

THÈSE

Présentée par

ABDELHAK FLIH

Pour l'obtention du grade de

DOCTORAT EN 3^{ème} CYCLE LMD

Spécialité : Réseaux électriques

Thème

Classification et localisation des défauts dans les systèmes de transmission bipolaires HVDC

Devant le Jury composé de :

Soutenue le :

Nom & prénoms	Grade	Qualité	Domiciliation
M. Merah Mostefa	Pr	Président	UAB.Mostaganem
M.Khiat mounir	Pr	Examineur	ENP MA Oran
Mme Bekri Loubaba	MCA	Examinatrice	Université de Saïda
M.Bekkouche benaïssa	Pr	Examineur	UAB.Mostaganem
Mme GHOMRI Lila	MCA	Directeur de thèse	UAB.Mostaganem
M.SOUAG Slimane	MCB	Co-directeur de thèse	UAB.Mostaganem

Année Universitaire :2024/2025



People's Democratic Republic of Algeria
Ministry of Higher Education and Scientific Research
University of Mostaganem Abdelhamid Ibn Badis
Faculty of Science and Technology
Department of Electrical Engineering



THESIS

Presented by

ABDELHAK FLIH

For obtaining the grade of

Doctorate in 3rd LMD cycle

Speciality: Electric Networks

Theme

**Classification and Localization of Faults in Bipolar HVDC
Transmission Systems**

In front of a jury composed of:

date:

Surname & first name	Grade	As	From
Mr. Merah Mostefa	Pr	President	UAB.Mostaganem
Mr.Khiat mounir	Pr	Examiner	ENP MA Oran
Ms. Bekri Loubaba	MCA	Examiner	University of Saïda
Mr. Bekkouche benaïssa	Pr	Examiner	UAB.Mostaganem
Ms.GHOMRI Lila	MCA	Thesis supervisor	UAB.Mostaganem
Mr. SOUAG Slimane	MCB	Thesis co- supervisor	UAB.Mostaganem

Academic Year:2024/2025

La patience est la capacité à attendre calmement les résultats tout en croyant en la valeur du processus.

Table des matières

1	Aperçu des Systèmes HVDC	13
1.1	Introduction à la Technologie HVDC	13
1.2	Avantages du HVDC	15
1.3	Composants des Systèmes HVDC	15
1.4	Types de Systèmes HVDC	15
1.5	Applications des Systèmes HVDC	16
1.6	Différentes Topologies Utilisées dans les Systèmes HVDC	16
1.6.1	Configuration Point-à-Point	16
1.6.2	Configuration Multi-Terminaux	17
1.6.3	Configuration back to back	17
1.7	Avantages des Systèmes HVDC par Rapport aux Systèmes HVAC	18
1.8	Composants et Technologies dans les Systèmes HVDC	19
1.8.1	Convertisseurs	19
1.8.2	Transformateurs	20
1.8.3	Câbles de Transmission	20
1.8.4	Filtres	21
1.8.5	Réacteurs Saturables	21
1.8.6	Principaux Éléments des Sous-Station de Conversion HVDC	21
1.9	Aspects Coûts des Systèmes HVDC par Rapport aux Systèmes HVAC	22
1.9.1	Coûts Initiaux	23
1.9.2	Dépenses d'Entretien	23
1.9.3	Avantages Opérationnels	23
1.9.4	Exemples Réels	23
1.10	Conclusion	24
2	Modélisation des Systèmes VSC HVDC	25
2.1	Introduction	25
2.2	Signification dans le domaine de la transmission d'énergie	26
2.3	Systèmes VSC Bipolaires	26
2.4	Avantages des Systèmes VSC Bipolaires	26
2.5	Topologie	26
2.6	Structure physique	26
2.7	Convertisseurs	27
2.8	Transformateurs et réacteurs de phase	27
2.9	Filtres CA	28
2.10	Câbles CC et disjoncteurs	28
2.11	Condensateurs et filtres CC	28

2.12	Valves IGBT	29
2.13	Grille en courant alternatif AC	29
2.14	Topologie du convertisseur	29
2.15	Modèle mathématique et formulation	31
2.16	Lignes de transmission	33
2.16.1	Propriétés électriques des lignes de transmission	33
2.16.2	Conducteurs	33
2.16.3	Modèles de lignes moyennes et courtes	35
2.16.4	Modélisation du câble	35
2.17	Contrôle des VSC	37
2.17.1	Réponse rapide aux perturbations	38
2.17.2	Technique de Modulation de Largeur d'Impulsion (PWM)	38
2.17.3	Régulation de Tension	38
2.17.4	Contrôle de Courant	38
2.18	Conclusion	38
3	Détection et localisation des défauts dans les Systèmes HVDC	41
3.1	Introduction	41
3.2	Importance de la détection et de la localisation des défauts	41
3.3	Méthodes de détection et localisation dans la littérature	41
3.3.1	Méthodes basées sur le temps de trajet des ondes (Time-Domain Reflectometry TDR)	43
3.4	Méthodes basées sur les ondes voyageuses progressives	43
3.4.1	Méthodes basées sur la fréquence naturelle	44
3.4.2	Méthodes basées sur l'impédance	45
3.4.3	Méthodes basées sur la transformée en ondelettes	47
3.4.4	Méthodes de protection basées sur les transitoires	48
3.4.5	Méthodes basées sur les dérivées de tension et de courant	49
3.4.6	Approches basées sur l'intelligence artificielle et l'apprentissage automatique	50
3.5	Protection et détection	51
3.6	La maintenance corrective	51
3.7	La maintenance préventive	52
3.8	La maintenance prédictive	52
3.9	Analyse et classification de données	52
3.10	Comportement du courant lors d'un défaut dans un système à courant continu (CC)	53
3.11	Les défauts dans le système HVDC	54
3.11.1	Défauts de circuit ouvert	55
3.11.2	Défauts de court-circuit	56
3.12	Classification des défauts	57
3.12.1	Apprentissage supervisé	58
3.12.2	Classification	58
3.12.3	Régression	59
3.12.4	Apprentissage non supervisé	59
3.13	Système de surveillance d'état de système HVDC	60
3.14	Technologies de mesure pour la surveillance des tensions, du champ électrique et de la charge dans les lignes HVDC	61

3.15 Conclusion	63
4 Classification des Défauts dans les Systèmes HVDC VSC par la machine learning	65
4.1 Introduction	65
4.2 L'apprentissage automatique	65
4.2.1 Types d'apprentissage automatique	66
4.2.2 Processus d'apprentissage automatique	67
4.3 Algorithmes pour l'apprentissage automatique	67
4.3.1 Machines à Vecteurs de Support (SVM)	69
4.3.2 Réseaux de Neurones	70
4.4 Définition de RPG	73
4.5 Concepts Clés	73
4.6 Avantages	74
4.7 Modèle Mathématique	74
4.8 Choix du Noyau	75
4.8.1 Rôle du Noyau	75
4.8.2 Types de Noyaux	75
4.8.3 Impact sur la Performance	76
4.8.4 Optimisation des Hyperparamètres	76
4.9 Hyperparamètres du Noyau	76
4.10 Optimisation bayésienne	76
4.11 Concepts Principaux	77
4.12 Étapes de l'Optimisation Bayésienne	77
4.13 Avantages	77
4.14 Applications	77
4.15 Modélisation via un processus gaussien	77
4.16 Fonction d'acquisition	78
4.17 Étapes de l'Optimisation Bayésienne	78
4.18 Évaluation des Modèles d'Apprentissage Automatique	79
4.19 Défis de l'Apprentissage Automatique	79
4.20 Le déroulement des opérations de la machine learning	80
4.20.1 1ère étape : Acquisition des données	80
4.20.2 2ème étape : Prétraitement des données	81
4.20.3 3ème étape : Sélection et extraction des caractéristiques	81
4.20.4 4ème étape : Formation du modèle	81
4.20.5 5ème étape : Évaluation du modèle	82
4.20.6 6ème étape : Déploiement et intégration	82
4.20.7 Entraînement de modèles	82
4.20.8 Matrice de confusion	83
4.20.9 Métriques d'évaluation	83
4.20.10 Validation croisée k-plis	84
4.21 Caractéristiques statistiques descriptives	85
4.22 Ajustement de courbe et moindres carrés non linéaires	86
4.23 Méthodologie	87
4.23.1 Étapes du Processus d'Ajustement de Courbe	87
4.24 Conclusion	88
5 Résultat et discussion de classification et régression par ML	89

5.1	Introduction	89
5.2	Emplacements des défauts	89
5.2.1	Défaut de pôle à pôle	90
5.2.2	Défaut de pôle à terre	91
5.3	Résultats des simulations	91
5.3.1	Collecte des données	92
5.3.2	Extraction des caractéristiques	92
5.3.3	Le modèle des K-voisins les plus proches (KNN) dans le diagnostic des défauts	95
5.3.4	k-fold Cross Validation : Renforcer la fiabilité du modèle	95
5.3.5	Résultat de classification	96
5.3.6	Résultat de localisation	99
5.3.7	Impact de la résistance de défaut R_f	100
5.4	Méthode hétérogène par ML et ajustement du courbe pour la classification et localisation des défauts	101
5.4.1	Complexité et Non-linéarité du Modèle	102
5.4.2	Impact de la fréquence d'échantillonnage sur le courant de crête	103
5.4.3	Obtention des données	104
5.4.4	Méthode proposée	104
5.5	Méthodologie	106
5.6	Analyse des pointes de courant défectueuses	107
5.7	Résultat de la classification	108
5.7.1	Analyse détaillée	110
5.8	Résultat de test	111
5.8.1	Pour une résistance de défaut de 0.01 ohm	111
5.8.2	Pour une résistance de défaut de 10 ohm	112
5.8.3	Pour une résistance de défaut de 100 ohm	113
5.9	Analyse comparative de la localisation des défauts proposée avec les méthodes existantes	115
5.10	Limites de La méthode de localisation de défauts basées sur l'apprentissage automatique et l'ajustement de courbe	115
5.11	Régression par Apprentissage Automatique pour la Localisation des Défauts dans les lignes HVDC VSC	116
5.11.1	Validation et Test de ANN	117
5.11.2	Validation et Test de GPR	118
5.11.3	Validation et Test de BO-GPR	118
5.12	Resultat et interprétation	119
5.13	Conclusion , Défis et orientations futures	121
	Bibliographie	124
	A Algorithmes d'optimisation et Ajustement de Courbe	137
	Abstract in English	141

Table des figures

1.1	Évolution technologique du HVDC [6]	14
1.2	Configuration Point-à-Point	16
1.3	Configuration Multi-Terminaux	17
1.4	Configuration back to back	17
1.5	principaux composants d'un système VSC-HVDC [23]	22
1.6	Comparaison des coûts totaux AC et DC en fonction de la distance	22
2.1	Configuration du Systeme VSC-HVDC [29]	27
2.2	VSC deux niveaux	30
2.3	VSC trois niveaux	30
2.4	VSC au système CA	32
2.5	Schéma équivalent du circuit VSC	32
2.6	Liaisons typiques	34
2.7	Modèle en π de ligne de transport	35
2.8	Système de Contrôle de la Technologie de Transmission VSC HVDC [29]	37
3.1	Calcul de la distance de défaut en utilisant deux diviseurs de tension	46
3.2	Modèle de la ligne de transmission en condition de défaut (f)	47
3.3	Caractéristiques du courant lors d'un défaut dans un système à courant continu.	54
3.4	Technologies de surveillance pour les lignes de transmission HVDC [127]	60
4.1	Illustration de la régression logistique : séparation entre deux classes par une ligne de décision (sigmoïde).	68
4.2	Exemple d'un arbre de décision illustrant les nœuds et les feuilles de classification.	68
4.3	Illustration du principe de séparation par SVM : l'hyperplan maximal sépare deux classes de données avec une marge maximale.	70
4.4	Architecture d'un réseau de neurones artificiels (ANN) à une couche cachée.	70
4.5	Illustration du principe du classificateur K plus proches voisins (KNN). Le point inconnu est classé selon les 3 voisins les plus proches.	73
4.6	Organigramme des étapes du processus de Machine Learning	80
5.1	Diagramme Schématique d'un Système Bipolaire VSC HVDC	90
5.2	Modèle de défaut pole-terre	91
5.3	Modèle de défaut pole-pole	91
5.4	signal du courant lors d'un défaut pole positif	92
5.5	signal de la tension lors d'un défaut pole positif	93
5.6	signal du courant lors d'un défaut pole négatif	93

5.7	signal de la tension lors d'un défaut pôle négatif	94
5.8	signal du courant lors d'un défaut bipole	94
5.9	signal de la tension lors d'un défaut bipole	95
5.10	Organigramme du processus de classification des défauts utilisant le modèle	
	KNN	96
5.12	Diagramme de dispersion entre les pics de I_{pos} et I_{neg}	97
5.13	Diagramme de dispersion entre les pics de $rmsV_{pos}$ et $rmsV_{neg}$	97
5.14	Diagramme de dispersion entre les pics de $rmsI_{pos}$ et $rmsI_{neg}$	98
5.15	Matrice du confusion pour les modèles 1,2,3	98
5.16	Matrice du confusion pour le modèle4	99
5.17	matrice du confusion1	100
5.18	nuage des points pour rf 0.01 ohm	100
5.19	matrice du confusion2	101
5.20	nuage des points pour rf 10 ohm	101
5.21	matrice du confusion3	102
5.22	nuage des points pour rf 100 ohm	102
5.23	Modèle à sections multiples en π	103
5.24	I_{peak} en fonction de la fréquence d'échantillonnage	104
5.25	Le cadre procédural utilisé dans notre étude	105
5.26	Courant de défaut dans différents scénarios 0,01, 10, 100 ohms	108
5.27	gravité de la faille par ML	109
5.28	Catégories de fautes par ML	109
5.29	Ajustements des courbes pour des défauts de pôle positif dans des résistances	
	de 0.01, 10 et 100 respectivement par l'optimisation de la région de confiance	
	$R=0.99$	109
5.30	Ajustements des courbes pour des défauts de pôle négatif dans des résistances	
	de 0.01, 10 et 100 respectivement par l'optimisation de la région de confiance	
	$R=0.99$	110
5.31	Ajustements des courbes pour des défauts de pôle positif à négatif dans	
	des résistances de 0.01, 10 et 100 respectivement par l'optimisation de la	
	région de confiance $R=0.99$	110
5.32	Organigramme de la méthode proposé	114
5.33	Illustration des variations de tension et extraction des nouvelles caractéristiques	116
5.34	Validation du modèle ANN	117
5.35	Test du modèle ANN	117
5.36	Validation du modèle GPR	118
5.37	Test du modèle GPR	118
5.38	Validation du modèle BO-GPR	118
5.39	Test du modèle BO-GPR	118
A.1	Schéma de bloc de la liaison HVDC vsc bipolaire utilisée	140

Liste des tableaux

1.1	Comparaison HVDC vs HVAC basée sur la littérature	19
1.2	Comparaison entre HVDC VSC et HVDC LCC	20
4.1	Caractéristiques statistiques descriptives : définitions et formules	85
5.1	Résultats de classification du modèle KNN	96
5.2	Relation entre RF (Ohm) et Ipos peak (kA)	107
5.3	Tableau des fautes à la terre positives	111
5.4	Tableau des fautes à la terre négatives	111
5.5	Tableau des fautes positives et négatives	112
5.6	Tableau des fautes à la terre positives	112
5.7	Tableau des fautes à la terre négatives	112
5.8	Tableau des fautes positives et négatives	112
5.9	Tableau des fautes à la terre positives	113
5.10	Tableau des fautes à la terre négatives	113
5.11	Tableau des fautes positives et négatives	113
5.12	Tableau des références et méthodes	115
5.13	Performance des modèles pour la localisation des défauts dans le systèmes HVDC VSC (validation)	119
5.14	Performance des modèles pour la localisation des défauts dans le système HVDC VSC (test)	119
5.15	Erreurs moyennes et maximales des modèles.	120

Acronymes et Nomenclature

Acronymes

- HVDC : High Voltage Direct Current
- VSC : Voltage Source Converter
- CSC : Current Source Converter
- ML : Machine Learning
- KNN : K-Nearest Neighbors
- GPR : Gaussian Process Regression
- ANN : Artificial Neural Network
- BO : bayésienne optimization
- CA : Courant Alternatif
- CC : Courant Continu
- STFT : Short-Time Fourier Transform
- WT : wavelet transform
- TF : transformée de Fourier

Nomenclature

- $w_{ij}^{(l)}$: poids du nœud
- $b_j^{(l)}$: biais du nœud
- e_i : Résidu pour chaque point de données i
- y_i : Valeur observée pour chaque point de données i
- $f(x_i; \theta)$: Valeur prédite pour le point de données i basée sur les paramètres du modèle θ
- θ : Paramètres du modèle
- $\sum_{i=1}^m e_i^2$: Somme des résidus au carré
- Δx : Pas de variation dans le sous-problème de la région de confiance
- $f(x)$: Fonction objectif
- $\nabla f(x)$: Gradient de la fonction objectif
- ρ_k : Rapport utilisé pour évaluer la qualité du pas dans la méthode de la région de confiance
- Δ : Rayon de la région de confiance
- x_k : Point actuel à l'itération k
- Δ_k : Rayon actuel de la région de confiance
- η : Paramètre d'acceptation
- γ : Facteur de mise à jour de la région de confiance
- $D_n = \{(x_1, y_1), \dots, (x_n, y_n)\}$: Jeu de données composé de n paires
- $d(x_i, x_j)$: Distance euclidienne
- R^2 : Coefficient de détermination
- Z : Score standard
- μ : Moyenne du vecteur
- σ : Écart-type
- a_0, a_i, b_i : Coefficients de la série de Fourier
- w : Fréquence angulaire
- a_1 : Amplitude de la fonction gaussienne
- x : Variable

- b_1 : Moyenne (centre) de la fonction gaussienne
- c_1 : Écart-type (largeur) de la fonction gaussienne
- $a_n, a_{n-1}, \dots, a_1, a_0$: Coefficients du polynôme
- SSR : Somme des carrés des résidus
- SST : Somme totale des carrés
- d : Distance euclidienne
- L : longueur totale de la ligne
- L_a : distance de défaut réelle
- L_f : distance de défaut estimée en utilisant l'approche proposée
- $f(t)$ est le signal temporel à analyser,
- $\Psi(t)$ est la fonction mère ondelette,
- $\Psi_{a,b}^*(t)$ est la version conjuguée complexe de l'ondelette après mise à l'échelle a et translation b .
- U_c : tension de sortie du convertisseur,
- U_f : tension au nœud de filtre côté alternatif (AC)
- X_r : réactance de l'inductance du convertisseur
- I_r : courant traversant l'inductance du convertisseur.
- I_t : courant traversant le transformateur du convertisseur
- I_f : courant traversant l'impédance du filtre.
- U_t : tension au primaire du transformateur de convertisseur,
- X_{tr} : réactance du transformateur.
- Z_f : impédance du filtre AC.

Introduction Générale

Cette thèse est le fruit d'un long travail de recherche et de réflexion, visant à aborder des problématiques complexes dans le domaine des systèmes de transmission d'énergie. Dans le contexte actuel de la transition énergétique, les systèmes de transmission d'énergie jouent un rôle crucial pour répondre à la demande croissante en électricité tout en intégrant des sources d'énergie renouvelable. Les systèmes HVDC (Haute Tension Courant Continu), en particulier ceux utilisant la technologie VSC (Voltage Source Converter), se sont imposés comme une solution efficace pour le transport d'énergie sur de longues distances.

Cependant, la fiabilité de ces systèmes est primordiale, et la détection, la localisation et la classification des défauts sont des enjeux majeurs pour assurer leur bon fonctionnement. Cette thèse aborde la problématique de la classification et de la localisation des défauts dans les lignes de transmission HVDC VSC bipolaire.

Le ****premier chapitre****, intitulé **Aperçu des Systèmes HVDC**, fournit une vision globale des systèmes HVDC, en expliquant leurs principes de fonctionnement, leurs avantages et leurs domaines d'application.

Le ****deuxième chapitre****, **Modélisation des Systèmes VSC HVDC**, s'attache à représenter ces systèmes à travers des modèles mathématiques et électrotechniques détaillés, afin de mieux comprendre les dynamiques en jeu dans le transport de l'énergie.

Le ****troisième chapitre****, **Détection et Localisation des Défauts dans les Systèmes HVDC**, se focalise sur les différentes approches et stratégies permettant d'identifier les anomalies et de localiser précisément les défauts le long de la ligne de transmission.

Le ****quatrième chapitre****, **Classification des Défauts dans les Systèmes HVDC VSC par la Machine Learning**, introduit l'usage de techniques d'apprentissage automatique pour catégoriser les défauts selon leur nature. Cette approche innovante améliore considérablement la précision et la rapidité d'identification des incidents.

