.4.2 *Réseaux de Kohonen*

Les réseaux de Kohonen décrivent en fait trois familles de réseaux de neurones [29] :

III.2.4.2.1 VQ (Vector Quantization)

Introduite par Grossberg (1976), la quantification vectorielle est une méthode généralement qualifiée d'estimateur non supervisé de densité. Elle permet de retrouver des groupes sur un ensemble de données [29].

III.2.4.2.2 SOM (Self Organizing Map)

Les SOM sont issus des travaux de Fausett (1994) et Kohonen (1995). Ces réseaux sont très utilisés pour l'analyse de données. Ils permettent de cartographier en deux dimensions et de distinguer des groupes dans des ensembles de données [29].

III.2.4.2.3 LVQ (Learning Vector Quantization)

Les réseaux utilisant la méthode LVQ ont été proposés par Kohonen (1988). Des trois types de réseaux présentés ici, la LVQ est la seule méthode qui soit réellement adaptée à la classification de données par "recherche du plus proche voisin" [29].

III.2.4.3 Réseaux de Hopfield

Ces réseaux sont des réseaux récurrents, un peu plus complexes que les perceptrons multicouches. Chaque cellule est connectée à toutes les autres et les changements de valeurs de cellules s'enchaînent en cascade jusqu'à un état stable. Ces réseaux sont bien adaptés à la reconnaissance de formes [29].

III.2.4.4 Réseaux à Résonance Adaptative (ART)

Ces modèles ont été développés par Carpenter et Grossberg (ART-1, ART-2, ARTMAP). Ils possèdent un réservoir de cellules de sortie qui ne sont utilisées que si nécessaire. Une cellule sera dite *recrutée* (committed) ou *libre* (uncommitted) si elle est utilisée ou non utilisée. Ces réseaux sont bien adaptés à la Classification et la Catégorisation au sein d'une classe [29].

III.2.4.5 Réseau à fonction radiale (RBF)

Le réseau RBF est un réseau de neurones utilise l'apprentissage supervisé. Il s'agit d'une '*spécialisation*' d'un PMC. Le réseau possède trois couches comme le PMC, où la couche cachée contient des neurones RBF qui contiennent chacune une fonction d'activation gaussienne.

III.2.5 Etapes de la conception d'un réseau de neurone

La conception de tout ANN suit les étapes suivantes :

III.2.5.1 *Choix et préparation des échantillons*

Le processus d'élaboration d'un réseau de neurones commence toujours par le choix et la préparation des échantillons de données. Comme dans les cas d'analyse des données, cette étape est cruciale et va aider le concepteur à déterminer le type de réseau le plus approprié pour résoudre son problème. La façon dont se présente l'échantillon conditionne : le type de réseau, le nombre de cellules d'entrée, le nombre de cellules de sortie et la façon dont il faudra mener l'apprentissage, les tests et la validation [29].

III.2.5.2 *Elaboration de la structure du réseau*

La structure du réseau dépend étroitement du type des échantillons. Il faut d'abord choisir le type de réseau : un perceptron standard, un réseau de Hopfield, un réseau de Kohonen, un ARTMAP,...etc. Dans le cas du perceptron par exemple, il faudra aussi choisir le nombre de neurones dans la couche cachée. Plusieurs méthodes existent et on peut par exemple prendre une moyenne du nombre de neurones d'entrée et de sortie, ou encore la méthode de corrélation [30,34].

III.2.5.3 *Apprentissage*

L'apprentissage consiste tout d'abord à calculer les poids optimaux des différentes connexions, en utilisant un échantillon. La méthode la plus utilisée est la rétropropagation [29,31] : on introduit des valeurs dans les cellules d'entrée et en fonction de l'erreur obtenue en sortie (la règle delta), on corrige les poids accordés aux pondérations. C'est un cycle qui est répété jusqu'à ce que le critère d'arrêt soit atteint.

Il existe deux types d'apprentissage :

- Apprentissage supervisé
- Apprentissage non supervisé.

III.2.5.4 *Validation et tests de généralisation*

Alors que les tests de généralisations concernent la vérification des performances d'un réseau de neurones hors échantillon et sa capacité de généralisation, la validation est parfois utilisée lors de l'apprentissage. Une fois le réseau calculé, il faut toujours procéder à des tests afin de vérifier que notre réseau réagit correctement. Il y a plusieurs méthodes pour effectuer une validation, dans le cas général, une partie de l'échantillon est simplement écarté de l'échantillon d'apprentissage et conservé pour les tests hors échantillon [34].

III.3 Application de ANN dans la protection numérique

Les applications des réseaux de neurones (ANN) dans le domaine de protection sont de plus en plus nombreuses [12,39]. Le modèle du réseau neuronal le plus utilisé est le perceptron multicouche (PMC) [10,28,38,40,42,44,45] , mais ces dernières années il y a plus en plus de nouveaux types de ANN utilisés comme les RBF [13,36,37,39,46], les réseaux SOM [35,43,47], les réseaux LVQ [41] , les réseaux de type ART [48] , et plusieurs autres architectures [42,43,50].

- Les ANN sont utilisés surtout pour la classification des défauts [15] ou un PMC 30 entrées 2 couches cachées de dimensions respectives (20,15), 11 sorties correspondant aux 11 types de défauts a été utilisé. Un code de calcul NETOMAC [50] a donné de bons résultats.
- D'autres travaux ont utilisé 3 ANN PMC avec sortie binaire qui sera décodée pour connaître le type de défaut, en utilisant en entrée les phaseurs tension et courant [13].
- Pour la détection, la référence [8] a utilisé un PMC contenant une entrée de 56 neurones (tensions et courant échantillonnés), 18 neurones cachées et un neurone de sortie qui donne la valeur 1 dans le cas ou il y a un défaut, et 0 si non.
- Pour la localisation un PMC (6 entrées contenant les 6 modules des tensions et courants, 20 neurones cachées et 1 neurone de sortie donnant la distance du défaut) a été proposé [8].
- D'autres travaux ont utilisé le PMC pour la détection, la classification et la localisation des défauts [51, 52,53].
- D'autres applications des ANN dans la protection électrique comme le diagnostique des défauts sont également présentées dans la littérature [10,44].

III.4 Application de ANN sur notre modèle

Dans cette partie, nous allons appliquer la technique des réseaux de neurones pour détecter, classifier et localiser n'importe quelle type de défaut (court-circuit à la terre) simulé sur notre modèle de ligne (bloc simulink figure II.2). Ceci est effectué en se basant sur les phaseurs des tensions et des courants issus des deux extrémités de la ligne qui sont estimés par la méthode des moindres carrés.

Pour chaque étape d'analyse (détection, classification et localisation), nous avons élaboré un programme sous environnement Matlab basé sur la technique des réseaux de neurones et qui contient les deux étapes suivantes :

- Génération de l'ensemble d'apprentissage.
- Conception du réseau de neurones.

III.4.1 Génération de l'ensemble d'apprentissage

Pour les trois réseaux de neurones, les entrées utilisées sont les modules et les phases des composantes symétriques des phaseurs estimés (des tensions et des courants), soient 24 entrées avec l'ordre suivant :

1. Les modules des composantes symétriques des tensions et des courants de première extrémité dans l'ordre 1, 2, 0. (1 : directe ; 2 : inverse ; 0 : homopolaire)
2. Les modules des composantes symétriques des tensions et des courants de deuxième extrémité dans l'ordre 1, 2, 0.
3. Les phases des composantes symétriques des tensions et des courants de première extrémité dans l'ordre 1, 2, 0.
4. Les phases des composantes symétriques des tensions et des courants de deuxième extrémité dans l'ordre 1, 2, 0.

La génération de l'ensemble d'apprentissage est l'étape la plus importante dans la conception de notre réseau de neurones. Elle nécessite une base de données réaliste reflétant le comportement du réseau électrique pendant l'apparition des défauts.

III.4.1.1 Ensemble d'apprentissage utilisé pour la détection

La matrice d'apprentissage pour cette étape d'analyse est composée de 90 lignes et 25 colonnes. Sachant que les colonnes de 1 jusqu'à 24 sont les entrées et la colonne 25 est la sortie désirée qui prend la valeur 1 pendant l'apparition d'un défaut et la valeur 0 sinon.

Chaque ligne de la matrice d'apprentissage représente un point de fonctionnement du réseau pour des conditions données. On a obtenu les 90 points de fonctionnement du réseau par la variation de la charge des deux générateurs (du réseau simulé) entre 1 et 80 GVA. 48 points représentent le comportement du réseau à l'état équilibré et les 42 points restants représentent le comportement du réseau pendant l'apparition des différents types des courts-circuits à la terre (monophasé, biphasé et triphasé) et ceci pour différentes charges et distances simulées.

III.4.1.2 Ensemble d'apprentissage utilisé pour la classification

La matrice d'apprentissage qu'on a utilisée pour la classification est composée de 167 lignes et 25 colonnes. Les colonnes de 1 jusqu'à 24 représentent les entrées et la 25^{ème} colonne représente la sortie désirée qui prend la valeur 1 lorsque le défaut est monophasé, la valeur 2 lorsque le défaut est biphasé et finalement La valeur 3 lorsque le défaut est triphasé. Chaque ligne de la matrice représente l'état du réseau pendant l'apparition d'un défaut.

Pour la construction de cette matrice, 15 niveaux de charge entre 50% et 150% de la charge nominale (35 GVA) sont simulés avec variation de la distance de défaut pour les trois différents types de défauts.

