



الجمهورية الجزائرية الديمقراطية الشعبية

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE

وزارة التعليم العالي والبحث العلمي

MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA RECHERCHE SCIENTIFIQUE

المدرسة الوطنية العليا للتكنولوجيا والهندسة - عنابة -

ÉCOLE NATIONALE SUPÉRIEURE DE TECHNOLOGIE ET D'INGÉNIERIE - ANNABA

Département d'Électronique, d'Électrotechnique et Automatique

MEMOIRE

En vue d'obtention du diplôme de Master

Spécialité : Réseaux électriques

Présenté par

BADJI Sabra

ZEMOULI Nour El Houda

Détection, classification et localisation des défauts dans un réseau de transport 60 kv

Encadré par

MCA. CHIHEB Sofiane

ENSTI Annaba

Membres du jury :

Pr. DOGHMANE Nouredine

Président

ENSTI -Annaba

Dr. SMILI Karima

Examineur

ENSTI-Annaba

ملخص

نقترح في هذه المذكرة استعمال تقنيات الذكاء الاصطناعي في كشف الأعطال وتصنيفها وتحديد موقعها في شبكة نقل كهربائي بتوتر 60 كيلوفولط. تمت مقارنة بين ثلاثة خوارزميات معتمدة على التعلم الخاضع للإشراف وهي: الغابة العشوائية وآلة المتجهات الداعمة و أقرب الجيران. تم تدريب هذه النماذج واختبارها باستخدام قاعدة بيانات محاكاة تحتوي على أكثر من 16000 عينة من بيانات التيارات والجهود ثلاثية الطور تشمل سيناريوهات متعددة مثل الأعطال الأحادية، والثنائية، والثلاثية الطور، إضافة إلى حالات التشغيل العادية. تبين أن خوارزمية الغابة العشوائية هي الأكثر كفاءة حيث حققت دقة إجمالية بلغت 97.2% في كشف الأعطال، 99% للتصنيف و حوالي 80% في تحديد الموقع.

كلمات مفتاحية: كشف الأعطال، الشبكات الكهربائية، الذكاء الاصطناعي، غابة عشوائية، آلة المتجهات الداعمة، أقرب الجيران التصنيف، تحديد موقع الأعطال، موثوقية الشبكة، استمرارية الخدمة.

Abstract

We propose in this work to use artificial intelligence in the detection, classification, and localization of faults in 60 kV power grid. A comparison between three supervised learning algorithms : Random Forest, Support Vector Machine, and K-Nearest Neighbors. These models were trained and tested on a simulated dataset containing over 16,000 samples of three-phase current and voltage measurements , representing various fault scenarios (single-phase, two-phase, three-phase) as well as normal operating conditions. After evaluating the three algorithms we found that Random Forest offers an overall accuracy of 97.2% for fault detection, 99% for fault identification and approximately 80% for localization.

Keywords : fault detection, power grids, artificial intelligence, Random Forest, Support Vector Machine, K-Nearest Neighbors, classification, fault localization, network reliability, service continuity.

Résumé

Nous proposons dans ce mémoire d'utiliser l'intelligence artificielle pour la détection, la classification et la localisation des défauts dans un réseau de transport électrique 60 kV. Une comparaison entre trois algorithmes basées sur l'apprentissage supervisé : Random Forest, Support Vector Machine et K-Nearest Neighbors . Ces modèles sont entraînés et testés sur une base de données simulée de plus de 16 000 échantillons de courants et tensions triphasés, représentant divers scénarios de défauts (monophasés , biphasés , triphasés) ainsi que fonctionnement normal. Nous constatons que l'algorithme Random Forest offre une précision globale de 97,2

% pour la détection et 99% pour l'identification et presque 80% pour la localisation.

Mots clés : détection des défauts, réseaux électriques, intelligence artificielle, Random Forest, Support Vector Machine , K-Nearest Neighbors , classification , localisation des défauts , fiabilité du réseau , continuité de service.

Dédicace

À la mémoire de mon père , Badji Yassine ,

Tu restes à jamais dans mon cœur.

Ce travail est dédié à toi , en hommage à tout ce que tu as été pour moi.

À nous-mêmes ,

Pour notre courage, nos efforts et notre persévérance tout au long de ce parcours.

À nos chers parents,

Merci pour votre amour, votre soutien et vos sacrifices. Sans vous, rien n'aurait été possible.

À nos amis,

Merci pour votre présence, votre aide et vos encouragements dans les moments difficiles
comme dans les moments de joie.

Sabra & Nour Elhouda

Remerciements

Nous tenons à exprimer notre profonde gratitude à tous ceux qui ont contribué de près ou de loin à la réalisation de ce travail de fin d'études .

Avant tout , nos remerciements les plus sincères vont à nos parents pour leur amour inconditionnel , leurs sacrifices et leur soutien moral et matériel tout au long de notre parcours. Leur présence constante et leurs encouragements ont été une source inestimable de force et de motivation.

Nous adressons également notre reconnaissance à Monsieur Chiheb Sofiane , notre encadrant , pour son accompagnement attentif , ses conseils avisés et son exigence qui ont grandement enrichi ce travail .

Nos remerciements vont aussi à Monsieur Messaoud Djeghaba , professeur à l'ENSTI, pour son encadrement pédagogique et son appui précieux durant tout le projet.

Nous remercions chaleureusement l'ensemble de nos enseignants de l'ENSTI d'Annaba pour la qualité de leur enseignement et leur engagement à nous transmettre un savoir solide, qui a constitué les fondations de notre formation.

Nos sincères remerciements s'adressent aussi aux ingénieurs de la centrale SPE Koudiet Ed Draouech :

Monsieur Cheloufi Nabil,

Monsieur Amor Ahmed Malek,

Monsieur Menacer Abderezek,

pour leur accueil , leur accompagnement technique et leur disponibilité durant notre stage ainsi que pour les connaissances pratiques qu'ils nous ont généreusement transmises.

À toutes et à tous, merci du fond du cœur.

Table des matières

Résumé	I
Table des matières	VI
Table des figures	VII
Table des tableaux	VIII
Liste des abréviations	IX
Introduction générale	1
I Généralités sur les défauts dans les réseaux électriques	3
I.1 Introduction	3
I.2 Classification des défauts dans les réseaux électriques	3
I.3 Les systèmes de protection actuels	4
I.4 Les contraintes d'analyse classique des défauts du court circuit	5
I.5 Conclusion	5
II Les techniques de détection, de classification et de localisation des défauts	6
II.1 Introduction	6
II.2 Etapes de fonctionnement de protection	6
II.3 Techniques de détection des défauts	7
II.3.1 Tension résiduelle et courant résiduel	7
II.3.2 Courant de phase	7
II.3.3 Tension neutre-terre	7
II.4 Techniques de classification des défauts	7
II.5 Techniques de localisation des défauts	8
II.5.1 Signaux d'onde progressive	8
II.5.2 Réflectométrie active	9
II.6 Conclusion	9
III Méthodes proposées et validation des résultats	10
III.1 Introduction	10
III.2 Présentation d'échantillon de test	10
III.3 Modèles d'apprentissage	11
III.3.1 Techniques d'apprentissage appliqués	11
III.4 Conclusion	14