Le ****cinquième chapitre****, **Résultats et Discussions**, présente une analyse approfondie des résultats expérimentaux issus de la classification et de la régression par apprentissage automatique. Dans ce chapitre, nous intégrons également des techniques d'optimisation stochastique, telles que l'optimisation bayésienne ou les régions de confiance, pour ajuster et améliorer les modèles de régression, notamment ceux basés sur le Gaussian Process Regression (GPR). Cette stratégie vise à augmenter la précision de la localisation des défauts en explorant différentes approches et critères d'optimisation.

Ainsi, cette thèse vise à contribuer à l'amélioration de la gestion des défauts dans les systèmes HVDC VSC bipolaires, en intégrant des approches modernes de classification, de localisation et d'optimisation afin de garantir la fiabilité, la précision et la durabilité

de ces infrastructures essentielles au réseau électrique du futur. Dans ce cadre, l'environnement **MATLAB** sera utilisé à la fois pour l'acquisition de données synthétiques simulant différents scénarios de défauts, et pour le traitement de ces données via des algorithmes d'apprentissage automatique, des outils de modélisation et des méthodes d'optimisation intégrés dans la plateforme. L'étude met également en évidence le potentiel élevé de l'intégration de l'intelligence artificielle dans les schémas de protection des systèmes HVDC VSC, ouvrant la voie à des solutions de protection plus intelligentes, rapides et adaptatives.

Chapitre 1

Aperçu des Systèmes HVDC

1.1 Introduction à la Technologie HVDC

Le Courant Continu à Haute Tension (HVDC) est une technologie utilisée pour la transmission de l'énergie électrique sur de longues distances. Contrairement à la transmission en Courant Alternatif (CA), le HVDC transmet l'énergie sous forme de courant continu. L'industrie électrique est marquée par une grande "bataille" entre le courant continu (CC) et le courant alternatif (CA). Avec l'augmentation de la demande en énergie et donc de la production d'énergie, de plus en plus de questions ont été enregistrées pour l'utilisation de solutions AC.

Par exemple, il est très difficile d'augmenter le niveau de tension des câbles sous-marins (et donc leur capacité à transférer de grandes quantités d'énergie) [1]. De même, l'existence de projets hydroélectriques à haute capacité de production en cours de développement dans des zones d'exploitation éloignées de la consommation est devenue un problème pour l'application classique de la transmission d'énergie en utilisant le courant alternatif (la transmission d'une énergie en courant alternatif sur de longues distances pose des problèmes en termes de stabilité statique et augmente les pertes totales de puissance) [1].

Actuellement, les deux principales technologies de courant continu haute tension (HVDC) sont les suivantes :

- les convertisseurs commandés en ligne (LCC) également appelés convertisseurs de source de courant (CSC) qui utilisent des thyristors et des transformateurs (CSC) utilisant des thyristors.
- les convertisseurs de source de tension (VSC)-HVDC utilisant des transistors IGBT qui conviennent tous deux à un large éventail d'applications [1].

Pour les liaisons de transmission de longue distance et de grande capacité, la technologie CSC-HVDC offre à la fois un meilleur rendement et un meilleur transfert de puissance. Elle présente à la fois un meilleur rendement et une plus grande capacité de transfert de puissance que les solutions CA classiques.

Dans le cas de la transmission d'énergie à partir de centrales électriques offshore ou d'autres régions éloignées où l'espace est limité, la technologie VSC-HVDC est préférable car elle offre de grandes capacités de contrôle de la puissance active et réactive [1].

La forme moderne des systèmes HVDC fait appel à des technologies largement développées

dans les années 1930 (arc au mercure) en Suède et en Allemagne. Les premières applications commerciales antérieures comprenaient un système HVDC en Union soviétique en 1951 entre Moscou et Kashira et une liaison de 100 kV 20 MW entre Gotland Island et la Suède continentale en 1954 [1].

Les valves à thyristors ont été utilisées pour la première fois dans des applications HVDC depuis les années 1970. De nombreuses limitations de la technologie de l'arc au mercure ont été supprimées. Le premier HVDC mis en service a été la station de conversion d'Eel River au Canada en 1972 [3,4].

Les valves IGBT utilisées dans les convertisseurs de source de tension constituent une solution améliorée par rapport aux valves à thyristor. En 1999, ABB a mis en service la première connexion commerciale VSC-HVDC entre Gotland Island et la Suède continentale constituée de câbles sous-marins d'une capacité nominale de 50 MW et d'une tension nominale de ± 80 kV [5].

L'article [6] présente une analyse complète des applications actuelles des technologies HVDC, en mettant en évidence leurs avantages en matière de stabilité, de contrôle de puissance et d'intégration des énergies renouvelables. Il explore également les tendances futures, notamment l'évolution vers les convertisseurs multiniveaux (MMC), les systèmes hybrides AC/DC, et l'utilisation croissante de l'intelligence artificielle pour la gestion et la protection des réseaux HVDC.

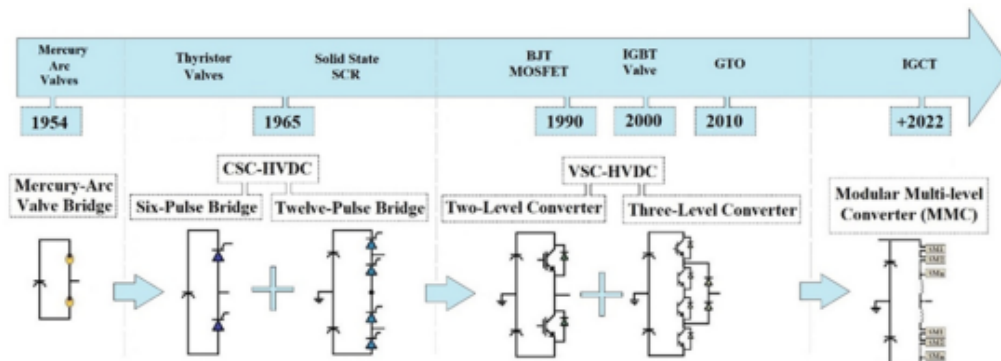


FIGURE 1.1 – Évolution technologique du HVDC [6]

1.2 Avantages du HVDC

Il existe plusieurs avantages à l'utilisation des systèmes HVDC :

- **Pertes de Puissance Réduites** : La transmission HVDC connaît des pertes moins importantes par rapport à la transmission CA particulièrement sur de longues distances.
- **Efficacité pour les Câbles Sous-Marins** : Le HVDC est le choix privilégié pour les câbles sous-marins car il souffre moins de l'effet de peau et des pertes capacitatives.
- **Contrôlabilité** : Les systèmes HVDC offrent un contrôle précis sur le flux d'énergie les rendant appropriés pour la stabilisation des réseaux et l'intégration d'énergies renouvelables.
- **Indépendance de Fréquence** : Puisque le HVDC ne dépend pas de la fréquence du réseau, il peut connecter des réseaux asynchrones et stabiliser des systèmes CA faibles.

La technologie HVDC a progressivement gagné en popularité dans le monde entier. L'utilisation de liaisons en courant continu au détriment des solutions classiques en courant alternatif se justifie par plusieurs avantages (par ex contrôle de la puissance active, capacités de transfert plus élevées, pas de puissance réactive, longueurs de transmission possibles et des pertes de puissance active plus faibles) étant dans certains cas la seule technologie possible [7,8].

1.3 Composants des Systèmes HVDC

Les systèmes HVDC se composent de plusieurs éléments clés :

- **Poste Redresseur** : Convertit le courant alternatif en courant continu. Il inclut des transformateurs, des valves à thyristors et des filtres.
- **Ligne de Transmission** : Transporte l'énergie en courant continu jusqu'au point de réception. Elle peut être une ligne aérienne ou un câble sous-marin.
- **Poste d'Onduleur** : Convertit le courant continu en courant alternatif au point de réception. Similaire au poste redresseur, il inclut des transformateurs, des valves à thyristors et des filtres.
- **Systèmes de Contrôle et de Protection** : Garantissent le fonctionnement sûr et fiable du système HVDC. Cela comprend des algorithmes de contrôle, des dispositifs de surveillance et des relais de protection.

1.4 Types de Systèmes HVDC

Il existe deux principaux types de systèmes HVDC :

- **Convertisseur à Commutation de Ligne (LCC) HVDC** : Utilise des valves à thyristors pour la conversion CA vers CC et CC vers CA. Il convient à la transmission sur de longues distances.
- **Convertisseur à Source de Tension (VSC) HVDC** : Utilise des dispositifs à semi-conducteurs pour la conversion. La technologie VSC offre plus de contrôlabilité et convient à des applications comme l'intégration d'énergies renouvelables.

1.5 Applications des Systèmes HVDC

La technologie HVDC trouve des applications dans divers secteurs :

- **Transmission d'Énergie sur de Longues Distances** : Le HVDC est utilisé pour transmettre l'énergie sur des centaines voire des milliers de kilomètres particulièrement dans des régions au relief difficile.
- **Câbles Sous-Marins** : Le HVDC est le choix privilégié pour connecter les parcs éoliens offshore ou les îles au réseau principal.
- **Interconnexion de Réseaux** : Le HVDC interconnecte des réseaux CA asynchrones permettant l'échange d'énergie entre des régions avec des fréquences différentes.
- **Intégration d'Énergies Renouvelables** : Le HVDC facilite l'intégration de sources d'énergie renouvelable en fournissant une stabilité au réseau et en permettant le contrôle du flux d'énergie.

1.6 Différentes Topologies Utilisées dans les Systèmes HVDC

Dans le domaine de la transmission d'énergie électrique en courant continu à haute tension (HVDC), différentes topologies sont utilisées pour répondre à des besoins spécifiques. Ce chapitre explore les configurations point-à-point, multi-terminaux et dos-à-dos en expliquant leurs avantages et applications.

1.6.1 Configuration Point-à-Point

La configuration point-à-point est la forme la plus simple des systèmes HVDC. Elle relie un seul point d'origine à un seul point de destination. Cette topologie est couramment utilisée pour les transmissions à longue distance sur terre ou sous l'eau. Les avantages de cette configuration comprennent une efficacité élevée sur de longues distances et la capacité de surmonter des obstacles naturels tels que des montagnes ou des fonds marins.

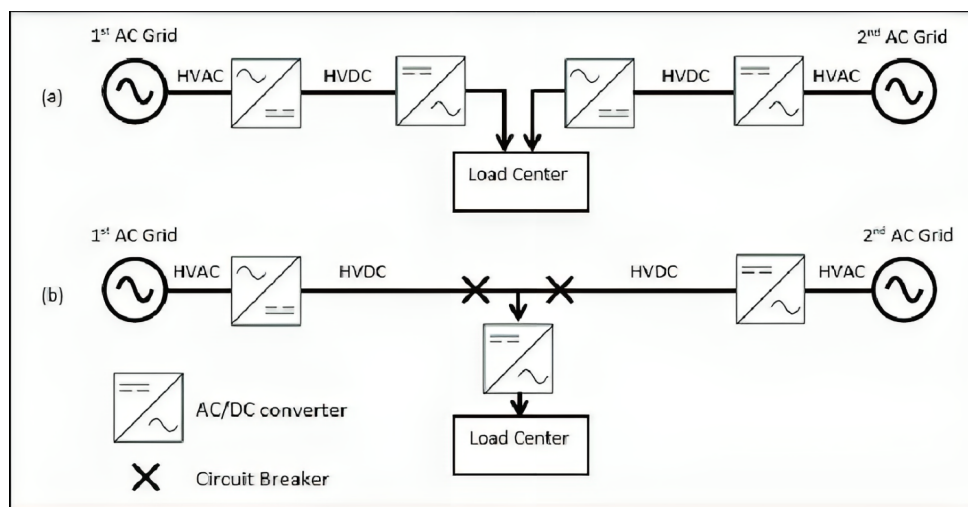


FIGURE 1.2 – Configuration Point-à-Point

1.6.2 Configuration Multi-Terminaux

La configuration multi-terminaux implique trois points ou plus reliés par des lignes de transmission HVDC. Elle permet des flux d'énergie entre plusieurs points, ce qui la rend utile pour l'intégration de multiples sources d'énergie ou la connexion de plusieurs réseaux.

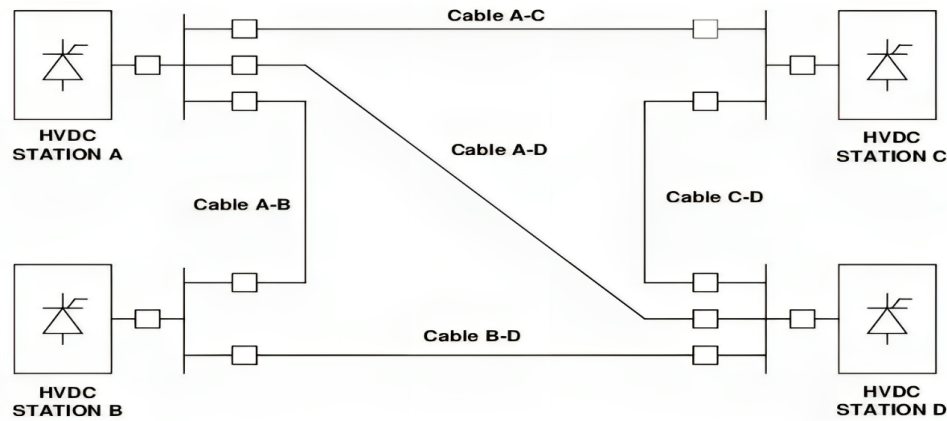


FIGURE 1.3 – Configuration Multi-Terminaux

1.6.3 Configuration back to back

La configuration dos-à-dos ou back-to-back est utilisée pour connecter deux réseaux AC qui fonctionnent à des fréquences différentes ou qui ne sont pas synchronisés. Elle consiste en deux convertisseurs HVDC placés côte à côte. Cette topologie permet le contrôle précis du flux d'énergie entre les deux réseaux, facilitant ainsi l'interconnexion de systèmes électriques distincts.

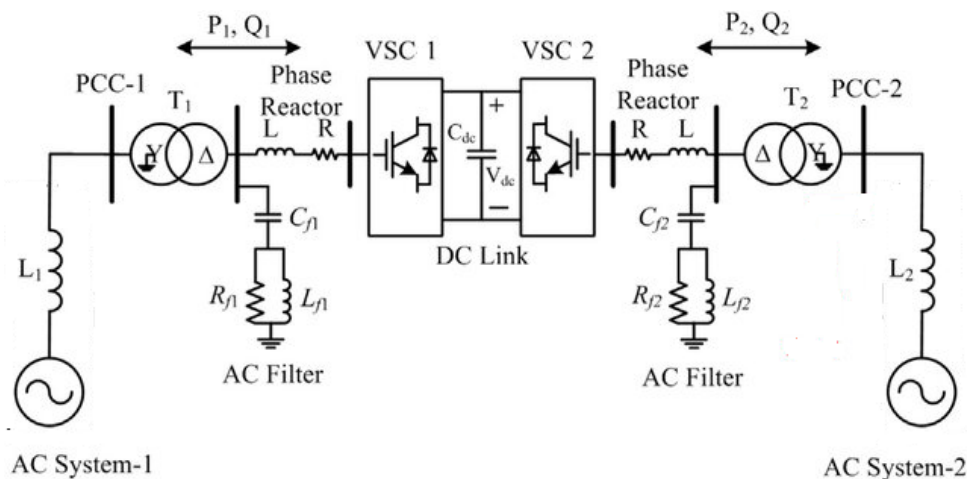


FIGURE 1.4 – Configuration back to back

Chaque configuration de système HVDC a ses propres avantages et applications spécifiques. Le choix de la topologie dépend des besoins de transmission d'énergie, de la géographie et des caractéristiques des réseaux électriques impliqués.

1.7 Avantages des Systèmes HVDC par Rapport aux Systèmes HVAC

- **Pertes de Transmission Réduites** : Les systèmes HVDC ont des pertes de transmission inférieures par rapport aux systèmes HVAC. Cela est dû au fait que le courant continu a moins de pertes ohmiques par unité de distance que le courant alternatif. Ainsi, les HVDC sont plus efficaces pour transporter de l'énergie sur de longues distances.
- **Capacité de Transmission Accrue** : Les systèmes HVDC offrent une capacité de transmission supérieure par rapport aux systèmes HVAC. En utilisant des technologies de commutation avancées, les HVDC peuvent transporter une plus grande quantité d'énergie sur les mêmes lignes de transmission.
- **Transfert d'Énergie sur de Longues Distances** : Les HVDC sont particulièrement adaptés pour le transfert d'énergie sur de très longues distances. Alors que les systèmes HVAC rencontrent des limitations en raison des pertes élevées sur de longues lignes, les HVDC peuvent surmonter ces limitations et fournir de l'énergie sur des milliers de kilomètres.
- **Stabilisation de Réseaux Faibles** : Les systèmes HVDC offrent un contrôle précis sur le flux d'énergie. Cela les rend efficaces pour stabiliser les réseaux électriques faibles. En injectant ou absorbant de la puissance réactive, les HVDC peuvent améliorer la stabilité et la fiabilité du réseau.
- **Intégration de Sources d'Énergie Renouvelable** : Avec la croissance des énergies renouvelables, les HVDC sont essentiels pour intégrer efficacement ces sources dans les réseaux électriques existants. Ils permettent un contrôle précis du flux d'énergie, ce qui facilite l'intégration de sources intermittentes comme l'énergie solaire et éolienne.

La technologie HVDC s'avère particulièrement appropriée pour le transport d'énergie par le biais de câbles sous-marins en particulier lorsque la distance excède 50 km. Contrairement aux câbles classiques en courant alternatif, les câbles HVDC ne sont pas limités par les contraintes physiques imposées par les composantes de puissance réactive et capacitive, lesquelles tendent à réduire la capacité totale de transfert de puissance active [12]. Compenser la composante réactive, bien que possible grâce à l'utilisation de réacteurs shunt, devient une tâche complexe, notamment dans le contexte des câbles sous-marins.

Lorsqu'il s'agit d'établir des interconnexions sous-marines entre des réseaux fonctionnant de manière asynchrone ou de transmettre l'énergie produite par l'éolien en mer depuis des sites éloignés, la technologie VSC-HVDC se présente comme l'option privilégiée. Cette dernière offre une multitude d'avantages incluant un encombrement réduit ainsi qu'une grande souplesse en termes d'actifs et de réactifs avec des capacités de contrôle de la puissance active et réactive très adaptables [13].

À l'heure actuelle, le câble sous-marin HVDC de transport d'énergie le plus long en service est associé à la "liaison NorNed Link" [14] reliant la Norvège aux Pays-Bas, s'étalant sur une distance totale de 580 km et offrant une capacité de transfert totale de 700 MW.

En ce qui concerne les liaisons entre des réseaux fonctionnant de manière asynchrone, l'utilisation des technologies HVDC permet d'atteindre plusieurs objectifs clés : améliorer la sécurité opérationnelle (en permettant un échange d'énergie précisément contrôlé qui

renforce la stabilité du système), fournir des réserves supplémentaires de puissance active et offrir une aide d'urgence aux systèmes voisins tout en répondant à des considérations économiques telles que les contrats d'échange de puissance [15, 16].

Les systèmes HVDC facilitent l'intégration de sources d'énergie renouvelable telles que l'énergie éolienne et solaire. Ils permettent de transférer l'énergie produite dans des régions éloignées vers les centres de consommation, contribuant ainsi à la transition vers une économie basée sur les énergies renouvelables.

TABLE 1.1 – Comparaison HVDC vs HVAC basée sur la littérature

Caractéristique	HVDC	HVAC
Efficacité de Transmission	Haute	Moyenne
Perte en ligne	Faible	Élevée
Distance de Transmission	Longue	Courte à Moyenne
Effet corona	Très faible	Élevé, accentué par la fréquence
Effet de peau	Absent (courant uniforme)	Présent, résistance accrue
Nombre de conducteurs	2 conducteurs (\pm)	3 phases ou plus
Contrôle du flux	Total (via convertisseurs)	Limité (via angle de phase)
Interconnexion asynchrone	Possible	Impossible (synchronisation requise)
Fiabilité dynamique	Stabilité améliorée	Flexibilité limitée
Coût station conversion	Très élevé	Relativement faible
Impact environnemental	Faible	Plus élevé (bruit, interférences)

1.8 Composants et Technologies dans les Systèmes HVDC

1.8.1 Convertisseurs

Les convertisseurs sont des composants essentiels des systèmes HVDC. Ils sont responsables de la conversion entre le courant alternatif (CA) et le courant continu (CC). Il existe deux types principaux de convertisseurs utilisés dans les systèmes HVDC :

- **Convertisseurs à Commutation de Ligne (LCC)** : Utilisent des valves à thyristors pour effectuer la conversion CA vers CC et vice versa. Ils sont appropriés pour les applications de transmission à longue distance.
- **Convertisseurs à Source de Tension (VSC)** : Utilisent des dispositifs à semi-conducteurs pour la conversion. Ils offrent plus de contrôlabilité et sont adaptés à des applications comme l'intégration d'énergies renouvelables.