III.4.1.3 Ensemble d'apprentissage utilisé pour la localisation

Pour cette partie, une matrice d'apprentissage de 167 lignes et 25 colonnes a été utilisée. Les colonnes de 1 jusqu'à 24 représentent les entrées, tan disque la 25^{ème} colonne représente la sortie désirée qui est la distance de défaut.

Dans cette partie, nous avons simulé les trois types de défauts pour 15 niveaux de charge qui ont été sélectionnés entre 50% et 150% de la charge nominale (35 GVA) et pour 6 différentes distances : 10, 30, 64, 80, 90 ,110 km.

L'apprentissage des trois réseaux de neurones proposés est basé sur l'utilisation d'un algorithme dit de rétropropagation [29,32]. Ce dernier corrige les poids des connexions entre les neurones des différentes couches initialisés aléatoirement en fonction des erreurs commises.

III.4.2 Conception du réseau de neurones

Les trois réseaux de neurones qu'on a construits pour les trois étapes d'analyse des défauts ont presque la même structure. Chaque réseau se composant de trois couches.

- Une couche d'entrée contenant 24 neurones qui sont les modules et les phases des composantes des tensions et des courants des extrémités de la ligne.
- Une couche cachée contenant le nombre de neurones nécessaires pour satisfaire le critère de la construction incrémentale, que nous détaillons par la suite.
- Une couche de sortie contenant un seul neurone pour les trois réseaux: pour la détection, ce neurone prend deux valeurs (1 : il y a défaut, 0 : sinon), pour la classification ce neurone prend trois valeurs (1 : défaut monophasé, 2 : défaut biphasé, 3 : défaut triphasé), pour la localisation ce neurone prend une seule valeur qui est la distance de défaut.

Le choix du nombre de neurones de la couche cachée pour les trois réseaux de neurones est effectué en utilisant le critère de 'la construction incrémentale' [30,34] basée sur le calcul des indicateurs de performance (ε 'erreur quadratique moyenne' et ρ 'coefficient de corrélation') à partir de la matrice d'apprentissage en utilisant les deux relations suivantes :

$$\varepsilon = \sqrt{\frac{1}{E} \sum_{i=1}^E (d_i - f_i)^2} \quad (\text{III.1})$$

$$\rho = \frac{\sum_{i=1}^E (d_i - \bar{d})(f_i - \bar{f})}{\sqrt{\sum_{i=1}^E (d_i - \bar{d})^2 \sum_{i=1}^E (f_i - \bar{f})^2}} \quad (\text{III.2})$$

Sachant que : f_i est la sortie fournie par le pattern 'i'.

d_i est la sortie désirée qui correspond au pattern 'i'.

E est l'effectif d'ensemble d'apprentissage ou de test.

\bar{f} est la moyenne des f_i .

\bar{d} est la moyenne des d_i .

Le nombre de neurones choisi dans la couche cachée pour chaque réseau de neurones correspond à l'erreur quadratique la plus faible et au coefficient de corrélation le plus élevé [30]. Les résultats de calcul sont mentionnés sur le tableau II.1.

Tableau II.1 Erreurs quadratiques moyennes coefficients de corrélation

Nombre de neurones dans la couche cachée	Détection		Classification		Localisation	
	ε	ρ	ε	ρ	ε	ρ
10	0.0012	0.999	0.2988	0.9166	3.420	0.995
11	0.0012	0.999	0.3000	0.9148	4.381	0.992
12	0.0012	0.999	0.2927	0.9188	0.313	0.999
13	0.0012	0.999	0.2623	0.9356	0.277	0.999
14	0.0012	0.999	0.3068	0.9198	0.312	0.999
15	0.0010	0.999	0.2915	0.9194	0.316	0.999
16	0.0012	0.999	0.3118	0.9072	0.497	0.999
17	0.0012	0.999	0.3112	0.9090	6.227	0.984
18	0.0012	0.999	0.2685	0.9321	7.214	0.979
19	0.0012	0.999	0.3159	0.9132	5.355	0.988
20	0.0012	0.999	0.2967	0.9186	7.358	5.355

D'après le tableau II.1, le nombre de neurones qui satisfait le critère de 'la construction incrémentale' est 15 pour la détection, 13 pour la classification et la localisation.

Nous limitons les critères d'arrêts pour chaque réseau de neurones selon le nombre de cycles d'apprentissage à 20000 et l'erreur lorsqu'elle atteint la valeur 10^{-8} pour la détection et la valeur 10^{-5} pour la classification et la localisation.

III.4.3 Phase de test

Cette phase aura pour rôle de tester la capacité des trois réseaux construits. On a présenté pour chaque réseau dix entrées utilisées dans la phase d'apprentissage. Les résultats sont présentés sur les tableaux III.2, III.3 et III.4.

Tableau III.2 Résultats de phase de test pour l'ANN de détection

Niveau de charge en (GVA)	Type de défaut (court-circuit à terre)	Distance de défaut en (km)	Détection de défaut	
			Simulation en Matlab	ANN
45	A	90	1	0.999
37.5	A-C	80	1	1
20	A-B-C	64	1	0.999
30	A-B	80	1	1
17.5	A	64	1	1
65	Pas de défaut		0	0.001
14			0	0
22.5			0	0
70			0	0.001
15			0	0
Erreur moyenne de détection				0.08 %

Tableau III.3 Résultats de phase de test pour l'ANN de classification

Niveau de charge en (GVA)	Distance de défaut en (km)	Classe de défaut		
		Simulation en Matlab	ANN	
35	30	1	1	
42.5	90	2	1.96	
40	30	1	0.97	
50	10	2	2.03	
47.5	64	3	2.94	
17.5	30	3	3.03	
20	110	3	2.99	
20	90	1	0.99	
20	64	3	3.01	
17.5	90	2	1.99	
Erreur moyenne de classification				1.09 %

Tableau III.4 Résultats de phase de test pour l'ANN de localisation

Niveau de charge en (GVA)	Type de défaut (court-circuit à terre)	Distance de défaut en (km)		
		Simulation en Matlab	Moindres carrés	ANN
45	A	30	30.36	30.15
35	B	10	10.59	10.67
17.5	A-B	90	90	89.80
37.5	A-B-C	110	110.01	109.60
47.5	A-C	10	10	9.99
50	B	110	110.24	109.97
30	A	30	30.02	30.25
30	A-B-C	64	64.09	63.78
35	B-C	80	80.39	80.10
27.5	A-B-C	30	30.07	29.96
Erreur moyenne de localisation				0.36 %

III.4.4 Phase de généralisation

Cette phase aura comme rôle de tester la capacité de généralisation des trois réseaux de neurones. Pour effectuer cette opération, on a testé ces réseaux de neurones par des nouvelles entrées (niveaux de charge, type de défaut et distance de défaut) non incluses dans la phase d'apprentissage. Les résultats présentés sur les tableaux III.5, III.6 et III.7.

Tableau III.5 Résultats de phase de généralisation pour l'ANN de détection

Niveau de charge en (GVA)	Type de défaut (court-circuit à terre)	Distance de défaut en (km)	Détection de défaut	
			Simulation en Matlab	ANN
52.5	C	110	1	1.001
37.5	BC	80	1	0.834
35	AC	30	1	0.999
42.5	ABC	80	1	0.917
50	B	30	1	0.997
17.5	Pas de défaut		0	0
60			0	0
80			0	0
10			0	0.001
70			0	0.001
Erreur moyenne de la détection				5.12 %

Tableau III.6 Résultats de phase généralisation pour l'ANN de classification

Niveau de charge en (GVA)	Distance de défaut en (km)	Classe de défaut	
		Simulation en Matlab	ANN
52.5	110	1	0.97
35	110	3	2.95
48	10	2	1.97
52.5	64	3	2.94
21	64	2	1.97
31	10	3	2.81
35	10	2	1.91
40	30	2	1.99
42	10	1	0.97
25	64	1	1.01
Erreur moyenne de la classification			2.65 %

Tableau III.7 Résultats de phase de généralisation pour la localisation

Niveau de charge en (GVA)	Type de défaut (court-circuit à terre)	Distance de défaut en (km)		
		Simulation en Matlab	Moindres carrés	ANN
52.5	ABC	30	30.27	30.25
27.5	B	64	64.01	64.12
25	AB	64	64	64.21
47.5	BC	110	110.02	109.75
35	A	30	30.01	30.04
40	ABC	10	10.42	10.8
31	A	110	110.02	110.07
23	AC	80	80.01	79.97
52.5	C	110	110.18	110.07
35	A	110	109.99	110.07
Erreur moyenne de la localisation				0.26 %

III.4.5 Interprétation des résultats

La phase de test pour les trois ANN nous délivre une faible erreur ce qui signifie que ces ANN fonctionnent bien. Pour la phase de généralisation et après les erreurs mentionnées dans les trois tableaux III.5, III.6, III.7, nous pouvons dire que les trois ANN possèdent une bonne capacité de généralisation.