IV Validation des modèles d'apprentissage automatique	15
IV.1 Introduction	15
IV.2 Visualisation des jeux de données	15
IV.3 Visualisation des Résultats des Méthodes d'Intelligence Artificielle	17
IV.3.1 Résultats de détection des défauts	17
IV.3.2 Résultats de l'identification des défauts	20
IV.3.3 Résultats de la localisation des défauts	21
IV.4 Conclusion	23
Conclusion générale	24
Bibliographie	25

Table des figures

Figure I.1	Eléments constitutifs d'un système de protection	4
Figure II.1	Illustration de la méthode d'ondes progressives(Traveling-Waves) [6]	8
Figure III.1	Simulation d'un Réseau électrique 60 KV sous Simulink/MATLAB .	11
Figure III.2	Structure de l'arbre de décisions	11
Figure III.3	Entraînement avec RF	13
Figure III.4	Exemple des hyperplans et le choix de la droite optimale selon l'algorithme SVM	13
Figure III.5	Entraînement avec SVM	13
Figure III.6	Entraînement avec KNN	14
Figure IV.1	Diagramme circulaire de répartition des classes binaires	15
Figure IV.2	Diagramme circulaire de classification Multi-Classes	16
Figure IV.3	Courbe des tensions triphasées en fonction du temps	17
Figure IV.4	Courbe des courants triphasés en fonction du temps	17
Figure IV.5	Matrice de confusion de la classification binaire avec RF	18
Figure IV.6	Matrice de confusion de la classification binaire avec SVM	18
Figure IV.7	Matrice de confusion de la classification binaire avec KNN	18
Figure IV.8	Comparaison des performances des algorithmes en classification binaire	20
Figure IV.9	Matrice de confusion de la classification multi-classes avec RF	20
Figure IV.10	Matrice de confusion de la classification multi-classes avec SVM	20
Figure IV.11	Matrice de confusion de la classification multi-classes avec KNN	21
Figure IV.12	Comparaison des performances des algorithmes en classification multi-classe	22
Figure IV.13	Matrice de confusion pour ligne de défaut	23

Liste des tableaux

Tableau IV.1	Résultats de la classification binaire	19
Tableau IV.2	Résultats de la classification multi-classe	21
Tableau IV.3	Résultats de localisation des défauts dans le réseau	22

Liste des abréviations

IA *Intelligence Artificielle*

RF *Random Forest*

SVM *Support Vector Machine*

KNN *K-Nearest Neighbors*

TC *Transformateur de Courant*

TT *Transformateur de Tension*

TP *True Positive (vrai positif)*

TN *True Negative (vrai négatif)*

FP *False Positive (faux positif)*

FN *False Negative (faux négatif)*

I_o *Courant homopolaire*

I_d *Courant inverse*

I_i *Courant direct*

V_n *Tension nominale*

Introduction Générale

Aujourd'hui, l'énergie électrique joue un rôle important dans la vie humaine. Elle est présente dans tous les secteurs : santé, éducation, télécommunication, transport... Le dernier blackout dans l'Espagne et le Portugal du 28 avril 2025 est l'exemple le plus clair de l'impact de l'absence de cette énergie sur la vie actuelle. Les ruptures des fonctions de transport, les paiements électroniques bloqués, les systèmes de communication sont aussi bloqués. Ce phénomène est un résultat de l'accumulation de plusieurs défauts sur le réseau électrique.

Ce dernier se compose d'un ensemble d'éléments (centrales électriques, lignes, etc.) qui sont liés pour apporter l'énergie aux consommateurs. Il représente un investissement de grand ordre, qui implique plusieurs équipements (générateurs, transformateurs...) censés fonctionner sans interruptions.

Par contre, des pannes peuvent affecter ces équipements comme le déséquilibre entre la consommation et la production, une surcharge, un problème de synchronisation et de chutes de fréquence ou de tension. Ces pannes sont détectées par des systèmes de protection identifiant le défaut à travers des relais et éliminent le avec les équipements de coupure .

Une fois le défaut détecté et éliminé, le système reprend son fonctionnement, seulement avec un fichier gardé dans l'historique donnant quelques détails techniques. Ces données ne sont pas exploitées, et il arrive parfois que des défauts similaires arrivent, et une partie importante du temps est perdue pour localiser le défaut, et si la longueur de ligne est importante, le temps de localisation du défaut est important aussi. L'intelligence artificielle propose aujourd'hui des solutions innovantes pour détecter et prédire les défauts avec une large précision. Ce travail s'inscrit dans cette perspective en explorant l'application du Machine Learning pour la surveillance intelligente des réseaux de transport d'électricité. Il s'agit d'une étude comparative entre trois algorithmes d'apprentissage supervisé : Random Forest, Support Vector Machine et K-Nearest Neighbors afin d'évaluer leur efficacité dans la détection, la classification et la localisation des défauts. L'objectif est de déterminer la méthode la plus performante pour identifier et diagnostiquer rapidement les défauts et les localiser précisément, dans le but de réduire les temps d'intervention et d'améliorer la fiabilité ainsi que l'efficacité du réseau.

Ce mémoire est structuré en quatre chapitres, chacun abordant une étape essentielle de notre démarche.

Le premier chapitre est consacré aux généralités nécessaires sur les défauts dans les réseaux électriques pour pouvoir les analyser par la suite. Il présente les différents types de défauts susceptibles de survenir, leur classification (monophasés, biphasés, triphasés), ainsi que les systèmes de protection classiques utilisés pour les détecter et les isoler. Aussi, on présente la problématique de recherche en mettant en lumière les limites des méthodes traditionnelles, en particulier leur manque de précision et leur lenteur dans des réseaux de plus en plus complexes

Dans le deuxième chapitre, nous abordons les principales techniques de détection, classification et localisation des défauts . Il s'agit d'un résumé des approches classiques basées sur les grandeurs électriques et les équations d'impédance, ainsi que des méthodes plus récentes fondées sur l'intelligence artificielle .

Le troisième chapitre présente en détail les algorithmes utilisés pour l'apprentissage : Random Forest (RF), K-Nearest Neighbors (KNN) et Support Vector Machine (SVM). L'étude du cas d'apprentissage a été présentée aussi dans ce chapitre : un réseau 60 kV sera simulé pour la génération de la base de données, le prétraitement des données ainsi que l'implémentation des trois modèles d'apprentissage supervisé. Chaque algorithme est évalué dans des conditions identiques pour permettre une comparaison équitable de leurs performances .

Enfin , le quatrième chapitre est consacré à l'analyse des résultats obtenus . En comparant les performances des trois algorithmes dans la détection et l'identification des défauts. La comparaison a été faite en termes de précision, de rappel et de F1-score. A la fin de chapitre nous évaluons les performances d'un de ces algorithmes pour la localisation des défauts.

A la fin, nous englobons les résultats obtenus dans une conclusion générale.