TABLE 1.2 – Comparaison entre HVDC VSC et HVDC LCC

Caractéristique	HVDC VSC	HVDC LCC
Commutation	Auto-commuté	Commutation par ligne
Tension de Commutation	Contrôlable	Fixe
Harmoniques	Faibles	Élevées
Taille de la Station	Compacte	Grande
Environnement	Plus Souple	Plus Restreint
Contrôle de la Puissance	Bidirectionnel	Unidirectionnel
Pertes	Moins	Plus
Efficacité	Plus Élevée	Moins Élevée

1.8.2 Transformateurs

Les transformateurs sont utilisés pour ajuster les niveaux de tension dans les systèmes HVDC. Ils sont présents à la fois dans les postes redresseurs et les postes d'onduleurs. Les transformateurs permettent de passer d'une haute tension à une autre et sont cruciaux pour le fonctionnement efficace des systèmes HVDC.

1.8.3 Câbles de Transmission

Les câbles de transmission dans les systèmes HVDC jouent un rôle vital dans le transport de l'énergie sur de longues distances, en particulier dans les applications sous-marines. Ces câbles doivent être conçus pour minimiser les pertes et fournir une isolation électrique adéquate pour garantir un transfert d'énergie efficace.

Les câbles de transmission sont des composants essentiels des réseaux électriques, permettant le transport efficace de l'électricité sur de longues distances. Il existe différents types de câbles HVDC (courant continu à haute tension), notamment les lignes aériennes et les câbles sous-marins/souterrains.

Types de câbles de transmission HVDC

- **Lignes aériennes** : Les lignes aériennes sont des câbles conducteurs suspendus sur des pylônes. Elles sont souvent utilisées pour les distances relativement courtes sur terre. Elles sont plus visibles et peuvent nécessiter plus d'espace, mais elles sont généralement moins coûteuses à installer que les câbles souterrains ou sous-marins.
- **Câbles sous-marins/souterrains** : Ces câbles sont utilisés pour traverser des obstacles tels que des mers, des rivières, des zones urbanisées ou des zones protégées. Ils sont enterrés sous terre ou installés au fond de l'eau. Les câbles sous-marins sont complexes à fabriquer et à installer en raison des contraintes environnementales.

Avantages, limitations et coûts

- **Lignes aériennes** : Avantages : Coût initial relativement bas, facilité de réparation et d'entretien, peu de pertes de transmission. Limitations : Impact visuel, vulnérabilité aux intempéries et aux catastrophes naturelles, besoin d'espace. Coûts : Coût initial moins élevé, mais peuvent nécessiter des coûts d'entretien plus élevés à long terme.

- **Câbles sous-marins/souterrains** : Avantages : Pas d'impact visuel, moins vulnérables aux intempéries, adaptés pour les zones densément peuplées. Limitations : Coûts d'installation élevés, complexité de la réparation en cas de défaut, possibilité de pertes de transmission légèrement supérieures. Coûts : Coûts initiaux élevés, mais potentiellement moins de coûts d'entretien sur le long terme.

Importance de l'isolation et de l'entretien

La fiabilité à long terme des câbles de transmission dépend en grande partie de leur isolation. Une isolation adéquate garantit que le courant électrique circule de manière sécurisée et efficace. De plus, un entretien régulier est crucial pour identifier et corriger tout défaut potentiel, assurant ainsi la stabilité du réseau.

En conclusion, le choix entre lignes aériennes et câbles sous-marins/souterrains dépend des contraintes géographiques, environnementales et économiques spécifiques à chaque projet. Chacun présente des avantages et des inconvénients distincts et l'entretien adéquat est essentiel pour assurer une transmission électrique fiable à long terme.

1.8.4 Filtres

Les filtres sont utilisés pour éliminer les harmoniques et les surtensions indésirables dans les systèmes HVDC. Ils garantissent une qualité d'onde optimale dans le courant continu transmis, contribuant ainsi à la fiabilité du système et à la protection des équipements.

1.8.5 Réacteurs Saturables

Les réacteurs saturables sont des composants utilisés pour fournir une certaine impédance au système HVDC. Ils aident à stabiliser le système en régulant le courant et en limitant les surtensions. Ces réacteurs sont particulièrement utiles dans les situations où le réseau est faible ou instable.

1.8.6 Principaux Éléments des Sous-Stations de Conversion HVDC

La station de conversion HVDC est l'interface cruciale entre le réseau CA et le système HVDC. Le réseau CA se connecte à la station de conversion HVDC par l'intermédiaire d'un jeu de barres de convertisseur qui peut être représenté par un ou plusieurs jeux de barres CA typiques auquel le convertisseur est rattaché [17,18].

En ce qui concerne la partie CA de la sous-station de conversion, plusieurs équipements essentiels sont impliqués. On compte notamment : les lignes aériennes ou câbles souterrains en courant alternatif (AC-OHL/UGC), les systèmes de jeux de barres, l'appareillage de commutation en courant alternatif (sectionneurs/disjoncteurs), les transformateurs de puissance de conversion, les instruments de mesure en courant alternatif (transformateurs de tension/courant), les filtres pour éliminer les harmoniques en courant alternatif ainsi que les condensateurs shunt en courant alternatif [19].

La partie DC de la sous-station de conversion est interconnectée avec la partie AC par le biais d'un convertisseur (qu'il soit de type VSC ou CSC) situé dans le bâtiment ou la salle des vannes de conversion.

Quant aux composants principaux associés à la partie DC de la sous-station de conversion, ils englobent [21] : les lignes aériennes ou câbles souterrains en courant continu (DC-OHL/UGC, généralement câbles XLPE dans le cas de la technologie VSC), les filtres pour éliminer les harmoniques en courant continu, les réacteurs de phase (dans le cas du VSC-HVDC), les condensateurs en courant continu (VSC-HVDC), les réacteurs de lissage, les instruments de mesure en courant continu (tension/ transformateurs du courant CT) ainsi que l'appareillage de commutation en courant continu (interrupteurs-sectionneurs). La figure 1.5 montre la structure de base du VSC-HVDC [21-23].

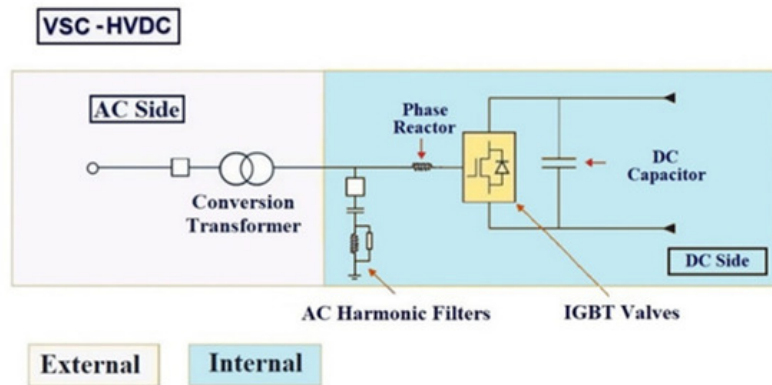


FIGURE 1.5 – principaux composants d’un système VSC-HVDC [23]

1.9 Aspects Coûts des Systèmes HVDC par Rapport aux Systèmes HVAC

La décision entre l’adoption d’un système HVDC ou HVAC dans une infrastructure de transmission électrique repose en grande partie sur des considérations financières. Cette section examine les aspects coûts des deux systèmes en mettant en lumière les coûts initiaux, les dépenses d’entretien et les avantages opérationnels.

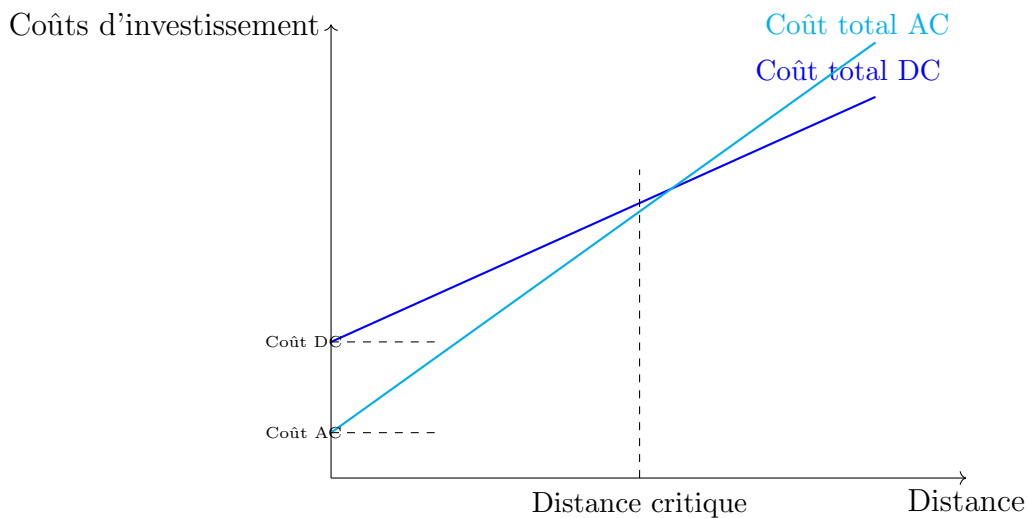


FIGURE 1.6 – Comparaison des coûts totaux AC et DC en fonction de la distance

1.9.1 Coûts Initiaux

Les systèmes HVDC nécessitent souvent un investissement initial plus élevé que les systèmes HVAC en raison de la complexité des composants tels que les convertisseurs et les câbles spéciaux. Cependant, cette dépense supplémentaire peut être justifiée par les avantages à long terme, notamment les pertes de transmission réduites et la capacité de transmission accrue.

1.9.2 Dépenses d'Entretien

En termes de coûts d'entretien, les systèmes HVDC tendent à être plus économiques à long terme. Les composants tels que les convertisseurs à thyristors dans les systèmes HVAC nécessitent souvent un entretien fréquent tandis que les technologies VSC dans les systèmes HVDC offrent une fiabilité supérieure et nécessitent moins d'entretien.

L'article [24] s'appuie sur une approche économique de type DCF (Discounted Cash Flow) pour comparer les systèmes HVAC et VSC-HVDC dans le cadre de la connexion d'un parc éolien offshore de 300MW à différentes distances. Elle montre que le HVAC est économiquement préférable pour les courtes distances (inférieures à 75km), tandis que le VSC-HVDC devient plus avantageux au-delà (environ 80km) en raison de coûts de câbles plus faibles et de pertes réduites. Une analyse de sensibilité montre que des prix d'électricité plus élevés ou une réduction des pertes des convertisseurs renforcent encore l'intérêt du VSC-HVDC, réduisant la distance critique. De plus, les auteurs soulignent que la longueur critique à partir de laquelle HVDC devient avantageux dépend fortement de la propriété des câbles et des paramètres économiques (tarifs, taux d'intérêt, pertes). Par ailleurs, le coût annuel de maintenance d'un lien VSC-HVDC est estimé à environ 0,5% du coût en capital des composants, tandis que le coût de maintenance à vie pour un système HVAC est supposé atteindre 15% des coûts d'investissement [24].

1.9.3 Avantages Opérationnels

Les systèmes HVDC apportent des avantages opérationnels significatifs. Par exemple, ils permettent le transfert d'énergie sur de très longues distances, ce qui est difficile à réaliser avec les systèmes HVAC en raison des pertes élevées. De plus, les HVDC facilitent l'intégration d'énergies renouvelables et la stabilisation de réseaux faibles.

1.9.4 Exemples Réels

Un exemple de l'impact financier des systèmes HVDC est le projet "North Sea Link" reliant le Royaume-Uni et la Norvège. Bien que le coût initial soit élevé, les avantages en termes de transfert d'énergie entre les deux pays et l'intégration d'énergie hydraulique renouvelable en font un investissement viable à long terme.

La nécessité de recourir à la transmission HVDC devient évidente notamment pour les longues distances de plusieurs centaines de kilomètres. En effet, les systèmes HVDC se démarquent comme une alternative à la fois économiquement plus avantageuse et plus performante en termes d'investissement initial et de réductions de pertes d'énergie. Comparativement aux technologies traditionnelles en courant alternatif (CA), elles se révèlent être à la fois plus rentables et plus efficaces [9,10].

Actuellement, le record de la ligne aérienne de transmission HVDC la plus étendue et de la liaison ayant la capacité de transfert la plus élevée est détenu par la "liaison Changji-Guquan" en Chine [11]. Cette technologie CSC-HVDC affiche une remarquable capacité de transfert totale de 12 GW.

1.10 Conclusion

Les systèmes HVDC jouent un rôle central dans l'évolution des réseaux électriques modernes, en apportant des solutions efficaces, flexibles et adaptées aux exigences croissantes en matière de transport d'énergie à longue distance et d'intégration des sources renouvelables. Ce chapitre a permis de présenter les fondements de la technologie HVDC, en mettant en évidence ses principaux composants ainsi que les avantages significatifs qu'elle offre en comparaison avec les systèmes HVAC, notamment en termes de pertes réduites, de stabilité accrue et de maîtrise du flux de puissance.

Une attention particulière a été portée à la comparaison entre les deux principales technologies de conversion : les convertisseurs à commutation de ligne (LCC) et ceux à source de tension (VSC). Chacune de ces technologies présente des caractéristiques distinctes, les LCC étant plus adaptés aux grandes puissances sur de longues distances, tandis que les VSC se démarquent par leur capacité de commande indépendante, leur aptitude au *black-start*, et leur compatibilité avec les réseaux faibles ou insulaires.

Par ailleurs, l'analyse des différentes topologies HVDC – monopolaire, bipolaire, *back-to-back*, multiterminal et hybrides – a démontré la diversité des configurations possibles, permettant une adaptation fine aux besoins spécifiques des projets, qu'ils soient terrestres ou sous-marins, centralisés ou décentralisés.

En définitive, la compréhension approfondie des systèmes HVDC, de leurs variantes technologiques et de leurs topologies constitue un préalable essentiel pour la conception de réseaux de transport d'énergie fiables, performants et durables, répondant aux défis actuels de la transition énergétique.

Dans cette continuité, le chapitre suivant se focalise sur la modélisation des systèmes VSC-HVDC, élément clé pour l'analyse dynamique et le contrôle de ces architectures avancées. Une attention particulière sera portée à la représentation mathématique des convertisseurs, des lignes de transmission et des systèmes de contrôle associés.

Chapitre 2

Modélisation des Systèmes VSC HVDC

2.1 Introduction

La transmission HVDC conventionnelle repose sur l'utilisation de convertisseurs à commutation de ligne (LCC) équipés de valves à thyristor, nécessitant une source de tension AC robuste et une gestion sophistiquée de la puissance réactive via des filtres shunt ou des condensateurs série pour maintenir la tension alternative dans des limites sécurisées. Plus le système est faible ou éloigné de la source de production, plus la précision de l'équilibrage de la puissance réactive devient critique.

Depuis la fin des années 1990, l'introduction des systèmes HVDC à source de tension (VSC) — utilisant des IGBT et une modulation de largeur d'impulsion (MLI) — a transformé le paysage HVDC en permettant des solutions plus flexibles et compactes, associées à une compensation active de la puissance réactive [25, 26].

Ces dernières années, les recherches ont confirmé l'intérêt du HVDC VSC pour connecter de grandes fermes éoliennes offshore, améliorant la stabilité réseau et réduisant les coûts sur de longues distances [27, 28]. En comparaison, les systèmes LCC, bien qu'optimisés depuis leur première application, restent privilégiés pour les très forts transferts de puissance, mais présentent des limitations notables pour le *black-start* et les réseaux faibles [28].

Ce chapitre se concentre sur les fondements de la technologie HVDC à convertisseurs à source de tension (VSC) en mettant en lumière la structure bipolaire, qui constitue aujourd'hui une solution performante pour les applications de transmission d'énergie longue distance et à haute fiabilité. La modélisation d'un système HVDC VSC bipolaire repose sur une représentation détaillée des convertisseurs VSC basés sur la modulation de largeur d'impulsion (PWM), des liaisons continues (câbles ou lignes aériennes), ainsi que des systèmes de commande et de protection associés. Cette approche permet de simuler avec précision le comportement dynamique du système en régime normal, tout en évaluant les stratégies de contrôle de la tension DC, l'équilibrage des puissances entre les pôles. La modélisation précise de ce type de structure constitue une étape essentielle pour concevoir des solutions de transmission robustes, flexibles et adaptées aux réseaux électriques de nouvelle génération.

2.2 Signification dans le domaine de la transmission d'énergie

La technologie HVDC permet de transmettre l'électricité sur de longues distances avec une efficacité élevée. Elle offre des avantages significatifs par rapport aux systèmes de courant alternatif (CA) notamment en termes de pertes de transmission réduites et de possibilité de connecter des réseaux électriques asynchrones.

2.3 Systèmes VSC Bipolaires

Les systèmes VSC (Voltage Source Converter) bipolaires sont motivés par la nécessité de contrôler la puissance bidirectionnelle et d'assurer la stabilité du réseau. Ils utilisent des convertisseurs de tension pour générer et réguler le courant continu.

2.4 Avantages des Systèmes VSC Bipolaires

Les systèmes VSC bipolaires offrent plusieurs avantages tels que la possibilité de contrôler la tension et la fréquence, la réduction des perturbations électromagnétiques et la capacité de fonctionner en mode réversible.

2.5 Topologie

Le HVDC (Courant Continu à Haute Tension) est une technologie qui offre la capacité de transporter des quantités considérables d'énergie électrique sur de longues distances avec des pertes minimales. Il existe différentes configurations pour la transmission HVDC parmi lesquelles la topologie "dos à dos" (ou "back-to-back" abrégé BTB) qui repose sur un convertisseur de source de tension (VSC).

Dans un système HVDC "dos à dos" deux convertisseurs sont reliés en opposant une tension continue d'un côté et une tension alternative de l'autre. Ces convertisseurs utilisent des VSC pour convertir le courant alternatif en courant continu et vice versa permettant ainsi le transfert d'énergie entre deux systèmes à courant alternatif possédant des fréquences, tensions ou angles de phase différents. L'approche bipolaire signifie qu'elle met en jeu deux pôles de tension continue de polarités opposées pour atteindre le niveau de tension requis.

La topologie BTB basée sur les VSC offre plusieurs avantages par rapport à d'autres configurations HVDC. Ces avantages incluent un meilleur contrôle, une distorsion harmonique réduite et une réactivité plus rapide face aux perturbations du système. Elle est couramment utilisée pour interconnecter les réseaux à courant alternatif, intégrer les sources d'énergie renouvelable et renforcer la stabilité du réseau.

2.6 Structure physique

Un système de transmission VSC HVDC typique se compose de convertisseurs, de transformateurs et de réacteurs de phase, de filtres AC, de câbles et d'interrupteurs DC, ainsi

que de condensateurs et de filtres DC comme illustré dans la Figure 2.1 . Les transformateurs, les filtres et les condensateurs auxiliaires se trouvent à l'extérieur. Le convertisseur et son système de contrôle sont placés dans un bâtiment fermé climatisé et chauffé. Le système VSC HVDC permet des stations compactes adaptées aux endroits où l'espace est une préoccupation en raison de restrictions liées à l'impact environnemental, à la rareté des terres ou à des raisons économiques Le rôle et la structure de chaque composant sont brièvement décrits dans les sous-sections suivantes. [29]

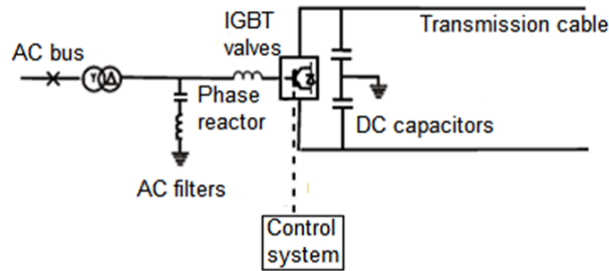


FIGURE 2.1 – Configuration du Systeme VSC-HVDC [29]

2.7 Convertisseurs

Les convertisseurs VSC bipolaires reposent sur une modulation de largeur d'impulsion (PWM) pour générer la tension alternative à partir de la tension continue. Les IGBT sont commutés à des fréquences typiques de 1 à 2 kHz, voire jusqu'à 3 kHz avec l'utilisation de semi-conducteurs avancés, permettant un contrôle indépendant des composantes active et réactive, ainsi qu'un fonctionnement autonome sur un réseau passif [29]. La PWM permet de synthétiser presque n'importe quelle forme d'onde souhaitée en ajustant l'angle de phase et l'amplitude, ce qui confère une grande flexibilité [29].

Cependant, la commutation fréquente génère des harmoniques autour de la fréquence porteuse. Pour réduire le contenu harmonique de basse fréquence, il faut augmenter la fréquence de commutation, ce qui accroît les pertes de commutation Korompili2016. Il est donc essentiel de trouver un compromis entre qualité de la forme d'onde et efficacité énergétique .