III.4.6 Implantation dans Simulink

Pour faciliter l'utilisation des trois réseaux de neurones simultanément dans la détection et la classification, une implantation des trois réseaux de neurones construits dans un bloc Simulink (sous l'environnement Matlab) contient trois afficheurs. Le premier pour la détection, le second

pour la classification et le troisième pour la localisation. La figure III.3 représente le schéma bloc de Simulink utilisé dans cette partie :

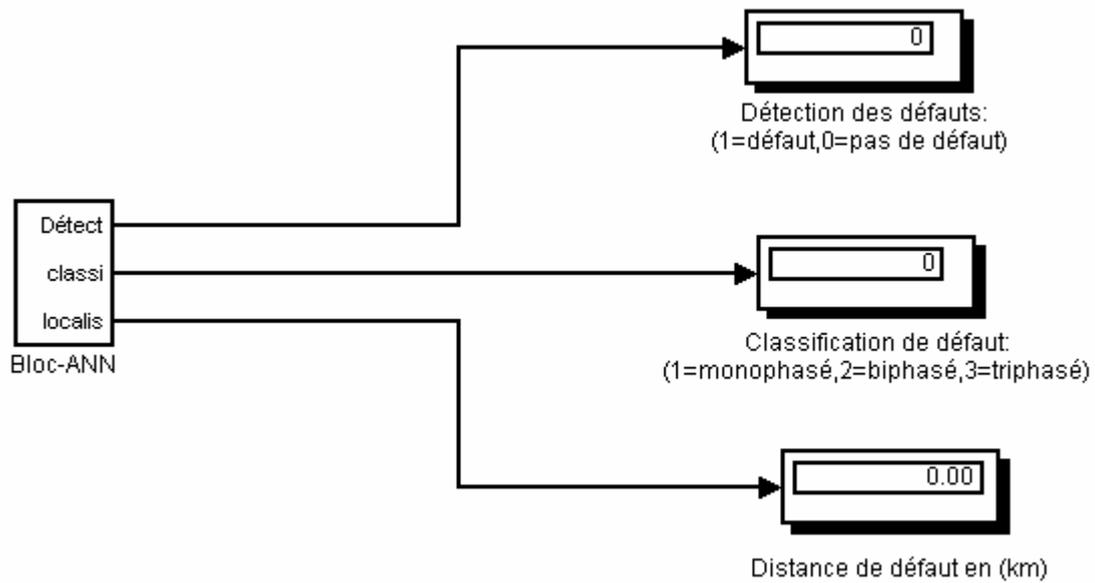


Figure III.3 Schéma bloc des trois ANN utilisés dans le Simulink

Pour tester le fonctionnement du bloc présenté sur la figure III.3, nous avons présenté à l'entrée des nouveaux points de fonctionnement non inclus dans les phases précédentes (phase d'apprentissage, de test et de généralisation) des trois ANN. Les résultats obtenus sont regroupés dans le tableau II.8.

Tableau II.8 Résultat Bloc-ANN

Paramètres simulés			Résultats obtenus Bloc-ANN		
Niveau de charge en (GVA)	Type de défaut (court-circuit_terre)	Distance de défaut en (km)	Afficheur (1) détection	Afficheur (2) classification	Afficheur (3) Localisation en (km)
41	A-B-C	50	1	3	49.97
17	A-B	75	1	2	77
66	A	100	1	1	98.82
90	Pas de défaut		0	0	0

Le tableau III.8 nous indique que le Bloc-ANN donne de bons résultats avec des erreurs moyennes nulles pour la détection et la classification et avec une erreur moyenne qui ne dépasse pas 1% pour la localisation.

III.5 Conclusion

Dans ce chapitre, nous avons cité les différentes étapes essentielles pour la construction d'un réseau de neurone artificiel à trois couches en se basant sur l'algorithme de rétropropagation. Nous avons montré la possibilité d'utiliser ce type de ANN pour détecter, classifier et localiser les défauts qui apparaissent sur les lignes de transport d'énergie électrique. Les résultats obtenus laissent entrevoir une application en temps réel de ces architectures avec des performances appréciables.

Afin de gagner en temps et en effort de calcul, nous nous sommes orientés vers une deuxième approche qui est l'utilisation des algorithmes génétiques pour optimiser les entrées des ANN. Etude qui fera l'objet du chapitre suivant.

IV.1 Introduction

Les algorithmes génétiques (GA) représentent une famille assez riche et très intéressante d'algorithmes d'optimisation stochastique fondés sur les mécanismes de la sélection naturelle et de la génétique [54]. Les champs d'application sont fort diversifiés. On les retrouve aussi bien en théorie des graphes qu'en compression d'images numériques ou encore en programmation automatique et en reconnaissance de formes et aussi en apprentissage des réseaux de neurones (Renders, 1995) [62]. Le choix des GA parmi d'autres méthodes se justifie en fonction des quatre propriétés suivantes [54] :

- Les GA utilisent un codage des paramètres et non les paramètres eux-mêmes.
- Les GA travaillent sur une population de points, au lieu d'un point unique.
- Les GA n'utilisent que les valeurs de la fonction étudiée, pas sa dérivée ou une autre connaissance auxiliaire.
- Les GA utilisent des règles de transition probabilistes, et non déterministes.

Les principes de base des GA ont été développés par Holland [53]. Ils ont été inspirés par le mécanisme de sélection naturelle (élaboré par Charles Darwin 1859) [62] où les meilleurs candidats sont probablement les mieux adaptés aux conditions de concurrence.

Nous allons voir dans ce chapitre quelques concepts fondamentaux sur les algorithmes génétiques et son application pour l'optimisation des paramètres d'entrée des ANN pour l'analyse des défauts dans les lignes des réseaux électriques.

IV.2 Principe des algorithmes génétiques

La technique des GA utilise alors une analogie directe avec l'évolution naturelle. À travers la méthode d'évolution génétique, une solution optimale peut être trouvée et représentée par le dernier gagnant de la technique génétique [56]. Ces algorithmes sont simples et très performants dans la recherche d'une solution optimale. Les GA fonctionnent avec une population regroupant un ensemble d'individus appelés chromosomes. Chaque chromosome est constitué d'un ensemble de gènes. Pour chaque individu on attribue une valeur calculée par une fonction appelée fonction d'adaptation ou fitness. En pratique, à partir d'une population, des chromosomes sont générés d'une façon aléatoire lors de l'initialisation. Dans chaque cycle d'opérations génétiques, une nouvelle population appelée génération est créée à partir des chromosomes de la population courante. Pour cela certains chromosomes appelés 'parents' sont sélectionnés afin d'élaborer les opérations

génétiques. Les gènes de ces parents sont mixés et recombinaison pour la production d'autres chromosomes appelés 'enfants' constituant la nouvelle génération [30].

Les étapes de GA sont répétées durant t cycles (Figure IV.1) [63]. L'arrêt de l'algorithme est fixé d'après un critère qui peut être adopté lorsque :

- Le nombre de génération fixé initialement a été atteint.
- La valeur de la fonction d'adaptation a atteint une valeur fixée a priori.

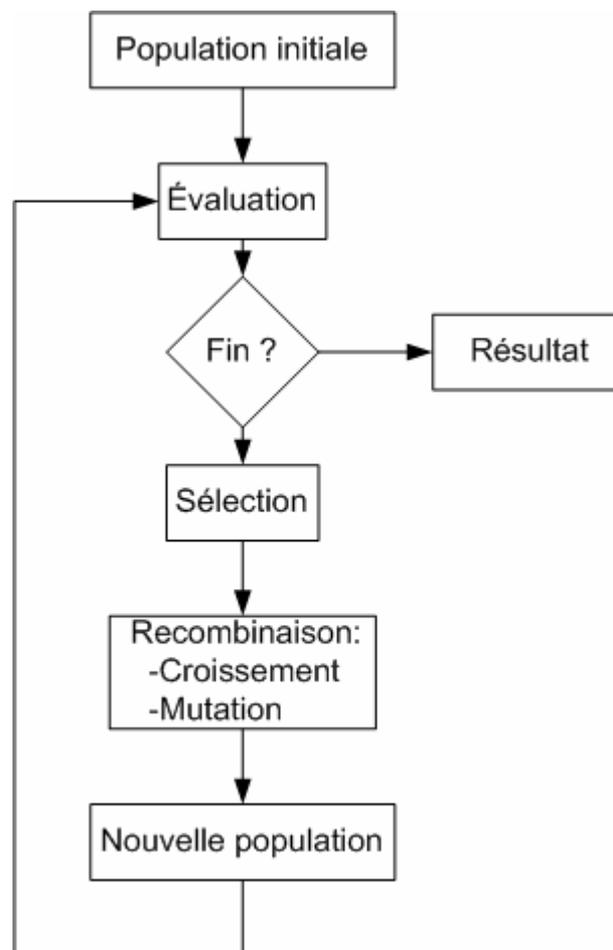


Figure IV.1 Organigramme d'un Algorithme Evolutionnaire

On peut résumer que GA est fondé sur :

- Une représentation chromosomique des solutions du problème.
- Une méthode pour créer une population initiale de solutions.
- Une fonction d'évaluation (fitness) pour classer les solutions en fonction de leurs aptitudes.
- Des opérateurs génétiques qui définissent la manière dont les caractéristiques génétiques des parents sont transmis aux descendants (enfants).
- Les valeurs des paramètres utilisés par GA.

IV.3 Etapes d'un algorithme génétique

Dans ce qui suit, nous allons décrire brièvement les différentes étapes d'un algorithme génétique :

IV.3.1 Codage des chromosomes

Un chromosome est un ensemble de paramètres (gènes) qui sont reliés entre eux pour former une chaîne de valeurs. La représentation la plus utilisée est la représentation binaire (0 ou 1) [54, 55, 56, 57, 58, 62]. Soit la notation de la représentation du chromosome C suivante :

$$C = (c1, c2, \dots, ci, \dots, cL)$$

Où L représente le nombre de variables dans le chromosome et ci représente le $i^{\text{ème}}$ gène du chromosome C avec une représentation de type binaire ou réelle [64].