Chapitre I

Généralités sur les défauts dans les réseaux électriques

I.1 Introduction

Dans les réseaux électriques, l'apparition des défauts peut affecter à la fois la stabilité, la sécurité et la continuité du service. Afin de les détecter, nous devons avoir une compréhension approfondie des phénomènes accompagnant le défaut afin de définir des mécanismes de protection permettant de les isoler et limiter les conséquences. Ce chapitre présente les concepts fondamentaux d'étude des protections électriques.

I.2 Classification des défauts dans les réseaux électriques

Le réseau électrique est dimensionné et installé pour répondre à la demande des clients, avec respect des limites de tension et de puissance (courant maximal). Pour améliorer sa fiabilité, ce réseau doit également être protégé contre les différents défauts affectant sa fonction [1]. Le fonctionnement des réseaux électriques en courant alternatif nécessite une stabilité des signaux de courant et de tension, et donc ces signaux sont maintenus dans des marges bien définies. toute fluctuations soudaines ou inhabituelles de l'une ou plusieurs de ces grandeurs est considérée comme signe d'apparition de défaut. Parmi les défauts les plus couramment enregistrés dans les réseaux électriques, on peut citer [2] :

- La surcharge entraînant une surintensité .
- Le court-circuit, cause majeure de surintensité brutale .
- La surtension, conséquence des phénomènes transitoires comme la foudre .
- La chute de tension, affectant la qualité de l'énergie .

Parmi ces défauts, le court-circuit -qui caractérise le problème d'isolement entre deux conducteurs de potentiel différent- est classé parmi les défauts les plus fréquents. En présence d'un court-circuit, une variation anormale des grandeurs électriques nominales telles que la tension,

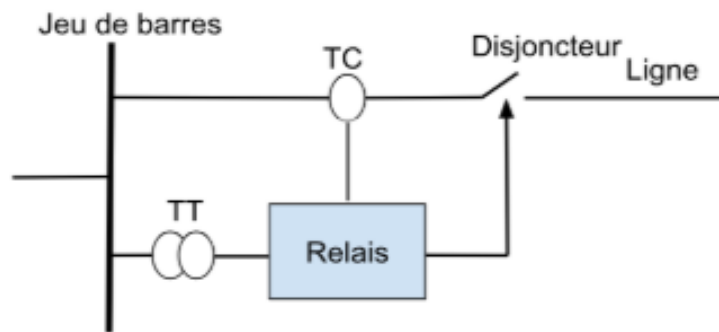


Fig. I.1 : Eléments constitutifs d'un système de protection

le courant (parfois la fréquence) est observée. Parfois, il est indispensable de se présenter dans le lieu du défaut pour éliminer la source de défaut. Cela engendre une autre contrainte, car de localiser le défaut sur des dizaines de kilomètres est difficile, et plus l'erreur de localisation est augmentée, plus le temps de coupure devient important et la fiabilité de système est réduite [1].

I.3 Les systèmes de protection actuels

Au niveau de la haute tension, le système de protection électrique se compose de trois parties [2] :

- Réducteurs de mesure (Transformateur de courant et de tension, etc.), qui adaptent les grandeurs électriques à des niveaux compatibles avec les systèmes de traitement (relais de protection).
- Relais de protection, qui servent à traiter les informations acheminés de la part des réducteurs de mesure et donnent l'ordre de déclencher l'action appropriée .
- Disjoncteurs qui vont servir à la coupure de l'alimentation de défaut.

La Figure I.1 illustre un exemple typique de système de protection pour un départ d'une ligne haute tension englobant les réducteurs de mesure, le relais et le disjoncteur.

Les relais de protection sont reliés aux transformateurs de courant (TC) et aux transformateurs de tension (TT) dont ils reçoivent les signaux électriques nécessaires à l'analyse du fonctionnement du réseau. Ils sont également connectés aux bobines des disjoncteurs auxquels ils transmettent des ordres d'ouverture ou de fermeture en fonction des anomalies détectées . Ainsi , en cas de défaut , le rôle du relais est de détecter l'anomalie et d'envoyer un ordre de déclenchement au disjoncteur afin d'isoler la partie défaillante du réseau [2] .

I.4 Les contraintes d'analyse classique des défauts du court circuit

Pour identifier un défaut, les méthodes traditionnelles reposent principalement sur le calcul des courants de phase et/ou l'analyse des composantes symétriques de système triphasé [3].

Ces approches permettent de détecter les anomalies en comparant les mesures aux grandeurs nominales, de classifier les défauts selon leur nature (monophasé, biphasé, triphasé). De plus, pour intervenir et éliminer le défaut d'isolement, il est indispensable de localiser les défauts en estimant leur distance à partir du calcul de l'impédance du défaut. Dans les réseaux simples, ces méthodes deviennent complexes et peu flexibles lorsqu'on les applique à des réseaux de grande taille ou à topologie évolutive, et elles atteignent leurs limites en matière de rapidité, d'adaptation et de précision [4].

Alors, l'utilisation de l'intelligence artificielle peut représenter une solution pertinente pour la détection et la localisation du défaut et cela en exploitant et analysant des bases de données contenant des défauts pour l'apprentissage des modèles d'IA.

I.5 Conclusion

La contrainte de localisation et de classification de défaut devient de plus en plus compliquée avec la complexité de structure du réseau ou la diversité des sources. Et dans ce cas, la détection de défaut sera limitée à la protection du système concerné ou la protection des lignes voisines. Pour centraliser cette opération, et assurer une deuxième alternative, il est possible d'utiliser l'IA afin de détecter et localiser le défaut dans les structures complexes.

Chapitre II

Les techniques de détection, de classification et de localisation des défauts

II.1 Introduction

Lorsqu'un défaut survient dans le réseau électrique, la protection doit fonctionner rapidement afin d'isoler localement le défaut. Ce chapitre propose une étude détaillée des principales méthodes utilisées dans ce contexte en abordant à la fois les approches classiques **et les techniques modernes reposant sur l'intelligence artificielle.**

II.2 Etapes de fonctionnement de protection

Généralement , lorsque un court-circuit arrive, son traitement se fait sur trois niveaux distincts [3] :

Détection du défaut : Une fois le défaut détecté, le système de protection peut appliquer la mise hors tension de la zone défectueuse du réseau. Cette détection peut se faire à travers plusieurs techniques.

Identification du point de défaut : Parfois plusieurs protections en cascade détectent le défaut, mais il faut juste couper la partie concernée sur lequel le défaut s'est produit . Elle facilite la prise de décision du disjoncteur concerné.

Localisation du défaut : Une fois le défaut mis hors tension, il doit être localisé afin de régler le problème d'isolement : il faut donc estimer la distance entre le défaut et un point de référence.

II.3 Techniques de détection des défauts

Le principe de détection des défauts est basé sur l'analyse des tensions et des courants de réseau protégé. En fonction de la grandeur choisie comme référence, nous pouvons classer les techniques de détection de défauts [4].