Les filtres AC, en configuration L ou LCL, sont indispensables pour atténuer les harmoniques et préserver la qualité du réseau. Par ailleurs, des techniques de modulation avancées, telles que la modulation vectorielle spatiale (SVM) [30] et la modulation par bande de tolérance (TBM) [31], permettent d'améliorer la synthèse des tensions, de réduire les pertes et les interférences harmoniques.

2.8 Transformateurs et réacteurs de phase

Dans un système VSC-HVDC, trois transformateurs monophasés sont utilisés pour adapter la tension du bus AC à la tension d'entrée requise par le convertisseur. Ces transformateurs sont généralement dotés de dévolteurs afin de maintenir une tension appropriée aux bornes des valves, assurant ainsi une performance stable du convertisseur. La conception des transformateurs VSC est souvent plus simple que celle des systèmes LCC en raison

du faible contenu harmonique du courant côté AC, inhérent à l'utilisation des IGBT et de la modulation PWM

En parallèle, des réacteurs monophasés refroidis par air sont insérés entre le transformateur et le convertisseur. Ces réacteurs permettent non seulement de réguler les courants traversant le convertisseur — et donc le flux de puissance active et réactive — mais jouent également un rôle crucial dans la filtration des harmoniques haute fréquence générées par les opérations de commutation rapide des IGBT. Selon Korompili *et al.*, l'utilisation de réacteurs permet de réduire les contraintes électromagnétiques sur les équipements voisins et d'améliorer la stabilité globale du système offshore connecté en VSC-HVDC [29].

2.9 Filtres CA

Dans les systèmes HVDC à convertisseur de source de tension (VSC), les harmoniques de haute fréquence générées par la commutation rapide des IGBT peuvent provoquer des perturbations dans les équipements sensibles et les systèmes de communication. Pour atténuer ces effets, des filtres CA sont utilisés afin de garantir une forme d'onde de tension et de courant quasi sinusoïdale du côté AC du convertisseur.

Selon [32], l'utilisation de schémas de modulation comme la PWM permet de réduire les distorsions harmoniques, rendant possible l'emploi de filtres plus simples et de plus petite taille. Ces filtres sont généralement de type passe-haut, qu'ils soient passifs ou actifs, et leur conception dépend du contenu harmonique généré par le convertisseur. Par ailleurs, comme l'indiquent [29], les topologies VSC modernes sont capables de limiter efficacement les harmoniques, réduisant ainsi le besoin de compensation réactive massive et de filtrage complexe. Cette évolution contribue à une intégration plus fiable des systèmes VSC-HVDC dans les réseaux AC, notamment dans les applications offshore ou industrielles.

2.10 Câbles CC et disjoncteurs

Dans les systèmes VSC-HVDC, le circuit de transmission continue comprend les câbles CC, les disjoncteurs rapides et les électrodes de terre. Des progrès technologiques récents ont permis de développer de nouveaux types de câbles CC mieux isolés, plus légers et flexibles, avec des pertes réduites, adaptés aussi bien aux applications sous-marines qu'aériennes [29].

Pour les disjoncteurs CC, la technologie hybride constitue une alternative performante aux commutateurs purement mécaniques (lents) ou entièrement électroniques (coûteux). Les disjoncteurs hybrides offrent une commutation rapide, fiable et efficace, avec une conception modulaire facilement adaptable aux exigences en tension et courant des réseaux HVDC modernes [29].

2.11 Condensateurs et filtres CC

Dans les systèmes VSC-HVDC, deux empilements de condensateurs de même capacité sont installés côté courant continu. Leur dimensionnement dépend de la tension continue du lien. Ces condensateurs assurent plusieurs fonctions essentielles : ils agissent comme

une réserve d'énergie pour maintenir l'équilibre de puissance pendant les transitoires, limitent l'ondulation de tension CC, et facilitent le contrôle du flux de puissance [29, 32].

De plus, même si les niveaux d'harmoniques sont faibles grâce à la technologie VSC, des filtres CC peuvent être ajoutés afin de minimiser les interférences électromagnétiques susceptibles d'affecter les réseaux de communication voisins. Ces filtres sont généralement compacts en raison de la bonne qualité des signaux côté CC [29].

2.12 Valves IGBT

Les modules à transistor bipolaire à grille isolée (IGBT) utilisés dans les convertisseurs VSC sont composés de plusieurs IGBT connectés en série. Chaque position d'IGBT est constituée d'un IGBT, d'une diode antiparallèle, d'une unité de grille, d'un diviseur de tension et d'un dissipateur thermique refroidi à l'eau. Contrairement à la base contrôlée par courant d'un transistor bipolaire classique, l'IGBT possède une grille capacitive contrôlée par tension similaire au dispositif MOSFET. Chaque unité de grille inclut des circuits de commande de grille, des circuits de surveillance et une interface optique. L'électronique de commande de grille régule la tension et le courant de la grille lors de la mise en marche et de l'arrêt afin d'obtenir des processus de mise en marche et d'arrêt optimaux de l'IGBT. Pour pouvoir commuter des tensions supérieures à la tension nominale d'un seul IGBT, de nombreuses positions sont connectées en série dans chaque valve, similairement aux thyristors dans les valves HVDC conventionnelles. Tous les IGBT doivent s'allumer et s'éteindre exactement en même temps pour obtenir une répartition uniforme de la tension à travers la valve. Les courants plus élevés sont gérés en mettant en parallèle les composants IGBT ou en utilisant des packs de presse.

2.13 Grille en courant alternatif AC

Habituellement, un modèle de grille peut être développé en utilisant le circuit équivalent de Thevenin. Toutefois, pour des raisons de simplicité, le réseau a été modélisé comme une source de tension triphasée symétrique idéale.

2.14 Topologie du convertisseur

Les convertisseurs utilisés jusqu'à présent dans les applications de transmission réelles sont composés d'un certain nombre de convertisseurs élémentaires, c'est-à-dire de ponts triphasés à deux niveaux à six impulsions comme le montre la figure 2 ou de ponts triphasés à trois niveaux à 12 impulsions.




FIGURE 2.2 – VSC deux niveaux




FIGURE 2.3 – VSC trois niveaux

Le convertisseur à trois niveaux NPC (Point Neutre Clampé) est un type de convertisseur multiniveau utilisé dans les systèmes de transmission à haute tension (HVDC). Il permet de convertir l'énergie entre des systèmes à haute tension en courant continu et en courant alternatif de manière efficace. Ce convertisseur est constitué d'un ensemble de commutateurs à semi-conducteurs de puissance et de diodes de serrage arrangés de manière à produire trois niveaux de tension à partir d'une source de courant continu. Ces trois niveaux de tension sont obtenus en bridant le point médian de la source de courant continu à deux niveaux de tension différents, créant ainsi trois niveaux distincts.

Comparativement aux convertisseurs traditionnels à deux niveaux, l'utilisation d'un convertisseur à trois niveaux NPC dans un système HVDC présente plusieurs avantages. Il permet de réduire la distorsion harmonique, de diminuer les pertes de commutation et d'améliorer le rendement global du système. Cependant, il est important de noter que les convertisseurs NPC à trois niveaux sont plus complexes et ont tendance à être plus coûteux que leurs homologues à deux niveaux, ce qui peut les rendre moins adaptés à certaines applications.

Un convertisseur de source de tension typique utilise des IGBT connectés en série comme dispositifs de commutation pour supporter des tensions de blocage élevées. Les diodes de roue libre anti-parallèles assurent un fonctionnement bidirectionnel du convertisseur. Les condensateurs du côté courant continu supportent la commutation et fournissent un filtrage des harmoniques sur le côté courant continu.

2.15 Modèle mathématique et formulation

Vu que le système HVDC –VSC est composé d'un redresseur et un onduleur relié par une source de tension alternative, la modélisation sera celle d'un redresseur et un onduleur.

$$L \frac{di_a}{dt} = e_a - v_a - Ri_a = e_a - v_{dc}s_a - \frac{1}{3} \sum_{j=abc} s_j - Ri_a \quad (2.1)$$

$$L \frac{di_b}{dt} = e_b - v_b - Ri_b = e_b - v_{dc}s_b - \frac{1}{3} \sum_{j=abc} s_j - Ri_b \quad (2.2)$$

$$L \frac{di_c}{dt} = e_c - v_c - Ri_c = e_c - v_{dc}s_c - \frac{1}{3} \sum_{j=abc} s_j - Ri_c \quad (2.3)$$

$$C \frac{dv_{dc}}{dt} = s_a i_a + s_b i_b + s_c i_c - i_{dc} \quad (2.4)$$

Remarque : s_j (j=abc) est la fonction de commutation logique, lorsque $s_j = 1$ le bras de pont supérieur est conduit et le bras de pont inférieur est désactivé, lorsque $s_j = 0$ le cas contraire.

En utilisant la transformation de Park d-q on peut déduire les équations suivantes :

$$L \frac{di_d}{dt} = e_d - v_d - Ri_d - \omega Li_q = e_d - s_d v_{dc} - Ri_d - \omega Li_q \quad (2.5)$$

$$L \frac{di_q}{dt} = e_q - v_q - Ri_q + \omega Li_d = e_q - s_q v_{dc} - Ri_q + \omega Li_d \quad (2.6)$$

$$\frac{3}{2} C \frac{dv_{dc}}{dt} = s_d i_d + s_q i_q - \frac{3}{2} i_{dc} \quad (2.7)$$

La puissance réelle P qui s'écoule du convertisseur vers le système CA est donnée par la relation :

$$p = \frac{U_{sys} U_{vsc}}{X_t} \sin \delta \quad (2.8)$$

où U_{sys} est la tension du système CA, U_{vsc} est la tension aux bornes du VSC ; X_t est la réactance reliant le VSC au système CA, δ indique l'angle de tension entre le VSC et le système CA.

La puissance réactive qui sera échangée entre le VSC et le système est donnée par la relation suivante :

$$Q = \frac{U_{vsc}(U_{vsc} - U_{sys} \cos \delta)}{X_t} \quad (2.9)$$

$U_{vsc} > U_{sys}$: Q est supérieur à zéro et implique un fonctionnement capacitif (VSC délivre une puissance réactive au réseau).

$U_{sys} > U_{vsc}$: Q est inférieur à zéro et implique un fonctionnement inductif (VSC absorbe la puissance réactive).

Pour des amplitudes égales de tension la puissance réactive est égale à zéro et la puissance réelle est déterminée par l'angle de tension entre les deux vecteurs. Si $\delta > 0$, la puissance passe du VSC au système CA (fonctionnement en onduleur). Si $\delta < 0$, la puissance passe du système CA au VSC (fonctionnement en redresseur).




FIGURE 2.4 – VSC au système CA

Pour les tensions et courants représentés à la figure suivante les équations du convertisseur peuvent être définies :




FIGURE 2.5 – Schéma équivalent du circuit VSC

La tension du convertisseur est donnée par la relation :

$$U_c = U_f + X_r I_r \quad (2.10)$$

où U_f est la tension du nœud de filtre CA, X_r est la réactance de l'inductance du convertisseur et I_r est le courant traversant l'inductance du convertisseur.

Le courant I_r est donné par la relation :

$$I_r = I_t + I_f \quad (2.11)$$

où I_t est le courant total à travers le transformateur du convertisseur et I_f est le courant traversant l'impédance du filtre.

La tension U_f du nœud de filtre CA est donnée par la relation :

$$U_f = U_t + X_{tr} I_t \quad (2.12)$$

où U_t est la tension sur le côté primaire du transformateur de convertisseur, X_{tr} est la réactance du transformateur de convertisseur.

Le courant de filtre I_f est donné par la relation suivante :

$$I_f = \frac{U_f}{Z_f} \quad (2.13)$$

2.16 Lignes de transmission

La transmission et la distribution de l'énergie électrique s'effectuent par l'intermédiaire de câbles métalliques.

- a) AC ou DC aériens
- b) souterrains à courant alternatif ou à courant continu

2.16.1 Propriétés électriques des lignes de transmission

- Résistance en série : Chute de tension (IR) et perte de puissance réelle (I^2R) le long de la ligne. Due à la conductivité finie de la ligne.
- Inductance en série : Chute de tension pas de perte de puissance réelle. Inductance propre uniquement (pas d'inductance mutuelle) dans les systèmes équilibrés.
- Capacité de shunt : Capacitance à d'autres conducteurs et à la terre.

Remarque : La conductivité shunt est négligeable dans les systèmes HVDC.

2.16.2 Conducteurs

Les systèmes HVDC (High Voltage Direct Current) sont utilisés pour transmettre de grandes quantités d'énergie électrique sur de longues distances, généralement des centaines voire des milliers de kilomètres. Par rapport au transport de courant alternatif, le HVDC présente plusieurs avantages tels que des pertes moindres, un meilleur contrôle du flux d'énergie et la possibilité d'interconnecter différents systèmes de courant alternatif. Dans un système HVDC, l'énergie électrique est convertie du courant alternatif en courant continu à l'extrémité émettrice, transmise sur une ligne à courant continu puis reconvertie en courant alternatif à l'extrémité réceptrice.

Les conducteurs utilisés dans un système HVDC sont généralement en cuivre ou en aluminium, tout comme dans une ligne de transmission à courant alternatif. Cependant, les systèmes HVDC nécessitent des tensions beaucoup plus élevées que les systèmes à courant alternatif, généralement de l'ordre de 500 kV à 800 kV voire plus. Cela signifie que les conducteurs doivent être conçus pour résister à des contraintes électriques beaucoup plus importantes telles que les décharges corona et les champs électriques.

- Les câbles unipolaires : Ils sont utilisés pour la transmission souterraine ou sous-marine et sont généralement fabriqués en polyéthylène réticulé (XLPE) ou en caoutchouc éthylène-propylène (EPR).
- Lignes aériennes bipolaires : Il s'agit de deux conducteurs, l'un positif et l'autre négatif montés sur des tours ou des poteaux distincts. Les conducteurs sont généralement en aluminium ou en alliage d'aluminium avec une âme en acier.
- Lignes aériennes monopolaires : Il s'agit d'un conducteur unique avec une voie de retour à la terre utilisé pour des niveaux de puissance plus faibles ou pour des projets pilotes. Le conducteur est généralement un conducteur en aluminium à âme en acier (ACSR).
- Lignes aériennes hybrides : Elles combinent les conceptions bipolaires et monopolaires et sont utilisées dans les situations où une conception bipolaire n'est pas possible en raison de l'espace disponible ou d'autres contraintes.




FIGURE 2.6 – Liaisons typiques

Le choix du type de conducteur dépend de divers facteurs tels que le niveau de puissance, la distance de transmission, le terrain et les conditions environnementales.

L'aluminium est le conducteur le plus courant

- Bonne conductivité
- Poids léger
- Faible coût

Le type de câble le plus courant combine l'aluminium et l'acier. **Conducteur en aluminium renforcé d'acier (ACSR)**

- Câble nu toronné
- L'âme des brins d'acier assure la solidité
- Les torons extérieurs en aluminium assurent une bonne conductivité

Regroupement Le regroupement dans la transmission par ligne fait référence à la pratique consistant à regrouper plusieurs conducteurs électriques en une seule ligne de transmission. Cette pratique est généralement utilisée pour les lignes à haute tension afin d'augmenter la capacité et l'efficacité globales du système de transmission.

En regroupant plusieurs conducteurs, on augmente la surface totale des conducteurs, ce qui réduit la résistance de la ligne et permet de transmettre plus d'énergie électrique sur de plus longues distances. Le regroupement permet également de réduire la taille et le poids du système de transmission, ce qui peut réduire les coûts de construction et faciliter l'installation et la maintenance du système.

Le regroupement peut se faire de différentes manières, par exemple en tordant les conducteurs ensemble, en utilisant des connecteurs ou des colliers spéciaux, ou en plaçant les conducteurs dans un seul câble ou faisceau. La méthode spécifique utilisée dépendra des exigences du système de transmission et de l'environnement dans lequel il sera installé.

Liaisons typiques :

- 345 kV : deux conducteurs
- 500 kV : trois conducteurs
- 765 kV : quatre conducteurs

Avantages de la mise en faisceau :

- Résistance plus faible
- Réactance (inductance) plus faible
- Augmentation de l'ampacité
- Réduction du gradient de champ électrique autour du conducteur de phase
- Réduction de l'effet couronne
- Réduction des pertes, du bruit et des interférences RF
- Amélioration de la dissipation de la chaleur

2.16.3 Modèles de lignes moyennes et courtes

Modèle de ligne courte

La façon dont nous choisissons de modéliser les caractéristiques électriques d'une ligne de transmission dépend de la longueur de la ligne.

Modèle de ligne courte :

- ≤ 50 km
- Ne tient compte que de l'impédance en série
- Ne tient pas compte de la capacité shunt

La modélisation d'une ligne de transport entre les jeux de barres i et j est représentée par un schéma équivalent en π comme illustré dans la figure suivante :




FIGURE 2.7 – Modèle en π de ligne de transport

r et ωL sont la résistance et la réactance par unité de longueur, chacun avec des unités de Ω/m . l est la longueur de la ligne.

2.16.4 Modélisation du câble

Modèle de section PI

Ce modèle regroupe la résistance du câble R , la capacité C et l'inductance L et convient généralement aux simulations en régime permanent et à la modélisation de courtes longueurs de câble. Lorsque la fréquence d'intérêt ou la longueur du câble augmente, il faut davantage de sections PI pour tenir compte de la nature distribuée du câble. Cela entraîne un temps de calcul supplémentaire. Ce type de modèle est facilement disponible dans SimPower Systems.

Modèle de Bergeron

Le modèle de Bergeron est basé sur la théorie des ondes progressives et représente la nature distribuée des paramètres LC du câble. La résistance du câble est regroupée et divisée en trois parties : 50 % au milieu du câble et 25 % à chaque extrémité. Ce modèle, similaire à la section PI, ne tient pas compte de la dépendance en fréquence des paramètres du câble et est donc essentiellement un modèle à fréquence unique. Les systèmes SimPower contiennent une forme du modèle Bergeron.

Modèles dépendant de la fréquence

Les modèles basés sur la fréquence décrivent le câble comme un réseau RLC distribué prenant en compte la variation de tous les paramètres en fonction de la fréquence. Pour utiliser ce type de modèle, il est essentiel de disposer d'informations précises sur la géométrie du câble ainsi que sur les caractéristiques des matériaux utilisés. Il est également impératif de connaître à la fois le modèle de mode dépendant de la fréquence et le modèle de phase dépendant de la fréquence.

La distinction entre ces deux modèles réside dans le fait que le modèle de phase prend en considération la variation de la matrice de transformation interne en fonction de la fréquence, tandis que le modèle de mode suppose que cette matrice reste constante. En termes de robustesse et de précision numérique, le modèle de phase qui tient compte de la variation de la matrice interne est considéré comme la meilleure option disponible commercialement en ce qui concerne la modélisation des lignes ou câbles [93].

Nous allons utiliser le modèle en π avec la correction hyperbolique dans le reste de notre étude car le modèle à éléments distribués à constante répartie n'est généralement appliqué que lorsque la précision l'exige. L'emplacement de ce point dépend de la précision requise dans une application spécifique ; dans notre cas, il s'agit de l'emplacement du défaut.

Correction hyperbolique des éléments RLC

Pour les tronçons de ligne courts (environ $l_{sec} < 50$ km) les éléments RLC pour chaque tronçon de ligne sont simplement donnés par :

$$R = r \cdot l_{sec} \quad (2.14)$$

$$L = l \cdot l_{sec} \quad (2.15)$$

$$C = c \cdot l_{sec} \quad (2.16)$$

Cependant pour les longues sections de ligne, les éléments RLC donnés par les équations ci-dessus doivent être corrigés afin d'obtenir un modèle de ligne exact à une fréquence donnée. Les éléments RLC sont alors calculés à l'aide de fonctions hyperboliques comme expliqué ci-dessous.

$$\omega = 2\pi f \quad (2.17)$$

L'impédance série par unité de longueur à la fréquence f est

$$Z = r + j\omega l \quad (2.18)$$

L'admittance shunt par unité de longueur à la fréquence f est

$$Y = j\omega c \quad (2.19)$$

L'impédance caractéristique est

$$Z_c = \sqrt{\frac{Z}{Y}} \quad (2.20)$$

La constante de propagation est

$$\gamma = \sqrt{z \cdot y} \quad (2.21)$$

$$Z = R + j\omega L = Z_c \cdot \sinh(\gamma \cdot l_{sec}) \quad (2.22)$$

$$R = \text{real}(Z) \quad (2.23)$$

$$L = \frac{\text{imag}(Z)}{\omega} \quad (2.24)$$

$$Y = \frac{2}{Z_c \tanh\left(\frac{\gamma \cdot l_{sec}}{2}\right)} \quad (2.25)$$

$$C = \frac{\text{imag}(Y)}{\omega} \quad (2.26)$$

2.17 Contrôle des VSC

Avec le schéma de modulation de largeur d'impulsion (PWM) appliqué aux IGBT du convertisseur, il est possible d'ajuster simultanément l'amplitude et la phase de la tension alternative (AC) en sortie du convertisseur. Cette capacité permet un contrôle précis de la puissance : la puissance active est régulée en modifiant la phase de la tension AC, tandis que la puissance réactive est contrôlée via l'amplitude de cette tension [29, 32].