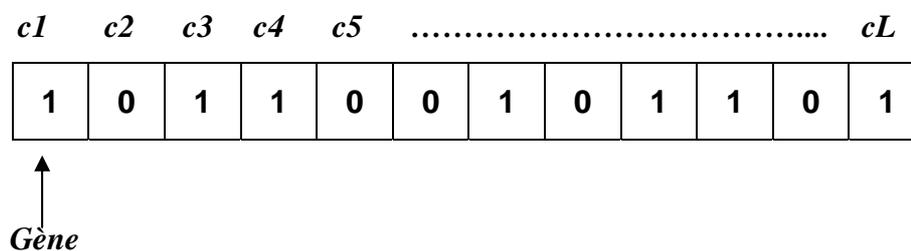


Figure IV.2 Chromosome en codage binaire

IV.3.2 Initialisation de la population

La population initiale est constituée d'un ensemble d'individus (chromosomes) générés aléatoirement. Le nombre d'individus d'une population où la taille de la population constitue un paramètre important pour le GA qu'il faudra déterminer. La représentation de la population P est :

$$P = (C1, \dots, C2, \dots, Ci, \dots, Cta)$$

Où Ci représente la $i^{\text{ème}}$ chromosome dans la population et ta représente le nombre de chromosomes dans la population [58, 62, 63].

IV.3.3 Fonction d'évaluation

La fonction d'évaluation ou d'adaptation (fitness) associe un coût à chaque chromosome. Il faut distinguer entre la fonction objective et la fonction d'adaptation. Dans certains cas, elles peuvent être identiques mais en général la fonction d'adaptation dépend de la fonction objective, laquelle dépend de la nature du problème à résoudre.

Il existe des méthodes pour la définition des fonctions à optimiser qui dépendent du problème à résoudre. Parmi ces méthodes de fonction d'adaptation, on trouve : no scaling, linear scaling, sigma truncation, power law scaling et ranking [30, 59, 62].

IV.3.4 Méthodes de sélection

Pour générer de nouveaux descendants (enfants), des parents sont sélectionnés puis des opérations génétiques leur sont appliquées. Pour sélectionner les meilleurs chromosomes dans une population, certaines techniques proposées par différents auteurs sont les suivantes : rank selection, roulette wheel selection, tournament selection, uniform selection [30, 59, 62].

IV.3.5 Opérateurs génétiques de reproduction

Durant la phase de reproduction de le GA, des individus de la population sont sélectionnés d'après la méthode de sélection choisie et sont recombinaison produisant des enfants de la prochaine génération. Cette phase utilise des mécanismes de reproduction qui sont : 'le croisement' et 'la mutation' [30, 63].

Les méthodes de reproduction proposées dans la littérature concernent les chromosomes dont la représentation des gènes est binaire. Dans le cas d'un problème d'optimisation où les gènes du chromosome sont des nombres réels, avant d'effectuer les opérations de reproduction, les gènes du chromosome sont convertis en bits (32 ou 16 bits), puis les opérations de reproduction sont effectuées sur cette représentation binaire [30].

IV.4 Choix des paramètres d'un algorithme génétique

Pour lancer le GA, il faut définir certains paramètres tels que : la taille de la population, les probabilités de mutation et de croisement et le nombre de générations. Il est difficile de les fixer ou de trouver les meilleurs avant l'exécution de l'algorithme [60, 61]. C'est un problème de réglage qui doit être optimisé pour chaque type de problème traité.

Cela constitue une part importante du travail de l'expérimentateur. Dans la littérature, la définition de ces paramètres diffère d'une application à une autre. Les paramètres que nous abordons sont : la taille de la population, le nombre de générations et les probabilités de reproduction [62].

IV.5 Applications de l'algorithme génétique dans la protection électrique

L'algorithme génétique est surtout appliqué pour l'optimisation des ANN [64, 66, 67], plusieurs travaux ont été effectués par les chercheurs comme Y.H.Song et al. [65] qui ont utilisé les algorithmes génétiques pour optimiser les poids du ANN et améliorer l'apprentissage et la performance du réseau neuronal pour la classification des défauts. D'autres ont utilisé le GA pour optimiser les paramètres l'algorithme de localisation de défaut comme M. Kezunovic, P.E. Eugene et E. Webb [66].

IV.6 Application des GA pour optimiser les entrées des ANN

Nous avons cité dans les parties précédentes les notions de base d'un algorithme génétique simple. Dans cette partie, nous allons essayer d'élaborer un algorithme génétique qui aura pour fonction d'optimiser les entrées des trois réseaux de neurones étudiés dans le chapitre précédent. Une comparaison entre les sorties délivrés de réseaux de neurones avant l'optimisation et après l'optimisation est alors effectuée pour les mêmes entrées. Celle ci nous permettra d'aboutir à une conclusion sur l'efficacité des algorithmes génétiques.

IV.6.1 Création des GA

Pour la création des trois GA qui correspondent aux trois ANN étudiés précédemment nous avons suivis les étapes suivantes :

IV.6.1.1 Génération d'une population initiale

La population initiale utilisée pour les trois GA est composée de 27 individus, trois individus pour chaque degré de cardinalité (le nombre d'entrées choisies parmi les 24) allant de 5 à 13 pour les trois étapes d'analyse (détection, localisation, classification).

Dans ce cas, la plupart des 24 paramètres d'entrées sont contrôlables et leurs choix s'effectue aléatoirement.

IV.6.1.2 Codages des individus

Chaque individu est un ensemble de plusieurs gènes dont chacun peut prendre deux valeurs suivant le choix ou non de ce gène qui s'effectue aléatoirement. S'il est choisi, il prend la valeur 1, sinon il prend la valeur 0. Donc chaque individu peut être considérée comme un vecteur binaire. Le nombre des gènes choisis de chaque individu est relié au degré de cardinalité de cet individu.

IV.6.1.3 Evaluation de la fonction d'adaptation

Pour évaluer la fonction d'adaptation des trois GA, nous avons suivis les étapes suivantes :

1. La conception de 9 réseaux de neurones, allant de 5 à 13, en décodant tous les 1 des individus.
2. La comparaison entre les sorties délivrés par les 9 réseaux de neurones (S_i , avec $i = 5$ à 13) et la sortie délivrée par le réseau de neurone principal (S).
3. Le calcul d'erreur R pour chaque AG en utilisant la formule suivante :

$$R = \sum (S_i - S)^2 \quad (\text{IV.1})$$

Les GA cherchent à minimiser l'erreur calculée dans l'étape trois pour avoir le meilleur individu qui correspond à la plus petite erreur.

IV.6.1.4 Sélection

Nous avons sélectionné le meilleur individu qui survivra à la génération suivante 'principe d'élitisme'.

IV.6.1.5 Croisement

Pour les trois GA, le croisement s'effectue en un seul point placé arbitrairement, pour créer le codage génétique d'un individu fils.

IV.6.1.6 Critère d'arrêt

Pour les trois GA, nous avons pris comme critère d'arrêt le nombre de générations, que nous avons fixé à 10.

Le schéma présenté sur la figure IV.2 fait la synthèse des différentes étapes de calcul que nous avons suivies pendant la création des trois GA :

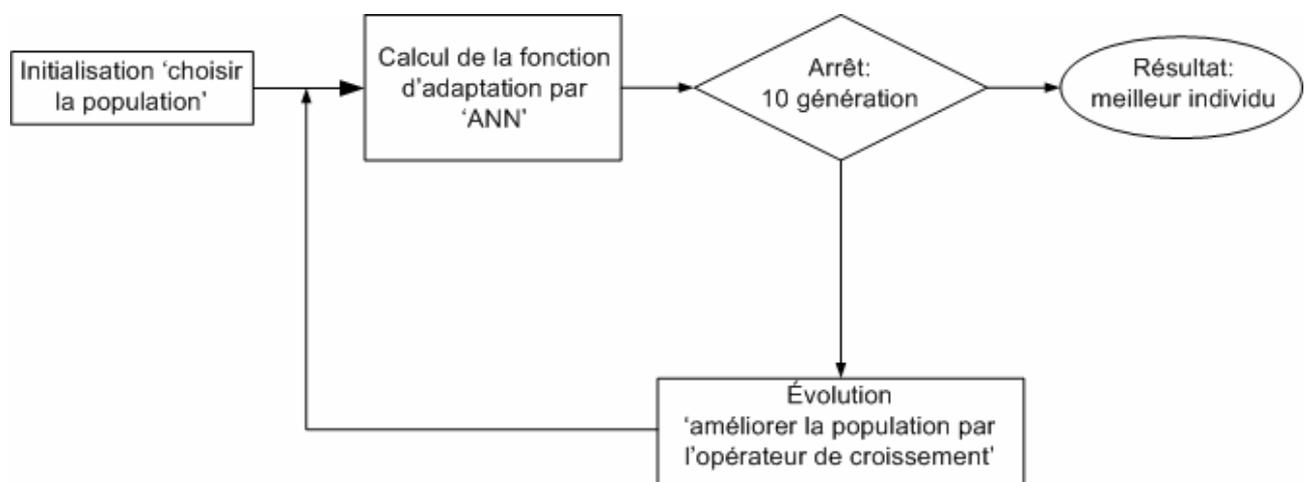


Figure IV.2 Schéma bloc de étapes suivies dans la création des GA

IV.6.2 Résultats de programmation

Nous avons élaboré sur environnement Matlab trois programmes en suivant les étapes précédentes de calcul. Nous sommes arrivés finalement à réduire les vecteurs d'entrées en fonction des différents degrés de cardinalité. Les meilleurs individus de chaque degré de cardinalité sont représentés dans les tableaux IV.1, IV.2 et IV.3