II.3.1 Tension résiduelle et courant résiduel

En effectuant une somme vectorielle des tensions (courants) des trois phases, nous obtenons une tension résiduelle. Dans le cas normal le résultat est nul, mais dans le cas contraire, une valeur de tension résiduelle est obtenue. Donc à travers cette grandeur, nous pouvons détecter les défauts en comparant les valeurs résiduelles à des seuils prédéfinis [?] .

II.3.2 Courant de phase

Le défaut d'isolement se manifeste par une surintensité rapide et significative du courant de phase . Donc , cette variation est exploitée pour détecter la présence d'un défaut. Cette technique est efficace pour identifier les défauts triphasés , biphasés ou monophasés, mais elle dépend aussi de régime de neutre [4].

II.3.3 Tension neutre-terre

Lors de l'apparition d'un défaut monophasé, la différence de potentiel entre le point neutre et la terre augmente brusquement, et parfois peut atteindre la valeur nominale simple du réseau . Alors avec la mesure de cette différence de potentiel, nous pouvons détecter des défauts d'isolement [4].

II.4 Techniques de classification des défauts

Parmi les techniques existantes de la classification des défauts dans le réseau électrique, la méthode de composante symétrique reste la méthode la plus fiable : en exploitant la décomposition des courants et tensions triphasés en composantes symétriques : directe I_d , inverse I_i et homopolaire I_o [10]. nous pouvons classer le défaut en se basant sur ces trois composantes.

$$\begin{aligned} I_a &= I_a^o + I_a^d + I_a^i \\ I_b &= I_a^o + \alpha^2 \cdot I_a^d + \alpha \cdot I_a^i \\ I_c &= I_a^o + \alpha \cdot I_a^d + \alpha^2 \cdot I_a^i \end{aligned} \quad (\text{II.1})$$

A titre d'exemple, dans le défaut monophasé nous pouvons distinguer [10] : Le courant homopolaire I_o sera différent de zéro. $\alpha = \arg(\frac{I_d}{I_o})$, $\beta = \arg(\frac{I_i}{I_o})$

- Défaut entre la phase a et la terre : $\alpha = 0^\circ$ et $\beta = 0^\circ$.
- Défaut entre la phase b et la terre : $\alpha = 120^\circ$ et $\beta = 240^\circ$.

- Défaut entre la phase c et la terre : $\alpha = 240^\circ$ et $\beta = 120^\circ$.

Pour un défaut biphasé avec terre on a [10] : Le courant homopolaire I_0 sera différent de zéro.

Pour chaque type de défauts on a :

- Défaut a-b-t : $\lambda = \arg\left(\frac{I_d - I_0}{I_i - 2I_0}\right) = -60^\circ$.
- Défaut b-c-t : $\delta = \arg\left(\frac{I_d - 2I_0}{I_i - I_0}\right) = 180^\circ$.
- Défaut a-c-t : $\mu = \arg\left(\frac{I_d - 2I_0}{I_i - I_0}\right) = 60^\circ$.

II.5 Techniques de localisation des défauts

Plusieurs techniques permettent de localiser les défauts sur les lignes électriques [5] :

Technique basée sur le paramètre d'impédance

A partir des mesures de courant et de tension relevées à une ou deux extrémités de la ligne électrique, le rapport tension-courant est comparé avec l'impédance d'unité de la ligne (généralement un kilomètre) pour estimer la distance du point de défaut [5]. Cette méthode peut être erronée en cas de défaut résistant.

II.5.1 Signaux d'onde progressive

La technique des ondes progressives repose sur l'analyse des ondes à haute fréquence générées par un défaut et leurs réflexions qu'elles provoquent dans la ligne électrique. La localisation s'effectue en mesurant ces ondes transitoires à une ou deux extrémités de la ligne, puis en analysant les signaux pour déterminer le temps de propagation de l'onde jusqu'au défaut comme illustré sur la figure II.1 [5].




Fig. II.1 : Illustration de la méthode d'ondes progressives(Traveling-Waves) [6]

II.5.2 Réflectométrie active

La réflectométrie active repose sur la détection de réflexion : lors d'émission d'un signal depuis une extrémité du câble, une partie de ce signal est réfléchi en présence de défaut (à cause de discontinuité d'impédance). En mesurant le délai entre l'émission et la réception de l'écho réfléchi, on peut estimer la distance jusqu'au défaut [5].

II.6 Conclusion

La présence de défaut d'isolement change la composante résiduelle, l'intensité du courant ainsi que la différence de potentiel entre les points neutre-terre. Donc il est efficace de le détecter en surveillant ces paramètres. Pour la classification, il est efficace d'utiliser la méthode des composantes symétriques. La localisation est facile pour les réseaux homogènes (même structure de lignes) donc la méthode des impédances est efficace. Mais dans le cas des réseaux complexes, d'autres techniques de détection peuvent être utilisées. Le prochain chapitre présente les techniques de l'IA utilisées dans l'analyse des données.

Chapitre III

Méthodes proposées et validation des résultats

III.1 Introduction

Dans les méthodes classiques, chaque défaut doit être identifié localement . Si nous souhaitons utiliser l'IA , il faut avoir une base de données pour utiliser les techniques d'apprentissage. Dans ce chapitre nous présentons les approches mises en œuvre pour résoudre le problème de détection , classification et localisation des défauts dans un réseau de transport électrique à l'aide de l'intelligence artificielle. Trois méthodes d'apprentissage supervisé ont été appliquées : K-Nearest Neighbors (KNN) , Support Vector Machine (SVM) et Random Forest (RF).

III.2 Présentation d'échantillon de test

La base de données utilisée de cette étude a été générée à partir de la simulation d'un réseau électrique de transport haute tension de 60 kV , simulé sous MATLAB/Simulink (Figure III.1) . Ce réseau est constitué de quatre jeux de barres interconnectés et alimentés par une seule source , et représente un scénario simplifié mais représentatif pour l'analyse des défauts dans les réseaux de transport .

Les données simulées comprennent plus de 16 000 échantillons, chacun contenant des mesures de courants et de tensions triphasées enregistrées à différents points du réseau ; à chaque échantillon est associée une étiquette précisant la présence ou l'absence d'un défaut, ainsi que des informations détaillées sur la nature du défaut (monophasé , biphasé , triphasé) et sa localisation précise par rapport aux lignes et aux jeux de barres .

Afin de garantir la fiabilité des résultats issus de l'apprentissage automatique , un pré traitement des données a été réalisé . Celui-ci comprend la normalisation des grandeurs électriques , l'encodage des variables et la division du jeu de données en ensembles d'entraînement et de test (80% et 20%) , nécessaires à l'évaluation des performances du modèle.