La boucle de contrôle de la puissance active peut être configurée pour réguler le flux de puissance en fonction de la tension continue (DC), des variations de fréquence ou selon une valeur de référence définie. De même, la boucle de contrôle de la puissance réactive peut être réglée selon la tension AC ou une consigne prédéfinie [29, 32].

Le système global de commande, tel qu'illustré dans la littérature [29], repose généralement sur une structure à deux boucles hiérarchiques. La boucle intérieure assure un contrôle vectoriel rapide du courant du convertisseur, tandis que la boucle extérieure, plus lente, inclut les régulateurs de tension DC et AC, ainsi que ceux de puissance active, réactive et de fréquence.

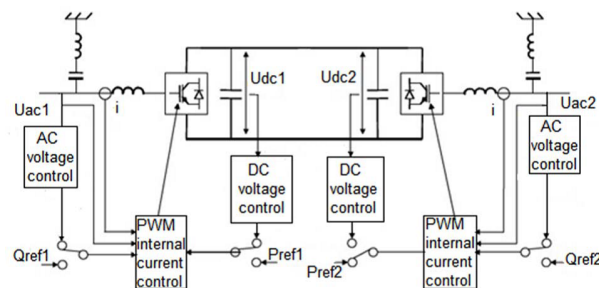


FIGURE 2.8 – Système de Contrôle de la Technologie de Transmission VSC HVDC [29]

2.17.1 Réponse rapide aux perturbations

Un contrôle rapide de la puissance active et réactive du convertisseur améliore les performances dynamiques du système en cas de perturbations. Grâce à cette rapidité de réponse, le VSC est capable de gérer les transitoires et de maintenir la tension du bus AC constante, renforçant ainsi la stabilité transitoire du système. De plus, grâce à une modulation rapide de la puissance active et réactive, les VSC offrent également un amortissement efficace pour atténuer les oscillations électromécaniques [29,39-42].

Selon [42], des résultats de recherche montrent une amélioration de l'amortissement de torsion sous-synchrone grâce aux systèmes VSC HVDC. Il est conclu que le choix du mode de contrôle de la puissance active plutôt que le contrôle de la tension continue (DC) est plus bénéfique pour le contrôle de l'amortissement. [40,41] suggèrent la combinaison du contrôle de la puissance active et réactive pour de meilleures caractéristiques d'amortissement.

2.17.2 Technique de Modulation de Largeur d'Impulsion (PWM)

La technique de modulation de largeur d'impulsion (PWM) est largement utilisée dans les systèmes VSC bipolaires pour réguler la tension de sortie et le courant. Elle permet un contrôle précis de la forme d'onde du signal de sortie, ce qui est essentiel pour le transfert efficace de puissance.

2.17.3 Régulation de Tension

La régulation de tension est un aspect crucial du contrôle dans les systèmes VSC bipolaires. Elle vise à maintenir la tension de sortie à des niveaux spécifiques pour assurer une transmission d'énergie fiable et stable.

2.17.4 Contrôle de Courant

Le contrôle de courant est essentiel pour réguler le flux d'énergie à travers le système. Il garantit que les courants circulant dans le réseau restent dans des plages sécuritaires et optimales.

2.18 Conclusion

En conclusion, le chapitre sur la modélisation et la formulation mathématique des HVDC VSC fournit une compréhension approfondie des principaux composants et des modèles utilisés pour décrire le comportement de ces systèmes. De plus, nous avons discuté de l'importance de la correction hyperbolique des éléments RLC pour optimiser les performances des réseaux électriques. Cette technique s'avère cruciale dans les systèmes à haute tension où la précision des signaux est primordiale. Enfin, nous avons abordé la fonction principale du VSC-HVDC qui consiste à assurer un transfert de puissance continu et stable entre le redresseur et l'onduleur en mettant en lumière les composants clés qui le composent. Dans l'ensemble, cette compréhension approfondie des modèles et des composants est essentielle pour une analyse précise et une conception efficace des systèmes HVDC VSC.

Dans cette perspective, le chapitre suivant s'intéresse à un aspect critique pour la fiabilité du système : la détection et la localisation des défauts dans les lignes HVDC. Une revue de

la littérature sera menée afin d'identifier les approches existantes et de mettre en évidence les lacunes (gaps) à combler, en vue de proposer des solutions innovantes et performantes.

Chapitre 3

Détection et localisation des défauts dans les Systèmes HVDC

3.1 Introduction

La détection et la localisation des défauts dans les réseaux à courant continu haute tension (HVDC) sont des sujets de recherche essentiels pour garantir la fiabilité et la stabilité des systèmes de transmission d'électricité. Les systèmes HVDC, de par leur capacité à transmettre de grandes quantités d'énergie sur de longues distances avec des pertes minimales, sont devenus de plus en plus cruciaux dans les infrastructures électriques modernes. Cependant, les défis posés par la détection et la localisation des défauts dans ces systèmes sont significatifs en raison de la nature complexe des phénomènes transitoires qui se produisent lors de ces incidents.

3.2 Importance de la détection et de la localisation des défauts

La détection rapide et précise des défauts est cruciale pour minimiser les temps d'arrêt, réduire les coûts de maintenance et éviter les dommages graves aux équipements. Une localisation précise permet une intervention rapide et ciblée, réduisant ainsi les interruptions de service et améliorant la résilience du réseau. Les méthodes de détection et de localisation des défauts sont donc un élément clé pour la gestion efficace des réseaux HVDC.

3.3 Méthodes de détection et localisation dans la littérature

Les approches de détection et de localisation des défauts dans les systèmes HVDC peuvent être classées en plusieurs catégories, chacune ayant ses avantages et ses inconvénients. Les méthodes traditionnelles reposent souvent sur des techniques de mesure et d'analyse des signaux électriques, tandis que les approches modernes exploitent les avancées technologiques en matière de traitement de signal et d'intelligence artificielle.

Plusieurs approches sont mentionnées dans la littérature. La méthode des ondes de déplacement pour la classification des défauts dans les systèmes VSC-HVDC utilisant les réflexions successives des défauts est décrite dans [43]. Elle détecte le défaut par le pic de réflexion en utilisant le différentiateur et le lisseur. Une autre méthode a développé un algorithme basé sur les ondes de déplacement et a utilisé la corrélation croisée avec le vecteur de l'espace d'échantillonnage [44] qui utilise des transformations en ondelettes pour déplacer l'onde réfléchie vers le défaut estimé dans le système de transmission HVDC. Cette approche est également utilisée pour localiser les défauts dans les réseaux de transmission HVDC conventionnels à deux terminaux et est également considérée comme adaptée aux systèmes de transmission VSC-HVDC mixtes aériens et câblés.

L'article [45] présente une approche basée sur la transformée de Fourier rapide (FFT) et la transformée de Pony utilisant les données de courant à une extrémité pour la localisation des défauts. L'article [46] utilise une fonction de réseau neuronal RBF avec une transformée de décomposition de paquets d'ondelettes pour estimer les défauts dans le système de transmission HVDC. Quelques articles ont présenté un schéma de coordination basé sur l'analyse de la relation entre l'onde frontale et la vitesse de l'onde pour localiser le point de défaut. Ce schéma de détection s'attaque également à la singularité de l'onde frontale afin de détecter le point précis de l'onde frontale.

L'article [47] présente une méthode basée sur les hautes fréquences pour la localisation des défauts à l'aide de données asymétriques dans les systèmes de transmission UHVDC. L'extraction de la fréquence naturelle peut être réalisée en examinant les signaux transitoires après l'apparition du défaut. La transformée en ondelettes continue peut améliorer la précision de l'approche DTFT et la précision de la méthode DTFT peut être améliorée en utilisant la transformée en ondelettes continue et vérifiée en utilisant une approche d'onde de déplacement à deux terminaux pour prédire l'heure d'arrivée de l'onde réfléchie.

Le document de recherche [48] propose une approche sans paramètre de ligne pour la localisation des défauts à l'aide de données de désynchronisation à deux terminaux dans les systèmes de transmission HVDC. L'article [49] utilise un convertisseur de source de tension et un redresseur de diodes antiparallèle pour un schéma de circuit dépendant de l'indice de modulation équivalent basé sur un convertisseur de source de tension (VSC). Cette impédance transfère le côté CA avec une transition orthogonale vers le côté CC du convertisseur en utilisant l'analogie du transformateur. En raison des diodes antiparallèles connectées dans la configuration du convertisseur, un pont redresseur à diodes triphasé est créé cet article discute également de la représentation équivalente de ce pont à diodes.

Diverses méthodes de détection et de localisation des défauts ont été proposées dans la littérature. L'onde progressive, la surintensité et la sous tension possèdent un temps de détection rapide des défauts mais elles sont incapables de détecter les défauts à haute impédance. Pour les défauts à haute impédance, la protection différentielle est utilisée. Ce type de protection nécessite un support de communication tel que l'optique, ce qui augmente le temps de détection des défauts par rapport à la longueur du câble [52]. Un autre problème lié à la méthode de base des ondes progressives est sa mise en œuvre pratique en raison de la méthode d'échantillonnage élevée, elle est difficile à mettre en œuvre dans le matériel [51].

Le spectre de fréquence de la tension et du courant peut être utilisé pour concevoir un schéma de protection efficace. Cependant, elles ne sont pas assez rapides par rapport aux autres méthodes. La transformée en ondelettes est un outil efficace pour extraire des

informations de la tension et du courant ce qui permet de réduire le bruit. L'intelligence artificielle (IA) est une approche prometteuse pour la détection et la localisation des défauts en raison de ses capacités supérieures de reconnaissance des formes mais au prix d'énormes algorithmes de calcul [51]. Les travaux de recherche menés dans le cadre du projet TWENTIES [53] suggèrent que le meilleur scénario de protection peut être créé à l'aide d'une protection différentielle de courant comme schéma de protection principal et la surintensité comme protection de secours.

La méthode de direction du courant continu peut être utilisée efficacement pour identifier la ligne défectueuse dans un réseau MTDC [54]. Cependant, avec cette méthode, les lignes défectueuses ne peuvent être identifiées qu'au cours du processus d'élimination des défauts. Plusieurs méthodes de détection et de localisation des défauts sont proposées dans [55]–[58] sur la base de tensions et les courants transitoires mais elles ne sont pas sensibles aux défauts à haute résistance. Les méthodes basées sur les ondelettes et les ondes progressives ont été proposées dans [59]–[63] qui identifient avec précision le type de défaut et son emplacement et sa localisation. Dans [64]–[65] plusieurs méthodes basées sur des ANN et des machines à vecteur de support (SVM) ont été proposées pour identifier le type de défaut et sa localisation. Plusieurs chercheurs ont proposé des schémas de protection hybrides qui sont une combinaison des systèmes de protection existants. Dans [63] une détection de front d'onde et la théorie des graphes est mise en œuvre pour la localisation des défauts dans le réseau MTDC. Dans [66] une stratégie de protection coordonnée combinée est proposée pour les réseaux MTDC offshore à l'aide de mesures locales de la tension et de courant et leurs dérivés. Dans [67] la transformée en ondelettes est utilisée pour traiter le signal de tension continue et l'IA est appliquée pour détecter le défaut dans le système MTDC. Un modèle transitoire simplifié avec des composantes à haute fréquence est proposé par [68] pour la détection des défauts dans les systèmes MTDC.

3.3.1 Méthodes basées sur le temps de trajet des ondes (Time-Domain Reflectometry TDR)

Ces méthodes utilisent les réflexions des ondes électromagnétiques générées par les défauts pour estimer leur emplacement. En mesurant le temps de retour de ces réflexions, il est possible de déterminer la distance à laquelle le défaut s'est produit. Les méthodes TDR sont bien établies et offrent une bonne précision mais peuvent être limitées par la complexité des réseaux HVDC modernes et les effets des phénomènes transitoires.

3.4 Méthodes basées sur les ondes voyageuses progressives

Les méthodes basées sur les ondes progressives et leur principe de localisation des défauts pour les lignes de transmission sont expliqués dans [69] et [70]. Dans le cas d'une ligne de transmission en courant alternatif, il n'y a pas d'onde progressive transitoire au point de défaut pour l'angle d'inception du défaut au point de croisement zéro. Cependant, dans le cas d'une ligne de transmission en courant continu, l'onde progressive transitoire est présente pour le défaut en tout point. Par conséquent, la méthode des ondes progressives est plus adaptée pour une ligne de transmission HVDC. Un schéma de protection basé sur les ondes progressives pour le système HVDC point à point est présenté dans [71]

et [72]. Cependant, il n'est pas capable de protéger contre les défauts proches tandis qu'il est difficile de détecter les fronts d'onde et qu'il est influencé par le bruit. Par conséquent, une protection de frontière est également utilisée en combinaison avec la méthode des ondes progressives pour identifier le défaut dans la ligne HVDC [71]. Elle utilise un signal transitoire haute fréquence à une extrémité pour différencier le défaut interne du défaut externe et peut également détecter les défauts proches. Cependant, elle nécessite une fréquence d'échantillonnage élevée allant jusqu'à 50 kHz. Dans le cas d'un système HVDC basé sur VSC, la protection de frontière peut ne pas être capable de différencier les défauts internes des défauts externes. Dans [120] le défaut est détecté en utilisant les caractéristiques des valeurs initiales des ondes progressives. Aussi, le gradient de l'onde progressive est utilisé pour différencier le défaut interne du défaut externe car il est limité par le réacteur terminal en courant continu.

Ces méthodes exploitent les ondes transitoires générées par les défauts et leur propagation à travers le réseau. En analysant les différences de temps d'arrivée des ondes à différents points du réseau, il est possible de localiser le défaut. Les techniques basées sur les ondes voyageuses sont très efficaces pour les réseaux HVDC mais nécessitent des capteurs à haute vitesse et une analyse sophistiquée des signaux.

Dans [73] la méthode de localisation des défauts basée sur les ondes progressives à deux terminaux est appliquée pour protéger la ligne HVDC MT VSC contre les défauts en courant continu. Elle utilise la différence de temps d'arrivée des surtensions pour localiser le défaut en utilisant la vitesse de propagation. La distance du défaut (x_F) à un terminal peut être calculée par...

$$x_F = L - \Delta t \cdot \frac{v}{2} \quad (3.1)$$

où L est la longueur de la ligne, v est la vitesse de propagation et Δt est la différence de temps d'arrivée de la surtension. Δt peut être calculé par mesure synchronisée dans le temps en utilisant le système de positionnement global (GPS). Une transformation continue en ondelettes (CWT) est utilisée pour suivre le temps d'arrivée de la surtension avec une grande précision. Ici, le moment où la magnitude du coefficient CWT devient supérieure à la valeur de seuil sera considéré comme le temps d'arrivée de l'onde frontale au terminal. Cependant, dans la méthode basée sur les ondes progressives, la détection de la tête d'onde est le principal défi pour identifier les défauts dans une ligne HVDC. De plus, il est difficile de détecter le temps d'arrivée de la surtension car l'onde progressive est très faible en cas de haute résistance de défaut et de variation continue de la résistance de transition [77].

3.4.1 Méthodes basées sur la fréquence naturelle

Les composantes de fréquence de l'onde progressive générée en raison du défaut ou de tout événement transitoire peuvent être appelées la fréquence naturelle qui est une combinaison de fréquences harmoniques. Dans la méthode basée sur la fréquence naturelle, il n'est pas nécessaire de suivre la tête d'onde et un signal transitoire à une extrémité est suffisant pour détecter le défaut. Le concept de fréquence naturelle peut être vu dans [78] qui utilise le modèle à paramètres distribués et explique la relation entre la fréquence naturelle et la distance de défaut lorsque l'impédance du système est nulle ou infinie. Dans [79]–[82], le schéma de protection basé sur la fréquence naturelle est appliqué pour localiser le défaut dans une ligne de transmission en courant alternatif où moins d'énergie transitoire est présente si le défaut se produit lorsque la tension traverse ou se rapproche

du point zéro. L'extraction de la fréquence naturelle à partir du signal transitoire de défaut est compliquée. Cependant, dans le cas d'une ligne de transmission en courant continu, l'énergie transitoire est toujours très élevée et donc elle est adaptée pour localiser le défaut. Dans [77], une méthode qui utilise la fréquence naturelle est appliquée pour localiser le défaut dans un système HVDC bipolaire basé sur CSC dans lequel la fréquence naturelle dominante est utilisée pour trouver la distance de défaut en calculant la vitesse de l'onde progressive et le coefficient de réflexion.

Les auteurs de [83] et [84] présentent une méthode de localisation de défaut dans un système HVDC bipolaire basé sur VSC à deux terminaux en extrayant la fréquence naturelle du courant de défaut. Lorsque le défaut se produit, la ligne CC a une haute énergie transitoire qui créera plus de composantes de fréquence naturelle. La fréquence naturelle est générée par le système distribué. Les caractéristiques des paramètres et la réflexion d'une onde progressive. De plus, le signal de fréquence naturelle est réfléchi par les condensateurs shunt ce qui facilite son extraction. Il est lié à la vitesse de l'onde et à la distance de défaut et la distance de défaut (l) est donnée par...

$$l = \frac{k \cdot v_k}{2f_k} \quad (3.2)$$

où k est un entier, f_k est la fréquence naturelle du k -ème ordre et v_k est la vitesse de l'onde progressive. La précision de ce schéma de protection dépend de l'extraction de la fréquence naturelle et du calcul de la vitesse de l'onde progressive. N'importe quelle section des données pendant la période de défaut peut être utilisée pour identifier le défaut dans une ligne HVDC contrairement à la détection de la tête d'onde dans la méthode des ondes progressives. Cependant, la méthode basée sur la fréquence naturelle peut ne pas être adaptée aux transitoires variables dans le temps. Lorsque le défaut se produit dans une ligne CC, une fréquence naturelle peut être générée en raison de la résonance causée par le condensateur shunt et l'inductance de ligne. De plus, la précision de la mesure diminue à mesure que la distance de défaut augmente.

3.4.2 Méthodes basées sur l'impédance

Ces techniques mesurent les variations d'impédance dans le réseau pour détecter les défauts. Les changements dans l'impédance du réseau peuvent indiquer la présence et la localisation d'un défaut. Les méthodes basées sur les impédances sont simples à mettre en œuvre mais peuvent être influencées par les variations normales de charge et les conditions de fonctionnement du réseau. La méthode de localisation des défauts en domaine temporel basée sur une approche à paramètres distribués pour les lignes de transmission en courant alternatif et continu est présentée dans [85]–[88]. Elle utilise le calcul de la distribution de tension de la ligne pour localiser le défaut en utilisant la tension mesurée de manière synchrone et le courant aux deux extrémités de la ligne. Elle peut prendre n'importe quelle section des données depuis le transitoire de défaut jusqu'à l'état stable et seule une faible fréquence d'échantillonnage est requise pour obtenir des résultats précis. Cependant, elle est sensible à l'incertitude des paramètres tels que la vitesse, la résistance de ligne et l'impédance caractéristique. Cela peut entraîner une inexactitude dans le calcul de la distribution de tension. Les mesures à deux extrémités non synchronisées affectent également le schéma de protection. La référence [89] prend en compte les paramètres de ligne incertains et la différence de temps de mesure non synchronisée pour localiser le défaut dans une ligne de transmission HVDC.

Dans [118] et [119] la distance de défaut est calculée en utilisant un arrangement de deux diviseurs de tension. La mesure du courant continu n'est pas prise pour le calcul de la distance car le changement immédiat du courant de défaut élevé pourrait entraîner une erreur de mesure. Au lieu de cela, deux unités de capteurs de tension sont utilisées pour calculer la distance de défaut comme illustré dans la Figure 3.1 où une unité de capteur est utilisée au point de relais (n) et l'autre est l'unité de capteur de tension de référence (r) utilisée pour éviter la communication à longue distance. À partir de la Figure 3.1 la tension au point de relais (n) est donnée par...

$$x = d \left(\frac{V_n - V_F}{V_n - V_r} \right) \quad (3.3)$$




FIGURE 3.1 – Calcul de la distance de défaut en utilisant deux diviseurs de tension

ici $V(r)$ et $V(f)$ sont les tensions au capteur de référence et au point de défaut respectivement. R et L sont les paramètres de la ligne. Pour les défauts solides $R_f = 0$ et $V(f) = R_f \times i(f) = 0$ donc l'arrangement des deux diviseurs de tension peut localiser le défaut avec précision. Cependant, ce schéma de protection ne considère que la localisation du défaut plutôt que le processus de détection du défaut. Pour les cas de défaut à haute résistance, l'estimation de la distance de défaut peut ne pas être précise et le calcul de la distance dans ce schéma de protection prend également beaucoup de temps.