Tableau IV.1 Les meilleurs individus pour le GA de détection

No	Paramètres	Degrés de cardinalité								
		5	6	7	8	9	10	11	12	13
1	V_{d1}	0	0	0	0	1	0	0	1	1
2	V_{i1}	0	0	1	0	1	0	1	1	1
3	V_{h1}	0	0	0	1	1	0	1	1	0
4	I_{d1}	0	1	1	1	0	0	1	0	1
5	I_{i1}	0	0	0	0	0	1	0	0	1
6	I_{h1}	0	0	0	1	0	0	1	1	0
7	V_{d2}	0	1	1	0	0	0	1	0	1
8	V_{i2}	1	1	0	0	0	1	1	1	0
9	V_{h2}	0	0	1	0	1	1	1	1	1
10	I_{d2}	0	0	0	0	0	1	1	1	1
11	I_{i2}	0	0	0	0	1	1	0	0	0
12	I_{h2}	0	0	0	0	0	0	1	0	1
13	$\varphi_{V_{d1}}$	0	0	0	1	0	0	0	0	0
14	$\varphi_{V_{i1}}$	1	0	1	0	1	0	0	0	1
15	$\varphi_{V_{h1}}$	1	0	1	0	1	0	1	1	0
16	$\varphi_{I_{d1}}$	0	0	0	1	0	0	0	1	0
17	$\varphi_{I_{i1}}$	0	1	1	1	0	1	1	0	0
18	$\varphi_{I_{h1}}$	1	1	0	0	0	1	0	0	0
19	$\varphi_{V_{d2}}$	0	0	0	0	0	1	0	1	1
20	$\varphi_{V_{i2}}$	0	1	0	0	1	0	0	1	1
21	$\varphi_{V_{h2}}$	1	0	0	1	0	0	0	0	1
22	$\varphi_{I_{d2}}$	0	0	0	0	0	0	0	0	0
23	$\varphi_{I_{i2}}$	0	0	0	1	0	1	0	1	0
24	$\varphi_{I_{h2}}$	0	0	0	0	1	1	0	0	1
Erreur (R)		$6.8 e^{-6}$	2.4	3.3	2.5	$7.2e^{-1}$	2.45	$2.6e^{-1}$	$2.5e^{-1}$	$2.5e^{-1}$

Tableau IV.2 Les meilleurs individus pour le GA de classification

N o	Paramè tres	Degrés de cardinalité								
		5	6	7	8	9	10	11	12	13
1	V_{d1}	0	0	0	0	0	0	1	1	1
2	V_{i1}	1	0	0	0	1	0	1	0	0
3	V_{h1}	0	0	1	0	0	0	0	1	1
4	I_{d1}	0	1	1	0	0	1	0	0	1
5	I_{i1}	0	0	0	0	0	0	0	1	0
6	I_{h1}	1	1	0	1	0	1	0	1	1
7	V_{d2}	1	1	1	0	1	1	1	0	0
8	V_{i2}	0	0	0	1	0	0	0	1	0
9	V_{h2}	1	0	0	0	0	1	0	0	0
10	I_{d2}	0	0	1	1	0	0	1	0	0
11	I_{i2}	1	0	0	0	0	1	0	1	0
12	I_{h2}	0	1	0	1	0	0	0	0	1
13	$\varphi_{V_{d1}}$	0	0	0	0	1	0	1	0	1
14	$\varphi_{V_{i1}}$	0	0	0	1	1	0	1	0	0
15	$\varphi_{V_{h1}}$	0	0	0	0	1	1	0	1	1
16	$\varphi_{I_{d1}}$	0	1	0	1	0	1	0	0	1
17	$\varphi_{I_{i1}}$	0	0	1	0	1	1	1	1	1
18	$\varphi_{I_{h1}}$	0	0	0	0	0	0	0	1	0
19	$\varphi_{V_{d2}}$	0	1	0	1	0	0	0	0	1
20	$\varphi_{V_{i2}}$	0	0	0	0	1	1	1	1	0
21	$\varphi_{V_{h2}}$	0	0	0	0	1	0	1	1	1
22	$\varphi_{I_{d2}}$	0	0	1	0	0	0	0	1	1
23	$\varphi_{I_{i2}}$	0	0	1	1	1	1	1	0	1
24	$\varphi_{I_{h2}}$	0	0	0	0	0	0	1	0	0
Erreur (R)		0.0655	0.02567	0.0373	0.0165	0.0140	1.66e⁻³	4.06e⁻³	1.59e⁻³	1.67e⁻³

Tableau IV.3 Les meilleurs individus pour le GA de localisation

No	Paramètres	Degrés de cardinalité								
		5	6	7	8	9	10	11	12	13
1	V_{d1}	0	1	0	0	0	0	0	1	1
2	V_{i1}	0	0	1	1	0	0	0	0	1
3	V_{h1}	0	0	0	0	1	1	0	0	0
4	I_{d1}	1	1	0	1	0	1	1	1	1
5	I_{i1}	0	0	1	0	0	1	0	0	0
6	I_{h1}	1	0	0	0	0	0	0	1	0
7	V_{d2}	1	0	0	0	0	0	0	1	1
8	V_{i2}	0	1	1	0	1	1	1	0	1
9	V_{h2}	0	0	0	1	0	1	0	1	1
10	I_{d2}	0	0	0	1	0	0	1	1	1
11	I_{i2}	0	1	0	0	0	1	0	1	0
12	I_{h2}	0	0	1	0	0	0	0	0	0
13	$\varphi_{V_{d1}}$	0	0	0	0	1	0	1	0	0
14	$\varphi_{V_{i1}}$	0	0	1	0	1	1	1	1	0
15	$\varphi_{V_{h1}}$	0	0	0	1	0	0	0	1	0
16	$\varphi_{I_{d1}}$	0	1	0	1	0	0	1	0	1
17	$\varphi_{I_{i1}}$	0	0	1	1	1	0	1	1	1
18	$\varphi_{I_{h1}}$	0	0	0	0	0	0	0	1	0
19	$\varphi_{V_{d2}}$	1	1	0	0	0	0	1	0	1
20	$\varphi_{V_{i2}}$	0	0	0	0	1	1	0	1	1
21	$\varphi_{V_{h2}}$	0	0	0	0	1	0	1	0	1
22	$\varphi_{I_{d2}}$	1	0	0	0	0	1	1	0	0
23	$\varphi_{I_{i2}}$	0	0	1	1	1	0	1	0	1
24	$\varphi_{I_{h2}}$	0	0	0	0	1	1	0	0	0
Erreur (R)		0.482	0.028	0.802	0.024	0.844	0.132	0.001	0.011	0.031

A partir des trois tableaux VI.1, VI.2 et VI.3 nous pouvons tirer le meilleur individu qui correspond à l'erreur la plus petite pour chaque entrée (parmi les entrées des trois ANN) et qui sont les suivants :

- **Pour la détection**

L'application des GA sur les entrées des ANN de détection, nous a permis de réduire le nombre de ces entrées de 24 à 5 entrées qui sont : $V_{i2}, \varphi_{V_{i1}}, \varphi_{V_{h1}}, \varphi_{I_{h1}}, \varphi_{V_{h2}}$.

- **Pour la classification**

L'application des GA sur les entrées des ANN de classification, nous a permis de réduire le nombre de ces entrées de 24 à 12 entrées qui sont : $V_{d1}, V_{h1}, I_{i1}, V_{i2}, I_{h2}, \varphi_{V_{d1}}, \varphi_{V_{i1}}, \varphi_{V_{h1}}, \varphi_{I_{d1}}, \varphi_{I_{h1}}, \varphi_{V_{d2}}, \varphi_{I_{d2}}, \varphi_{I_{i2}}$.

- **Pour la localisation**

L'application des GA sur les entrées des ANN de la localisation, nous a permis de réduire le nombre de ces entrées de 24 à 11 entrées qui sont : $I_{d1}, V_{h1}, I_{d2}, \varphi_{V_{d1}}, \varphi_{V_{i1}}, \varphi_{I_{d1}}, \varphi_{I_{i1}}, \varphi_{V_{d2}}, \varphi_{V_{h2}}, \varphi_{I_{d2}}, \varphi_{I_{i2}}$.

Finalement, une optimisation des vecteurs d'entrée pour les trois ANN étudiés dans le chapitre précédent en utilisant les GA a été effectuée. Nous avons obtenu trois réseaux de neurones optimisés (GANN) avec 5 neurones dans la couche d'entrée pour la détection, 12 neurones dans la couche d'entrée pour la classification et 11 neurones dans la couche d'entrée pour la localisation. Pour les deux couches restantes (cachée et de sortie), le nombre de neurones est le même utilisé dans les trois ANN étudiés précédemment.

Dans la phase d'apprentissage de ces trois GANN, nous avons utilisés les mêmes matrices utilisées dans la phase d'apprentissage des trois ANN.