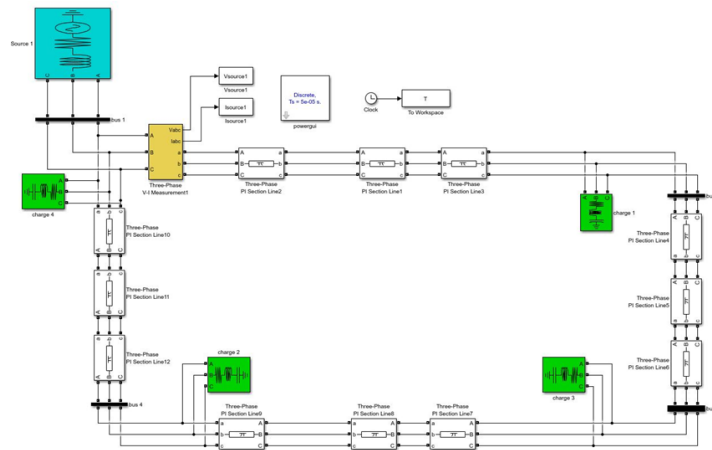


Fig. III.1 : Simulation d'un Réseau électrique 60 KV sous Simulink/MATLAB

III.3 Modèles d'apprentissage

III.3.1 Techniques d'apprentissage appliqués

RANDOM FOREST

Pour un premier essai de détection, classification et localisation des défauts dans ce réseau électrique, nous avons utilisé l'algorithme Random Forest. Ce choix s'explique par les nombreux avantages qu'offre ce modèle : robuste face au bruit, Capable de gérer des données complexes, résiste au surapprentissage, et facilite d'interprétation. Random Forest combine les résultats de plusieurs arbres afin de produire une prédiction plus stable et plus précise [7].

Un arbre de décision est un algorithme de classification supervisée qui divise un ensemble de données en sous-groupes homogènes selon des variables qualitatives ou quantitatives. L'arbre débute à une racine, et se divise en nœuds jusqu'à atteindre des feuilles (Figure III.2), qui représentent les classes finales. Ce processus de division s'arrête lorsqu'il n'est plus utile de continuer la séparation [7].




Fig. III.2 : Structure de l'arbre de décisions

Le Random Forest (RF) est fondée sur le concept de **bagging** (Bootstrap Aggregating) , consiste à générer plusieurs arbres de décision à partir des échantillons aléatoires d'un jeu de données d'entraînement. Ces arbres sont ensuite Regroupés pour produire une prédiction finale plus stable et précise.

L'échantillon bootstrap est généré en tirant aléatoirement avec remise n éléments parmi un ensemble de n données. Ainsi, certains éléments peuvent être sélectionnés plusieurs fois et d'autres peuvent ne pas être sélectionnés du tout . La probabilité Γ qu'un élément donné soit sélectionné au moins une fois dans cet échantillon est comme le montre l'équation suivante [7].

$$\Gamma = 1 - \left(1 - \frac{1}{n}\right)^n \quad (\text{III.1})$$

On mentionne les différentes étapes franchies lors de l'apprentissage du RF [7] :

- **Bootstrap** : À partir du jeu de données initial , on tire plusieurs sous-échantillons avec remise.
- **Construction d'arbres** : Pour chaque échantillon bootstrap , un arbre de décision non élagué est construit selon l'algorithme **CART** , on choisit à chaque nœud un sous-ensemble aléatoire de prédicteurs (\sqrt{p} pour p prédicteurs) et on Sépare le nœud en deux sous-nœuds et on continue la construction de l'arbre jusqu'à sa profondeur maximale .
- **Répétition** : Ce processus est répété pour créer un grand nombre d'arbres.
- **Prédiction par vote majoritaire** : Pour la classification , la classe prédite est celle qui reçoit le plus de votes parmi tous les arbres .

Dans notre cas , Random Forest est utilisée pour quatre tâches spécifiques :

- Détection binaire de la présence d'un défaut (0 = aucun défaut , 1 = défaut détecté)
- Classification multi-classes du type de défaut (monophasé , biphasé , triphasé)
- Identification de la ligne concernée par le défaut
- Estimation de la distance entre le point de défaut et les deux extrémités de la ligne

La prédiction par probabilité est utilisée à l'aide d'un classifieur basé sur les arbres de décision. Au lieu de se limiter à une simple classification binaire (défaut ou pas défaut) , l'algorithme fournit pour chaque échantillon une probabilité d'appartenance à chaque classe . Cela est réalisé grâce à la fonction `predict_proba` (Figure III.3), qui donne une estimation plus fine du risque de défaut . Cette approche permet une prise de décision plus souple .

- `model.binary.predict(input array)[0]` → renvoie la classe prédite (1 ou 0) .
- `model.binary.predict_proba(input array)[0]` → renvoie un tableau de probabilités pour chaque classe .

```
X_train_bin, X_test_bin, y_train_bin, y_test_bin = train_test_split(X_binary, y_binary, test_size=0.20, random_state=1)
model_binary = RandomForestClassifier(n_estimators=100, random_state=1)
model_binary.fit(X_train_bin, y_train_bin)
y_pred_bin = model_binary.predict(X_test_bin)
y_prob_bin = model_binary.predict_proba(X_test_bin)[:, 1]
```

Fig. III.3 : Entraînement avec RF

Support Vector Machine (SVM)

Le SVM (Support Vector Machine) machine à vecteurs de support, est un algorithme d'apprentissage supervisé utilisé pour résoudre des problèmes de classification ainsi que de régression.

Le principe des SVM repose sur la recherche d'un hyperplan dans un espace de caractéristiques qui permet de séparer les données en différentes classes, de manière à maximiser la distance entre cet hyperplan et les points de données les plus proches [11].




Fig. III.4 : Exemple des hyperplans et le choix de la droite optimale selon l'algorithme SVM

Dans le cas de notre étude, l'algorithme SVM (Support Vector Machine) est implémenté à l'aide de la classe SVC de la bibliothèque scikit-learn, en utilisant un noyau RBF (Radial Basis Function). Ce noyau permet de créer des frontières de décision non linéaires, adaptées à nos données. Ensuite, pour chaque point du jeu de test (les 20 % restants), le modèle calcule une fonction de décision basée sur la distance ou la similarité entre ce point et les vecteurs de support, à l'aide de la formule du noyau RBF, selon cette méthode les points sont classés, et les résultats sont ensuite comparés aux vraies classes pour mesurer la performance du modèle.

```
model_binary = SVC(kernel='rbf', probability=True, random_state=1)
model_binary.fit(X_train_bin, y_train_bin)
y_pred_bin = model_binary.predict(X_test_bin)
```

Fig. III.5 : Entraînement avec SVM

K-Nearest Neighbors (KNN)

La méthode des k plus proches voisins (k-Nearest Neighbors) est un algorithme d'apprentissage supervisé parmi les plus simples en machine learning. Son principe repose sur un apprentissage préalable qui consiste à associer des classes à des données, selon certaines caractéristiques prédictives [8].

L'algorithme KNN peut être exploité [8] :

- En classification , l'algorithme permet d'assigner une nouvelle donnée à une catégorie parmi un ensemble fini de classes.
- En régression , k-NN ne cherche une valeur réelle, en calculant la moyenne des valeurs associées aux k voisins les plus proches

L'algorithme KNN se déroule selon [9] :

- Choisir une valeur pour K le nombre de voisins à considérer .
- Calculer la distance entre la nouvelle donnée N et chaque donnée X_i déjà classée .
- Identifier les K données les plus proches de N parmi les X_i .
- Attribuer à N la classe la plus fréquente parmi ses K voisins .