La référence [100] propose une solution au défaut à l'extrémité distante dans la ligne de transmission HVDC bipolaire à deux terminaux illustrée dans la Figure 3.2. Dans cette méthode, la protection de distance considérant des paramètres dépendant de la fréquence est utilisée pour évaluer la distance de défaut dans la ligne HVDC puisque l'inductance (L) de la ligne de transmission dépend principalement de la fréquence. Comme illustré, le relais de distance est situé au point M tandis que V_m et i_m sont la tension et le courant mesurés à l'emplacement du relais (M) et V_k et i_k sont la tension et le courant au point de réglage (K). La précision dépend du critère donné dans (3.4) .

$$Er < l_f - l_{set} \quad (3.4)$$

où Er est l'erreur de mesure, l_f et l_{set} sont respectivement les distances de défaut et de réglage. L'erreur admissible ($l_f - l_{set}$) est la différence entre la distance de défaut et la distance de réglage. Une précision plus élevée est très importante car il y a une très petite

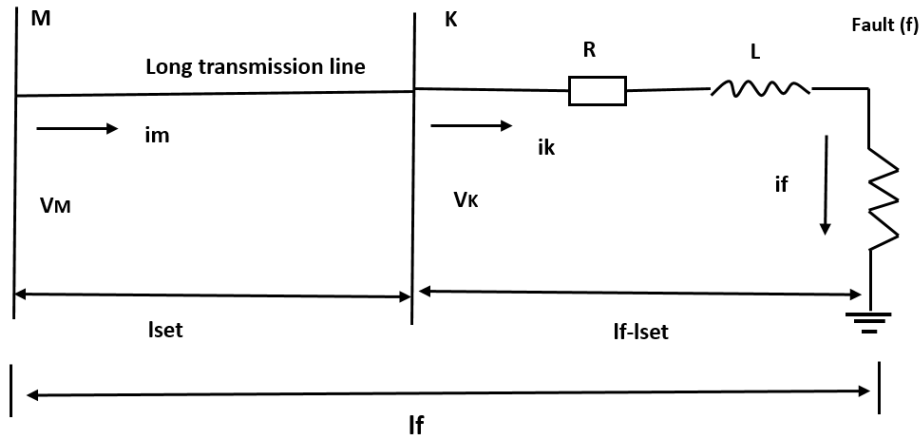


FIGURE 3.2 – Modèle de la ligne de transmission en condition de défaut (f)

marge d'erreur admissible lorsque le défaut se produit près du point de réglage K. Les mesures sont prises au point de réglage (K) avec l'aide du modèle de ligne à paramètres dépendant de la fréquence.

3.4.3 Méthodes basées sur la transformée en ondelettes

Dans le passé, la transformée de Fourier (TF) était utilisée pour extraire les composantes spectrales d'un signal, mais elle fournit les composantes de fréquence dans le signal sans information temporelle. Ainsi, elle n'est pas adaptée aux signaux non stationnaires qui sont très importants pour la protection d'une ligne de transmission HVDC. La transformée de Fourier à court terme (STFT) a ensuite été utilisée pour extraire les contenus spectraux du signal fournissant les bandes de fréquence existantes et les intervalles de temps correspondants, c'est-à-dire que la résolution est fixe. Cependant, elle ne fournit pas l'information de la fréquence existante au moment instantané. Par conséquent, la transformée en ondelettes (WT) est utilisée pour extraire les signaux transitoires dus aux défauts et autres perturbations. La WT est un outil puissant dans les méthodes de traitement du signal pour suivre les transitoires de défauts dans les signaux non stationnaires [91]– [95]. La transformée en ondelettes continue (CWT) d'un signal $f(t)$ est donnée par...

$$CWT_{a,b} = \int_{-\infty}^{+\infty} f(t)\Psi_{a,b}^*(t) dt \quad (3.5)$$

$$\Psi_{a,b}^*(t) = \frac{1}{a}\Psi\left(\frac{t-b}{a}\right) \quad (3.6)$$

où $\Psi_{a,b}(t)$ est le conjugué complexe de la mère ondelette et a et b sont les paramètres de mise à l'échelle et de décalage respectifs.

Le schéma de protection basé sur la WT peut être observé dans [96]– [100]. Les références [71] et [73] utilisent la WT pour détecter les ondes progressives et les transitoires de tension pour la détection d'un défaut en courant continu dans une ligne HVDC. Dans [101] la WT est appliquée pour identifier le défaut en courant continu dans le système HVDC MT VSC en utilisant des mesures locales où la tension continue, le courant et leurs dérivées sont utilisés comme coefficients d'ondelettes et la redondance modulaire triple (TMR) est utilisée pour obtenir la sélectivité. Dans [102] le temps de montée du courant de défaut

est capturé en utilisant la WT pour détecter le défaut dans le système HVDC. Dans [103] la WT complexe est utilisée pour extraire le courant à fréquence caractéristique et non caractéristique pour la détection de défaut dans une ligne MTDC. Dans [104] la WT est utilisée pour extraire le transitoire haute fréquence de la tension de gaine de câble pour détecter le défaut dans une ligne HVDC-VSC. Les références [105] et [106] utilisent la WT discrète pour suivre les signaux transitoires haute fréquence pour localiser le défaut dans le système HVDC MT. Dans [107] la protection de surintensité basée sur la WT discrète de frontière pour le système de distribution IEEE 30 bus avec génération distribuée (DG) est présentée et les résultats de simulation sont comparés à la protection de surintensité classique basée sur la TF.

Cependant, dans les méthodes de protection basées sur la WT, le coefficient d'ondelette est prédéfini pour la détection de défaut. L'angle d'inception de défaut et la résistance de défaut peuvent influencer l'efficacité du schéma de protection basé sur le coefficient d'ondelette. De plus, il peut ne pas être adapté comme méthode de protection autonome.

3.4.4 Méthodes de protection basées sur les transitoires

Dans [108] la différence d'énergie transitoire entre les extrémités redresseur et onduleur est utilisée pour détecter et discriminer entre les défauts internes et externes dans une ligne HVDC à deux terminaux. Le système de transmission HVDC à deux terminaux est illustré dans la Figure 9. Le relais est situé du côté redresseur (M) et du côté onduleur (N) de la ligne et il utilise la tension continue et le courant mesurés des deux côtés pour calculer la différence d'énergie transitoire. Elle est calculée sur la base des équations de la ligne de transmission dans le cadre d'un modèle à paramètres distribués. La variation d'énergie transitoire (ΔE) peut être calculée par...

$$\Delta E_M = \Delta u_M \cdot \Delta i_M \cdot \Delta t \quad \text{et} \quad \Delta E_N = \Delta u_N \cdot \Delta i_N \cdot \Delta t \quad (3.7)$$

$$\Delta E = \Delta E_M - \Delta E_N \quad (3.8)$$

où Δu_M , Δi_M , Δu_N , Δi_N sont les variations de la tension continue et du courant aux côtés redresseur et onduleur. Δt est la période continue de t_1 à t_2 . La variation de l'énergie transitoire (ΔE) est nulle dans des conditions normales mais a une certaine valeur en cas de défaut dans le système HVDC. Un défaut interne se produit lorsque $|\Delta E| > \Delta E_{set}$ et $\Delta E < 0$ tandis qu'un défaut externe se produit lorsque $|\Delta E| > \Delta E_{set}$ et $\Delta E > 0$ où ΔE_{set} est le réglage de la valeur seuil pour la variation de l'énergie transitoire. Cependant, la longueur de la ligne de transmission et la résistance de défaut peuvent affecter la précision du schéma de protection.

La détection de défaut basée sur le signal transitoire haute fréquence extrait à l'aide de la WT est présentée dans [71]. Dans [109] – [111] le schéma de protection non unitaire qui est la combinaison d'unités de démarrage, de délimitation de direction et d'identification de ligne défectueuse est proposé et testé sur le matériel. L'unité de démarrage utilise le gradient de tension pour différencier l'état anormal de l'état normal tandis que l'unité de délimitation basée sur l'énergie calculée à partir du signal transitoire haute fréquence est appliquée pour distinguer les défauts internes et externes. L'unité directionnelle utilise les ondes progressives avant et arrière pour détecter la direction du défaut. Étant donné que l'énergie transitoire de la ligne défectueuse a une valeur plus élevée que les lignes normales, l'unité d'identification de ligne défectueuse utilise la comparaison de l'énergie transitoire générée dans la ligne HVDC.

La référence [112] utilise le courant harmonique transitoire pour détecter et différencier les défauts internes et externes dans une ligne HVDC à deux terminaux. Le courant harmonique transitoire est faible en cas de défaut externe car il est limité par le filtre continu et le réacteur d'adoucissement, mais il a une valeur élevée pour un défaut interne. Par conséquent, la différence calculée du courant harmonique transitoire aux deux extrémités est appliquée pour différencier le défaut interne du défaut externe. Cependant, la sensibilité de ce schéma de protection est affectée par la résistance et l'emplacement du défaut et elle nécessite des informations des deux côtés pour prendre la décision. Dans [103] la localisation de défaut est réalisée en utilisant les caractéristiques des filtres continus dans la ligne MTDC. Les défauts internes et externes sont distingués en utilisant le courant aux fréquences caractéristiques et non caractéristiques qui sont extraites à l'aide d'une WT complexe. Un défaut interne se produit lorsque le courant à fréquence caractéristique est supérieur au courant à fréquence non caractéristique ; sinon, il est considéré comme un défaut externe.

Dans [104] une nouvelle méthode de localisation de défaut basée sur la tension de gaine pour un système HVDC VSC à deux terminaux est rapportée. La gaine du câble est mise à la terre à chaque extrémité de la sous-station HVDC et les tensions de gaine sont mesurées à ces points. Dans des conditions normales, la tension transitoire dans la gaine du câble est nulle et aucun courant ne circule à travers elle. Cependant, en cas de défaut, la tension transitoire de la gaine du câble a une certaine magnitude et le courant de défaut circule également à travers elle. Par conséquent, la tension transitoire de la gaine du câble est utilisée pour identifier le défaut et les signes des deux côtés sont appliqués pour différencier le défaut en courant continu et le déséquilibre de condensateur. La référence [105] utilise la différence de l'indice d'énergie qui peut être calculée à partir des signaux de courant transitoire haute fréquence mesurés aux deux extrémités pour détecter le défaut en courant continu dans les systèmes HVDC MT VSC. Dans [116] le signal transitoire haute fréquence à une extrémité est utilisé pour identifier le défaut et les défauts internes et externes sont distingués par le condensateur shunt connecté à la barre omnibus.

3.4.5 Méthodes basées sur les dérivées de tension et de courant

La référence [113] présente un schéma de protection basé sur les dérivées de tension (dv/dt) et de courant (di/dt) pour le système MTDC en utilisant les mesures à une seule extrémité. Le défaut peut être identifié si le taux de variation de la tension continue et du courant dépasse le seuil prédéfini. Dans [114] la détection de défaut dans un réseau HVDC mis à la terre est présentée sur la base du taux de variation de tension (ROCOV). L'inductance continue est connectée en série avec le disjoncteur continu pour contrôler le courant de défaut maximal afin qu'il soit inférieur à la capacité nominale du disjoncteur. La Figure 10 montre le schéma de détection de défaut proposé utilisant le ROCOV et l'inductance de limitation de courant. Où V_{bus} est la tension au terminal du bus, V_L la tension à travers l'inductance et V_{ligne} la tension sur la ligne de transmission ou du côté du câble. La tension de l'inductance est donnée par...

$$V_L(t) = L \frac{di}{dt} \quad (3.9)$$

$$\frac{di}{dt} = \frac{V_{bus}(t) - V_{ligne}(t)}{L} \quad (3.10)$$

où L est la valeur de l'inductance. Si le défaut se produit dans une ligne, V_{bus} est constant pendant les premières millisecondes et le taux de variation du courant (ROCO) au niveau du disjoncteur dépend principalement de la tension du côté ligne (V_{ligne}). Par conséquent, la localisation du défaut peut être réalisée en mesurant le ROCOC du côté ligne de l'inductance de limitation. La plage de variation du ROCOC peut être utilisée pour distinguer les différents défauts de zone et de bus en définissant des valeurs seuils prédéfinies. De plus, le taux de montée du courant de défaut peut être limité en augmentant la valeur de l'inductance connectée en série avec le disjoncteur. Cependant, cela suppose que la tension continue de la sortie du convertisseur est constante après le défaut. Dans [115] la plage de variation de la tension du réacteur continu est utilisée pour détecter le défaut dans les systèmes HVDC MT maillés. Les variations de la tension du réacteur continu sont observées en continu et comparées à la valeur seuil prédéfinie pour identifier le défaut. Cependant, le réglage de la valeur seuil pour le schéma de protection est un défi pour la distinction entre les différents défauts de zone ou de ligne et les défauts de haute résistance.

Dans [116] le schéma de protection non unitaire pour un défaut en courant continu dans le réseau HVDC MT VSC est présenté où une terminaison inductive détermine la zone de protection. Il applique la détection de sous-tension pour identifier le défaut et la valeur seuil pour le critère de sous-tension est fixée à 85 % de la tension continue nominale. Après l'identification du défaut, les dérivées de tension et de courant sont utilisées pour discriminer les défauts de première et deuxième zone. Cependant, la dérivée de tension est vulnérable aux défauts proches, aux erreurs de mesure et au bruit donc la direction de la dérivée de courant est utilisée pour différencier les défauts avant et arrière. Cependant, la discrimination du défaut à haute résistance de la Zone-1 par rapport au défaut solide de la Zone-2 devient très difficile et les limites de la deuxième zone ne sont pas considérées dans cet article. De plus, le réglage de la valeur seuil pour le critère de discrimination des défauts peut ne pas fonctionner correctement lorsque la variation de la résistance de défaut est significative.

Dans [117] les première et deuxième dérivées du courant de défaut sont utilisées pour détecter et discriminer le défaut dans le micro-réseau continu. Le calcul d'un réglage adaptatif de seuil du schéma de protection est présenté car il est essentiel de prendre en compte les défauts de haute impédance et les différentes conditions de fonctionnement.

3.4.6 Approches basées sur l'intelligence artificielle et l'apprentissage automatique

Avec l'essor des technologies de traitement de données et d'apprentissage automatique, des approches modernes exploitent des algorithmes avancés pour analyser les données du réseau et détecter les défauts. Les réseaux neuronaux, les machines à vecteurs de support (SVM) et d'autres techniques d'apprentissage supervisé et non supervisé sont utilisés pour améliorer la précision et la rapidité de la détection et de la localisation des défauts. Ces méthodes sont prometteuses mais nécessitent de vastes ensembles de données pour l'entraînement et peuvent être complexes à déployer en pratique. Au cours des deux dernières décennies, la recherche sur les techniques d'intelligence artificielle pour la conception et la protection des systèmes électriques a connu une forte augmentation. Les principales méthodes d'apprentissage automatique (ML) utilisées pour la protection des systèmes électriques incluent les systèmes experts, les réseaux de neurones artificiels (ANN), la

logique floue et les machines à vecteurs de support (SVM). Les ANN sont devenus particulièrement populaires pour la protection HVDC en raison de leur complexité réduite, de leur coût inférieur et de leur rapidité d'exécution. Ils peuvent soit échantillonner directement les signaux de tension et de courant, soit utiliser des techniques supplémentaires, telles que les méthodes de traitement du signal (SP), pour extraire des caractéristiques avant de les introduire dans le réseau. Bien que l'échantillonnage direct soit efficace pour la reconnaissance des défauts, il nécessite un entraînement intensif et une architecture complexe. D'autre part, les méthodes de SP comme la transformée de Fourier rapide (FFT) et la transformée en ondelettes (WT) peuvent être affectées par le bruit et nécessitent des données étendues pour l'entraînement. D'autres techniques de ML, y compris la logique floue, les SVM et les K-plus proches voisins (KNN), sont également utilisées pour la protection HVDC. Par exemple, la logique floue utilise des entrées de tension et de courant en axe dq pour un moteur d'inférence floue afin de détecter les défauts. Les SVM ont été appliqués à la reconnaissance des défauts en utilisant des caractéristiques dérivées de l'analyse des composants symétriques et de la transformée en ondelettes. Le KNN a été testé pour la reconnaissance du type de défaut, montrant des délais de détection allant de 1 à 3 millisecondes [123]- [132]. Actuellement, l'apprentissage profond (DL) est à la pointe de la recherche sur les systèmes électriques, avec des méthodes telles que la mémoire à long terme (LSTM) et les réseaux de croyances profondes (DBN) étant utilisées pour la protection HVDC. Ces techniques de DL démontrent une précision supérieure dans la détection des défauts mais nécessitent de grands ensembles de données pour l'entraînement. La performance de ces algorithmes de ML et DL est évaluée en fonction de la précision et de la sélectivité, déterminées par les vrais positifs (TP), les vrais négatifs (TN), les faux positifs (FP) et les faux négatifs (FN). Des valeurs plus élevées de ces métriques indiquent une meilleure performance de l'algorithme [133]- [136].

3.5 Protection et détection

Par conséquent, les schémas de protection qui sont applicables aux systèmes VSC et la gestion des défauts du système CC est similaire à celle des systèmes à courant alternatif et comprend la localisation et la détection des défauts et l'interruption des défauts. Le système de protection du système à courant continu doit donc fonctionner dans un laps de temps de quelques millièmes de secondes [50].

3.6 La maintenance corrective

La maintenance corrective, comme son nom l'indique, a pour but de remédier aux problèmes de fonctionnement des équipements ou des lignes de production dès leur apparition. Lorsqu'une panne survient et perturbe le processus de production et qu'elle n'a pas été anticipée par d'autres formes de maintenance comme la maintenance préventive, les techniciens responsables de la maintenance industrielle interviennent pour résoudre le problème rapidement. Il s'agit d'une forme de maintenance préventive non planifiée également appelée maintenance curative. Cette intervention peut engendrer des coûts importants pour les entreprises.

3.7 La maintenance préventive

La maintenance préventive est une forme de maintenance industrielle qui consiste à effectuer des actions de maintenance en amont de toute panne ou dysfonctionnement afin de réduire les risques de défaillance. Cela implique l'inspection et la maintenance des pièces détachées, des composants des machines et des équipements. Grâce à la numérisation des entreprises industrielles, de nombreuses solutions technologiques ont été développées pour permettre aux techniciens d'effectuer, de suivre et de planifier la maintenance préventive de manière efficace.

3.8 La maintenance prédictive

La maintenance prédictive a émergé grâce aux solutions de traitement et d'analyse des données ainsi qu'à l'intelligence artificielle. Les industriels peuvent maintenant planifier une maintenance prédictive ou prévisionnelle basée sur la prédiction des pannes et des dysfonctionnements. Ce type de maintenance permet aux entreprises d'anticiper les problèmes en planifiant les interventions nécessaires en fonction des prédictions. En conséquence, cela permet de limiter les dépenses causées par les pannes inattendues et les interruptions de production.

3.9 Analyse et classification de données

L'analyse des données peut être définie comme un ensemble de méthodes descriptives visant à résumer et à visualiser les informations pertinentes contenues dans de grands ensembles de données. Grâce aux récents progrès techniques en matière de puissance de calcul, de capacité de stockage et d'interconnexion des technologies de l'information, nous avons accès à des quantités sans précédent de données numériques. L'exploration de données est la discipline qui consiste à extraire des connaissances utiles de ces vastes réservoirs de données. Il s'agit d'un domaine interdisciplinaire en plein essor lié à l'informatique. Les techniques d'exploration de données ont été largement appliquées à des problèmes industriels, scientifiques et d'ingénierie [69].

Autrement dit, l'analyse de données peut être descriptive, exploratoire, prédictive ou prescriptive selon les objectifs de l'analyse. La modélisation statistique et l'apprentissage automatique sont couramment utilisés pour extraire des informations significatives des données et pour créer des modèles prédictifs ou des recommandations. À l'heure actuelle, le volume de données recueillies connaît une croissance exponentielle, ce qui accentue l'importance cruciale du critère temporel. Ainsi, les méthodes automatiques de classification des données jouent un rôle essentiel dans la facilitation de l'exploitation de ces informations. De nombreuses recherches et études ont été menées dans le domaine de la classification de formes afin de mieux comprendre et tirer profit des données, en particulier lorsque celles-ci sont massives et que les critères de sélection sont moins évidents.