IV.6.3 Phase de test

Pour que nous puissions faire la comparaison entre les ANN et les GANN, nous avons testé ces derniers avec des entrées utilisées dans la phase de test. Les résultats obtenus sont illustrés dans les tableaux IV.4, IV.5 et IV.6.

Tableau.IV.4 Phase de test de GANN pour la détection

Niveau de charge en (GVA)	Type de défaut (court-circuit à terre)	Distance de défaut en (km)	Détection de défaut		
			Simulation en Matlab	ANN	GANN
45	A	90	1	0.999	1.0001
37.5	A-C	80	1	1	1
20	A-B-C	64	1	0.999	0.9997
30	A-B	80	1	1	1
17.5	A	64	1	1	1
65	Pas de défaut		0	0.001	0.0007
14			0	0	0
22.5			0	0	0.0019
70			0	0.001	0
15			0	0	0
Erreur moyenne de détection				0.08 %	0.06 %

Tableau.IV.5 Phase de test de GANN pour la classification

Niveau de charge en (GVA)	Distance de défaut en (km)	Classe de défaut		
		Simulation en Matlab	ANN	GANN
35	30	1	1	0.976
42.5	90	2	1.96	2.023
40	30	1	0.97	0.979
50	10	2	2.03	1.916
47.5	64	3	2.94	2.980
17.5	30	3	3.03	3.001
20	110	3	2.99	3.002
20	90	1	0.99	1.001
20	64	3	3.01	3.012
17.5	90	2	1.99	2.029
Erreur moyenne de classification			1.09 %	1.03 %

Tableau.IV.6 Phase de test de GANN pour la localisation

Niveau de charge en (GVA)	Type de défaut (court-circuit à terre)	Distance de défaut en (km)			
		Simulation en Matlab	Moindres carrés	ANN	GANN
45	A	30	30.36	30.15	30.30
35	B	10	10.59	10.67	10.32
17.5	A-B	90	90	89.80	89.98
37.5	A-B-C	110	110.01	109.60	110
47.5	A-C	10	10	9.99	9.94
50	B	110	110.24	109.97	110.19
30	A	30	30.02	30.25	30.23
30	A-B-C	64	64.09	63.78	64.14
35	B-C	80	80.39	80.10	80.20
27.5	A-B-C	30	30.07	29.96	30.27
Erreur moyenne de localisation				0.36 %	0.3 %

IV.6.4 Phase de généralisation

Dans cette partie, nous testons la capacité des trois GANN pour la généralisation des résultats pour des entrées qui ont des paramètres différents non inclus dans la matrice d'apprentissage.

Nous avons testé les trois GANN avec les mêmes entrées utilisées dans la phase de généralisation des trois ANN. Les résultats obtenus sont regroupés dans les trois tableaux IV.7, IV.8, IV.9.

Tableau.IV.7 Phase de généralisation de GANN pour la détection

Niveau de charge en (GVA)	Type de défaut (court-circuit à terre)	Distance de défaut en (km)	Détection de défaut		
			Simulation en Matlab	ANN	GANN
52.5	C	110	1	1.001	1
37.5	BC	80	1	0.834	1.047
35	AC	30	1	0.999	1.000
42.5	ABC	80	1	0.917	1.015
50	B	30	1	0.997	0.999
17.5	Pas de défaut		0	0	0.001
60			0	0	0
80			0	0	0.001
10			0	0.001	0.002
70			0	0.001	0
Erreur moyenne de la détection				5.12 %	1.34 %

Tableau.IV.8 Phase de généralisation de GANN pour la classification

Niveau de charge en (GVA)	Distance de défaut en (km)	Classe de défaut		
		Simulation en Matlab	ANN	GANN
52.5	110	1	0.97	1.010
35	110	3	2.95	3.006
48	10	2	1.97	2.012
52.5	64	3	2.94	2.975
21	64	2	1.97	1.911
31	10	3	2.81	2.979
35	10	2	1.91	1.999
40	30	2	1.99	2.077
42	10	1	0.97	0.985
25	64	1	1.01	1.006
Erreur moyenne de la classification			2.65%	1.3 %

Tableau.IV.9 Phase de généralisation de GANN pour la localisation

Niveau de charge en (GVA)	Type de défaut (court-circuit à terre)	Distance de défaut en (km)			
		Simulation en Matlab	Moindres carrés	ANN	GANN
52.5	ABC	30	30.27	30.25	30.27
27.5	B	64	64.01	64.12	64.01
25	AB	64	64	64.21	64
47.5	BC	110	110.02	109.75	110.02
35	A	30	30.01	30.04	30
40	ABC	10	10.42	10.8	10.40
31	A	110	110.02	110.07	110.03
23	AC	80	80.01	79.97	80
52.5	C	110	110.18	110.07	110
35	A	110	109.99	110.07	109.99
Erreur moyenne de la localisation				0.26 %	1.03 %

IV.6.5 Interprétation des résultats

D'après les résultats obtenus dans la phase de test, nous remarquons qu'il n'y a pas une grande différence entre les erreurs délivrées par les ANN et les GANN.

La phase de généralisation pour les GANN nous délivre des erreurs variant entre 1.34 % pour la détection, 1.3 % pour la classification et 1.03 % pour la localisation, ce qui signifie que la capacité de généralisation des GANN est satisfaisante. Dans cette phase, il y a une nette amélioration des résultats délivrés par les GANN par rapport aux ANN. Ce qui montre l'efficacité de l'utilisation des GA dans l'optimisation des entrées des ANN.

IV.6.6 Implantation dans Simulink

Pour faciliter l'analyse des défauts simulés dans le bloc Simulink représenté sur la figure II.3, nous avons implantés les trois GANN dans le bloc Simulink représenté sur la figure IV.3.

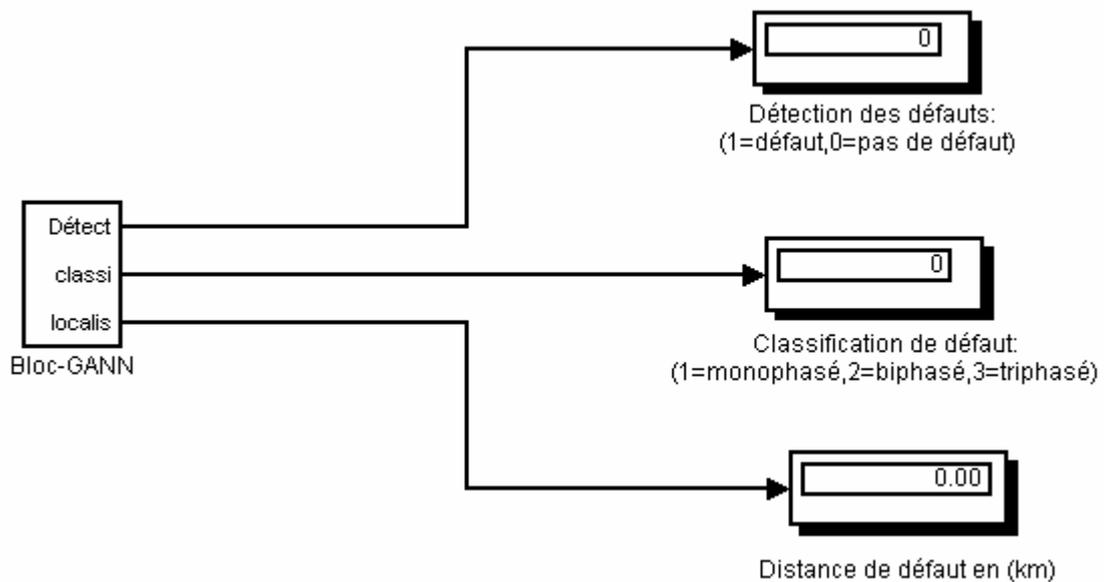


Figure IV.3 Schéma bloc utilisé dans la simulation des GANN

Le bloc Simulink utilisé contient trois afficheurs : le premier indiquant l'apparition des défauts (Aff1), le second indiquant la classe des défauts (Aff2) et le troisième indiquant la distance de défaut (Aff3). Afin de vérifier l'efficacité de ce schéma bloc, nous avons testés par des entrées utilisées pour le test du Bloc-ANN dans le chapitre précédent, afin d'effectuer une comparaison entre les deux blocs. Les résultats obtenus sont illustrés dans le tableau IV.10.

Tableau IV.10 Résultats Bloc-GANN

Paramètres simulés			Résultats Bloc-ANN			Résultats Bloc-GANN		
Niveau de charge en (GVA)	Type de défaut	Distance de défaut en (km)	Aff-1	Aff-2	Aff-3	Aff-1	Aff-2	Aff-3
41	A-B-C	50	1	3	49.97	1	3	50.05
17	A-B	75	1	2	77	1	2	75.34
66	A	100	1	1	98.82	1	1	100.30
90	Pas de défaut		0	0	0	0	0	0

D'après le tableau précédent, le Bloc-GANN donne de bons résultats avec des erreurs moyennes nulles pour la détection et la classification et une erreur moyenne de 0.92 % pour la localisation. Cette dernière est meilleurs, comparée à l'erreur moyenne relative de la localisation délivré par le Bloc-ANN pour entrée et qui est à 1.43 %.

IV.7 Conclusion

Dans ce chapitre, nous avons utilisé une technique d'optimisation basée sur les GA pour le choix du vecteur d'entrée des ANN proposés dans le chapitre précédent.

L'application de cette méthode nous a permis d'améliorer les résultats obtenus lors de l'application des ANN, ainsi qu'à réduire l'erreur obtenue par les ANN, cela en diminuant les vecteurs d'entrées des ANN de 61 %.