On emploie ici une distance Euclidienne usuelle :

$$AB = \sqrt{(x_B - x_A)^2 + (y_B - y_A)^2} \quad (\text{III.2})$$

Dans notre cas , nous avons séparé l'ensemble en données d'entraînement et de test . Le modèle KNN que nous avons utilisé regarde les 15 voisins les plus proches d'un point pour deviner à quelle classe ce point appartient. Il garde simplement les données et compare les nouvelles données avec celles déjà vues . Par ailleurs , nous avons utilisé aussi la sélection de caractéristiques (Features Selection) , ce qui veut dire que 4 caractéristiques les plus importantes ont été conservées pour l'entraînement du modèle .

```
model_multi = KNeighborsClassifier(n_neighbors=15)
model_multi.fit(X_train_multi, y_train_multi)
y_pred_multi = model_multi.predict(X_test_multi)
```

Fig. III.6 : Entraînement avec KNN

III.4 Conclusion

Dans ce chapitre nous avons présenté les différentes techniques d'apprentissage supervisé retenues pour aborder notre problématique , nous avons décrit l'implémentation des algorithmes KNN , SVM et Random Forest sur nos données . Chaque méthode a été préparée et entraînée dans un cadre expérimental identique afin d'évaluer objectivement leurs performances . Les résultats obtenus pour chaque modèle seront analysés et comparés en détails dans le chapitre suivant , afin d'identifier l'approche la plus pertinente pour notre problématique.

Chapitre IV

Validation des modèles d'apprentissage automatique

IV.1 Introduction

Ce chapitre est consacré à l'analyse comparative des performances des techniques étudiées, l'objectif est d'évaluer leur efficacité sur notre problématique. À travers cette comparaison nous cherchons à identifier le modèle le plus adapté à notre jeu de données, cette analyse permettra de justifier le choix final de l'algorithme retenu pour la suite de notre travail. La localisation des défauts a été traitée exclusivement à l'aide de la méthode Random Forest, en raison de ses performances supérieures observées lors des premières expérimentations.

IV.2 Visualisation des jeux de données

D'abord, il faut noter que dans notre base de données, la première classification permet de détecter la présence de défaut (1) ou son absence (0). Cela est représenté dans diagramme sur la Figure IV.1 où 66,8% des échantillons représentent un défaut et 31,2% sont les cas d'absence de défaut.

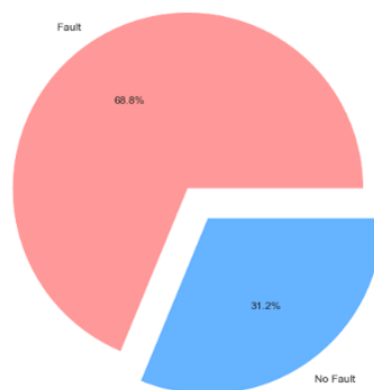


Fig. IV.1 : Diagramme circulaire de répartition des classes binaires

Une deuxième classification (Figure IV.2) a été réalisée, où dans ce cas les détails des 66.8% ont été classifiés avec 3 autres chiffres identifiant les phases concernées par le défaut :

- Cas sans défaut (0000) représente 31,2% des données .
- Cas avec défaut biphasé à la terre (1110) LLG Fault représente 12,5% des données.
- Cas avec défaut triphasé à la terre (1111) LLLG Fault représente 18,7% des données .
- Cas avec défaut monophasé à la terre (1001 défaut de la phase A et 1100 défaut à la phase C)LG Fault représente 18,7% des données .
- Cas avec défaut triphasé isolé (0111) LLL Fault : 18,7% des données .




Fig. IV.2 : Diagramme circulaire de classification Multi-Classes

Pour une meilleure illustration de cette base de données, nous avons présenté les signaux de tensions (Figure IV.3) et des courants (Figure IV.4) utilisés pour l'apprentissage des algorithmes de l'IA où les signaux peuvent être divisés en plusieurs zones comme suit :

- **Zone [0 - 1000]** : ça représente le cas normal (0000) , les courants et les tensions sont équilibrés et aucune anomalie n'est détectée .
- **Zone [1001 - 2000]** : ça représente un défaut monophasé à la terre sur la phase A (1001) où on remarque une augmentation brutale dans la valeur du courant I_a .
- **Zone [2001 - 4000]** : ça représente un défaut triphasé ; on remarque une chute de tensions sur les trois phases tandis que les trois courants augmentent (0111).
- **Zone [4001 - 5000]** : ça représente le cas normal (0000).
- **Zone [5001 - 8049]** : les trois courants et tensions sont déséquilibrés ; il s'agit d'un défaut triphasé équilibré (1111).
- **Zone [8050 - 10000]** : c'est le cas normal (0000).
- **Zone [10001 - 12000]** : il s'agit d'un court-circuit entre les deux phases B et C (1110).
- **Zone [12001 - 13000]** : les trois tensions et courants sont déséquilibrés donc il s'agit d'un défaut triphasé (1111).

- **Zone [13001 - 14000]** : ça représente un défaut monophasé à la terre sur la phase C (1100)
- **Zone [14001 - 15000]** : c'est le cas normal (0000).
- **Zone [15001 - 16000]** : il y a un déséquilibre sur la phase A ; c'est un défaut monophasé sur cette phase (1001).

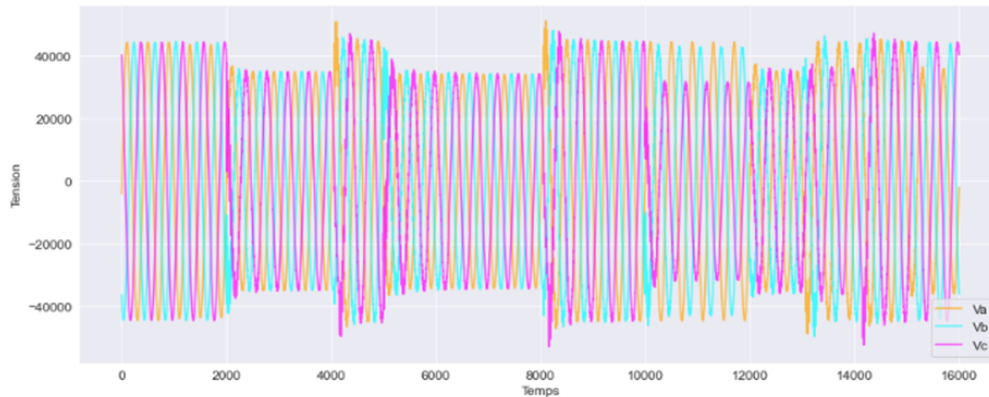


Fig. IV.3 : Courbe des tensions triphasées en fonction du temps




Fig. IV.4 : Courbe des courants triphasés en fonction du temps

Ces signaux ont été utilisés pour l'apprentissage de l'IA. et lors de notre étude nous avons testé d'autres signaux qui ont été générés par d'autres défauts (sur des lignes différentes et sur des positions différentes) afin de comparer les résultats des algorithmes de l'IA.