Le processus de classification de formes débute par une première phase d'acquisition et de prétraitement visant à éliminer les divers types de bruits présents dans les données enregistrées. La seconde étape implique la détermination des caractéristiques pertinentes à utiliser lors de la classification parmi lesquelles figurent des mesures telles que la moyenne, l'écart-type et la médiane. Ensuite, il s'agit de développer un classificateur capable de

reconnaître les différentes classes de formes. Enfin, la dernière phase du processus vise à évaluer et valider le système de classification. Le processus d'analyse de données comprend plusieurs étapes, notamment la collecte et la préparation des données, l'exploration et la visualisation des données, l'application de techniques statistiques et d'apprentissage automatique ainsi que l'interprétation des résultats. Les analystes de données ont souvent recours à des logiciels spécialisés et à des outils de visualisation tels que MATLAB, Tableau et Excel pour faciliter ces différentes étapes.

3.10 Comportement du courant lors d'un défaut dans un système à courant continu (CC)

Il est crucial d'étudier plusieurs défauts importants lors de la conception d'une liaison à courant continu haute tension (HVDC). Les caractéristiques des défauts posent des problèmes liés aux surtensions transitoires et aux surintensités transitoires. Certains emplacements de défauts peuvent causer des problèmes étendus, en particulier le défaut au niveau du bus du convertisseur qui fait référence à un défaut entre le réacteur du convertisseur et le transformateur et le défaut pôle à pôle qui fait référence à un défaut après le réacteur lissant entre les rails CC. Les courants transitoires les plus élevés déterminants pour le transformateur sont causés par un défaut triphasé sur le bus du convertisseur. Un défaut triphasé à la terre sur le bus du convertisseur connectera toutes les trois phases sur le bus du convertisseur à la terre forçant la tension de phase du bus du convertisseur à zéro. L'impédance des appareils connectés entre le réseau alternatif et le défaut ainsi que l'impédance du réseau alternatif limiteront le courant mais un transitoire élevé se produira. La valeur de crête du transitoire dépend du moment où le défaut se produit ou de l'endroit sur la sinusoïde de tension où le défaut se produit. Le défaut causant les courants les plus élevés à travers les valves est le défaut pôle à pôle du côté CC. Ce défaut crée un chemin de courant entre les rails CC positif et négatif et la tension sur les bus des pôles atteint zéro forçant des courants élevés à travers les valves. Un problème lié aux surtensions transitoires qui charge les condensateurs de cellules et la capacité côté CC est introduit par le défaut de phase à la terre sur le bus du convertisseur. Un défaut de phase à la terre provoquera la mise à zéro de la tension de phase défectueuse sur le bus du convertisseur et une augmentation de la tension sur les autres phases. Cela provoquera la conduction des diodes dans les bras supérieur et inférieur des phases non défectueuses. Le courant traversant les diodes charge les condensateurs et augmente les surtensions de bras créant des surtensions de cellules.

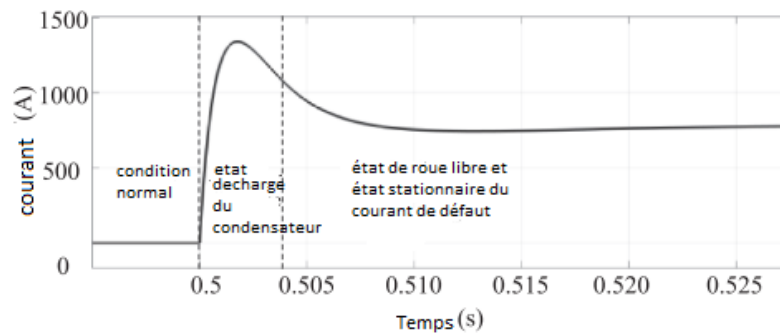


FIGURE 3.3 – Caractéristiques du courant lors d'un défaut dans un système à courant continu.

3.11 Les défauts dans le système HVDC

Le réseau électrique à courant continu haute tension (HVDC) présente certains défauts potentiels qui peuvent affecter sa fiabilité et son fonctionnement. Voici quelques-uns des défauts couramment associés au réseau HVDC :

- **Court-circuit** : Les courts-circuits peuvent se produire en raison de défauts d'isolement, de pannes d'équipement ou de défaillances du système de protection. Un court-circuit peut entraîner des surintensités et endommager les équipements du réseau HVDC.
- **Pannes de convertisseurs** : Les convertisseurs HVDC peuvent subir des défaillances mécaniques ou électriques, ce qui peut entraîner une interruption de la transmission d'énergie. Les pannes de convertisseurs peuvent nécessiter une intervention rapide pour rétablir le fonctionnement normal du réseau.
- **Perturbations électromagnétiques** : Les perturbations électromagnétiques telles que les surtensions transitoires, les surintensités et les interférences électromagnétiques peuvent se propager dans le réseau HVDC. Elles peuvent être causées par des décharges atmosphériques, des défauts d'équipement ou des interactions avec d'autres systèmes.
- **Problèmes de commutation** : La commutation des convertisseurs HVDC peut générer des transitoires électriques qui peuvent causer des problèmes de qualité de l'énergie tels que des variations de tension ou de fréquence. Une mauvaise commutation peut également provoquer des perturbations dans le réseau électrique connecté.
- **Problèmes de contrôle et de protection** : Les systèmes de contrôle et de protection du réseau HVDC peuvent présenter des défauts qui peuvent affecter la stabilité et la sécurité du système. Des erreurs de réglage des paramètres de contrôle ou des défaillances des dispositifs de protection peuvent entraîner des dysfonctionnements du réseau.

Il est important de noter que ces défauts ne sont pas spécifiques au réseau HVDC mais peuvent également se produire dans d'autres systèmes de transmission d'électricité. Les exploitants de réseaux HVDC mettent en œuvre des stratégies de maintenance préventive et des systèmes de surveillance avancés pour minimiser ces défauts et garantir la fiabilité du réseau. Les techniques de diagnostic avancées telles que la localisation des défauts et l'analyse des formes d'onde sont également utilisées pour identifier et réparer les défauts

plus efficacement.

Les défauts liés aux câbles sous-marins peuvent présenter divers problèmes et défis. Voici quelques-uns des aspects importants à considérer :

- **Rupture du Câble** : La rupture d'un câble sous-marin peut être causée par des facteurs tels que des chocs mécaniques, des activités humaines (par exemple, ancrage de navires) ou des conditions environnementales extrêmes. Une rupture de câble peut entraîner une interruption de la transmission d'énergie ou de données.
- **Courts-Circuits** : Des courts-circuits peuvent se produire en raison de la pénétration d'eau dans le câble entraînant des fuites de courant entre les conducteurs. Ces courts-circuits peuvent entraîner des surintensités et des risques de dommages aux équipements.
- **Défauts Diélectriques** : Les câbles sous-marins sont soumis à des conditions environnementales sévères, ce qui peut entraîner des défauts diélectriques. Ces défauts peuvent entraîner une diminution de l'isolation électrique entre les conducteurs et le revêtement, augmentant ainsi le risque de fuites de courant.
- **Corrosion** : Les conditions marines peuvent favoriser la corrosion des câbles sous-marins. La corrosion peut affaiblir la structure du câble et potentiellement conduire à des défauts mécaniques.
- **Défauts d'Isolation** : Les défauts d'isolation peuvent se produire en raison de la dégradation des matériaux d'isolation sous l'effet de l'eau de mer, des pressions élevées ou d'autres facteurs environnementaux. Ces défauts peuvent entraîner des fuites de courant et des problèmes de continuité.
- **Interférences Électromagnétiques** : Les câbles sous-marins peuvent être sensibles aux interférences électromagnétiques provenant d'autres équipements électriques ou de sources externes. Cela peut perturber les signaux transmis à travers les câbles.
- **Maintenance Difficile** : La maintenance des câbles sous-marins peut être coûteuse et complexe en raison de la difficulté d'accès aux emplacements sous-marins. La détection et la localisation des défauts peuvent nécessiter des équipements spécialisés.

Lors de la conception et de la mise en œuvre de câbles sous-marins, il est essentiel de prendre en compte ces différents types de défauts et de mettre en place des mesures de prévention, de surveillance et de réparation appropriées pour assurer la fiabilité et la durabilité du système.

3.11.1 Défauts de circuit ouvert

Un circuit ouvert dans un réseau électrique se produit lorsqu'il y a une interruption ou une discontinuité dans le chemin de circulation du courant électrique. Cela peut se produire pour diverses raisons et entraîne l'arrêt de la circulation du courant dans ce circuit spécifique. Voici quelques-uns des défauts courants de circuit ouvert dans les réseaux électriques :

- **Câbles ou fils endommagés** : Des dommages physiques tels que des coupures, des ruptures ou des connexions desserrées peuvent entraîner un circuit ouvert. Cela peut se produire en raison d'une mauvaise installation, d'une usure, de l'exposition aux intempéries ou de tout autre facteur pouvant endommager les câbles électriques.
- **Fusibles grillés** : Un fusible est un dispositif de protection utilisé dans les circuits électriques pour limiter le courant. Lorsqu'un courant excessif circule dans le circuit, le fusible se rompt pour interrompre le circuit. Si le fusible est grillé, cela

crée un circuit ouvert empêchant la circulation du courant.

- **Disjoncteurs déclenchés** : Les disjoncteurs sont des dispositifs de protection similaires aux fusibles, mais ils peuvent être réarmés manuellement. Lorsqu'un courant excessif est détecté, le disjoncteur se déclenche pour interrompre le circuit. Si le disjoncteur n'est pas réarmé après le déclenchement, le circuit reste ouvert.
- **Interrupteurs ou relais défectueux** : Les interrupteurs et les relais sont des dispositifs électromécaniques utilisés pour ouvrir ou fermer des circuits électriques. S'ils sont défectueux ou ne fonctionnent pas correctement, ils peuvent entraîner un circuit ouvert.
- **Problèmes de connexion** : Des connexions lâches ou mal faites dans les prises de courant, les interrupteurs, les boîtes de jonction ou les bornes peuvent provoquer un circuit ouvert. Une connexion défectueuse interrompt la circulation du courant.

Lorsqu'un circuit ouvert se produit, il est généralement nécessaire d'identifier la cause sous-jacente du problème et de réparer ou de remplacer les composants défectueux pour rétablir la continuité du circuit. Toutefois, malgré les solutions actuellement disponibles, il existe encore des possibilités d'amélioration, ce qui justifie la poursuite d'études visant à renforcer les solutions existantes. Une approche prometteuse consisterait à intégrer des solutions basées sur l'intelligence artificielle capables de détecter rapidement les défauts, d'identifier leur nature et de fournir une localisation précise facilitant ainsi leur élimination.

3.11.2 Défauts de court-circuit

Un court-circuit dans un réseau électrique se produit lorsqu'une connexion directe, généralement accidentelle, est établie entre deux conducteurs de potentiel électrique différent, ce qui entraîne une augmentation significative du courant électrique. Cela peut causer des dommages importants aux équipements électriques, des interruptions de courant voire des risques d'incendie. Voici quelques-uns des principaux défauts de court-circuit dans les réseaux électriques :

- **Court-circuit monophasé** : Il se produit lorsque deux conducteurs de phase différents ou un conducteur de phase et un conducteur neutre entrent en contact direct. Cela peut résulter d'un défaut d'isolation, d'une rupture de câble, d'un mauvais raccordement ou d'un contact accidentel avec un objet conducteur.
- **Court-circuit biphasé** : Il se produit lorsqu'une connexion directe est établie entre deux conducteurs de phase différents sans le conducteur neutre. Cela peut se produire lorsque des conducteurs sont endommagés et entrent en contact mutuel.
- **Court-circuit triphasé** : Il se produit lorsque les trois conducteurs de phase sont directement connectés ensemble, souvent en raison d'une défaillance de l'équipement électrique ou d'une erreur de câblage.
- **Court-circuit à la terre** : Il se produit lorsque l'un des conducteurs de phase entre en contact direct avec une masse conductrice telle que le sol ou une structure métallique. Cela peut être dû à une défaillance de l'isolation, à une mauvaise mise à la terre ou à des conditions environnementales défavorables.
- **Court-circuit interne** : Il se produit à l'intérieur d'un appareil ou d'un équipement électrique, souvent en raison d'une défaillance d'un composant interne tel qu'un transformateur, un moteur ou un disjoncteur.

Lorsqu'un court-circuit se produit, il peut provoquer une surcharge importante sur le réseau électrique, entraînant une augmentation rapide du courant électrique et une chute de tension. Cela peut endommager les équipements électriques connectés au réseau et

peut également provoquer des arcs électriques, des étincelles et des risques d'incendie. Pour éviter ces dangers, les réseaux électriques sont équipés de dispositifs de protection tels que des fusibles, des disjoncteurs et des relais de protection qui détectent les courts-circuits et interrompent rapidement le courant pour prévenir les dommages.

Depuis l'avènement des systèmes électriques, la détection des défauts est une préoccupation majeure pour les ingénieurs. La détection des défauts dans les réseaux électriques est une tâche essentielle pour garantir leur bon fonctionnement, leur sécurité et éviter les pannes. Non seulement elle joue un rôle essentiel dans le fonctionnement et le contrôle des réseaux électriques, mais une détection précise des défauts améliore également les performances opérationnelles et protège contre d'éventuelles situations indésirables. L'efficacité d'un mécanisme de détection est mesurée par sa précision et sa rapidité. En général, la détection des défauts est effectuée avant la classification et la localisation des défauts.

3.12 Classification des défauts

Les défauts survenant dans les lignes de transmission peuvent être catégorisés en divers types en fonction de leurs caractéristiques particulières. Les tensions et les courants transitoires exhibent des comportements distincts, ce qui offre la possibilité aux méthodes de classification des défauts de les identifier et de les classer avec précision. L'intelligence artificielle (IA) peut être utilisée pour la classification des défauts dans les réseaux électriques. Cette approche permet de détecter, d'analyser et de diagnostiquer rapidement les problèmes dans le réseau électrique, ce qui facilite la maintenance et la réparation. Voici quelques exemples de défauts courants dans les réseaux électriques et de la manière dont l'IA peut être utilisée pour les classer :

- **Court-circuit** : Un court-circuit se produit lorsqu'un chemin de faible résistance est créé entre deux points de tension différente. L'IA peut analyser les données de courant et de tension pour détecter les variations anormales, identifier les zones où se produit le court-circuit et classer le type de court-circuit (court-circuit monophasé, biphasé ou triphasé).
- **Défaut d'isolement** : Un défaut d'isolement se produit lorsque le matériau isolant entre les conducteurs électriques se détériore, ce qui peut entraîner des fuites de courant. L'IA peut analyser les variations de courant, de tension et les schémas de mise à la terre pour détecter les signes d'un défaut d'isolement et classer sa gravité (mineur, modéré, grave).
- **Défaut de ligne** : Un défaut de ligne se produit lorsqu'un conducteur se casse ou se déconnecte du réseau électrique. L'IA peut analyser les données de tension, de courant et les schémas de connexion pour détecter les variations anormales, localiser la zone du défaut et classer le type de défaut (rupture de ligne, déconnexion partielle).

Pour classer ces défauts, l'IA utilise généralement des techniques telles que l'apprentissage automatique, les réseaux de neurones artificiels et les algorithmes de classification. Elle est entraînée à partir de grandes quantités de données historiques contenant des exemples de défauts connus, ce qui lui permet d'apprendre à identifier et à classer les nouveaux défauts. Il convient de noter que l'IA peut être utilisée en combinaison avec d'autres méthodes traditionnelles de détection des défauts dans les réseaux électriques telles que les systèmes de protection basés sur des relais. L'IA apporte une valeur ajoutée en permettant une analyse plus rapide et plus précise des données, ce qui améliore la

détection et le diagnostic des défauts. De nombreux systèmes de classification reposent sur des modèles dérivés de la théorie de l'apprentissage statistique, tandis que d'autres approches exploitent des méthodes intelligentes qui font appel à l'expérience et aux données recueillies. Il est important de noter que les progrès réalisés dans ce domaine ont été essentiels pour le développement de la reconnaissance des motifs et de l'apprentissage automatique (machine learning), en particulier pour les algorithmes d'apprentissage supervisé utilisés dans la classification.

3.12.1 Apprentissage supervisé

L'apprentissage supervisé est une technique d'apprentissage automatique (machine learning) dans laquelle un modèle est entraîné à partir de données étiquetées. L'objectif de l'apprentissage supervisé est de permettre au modèle d'apprendre une fonction de correspondance entre les entrées et les sorties attendues en se basant sur un ensemble d'exemples d'apprentissage préalablement étiquetés. Dans ce type d'apprentissage, les données d'entraînement sont constituées de paires d'entrées et de sorties correspondantes appelées exemples d'apprentissage. Le modèle est ensuite entraîné à partir de ces exemples pour prédire les sorties attendues pour de nouvelles données non étiquetées. Il ajuste ses paramètres internes en fonction des erreurs commises lors des prédictions afin de minimiser l'écart entre les sorties prédites et les sorties attendues. L'apprentissage supervisé peut être utilisé pour résoudre une variété de tâches telles que la classification (prédire une classe ou une catégorie), la régression (prédire une valeur numérique) ou d'autres tâches plus avancées comme la détection d'anomalies ou la traduction automatique. Les algorithmes d'apprentissage supervisé couramment utilisés incluent les arbres de décision, les réseaux de neurones, les machines à vecteurs de support (SVM) et les méthodes basées sur les voisins les plus proches (k-plus proches voisins, k-NN).

3.12.2 Classification

La classification est une tâche d'apprentissage automatique qui consiste à attribuer une classe ou une catégorie prédéfinie à un objet ou à une instance donnée sur la base de ses caractéristiques ou de ses attributs. L'objectif de la classification est de construire un modèle prédictif à partir d'un ensemble de données d'entraînement étiquetées afin de pouvoir prédire la classe d'étiquette correcte pour de nouvelles données non étiquetées. Dans le processus de classification, les données d'entraînement sont utilisées pour apprendre une fonction de correspondance entre les caractéristiques des instances et leurs classes associées. Le modèle généré peut ensuite être utilisé pour prédire la classe des nouvelles instances en fonction de leurs caractéristiques. Il existe différentes méthodes et algorithmes de classification tels que les arbres de décision, les forêts aléatoires, les machines à vecteurs de support (SVM), les réseaux de neurones, les classificateurs bayésiens, etc. Chaque algorithme a ses propres caractéristiques, avantages et limitations et peut être plus adapté à certains types de données ou à certaines problématiques spécifiques. La classification est largement utilisée dans de nombreux domaines tels que la reconnaissance d'images, la détection de spam, la classification de documents, la prédiction de maladies, la détection de fraudes, la segmentation de clients, etc. Elle permet de prendre des décisions automatiques basées sur des caractéristiques ou des patterns identifiés dans les données et peut être un outil puissant pour l'automatisation de diverses tâches.

3.12.3 Régression

La régression est une technique d'apprentissage automatique (machine learning) utilisée pour prédire une valeur numérique continue à partir d'un ensemble de variables d'entrée. Contrairement à la classification qui prédit une classe ou une catégorie, la régression vise à estimer une valeur numérique spécifique. Dans le processus de régression, on utilise des données d'entraînement qui comprennent des paires de valeurs d'entrée et de sortie correspondantes. Le modèle de régression est alors entraîné à partir de ces données pour apprendre la relation entre les variables d'entrée et la variable de sortie continue. L'objectif de la régression est de trouver une fonction ou un modèle mathématique qui représente au mieux cette relation. Une fois que le modèle est entraîné, il peut être utilisé pour prédire la valeur de sortie pour de nouvelles données d'entrée. Il existe différents algorithmes de régression tels que la régression linéaire, la régression polynomiale, la régression logistique, la régression par les moindres carrés, etc. Chaque algorithme a ses propres caractéristiques et peut être plus adapté à certains types de données ou à certains problèmes spécifiques. Elle permet d'estimer des valeurs numériques à partir de données d'entrée et peut être utilisée pour prendre des décisions, effectuer des prévisions ou comprendre les relations entre les variables.

3.12.4 Apprentissage non supervisé

L'apprentissage non supervisé est une branche de l'apprentissage automatique qui vise à découvrir des modèles, des structures ou des relations dans les données sans l'aide d'étiquettes ou de réponses préexistantes. Contrairement à l'apprentissage supervisé, où un modèle est formé à l'aide de données étiquetées, l'apprentissage non supervisé explore les données pour trouver des motifs ou des clusters sans aucune information de sortie cible. L'un des principaux objectifs de l'apprentissage non supervisé est la segmentation des données. Cela peut être réalisé par différentes techniques telles que la classification non supervisée, la réduction de dimension et l'analyse de clustering. La classification non supervisée, également appelée clustering, regroupe les données similaires en clusters ou en groupes. Les algorithmes de clustering recherchent des similarités ou des motifs dans les données pour former des groupes cohérents. Les méthodes couramment utilisées incluent le k-means, le clustering hiérarchique, le clustering spectral, etc. La réduction de dimension est une autre technique importante de l'apprentissage non supervisé. Elle vise à réduire la dimensionnalité des données en extrayant les caractéristiques les plus significatives. Cela facilite la visualisation et la compréhension des données ainsi que l'amélioration des performances des modèles d'apprentissage automatique. Des méthodes telles que l'analyse en composantes principales (PCA) et la réduction des dimensions par des auto-encodeurs sont couramment utilisées pour la réduction de dimension. L'apprentissage non supervisé est largement utilisé dans de nombreux domaines, notamment l'exploration de données, la détection d'anomalies, la recommandation de contenu, la segmentation du marché, l'analyse de texte et bien d'autres. Il permet de découvrir des informations cachées et des structures sous-jacentes dans les données sans avoir besoin d'une supervision explicite. Il convient de noter que bien que l'apprentissage non supervisé soit très utile, il peut également être plus difficile à évaluer que l'apprentissage supervisé. Étant donné l'absence d'étiquettes de sortie, il est souvent nécessaire d'utiliser des mesures de qualité intrinsèque ou de faire appel à l'expertise humaine pour évaluer la pertinence des résultats obtenus.