Nous pouvons, par ailleurs, améliorer la performance de cette méthode par les propositions suivantes :

- Augmentation de la base de données utilisée.
- Utilisation des GA pour optimiser les neurones de la couche cachée.
- Augmentation du nombre générations.

Conclusion générale

Le travail présenté dans ce mémoire a montré l'efficacité des méthodes intelligentes appliquées à l'analyse des défauts dans les réseaux électriques ainsi qu'une nette amélioration des performances sur la précision et la rapidité de calcul par rapport aux méthodes conventionnelles.

Nous avons prouvé que les ANN construits pour la détection, la classification et la localisation des défauts donnent des résultats très intéressants et permettent une généralisation appréciable des cas non traités lors de la phase d'apprentissage. Cependant, il y a des entrées non pertinentes et/ou redondantes que nous avons éliminées en utilisant une méthode de calcul méta-heuristique (Calcul évolutionnaire, Recherche Taboue, Recuit Simulé, Particules en Essaim) qui est dans notre travail : l'algorithme génétique. Cette étude nous a permis de réduire considérablement le nombre des variables d'état représentant les entrées des ANN et d'obtenir un gain important en temps de calcul. Les ANN ainsi optimisés sont plus performants en termes de la précision des résultats obtenus et de la capacité de généralisation pour tous les types et distances des défauts et les niveaux de charge.

En premier lieu, une base de données de l'état du réseau d'application a été élaborée en utilisant la méthode des phaseurs à deux extrémités pour la localisation des défauts. L'estimation de ces phaseurs a été effectuée par deux méthodes : les moindres carrées et l'analyse de Fourier. Nous avons par ailleurs constaté que les résultats du programme développé sur Matlab sont très sensibles à la résistance du défaut à cause du modèle de simulation de la Ligne de transport utilisée dans ce travail.

L'implantation des réseaux de neurones optimisés et non optimisés a été ensuite effectuée moyennant la programmation sur Matlab et aussi sur le bloc Simulink pour faciliter leurs manipulations et utilisations futures. Ces modèles développés pourront par la suite être implantés dans un relai numérique pour une éventuelle utilisation en temps réel.

Pour la suite de ce travail, plusieurs propositions à même de compléter cette étude sont envisageables. Nous citerons certaines d'entre elles :

- Utiliser les systèmes hybrides comme les neurones flous pour améliorer la performance du réseau de neurone généraliste.

- Elargir la base de donnée de l'apprentissage des ANN en considérant d'autres niveaux de charge et types de défaut.
- Utiliser un outil de simulation plus performant comme le logiciel EMTP destiné au calcul du régime transitoire des systèmes Electromagnétiques qui considère l'influence de la résistance de défaut dans le modèle de la ligne de transport.

Références bibliographiques

- [1] **R.Kessasra**, *Relais de distance*, Thèse de magister, Dépt.Electrotechnique, université de Jijel 1999.
- [2] **A.Kimov**, *Protection par relais travaux de laboratoire-II*, Central Electricque de Jijel, pp.2-3, 1979.
- [3] **T.Wildi**, *Electrotechnique*, 3^{ème} edition , De Boeck Université, pp.999-1002,1999.
- [4] **M.Aichoune, N.Bouzergui**, *Localisation des défauts sur les lignes aériennes dans la protection numérique*, mémoire d'ingénieur d'état en électrtechnique, U.S.T.H.B, Octobre 2003.
- [5] **M.S.Sachdev, C.Ratanbas, V.Chair**, ''WG I 16 Repport-Understanding microprocessor-based, technology applied to relaying'' February 2004.
- [6] **A.S.AIFulaid, M.A.El-Sayed**''A Recursive Least-Saquares Digital Distance Relaying Algorithm'', IEEE, Electrical and Computer Engineering Departement, Kuwait University, 1998.
- [7] **M.Kezunovic, B.Perunicic**,''Automated transmission line fault analysis using synchronized sampling at two ends'', IEEE, Texas A&M University, pp.407-413, 1995.
- [8] **T.Bouthiba**, ''Fault Location In Ehv Transmission Lines Using Artificial Neural Networks'', University of Science and Technology of Oran Faculty of Electrical Engineering, Algeria, Vol. 14, No. 1, pp.69-78, 2004.
- [9] **M.Kezunovic, I. Rikalo**,''Detect and classify faults using Neural Nets'', IEEE, 1996.
- [10] **S.Websper, R.W.Dunn, R. K.Aggarwal, A. T. Johns, and A. Bennett**, ''Feature extraction methods for neural network-based transmission line fault discrimination'', in Proc. Inst. Elect. Eng., Gen., transm. Distrib, vol. 146, pp. 209–216, May 1999.
- [11] **S.Vasilic, M.Kezunovic**, ''Fuzzy ART neural network algorithm for classifying the power system faults'', IEEE transactions on power delivery, 2004.
- [12] **T.Dalstein, B.Kulicke**,''neural network approach to fault classification for high speed protective relaying'' Department of high voltage and power Engineering Technical University of Berlin, Germany, IEEE, Transcations on power delivery Vol.10, No.2, pp.1002-1011, April 1995.
- [13] **A.Poeltl, K.Frohlich**,''two new methods for very fast fault type detection by means of parameter fitting and artificial neural networks'', IEEE, Transactions on power delivery Vol.14, No.4, pp.1269-1275, October 1999.
- [14] **Y-H.Song and A.T.Johns**,''Applications of fuzzy logic in power systems'', Power engineering journal, April 1999.
- [15] **G.S.Wang, Y.H.Song, A.T.Johns**, ''Fuzzy logic controlled multilayer neural networks: theory and case studies'', IEEE, University of Bath, UK, 1996.
- [16] **Y-H.Song and Allan T.Johns**,''Applications of fuzzy logic in power systems'', Power engineering journal, October 1997.
- [17] **Y.Song, A.T.Johns**,''Applications of fuzzy logic in power systems'', Power engineering journal, August 1998.
- [18] **Z.Q.Bo, G.S.Wang, F.Jiang, P.J.Moore, A.T.Johns**,''Distinguish Between Fault And Switching Operation Generated Transients Using a Fuzzy Neural Network'', IEEE Catalogue No: 98EX137, 1998.

- [19] **R.K.Aggarwal, Q.Y.Xuan, A.T. Johns, F.Li, A.Bennett,** "A novel approach to fault diagnosis in multicircuit transmission lines using fuzzy ARTmap neural networks", IEEE, transactions on neural networks, vol.10, No.5, September 1999.
- [20] **Y.H. Song, A.T.Johns Q.Y. Xuan J.Y,** "Genetic algorithm based neural networks applied to fault classification for EHV transmission lines with a UPFC ", IEEE, Developments in Power System Protection, Conference Publication No. 434, 1997
- [21] **J.G.Webster,** "Fault location", Wiely Encyclopaedia of Electrical and Electronics Engineering, copyright by John Wiley and Sons, Inc, pp.276-285, 1999.
- [22] **J.F.Haurer, C.J.Demeure, L.L.Scharf,** "Initial resultats in prony analysis of power system response", IEEE transactions on power systems, Vol.5, No.1, February 1990.
- [23] **G.B.Ancell and N.C.Pahalawatha,** "Maximum likelihood estimation of fault location on transmission lines using travelling waves", IEEE Trans. Power Deliv, pp.9-680, 1994.
- [24] **D.L.Waikar, S.E.Langovan, A.C.Liew,** "Fault impedance estimation algorithm for digital distance relaying", IEEE transactions on power delivery, Dept.of Electrical Engineering Singapore Polytechnic, Singapore, Vol 9, NO, 3, July 1994.
- [25] **M.Adjrad,** *Application du filtrage de Kalman étendu à l'identification d'un chirp*, mémoire de magister, ENP, 1999.
- [27] **M.M.Saied, A.S.AL-Fuhaid,** "A computer relaying algorithm for direct determination of the fault distance", Computer and Elect Engng, Vol. 14, No.3/4, pp.93-104, 1988.
- [28] **J.Hertz, A.Kroghrt, R.G.Palmer,** "introduction to the theory of neural computation", Addison-Wesley, 1990.
- [29] **E.Davalo, P.Naim,** *des réseaux de neurones*, Edition Eyrolles, 1990.
- [30] **N.Benhamed,** *optimisation de réseaux de neurones pour la reconnaissance de chiffres manuscrits isolés: sélection et pondération des primitives par algorithmes génétiques*, mémoire d'ingénieur, Ecole de Technologie Supérieur Université du Québec, pp 17-26 mars 2002.
- [31] **M.Parizeau,** "Le Perceptron multicouche et son algorithme de rétropropagation des erreurs", Département de génie électrique et de génie informatique Université Laval 10 septembre 2004.
- [32] **R. Rojas,** "Neural Networks: A Systematic Introduction", Springer-Verlag, Berlin, pp.84-91 (perceptron learning); pp.159-162 (backprop), 1996.
- [33] **E.Aliame, A.Benzaouia,** *Identification des défauts dans un réseau électrique par technique des réseaux de neurones*, PFE, Dept.Genie électrique, 1999.
- [34] **M.Benrabah, M.Djaziri,** *Localisation des Défauts par les Algorithmes intelligents : Application des Réseaux de Neurones et Algorithmes Génétiques*, mémoire d'ingénieur, USTHB Juin 2005.
- [35] **Y. H. Song, Q. X. Xuan, and A. T. Johns,** "Comparison studies of five neural networks based fault classifiers for complex transmission lines", Elect. Power Syst. Res., vol. 43, no. 2, pp. 125–132, Nov. 1997.
- [36] **W.-M. Lin, C.-D.Yang, J.-H. Lin, M.-T. Tsay,** "A fault classification method by RBF neural network with OLS learning procedure", IEEE Trans. Power Delivery, vol. 16, pp. 473–477, Oct. 2001.