IV.3 Visualisation des Résultats des Méthodes d'Intelligence Artificielle

IV.3.1 Résultats de détection des défauts

Nous avons entraîné différents signaux afin de classifier d'abord la détection des défauts avec les trois méthodes RF, SVM et KNN. Les matrices de confusion sont illustrées sur les figures IV.5, IV.6 et IV.7 respectivement.

Il est à noter que le résultats se divisent en quatre parties :

- **Vrai Positif (True Positive TF) :** Le modèle prédit "défaut" et il y a vraiment un défaut (algorithme fonctionne correctement) .
- **Vrai Négatif (True Negative TF) :** Le modèle prédit "pas de défaut" et il n'y a pas de défaut (algorithme fonctionne correctement) .
- **Faux Positif (False Positive FP) :** Le modèle prédit "défaut" , mais en réalité il n'y a pas de défaut (fausse alerte) .
- **Faux Négatif (False Negative FN) :** Le modèle prédit "pas de défaut" , alors qu'il y a réellement un défaut (erreur grave , car un défaut réel n'a pas été détecté).

Donc plus le paramètre FN est important dans nos résultats, nous pouvons dire que l'algorithme n'est pas très fiable.




Fig. IV.5 : Matrice de confusion de la classification binaire avec RF




Fig. IV.6 : Matrice de confusion de la classification binaire avec SVM




Fig. IV.7 : Matrice de confusion de la classification binaire avec KNN

En analysant les résultats nous constatons :

Pour KNN :

- TP : 2109
- TN : 985
- FP : 69
- FN : 38

Nous pouvons le considérer comme un bon résultat global avec très peu de faux négatifs.

Pour SVM :

- TP : 1953
- TN : 1007
- FP : 62
- FN : 179

Les résultats de SVM sont moins performant que KNN , surtout avec un nombre élevé de faux négatifs.

Pour RF :

- TP : 2092
- TN : 1021
- FP : 48
- FN : 40

En comparant les résultats obtenus, nous observons que l'algorithme de Random Forest est le modèle le plus performant avec le plus de bonnes prédictions et le moins d'erreurs (que ce soient positifs ou négatifs), ce qui confirme que l'algorithme de Random Forest est le plus adapté à la problématique de détection binaire dans ce contexte .

Pour une meilleure comparaison entre les trois algorithmes, nous présentons dans le Tableau IV.1 un récapitulatif des résultats de classement binaire.

Tab. IV.1 : Résultats de la classification binaire

Algorithme	précision	recall	f1-score	support
Random Forest	0.97	0.97	0.97	3201
SVM	0.93	0.92	0.93	3201
KNN	0.96	0.96	0.96	3201

La figure IV.8 illustrant le F1 score des trois algorithmes montre que Random Forest atteint une précision, un rappel et un F1-score de 0.97 , ce qui indique qu'il détecte et classe les défauts avec très peu d'erreurs. KNN suit avec des scores de 0.96, et SVM obtient un F1-score de 0.93 légèrement inférieur aux deux autres . Il est à noter que tous les algorithmes ont été évalués sur un échantillon de 3201 données .

Ces résultats montrent que dans le cadre de cette tâche de classification binaire , Random Forest est l'algorithme le plus fiable et efficace .




Fig. IV.8 : Comparaison des performances des algorithmes en classification binaire

IV.3.2 Résultats de l'identification des défauts

Maintenant que la validation de détection (classification binaire) est faite, nous allons traiter maintenant le cas de l'identification de défaut (classification multi-classe). Les résultats des algorithmes RF, SVM et KNN sont illustrés sur les figures IV.9, IV.10 et IV.11 respectivement.




Fig. IV.9 : Matrice de confusion de la classification multi-classes avec RF

L'analyse des matrices de confusion multiclassées révèle que le modèle RF offre les meilleures performances : 1069 instances ont été classés correctement de la classe 0, 535 ont été mises de la classe 1, 389 de la classe 2, 213 de la classe 3, 400 de la classe 4, et 592 de la classe 5, avec très peu d'erreurs hors diagonale .

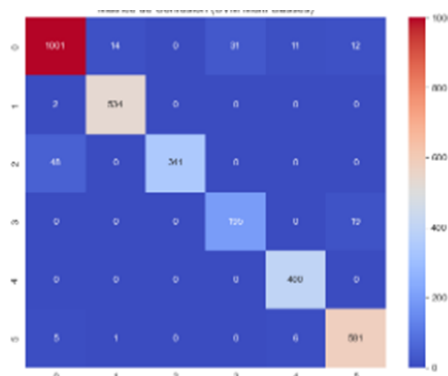


Fig. IV.10 : Matrice de confusion de la classification multi-classes avec SVM

Pour l'algorithme SVM, plus de confusions ont été enregistrées avec 48 instances de la classe 2 sont mal classées comme classe 0, 12 de la classe 0 comme classe 5, et 31 de la classe 0 comme classe 3.




Fig. IV.11 : Matrice de confusion de la classification multi-classes avec KNN

L'utilisation de l'algorithme KNN offre 1059 bons pour la classe 0, 534 pour la classe 1, mais fait quelques erreurs comme 6 confusions entre la classe 3 et 0.

Ces chiffres confirment l'efficacité du modèle RF, qui présente une répartition très nette sur la diagonale, en montrant une excellente précision de classification.

Pour une meilleure comparaison entre les trois algorithmes, nous présentons dans le Tableau IV.2 un récapitulatif des résultats de classement multi-classe.

Tab. IV.2 : Résultats de la classification multi-classe

Algorithme	précision	recall	f1-score	support
Random Forest	0.99	0.99	0.99	3201
SVM	0.95	0.95	0.95	3201
KNN	0.97	0.97	0.97	3201

Les résultats obtenus montrent encore que l'algorithme Random Forest est le plus fiable en comparant avec les autres algorithmes (SVM et KNN). En effet, Random Forest atteint une précision, un rappel et un F1-score de 0.99, traduisant une performance presque parfaite dans la classification des différentes classes de défauts. Le KNN suit avec 0.97 pour chaque métrique, tandis que le SVM affiche 0.95.

Le graphique de comparaison des F1-scores pondérés (Figure IV.12) illustre visuellement cette hiérarchie de performance confirmant que Random Forest est l'algorithme le plus adapté à notre problématique de classification multiclasse.