- [37] **A.K.Pradhan, P.K.Dash, and G. Panda**, “*A fast and accurate distance relaying scheme using an efficient radial basis function neural network*”, *Elect. Power Syst. Res.*, vol. 60, no.1, pp. 1–8, Nov. 2001.
- [38] **H.Wang, W.W. L. Keerthipala**, “*Fuzzy-neuro approach to fault classification for transmission line protection*” *IEEE Trans. Power Delivery*, vol. 13, pp.1093–1104, Oct.1998.
- [39] **M. Sanaye-Pasand, O.P.Malik**, “*Implementation and laboratory test results of an Elman network-based transmission line directional relay*” *IEEE Trans. Power Delivery*, vol. 14, pp.782–788, July 1999.
- [40] **T.Dalstein, T.Friedrich, B.Kulicke, D. Sobajic**, “*Multi neural network based fault area estimation for high speed protective relaying*” *IEEE Trans. Power Delivery*, vol. 11, pp. 740–747, Apr. 1996.
- [41] **P. K. Dash, A. K. Pradhan, and G. Panda**, “*Application to minimal radial basis function neural network to distance protection*” *IEEE Trans. Power Delivery*, vol. 16, pp. 68–74, Jan. 2001.
- [42] **A.G.Jongepier, L.van der Sluis**, “*Adaptive distance protection of double-circuit lines using artificial neural networks*” *IEEE Trans. Power Delivery*, vol. 12, pp. 97–105, Jan. 1997.
- [43] **R. K. Aggarwal, Q. Y. Xuan, R. W. Dunn, A. T. Johns, and A. Bennett**, “*A novel fault classification technique for double-circuit lines based on a combined unsupervised/supervised neural network*” *IEEE Trans. Power Delivery*, vol. 14, pp.1250–1256, Oct.1999.
- [44] **Z. Q. Bo, R. K. Aggarwal, A. T. Johns, H. Y. Li, and Y. H. Song**, “*A new approach to phase selection using fault generated high frequency noise and neural networks*” *IEEE Trans. Power Delivery*, vol. 12, pp. 106–115, Jan. 1997.
- [45] **B.Widrow, M. Lehr**, “*30 years of adaptive neural networks: Perceptron, madaline, and back propagation*” *Proc. IEEE*, vol. 78, no. 9, pp.1415–1442, Sept.1990.
- [46] **M. J. D. Powell**, “*Radial basis functions for multivariable interpolation: A review*”, in *Algorithms for the Approximations of Functions and Data*, J. C. Mason and M. G. Cox, Eds, Oxford, U.K.: Clarendon Press, pp.143–167,1987.
- [47] **T. Kohonen**, *Self-Organizing Maps*, New York, NY: Springer, p.501, 2001
- [48] **G. A. Carpenter and S. Grossberg**, “*ART2: Self-organization of stable category recognition codes for analog input patterns*”, *Applied Optics*, vol. 26, no. 23, pp. 4919–4930, Dec. 1987.
- [49] **E. A. Wan**, “*Temporal back propagation for FIR neural networks*” in *Proc. IEEE Intl. Joint Conf. Neural Networks*, vol. 1, San Diego, CA, pp. 575–580, June 1990
- [50] **Kulicke.B**, “*Digitalprogramm NETOMAC zur simulation elekromechanischer und-magnetischer ausgleichsvorgaenge in drehstromnetzen*”, *Elektrizitaetswirtschaft*, Heft, S.18-23, Germany, 1979.
- [51] **M.Oleskovicz, Coury D.V, Aggarwal R.K**, “*A complete scheme for fault detection, classification and localisation in transmission lines using neural network*”, *Proc.The7-th Int. Conf. Developments in Power System Protection*, Amsterdam, the Netherlands, pp. 335–338, 2001.
- [52] **Osowski.S, Salat.R**, “*Fault location in transmission line using hybrid neural network*”, *Compel*, Vol.21, No.1, pp.18–30.
- [53] **Purushothama.G.K, Narendranath A.U, Thukaram D, Parthasarathy.K**, “*ANN applications in fault locator*”, *Electrical Power & Energy Syst*, Vol. 23, No. 6, pp.491–506.

- [54] **G.David**, *Genetic algorithms in search, optimization and machine learning*, Addison-Wesley, 1989.
- [55] **Holland.J.H**, *Adaptation in natural and artificial systems*, MIT Press, 1975.
- [56] **Man.K.F, Tang K.S, Kwong S**,''*Genetic algorithms: Concepts and designs*'' , Springer, 2000.
- [57] **Janikow C.Z, Michalewicz.Z**, ''*An experimental comparison of binary and floating point representations in genetic algorithms*'' , Proceeding of the fourth international conference on Genetic Algorithms, Morgan Kaufmann, pp.31-36.
- [58] **Herrera F, Lozano.M, Verdegay J.L**,'' *Tackling real-coded genetic algorithms: operators and tools for behavioural analysis*'' . *Artificial Intelligence Review*, 12(4), pp.265-319, 1998.
- [59] **M.Wall, A.GALIB**,''*C++ library of genetic algorithms Components*'' , Massachusetts Institute of Technology MIT press, 1996. Available: <http://lancet.mit.edu/ga/>.
- [60] **Man K.F, Tang K.S**,'' *Genetic algorithms for control and signal processing*'' , Industrial Electronics, Control and Instrumentation IECON. 23rd International Conference on, 4, pp.1541-1555, 1997.
- [61] **Eiben A.E., Hinterding R & Michalewicz Z**,''*Parameter Control in Evolutionary Algorithms. Evolutionary Computation*'' , IEEE Transactions on, pp.124-141, 1999.
- [62] **V.Magnin**, ''Algorithmes génétique'', Mars 2000, polytechnique de Lille : http://www.polytech-lille.fr/~vmagnin/coursag/methodes_ag.html.
- [63] **R.Adel et Y.Tebbakh**,''*Amélioration de la Stabilité Dynamique des Réseaux Electriques par les Algorithmes Génétiques*'' ,mémoire d'ingénieur ,ENP, Dépt.Génie électrique, 2005.
- [64] **J.A.Vasconcelos, et al**,''*Improvements in genetic algorithms*'' , IEEE Transactions on Magnetics, Vol.37, No.5, pp.3414-3417, Sep 2001.
- [65] **L.L.Lai et al**,''*Design of neural networks with Gas for fault section estimation*'' , the 29th Universities Power Engineering Conference, Galway, Ireland, vol .2, and pp.569-596,1994.
- [66] **M. Kezunovic, Ph.D., P.E. Eugene E. Webb**,''*Accurate fault location in transmission networks using modelling ,simulation and limited field recorder data*'' , Final Project (PSERC) Report, pp.23-44 ,1996.
- [67] **Y.H.Song, A.T.Johns**,''*comparaison and integration with expert systems, neural networks and genetic algorithms*'' , part 2(tutorial fuzzy logic), pp.185-190.

ملخص:

هذا العمل يحتوي على التقاط و ترتيب و تحديد الأخطاء داخل الشبكات بواسطة التقنيات الذكية. تمكنا خلال هذه الدراسة من تحديد الأخطاء باستعمال طريقة تقليدية هي المربعات المتوسطة. كما استطعنا تقدير مسافة الخطأ بواسطة شبكات النورونات و شبكات النورونات المخفضة بواسطة الخوارزميات الجينية وكانت النتائج موافقة مع أخرى موجودة في المراجع. نظرا لسرعة و فعالية الطريقتين المستعملتين توصلنا إلى التقاط و ترتيب الأخطاء. هذه النتائج الجد مرضية تفتح لنا باب واسع أمام دراسة جديدة مكملة.

كلمات مفاتيح:
شبكات النورونات - الخوارزميات الجينية - التقاط - تحديد.

Résumé :

Ce présent travail comporte la détection, la classification et la localisation des défauts dans les réseaux par les techniques intelligentes.

On a pu confirmer la localisation des défauts par le biais d'une méthode conventionnelle qui est la méthode des moindres carrés, et on a estimé la distance de défaut par les réseaux de neurones et les réseaux de neurones optimisés par les algorithmes génétiques où les résultats sont en bon accord avec ceux trouvés dans la littérature.

Vu la rapidité et l'efficacité des deux méthodes utilisées on a abouti à la détection et la classification des défauts ; ces résultats assez prometteuses ouvrent la porte d'une nouvelle étude complémentaire.

Mots clés :

Réseaux de neurones, Algorithmes génétiques, Détection, Localisation.

Abstract :

In this present work, we have detected, classified and localised the defects in the network by intelligent techniques.

We have confirmed the localisation of the defects by conventional method whose least square method and we have estimated the defects distance by the neuron network and neuron network optimised by genetic algorithm, the results obtained are in good agreement with the available data in the literature.

Face at the speed and the efficiency of the both method utilised we succeed to the detection and the classification of defects; this results promise enough open a new complementary studies.

Key words:

Neural networks, Genetic algorithm, Detection, localisation.