IV.3.3 Résultats de la localisation des défauts

Dans cette partie, nous étudions le cas de localisation de défaut, mais cette fois-ci uniquement l'algorithme Random Forest est appliqué (vu que ses performances ont été approuvées dans les deux tests précédents). L'objectif est d'identifier avec exactitude la position des défauts par

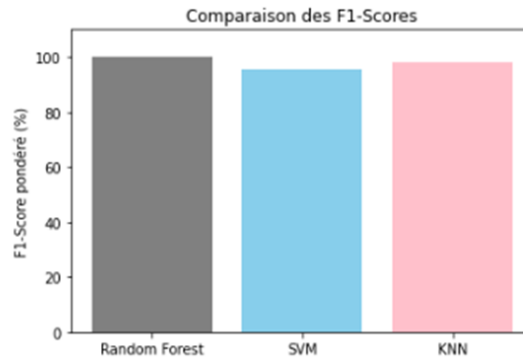


Fig. IV.12 : Comparaison des performances des algorithmes en classification multi-classe

rapport aux jeux de barres A et B qui bornent le défaut dans la ligne de transport afin de faciliter les interventions nécessaires .

Dix (10) cas de défauts ont été testés avec des défauts dans différentes lignes, et les résultats sont illustrés dans le Tableau IV.3.

Tab. IV.3 : Résultats de localisation des défauts dans le réseau

Echantillon	Ligne réelle (A-B)	Ligne détectée (A-B)	Distance réelle A (Km)	Distance détectée A(Km)	Distance réelle B (Km)	Distance détectée B (Km)
1	1-2	1-2	15.00	15.15	30.00	29.85
2	3-4	3-4	0.00	7.95	45.00	37.05
3	3-4	3-4	30.00	30.00	15.00	15.00
4	4-1	4-1	30.00	30.50	15.00	15.00
5	3-4	3-4	30.00	30.00	15.00	15.00
6	3-4	3-4	0.00	0.15	45.00	44.85
7	3-4	3-4	30.00	30.00	15.00	15.00
8	2-3	2-3	15.00	15.15	30.00	29.85
9	3-4	3-4	30.00	30.00	15.00	15.00
10	4-1	4-1	30.00	30.00	15.00	15.00

En analysant les résultats obtenus par les algorithmes, nous constatons ce qui suit :

- Précision de 100% dans l'identification des lignes de défaut (ligne réelle = ligne détectée pour tous les échantillons) .
- Localisation très précise des défauts avec des écarts de distance inférieurs à 0.5 km dans la majorité des cas .
- Léger écart observé dans 2 cas (échantillons 2 et 6) , mais sans impact significatif .
- Cohérence vérifiée avec les distances mesurées depuis les deux extrémités (points A et B).

La matrice de confusion des résultats est illustrée sur la figure 4.3.




Fig. IV.13 : Matrice de confusion pour ligne de défaut

La majorité des défauts sont correctement identifiés :

- **Ligne 1-2** : 791 sur 795 sont correctement prédits .
- **Ligne 2-3** : 192 sur 194 correctement prédits .
- **Ligne 3-4** : 824 sur 830 correctement prédits .
- **Ligne 4-1** : 378 sur 382 correctement prédits .

Il existe des erreurs légères de confusion entre lignes ce qui indique que le modèle est très efficace pour localiser les défauts dans le réseau électrique .

IV.4 Conclusion

Nous constatons que l'algorithme de Random Forest offre les meilleurs résultats dans la détection, l'identification et la localisation des défauts dans le réseau HT à 4 nœuds, où les résultats de ces dernières montrent toujours très peu de résultats erronés hors la diagonale.

Conclusion Générale

Avec l'augmentation de la demande énergétique, la protection des réseaux électriques devient de plus en plus indispensable, et aucune rupture n'est tolérée dans les systèmes électro-énergétiques. Et si une rupture apparaît, il est indispensable de la détecter et la traiter le plus rapidement possible pour assurer la continuité de service. Donc il faut avoir une identification et classification et localisation fiable du défaut. D'habitude, les détections sont faites localement par les relais, et certaines fois la localisation n'est pas fiable ce qui augmente le temps d'intervention et réduit la fiabilité.

En explorant l'apport de l'intelligence artificielle, nous avons appliqué dans ce mémoire trois algorithmes pour la détection, la classification et la localisation des défauts dans un réseau de transport de 60 kV composé de quatre nœuds.

Les trois techniques d'apprentissage supervisé utilisées dans notre mémoire sont : Random Forest, K-Nearest Neighbors et Support Vector Machine. Une base de données a été utilisée en simulant divers types de défauts sous environnement MATLAB/Simulink, nous avons pu entraîner et valider nos modèles.

Parmi ces techniques, l'algorithme Random Forest s'est révélé être le plus performant pour notre problématique en offrant :

- une précision de 97,2% pour la détection des défauts
- une performance quasi parfaite dans la classification multi-classes (F1-score de 0.99)
- une localisation des défauts sur les lignes du réseau avec une exactitude supérieure à 97%, y compris une identification correcte des distances avec une marge d'erreur plus ou moins tolérables.

Ces résultats démontrent que les techniques d'intelligence artificielle, en particulier Random Forest, sont très efficaces pour renforcer la réactivité, la sécurité et la continuité de service dans les réseaux de transport électrique. Elles permettent de réduire les temps d'intervention et d'assurer la continuité de service.

Bibliographie

- [1] N. E. Bay et F. Badji, « Localisation des Défaits dans les Réseaux Électriques par une Méthode Intelligente », Mémoire de Master en Electrotechnique, option Réseaux Électriques, Université de Bouira, (2021).
- [2] M. Bouchahdane, « Coordination de systèmes de protection appliquée au réseau national », Thèse de Doctorat en Électrotechnique, Université Frères Mentouri–Constantine 1, (2017).
- [3] A. Bouhafis, A. Rezgane et M. R. Bedda, « Détection et classification des défauts dans les réseaux électriques par les réseaux de neurones », thèse de Master en Génie Électrique, Université Kasdi Merbah Ouargla, 2023.
- [4] C. D. Pham, « Détection et localisation de défauts dans les réseaux de distribution HTA en présence de génération d'énergie dispersée », Thèse de doctorat, Institut National Polytechnique de Grenoble, France, (2005).
- [5] Bouchiba, N. « Application de l'intelligence artificielle pour la détection et la localisation des défauts dans les réseaux électriques ». Thèse de doctorat, Université de Moncton, Faculté d'Ingénierie, (2024).
- [6] Alilouch, Raghda. Mémoire : « Analyse et détection des défauts dans les réseaux électriques ». Université du Québec en Abitibi-Témiscamingue, (2021).
- [7] H. Suprême, « Détection en temps réel de l'instabilité transitoire des réseaux électriques avec les mesures synchronisées de phaseurs », Thèse de doctorat, École de technologie supérieure, Université du Québec, Montréal, Canada, 2017.
- [8] Framacalc (PGDG). (s. d.). Algorithme k plus proches voisins (k-NN). Consulté le 12 juin 2025, [Lien](#)
- [9] Cours NSI Première – K plus proches voisins (k-NN). [Lien](#).
- [10] YAHIAOUI, H., & BENAROUS, S. (2016). Analyse des défauts dans les réseaux électriques en utilisant la transformée d'ondelette . Mémoire de Master, Université Yahia Fares de Médéa. DSpace Université de Médéa. (2016)
- [11] O. Bousquet, « Introduction aux 'Support Vector Machines' (SVM) », Centre de Mathématiques Appliquées, École Polytechnique, Orsay, (2001)