3.13 Système de surveillance d'état de système HVDC

Un système de surveillance d'état pour un système HVDC (High Voltage Direct Current) est conçu pour collecter, surveiller et analyser les données liées au fonctionnement et à la performance du système HVDC. Il vise à assurer un fonctionnement sûr et fiable du système en détectant les problèmes potentiels et en fournissant des informations essentielles pour la maintenance préventive et corrective. Voici quelques éléments clés généralement inclus dans un système de surveillance d'état pour un système HVDC [127]




FIGURE 3.4 – Technologies de surveillance pour les lignes de transmission HVDC [127]

- **Acquisition de données :** Le système est équipé de capteurs et de dispositifs de mesure qui collectent des données sur divers paramètres du système HVDC tels que les tensions, les courants, les températures, les vibrations, les décharges partielles et le phénomène de corona. Ces données sont généralement collectées en temps réel [127].
- **Système de gestion des données :** Les données collectées sont stockées dans une base de données centralisée qui permet leur archivage et leur accès ultérieur. Des systèmes de gestion des données avancés peuvent être utilisés pour organiser et traiter les données, les visualiser sous forme de graphiques, de tableaux de bord et de rapports, et faciliter l'analyse des tendances et des performances à long terme.
- **Analyse avancée :** Les systèmes de surveillance d'état peuvent également intégrer des techniques d'analyse avancée telles que l'apprentissage automatique (machine learning) et l'intelligence artificielle (IA) pour détecter les modèles cachés, prédire les défaillances potentielles et recommander des actions de maintenance appropriées.
- **Intégration du système de contrôle :** Le système de surveillance d'état peut être intégré au système de contrôle global du système HVDC. Cela permet une surveillance en temps réel étroite et une interaction entre les deux systèmes pour une prise de décision rapide et précise.

- **Alarmes et notifications** : En cas de conditions anormales ou de défaillances détectées, le système de surveillance d'état peut générer des alarmes et des notifications pour alerter les opérateurs et le personnel de maintenance. Cela permet une intervention rapide pour résoudre les problèmes avant qu'ils ne deviennent critiques.

3.14 Technologies de mesure pour la surveillance des tensions, du champ électrique et de la charge dans les lignes HVDC

Les mesures électriques permettent de détecter des défauts tels que des court-circuit, des surcharges, des déséquilibres de tension ou de courant. Des appareils de mesure tels que Les capteurs optiques et les dispositifs de mesure de tension basés sur la résistance et la capacité jouent un rôle crucial dans les systèmes de surveillance des réseaux HVDC (High Voltage Direct Current). Les capteurs optiques offrent une solution sans contact et isolée, idéale pour les environnements à haute tension, car ils mesurent les paramètres électriques (comme le courant et la tension) en utilisant des signaux lumineux, éliminant ainsi les risques d'interférences électromagnétiques et de court-circuit. Cette technologie permet également une grande précision et une surveillance en temps réel, essentielle pour la protection et l'optimisation des systèmes HVDC.

En parallèle, les diviseurs de tensions et de courants utilisant des principes de résistance et de capacité sont couramment utilisés pour mesurer la tension dans ces systèmes., et offrent des mesures fiables même dans des conditions de forte tension. Ils permettent de détecter les anomalies de tension, contribuant ainsi à la protection du système en fournissant des données essentielles pour l'alarme et le contrôle de la qualité de l'énergie.

La comparaison des capteurs de tension existants met en lumière plusieurs types de dispositifs, chacun ayant ses caractéristiques et limitations. Le transformateur de potentiel fonctionne par induction électromagnétique et est utilisé pour mesurer les tensions alternatives (AC). Cependant, il présente des limitations : il est invasif, ce qui implique des dangers liés à la haute tension et rend son installation difficile, son coût est élevé en raison des exigences de conception de l'isolation, et il ne peut pas être utilisé pour les réseaux à courant continu (DC).

Le capteur de tension Hall, quant à lui, mesure à la fois l'AC et le DC en utilisant l'effet Hall et un principe de compensation magnétique. Ses inconvénients incluent également son caractère invasif et son coût élevé, lié à l'utilisation de résistances haute tension et à la conception de l'isolation.

En ce qui concerne le capteur de tension à fibre optique, qui utilise l'effet Pockels, il est capable de mesurer les deux types de courant (AC et DC) mais nécessite des émetteurs de lumière et des composants optiques, ce qui en fait un dispositif coûteux.

La sonde de tension AC, qui repose sur l'annulation du courant couplé capacitif, est également conçue pour mesurer l'AC uniquement. Ses limitations incluent un coût élevé en raison de la nécessité d'un générateur de tension intégré pour équilibrer le courant, et elle ne fonctionne pas pour les réseaux DC. Enfin, le capteur de tension à couplage capacitif mesure à la fois l'AC et le DC en utilisant un diviseur capacitif, mais son utilisation est

limitée aux conducteurs monophasés.

Des appareils de mesure tels que les capteurs optiques et les dispositifs de mesure de tension basés sur la résistance et la capacité jouent un rôle crucial dans les systèmes de surveillance des réseaux HVDC (High Voltage Direct Current). Les **capteurs optiques** offrent une solution sans contact et isolée, idéale pour les environnements à haute tension : ils mesurent les paramètres électriques (comme le courant et la tension) en utilisant des signaux lumineux, éliminant ainsi les risques d'interférences électromagnétiques et de court-circuit. Cette technologie permet également une grande précision et une surveillance en temps réel, essentielle pour la protection et l'optimisation des systèmes HVDC.

Plus récemment, une technique innovante basée sur un *couplage électrique sans contact*, assistée par la détection du champ magnétique, a été proposée. Elle repose sur l'utilisation de barres de couplage en cuivre et de capteurs magnétorésistifs pour reconstruire la tension de ligne HVDC sans contact direct, tout en maintenant un faible coût et une haute précision [128].

En complément de ces solutions, une architecture de réseau de capteurs sans fil (WSN) avec capteur opto-électrique a été développée pour mesurer le champ électrique total sous les lignes HVDC via communication Zigbee, offrant une grande précision, flexibilité et stabilité [129].

Enfin, une extension remarquable de ce WSN permet de gérer efficacement la mesure de charge de ligne en HVDC. Ce système s'appuie sur une gestion d'énergie optimisée pour les capteurs sans fil, assurant une surveillance continue et fiable de la charge des lignes ultra-haute tension [130].

Parallèlement, les **diviseurs de tensions et de courants** utilisant des principes résistifs et capacitifs sont largement utilisés pour mesurer la tension dans ces systèmes. Ils offrent des mesures fiables même sous forte tension, permettant de détecter les anomalies de tension et contribuant à la protection du système via des données essentielles pour les alarmes et la qualité de l'énergie.

L'intégration de capteurs en ligne, d'analyseurs de puissance et d'enregistreurs SCADA permet, dans un système HVDC, d'assurer une surveillance continue, une détection rapide des anomalies et une maintenance préventive efficace. Les mesures collectées sont comparées à des seuils prédéfinis pour identifier les défauts éventuels.

Pour détecter des anomalies plus subtiles, des méthodes avancées telles que l'analyse de la signature fréquentielle, l'analyse harmonique, la transformée de Fourier ou la transformée en ondelettes peuvent être utilisées. Ces techniques permettent de distinguer les défauts des variations normales du réseau.

Les systèmes de surveillance en ligne, associés à des dispositifs de communication en temps réel, signalent automatiquement les anomalies et peuvent anticiper les défauts à partir de l'analyse des données historiques. En combinant ces approches, le système HVDC bénéficie d'un fonctionnement sûr, fiable et optimisé, à condition que l'analyse soit menée par des professionnels qualifiés.

3.15 Conclusion

La détection et la localisation des défauts dans les systèmes HVDC sont des domaines de recherche dynamiques et en évolution rapide. Les méthodes traditionnelles et modernes offrent chacune des avantages uniques et une combinaison de ces techniques pourrait fournir des solutions robustes pour les réseaux HVDC de demain. Une analyse approfondie de la littérature révèle une tendance vers l'intégration des technologies avancées de traitement de signal et d'intelligence artificielle pour surmonter les défis posés par la complexité croissante des réseaux de transmission d'électricité. Dans ce prolongement, le chapitre suivant explore la problématique de la classification des défauts dans les systèmes HVDC VSC à l'aide d'approches basées sur le machine learning. L'objectif est d'identifier des modèles intelligents capables de distinguer efficacement les types de défauts, même dans des conditions de fonctionnement complexes et variées

Chapitre 4

Classification des Défauts dans les Systèmes HVDC VSC par la machine learning

4.1 Introduction

Les systèmes de transmission à courant continu haute tension (HVDC) à source de tension (VSC) jouent un rôle crucial dans le transport efficace et fiable de l'électricité sur de longues distances. Malgré leurs nombreux avantages, ces systèmes sont sujets à divers types de défauts qui peuvent compromettre leur performance et leur fiabilité. La détection, la classification et la localisation rapide et précise de ces défauts sont donc essentielles pour maintenir la stabilité du réseau électrique. L'évolution des technologies de machine learning offre des outils puissants pour l'analyse et l'interprétation des données de système HVDC. En exploitant des algorithmes de machine learning, il est possible de développer des modèles capables d'identifier et de classer les défauts en se basant sur des patterns observés dans les données de fonctionnement. Ces modèles peuvent apprendre à partir de données historiques et fournir des prédictions précises sur la présence et la nature des défauts.

Ce chapitre explore l'application des méthodes de machine learning pour la classification et la localisation des défauts dans les systèmes VSC HVDC. Nous examinerons les principes fondamentaux de ces approches, leur mise en œuvre pratique, et discuterons des résultats obtenus et de leur impact potentiel sur la fiabilité et l'efficacité des systèmes HVDC. En intégrant ces méthodes avancées, nous visons à développer des solutions innovantes pour améliorer la détection et la gestion des défauts dans les réseaux électriques modernes.

4.2 L'apprentissage automatique

L'apprentissage automatique est un domaine de l'informatique qui donne aux ordinateurs la capacité d'apprendre sans être explicitement programmés. L'apprentissage automatique explore l'étude et la construction d'algorithmes capables d'apprendre à partir de données et de faire des prédictions. Ces algorithmes fonctionnent en construisant un modèle à partir d'exemples d'entrées afin de faire des prédictions ou des décisions basées sur les données

plutôt que de suivre des instructions de programme statiques. Certaines des capacités clés de l'apprentissage automatique comprennent :

- Classification : Attribuer des catégories à des points de données, par exemple, courrier électronique indésirable contre courrier électronique non indésirable.
- Régression : Prédire des valeurs continues, par exemple, prédire les prix des maisons.
- Regroupement : Trouver des regroupements inhérents dans les données, par exemple, la segmentation de la clientèle.
- Réduction de la dimensionnalité : Réduire le nombre de variables prises en considération, par exemple, l'analyse en composantes principales.
- Détection d'anomalies : Découvrir des points de données anormaux ou des motifs inhabituels.
- Optimisation : Trouver la solution optimale à un problème, par exemple, l'allocation de ressources.

L'apprentissage automatique s'est généralisé dans de nombreuses applications telles que la vision par ordinateur, le traitement du langage naturel, la reconnaissance vocale et plus encore. Ce chapitre fournit un aperçu des concepts clés, des approches et des algorithmes en apprentissage automatique.

4.2.1 Types d'apprentissage automatique

Il existe trois principaux types d'apprentissage automatique :

- Apprentissage supervisé
- Apprentissage non supervisé
- Apprentissage par renforcement

Dans l'apprentissage supervisé, l'algorithme est entraîné à l'aide de données d'exemple étiquetées. Les étiquettes fournissent les sorties désirées permettant ainsi à l'algorithme d'apprendre la correspondance entre les entrées et les sorties. La classification et la régression sont des tâches d'apprentissage supervisé. Des algorithmes tels que la régression linéaire, la régression logistique et les machines à vecteurs de support sont utilisés pour l'apprentissage supervisé.

Dans l'apprentissage non supervisé, l'algorithme est alimenté avec des données non étiquetées. Il explore les données pour trouver des motifs et des relations cachées. Le regroupement est une technique courante d'apprentissage non supervisé. Des algorithmes comme le regroupement k-means et le regroupement hiérarchique sont utilisés.

L'apprentissage par renforcement implique qu'un agent interagisse avec son environnement pour apprendre un comportement optimal. L'agent reçoit des récompenses ou des pénalités pour les actions qu'il effectue. Il cherche à maximiser la récompense cumulative par essais et erreurs. Les problèmes d'apprentissage par renforcement sont généralement modélisés comme des processus de décision de Markov. Des algorithmes comme le Q-learning sont utilisés.

4.2.2 Processus d'apprentissage automatique

Le flux de travail typique de l'apprentissage automatique implique les étapes suivantes :

1. Définir le problème et collecter les données
2. Préparer les données
3. Choisir un modèle
4. Entraîner le modèle
5. Évaluer la performance du modèle
6. Ajuster les paramètres et optimiser
7. Faire des prédictions

Définir le problème implique de définir la tâche à accomplir (classification, régression, etc.) et de collecter des données pertinentes. Les données sont ensuite prétraitées, ce qui peut inclure le nettoyage, l'ingénierie des caractéristiques, la normalisation, et plus encore. Un modèle approprié est sélectionné et ses hyperparamètres sont configurés. Le modèle est entraîné sur les données en divisant généralement les données en ensembles d'entraînement et de test. La performance du modèle est évaluée sur l'ensemble de test en utilisant des métriques telles que l'exactitude, la RMSE, etc. Les hyperparamètres du modèle sont ajustés pour optimiser la performance. Enfin, le modèle entraîné peut être utilisé pour faire des prédictions sur de nouvelles données non étiquetées.

4.3 Algorithmes pour l'apprentissage automatique

De nombreux algorithmes sont utilisés pour les tâches d'apprentissage automatique. Nous passons brièvement en revue certains des algorithmes clés.

Régression linéaire

La régression linéaire est utilisée pour prédire des variables cibles continues. Elle ajuste un modèle linéaire aux données d'entraînement. Pour une entrée x et une cible y , un modèle de régression linéaire simple est :

$$y = wx + b \tag{4.1}$$

où w et b sont les paramètres du modèle appris. w représente les poids attribués à chaque variable d'entrée et b est le terme de biais ou d'interception. Les paramètres sont appris en minimisant l'erreur quadratique moyenne entre les valeurs cibles prédites et réelles sur l'ensemble d'entraînement. La régression linéaire fait l'hypothèse forte que la variable cible est linéairement liée aux entrées.

Régression logistique

La régression logistique est utilisée pour les problèmes de classification binaire. Elle modélise la probabilité de la classe positive :

$$P(y = 1 | x) = \sigma(wx + b) \tag{4.2}$$

où σ est la fonction sigmoïde qui transforme le modèle linéaire en probabilités. La perte d'entropie croisée est minimisée pour apprendre les paramètres du modèle. La régression logistique suppose une séparabilité linéaire et est sujette au surajustement.

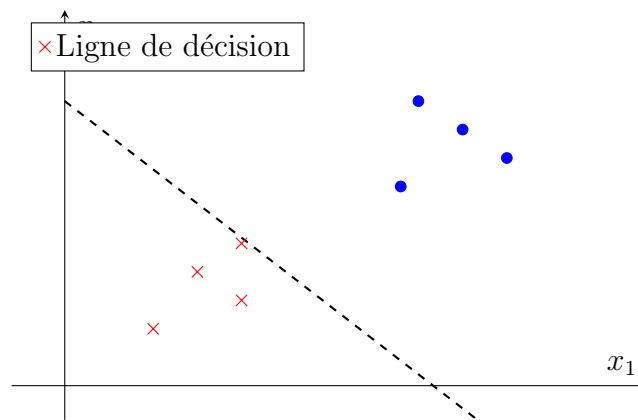


FIGURE 4.1 – Illustration de la régression logistique : séparation entre deux classes par une ligne de décision (sigmoïde).

Arbres de décision

Les arbres de décision sont des modèles qui utilisent une approche de type "si-alors" pour la classification. Ils divisent l'espace des caractéristiques en sous-ensembles plus petits et homogènes en fonction des attributs des données. Ces arbres peuvent être utilisés pour la classification binaire ou multiclass. Ils effectuent plusieurs divisions hiérarchiques des données pour classifier ou régresser. Chaque nœud interne divise les données selon une caractéristique spécifique tandis que les nœuds terminaux (feuilles) réalisent les prédictions. Ces modèles sont interprétables et capables de capturer des relations non linéaires. Les techniques d'ensemble telles que les forêts aléatoires améliorent les performances en combinant plusieurs arbres de décision.

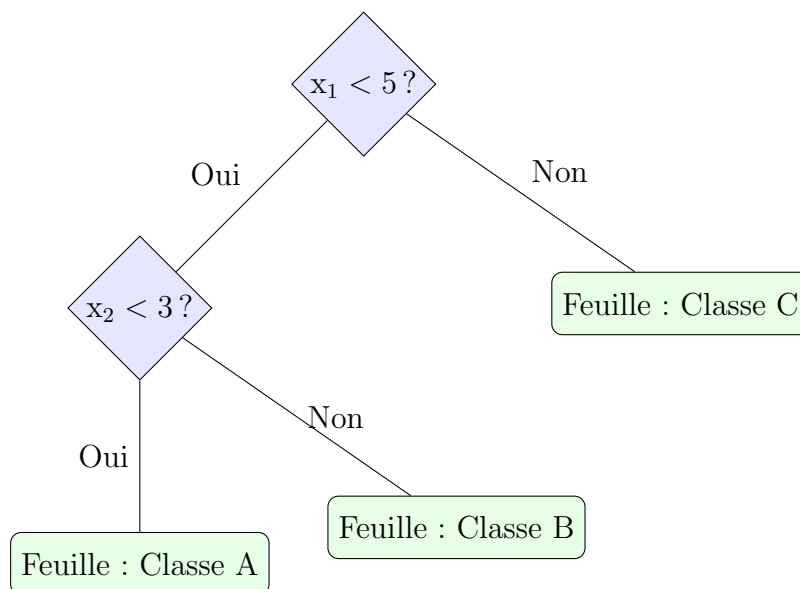


FIGURE 4.2 – Exemple d'un arbre de décision illustrant les nœuds et les feuilles de classification.

4.3.1 Machines à Vecteurs de Support (SVM)

Les machines à vecteurs de support (SVM) sont un type d'algorithme d'apprentissage automatique supervisé utilisé pour des tâches de classification et de régression. L'idée de base derrière les SVM est de trouver un hyperplan dans un espace de grande dimension qui sépare les points de données en différentes classes avec la marge maximale.

Les équations pour les SVM peuvent être exprimées comme suit :

$$f(x) = w \cdot x + b \quad (4.3)$$

où $f(x)$ est la fonction de décision, w est le vecteur de poids, x est le vecteur de caractéristiques en entrée, et b est le terme de biais.

Règle de classification :

- Si $f(x) \geq 0$, alors l'échantillon appartient à une classe.
- Si $f(x) < 0$, alors l'échantillon appartient à l'autre classe.

SVM avec noyaux non linéaires : Dans de nombreux cas, la frontière de décision n'est pas une ligne droite. Les SVM peuvent traiter des frontières de décision non linéaires en utilisant des fonctions de noyau. La fonction de décision est modifiée pour inclure le noyau :

$$f(x) = \sum_{i=1}^N \alpha_i \gamma_i K(x_i, x) + b \quad (4.4)$$

où α_i sont les multiplicateurs de Lagrange, γ_i est l'étiquette de classe de l'échantillon d'entraînement, x_i est le vecteur de caractéristiques d'échantillon d'entraînement, et $K(x_i, x)$ est la fonction de noyau.

Les fonctions de noyau courantes incluent :

- Noyau linéaire :

$$K(x_i, x) = x_i \cdot x \quad (4.5)$$

- Noyau polynomial :

$$K(x_i, x) = (x_i \cdot x + c)^d \quad (4.6)$$

- Fonction de base radiale (RBF) ou noyau gaussien :

$$K(x_i, x) = \exp\left(-\frac{\|x_i - x\|^2}{2\sigma^2}\right) \quad (4.7)$$

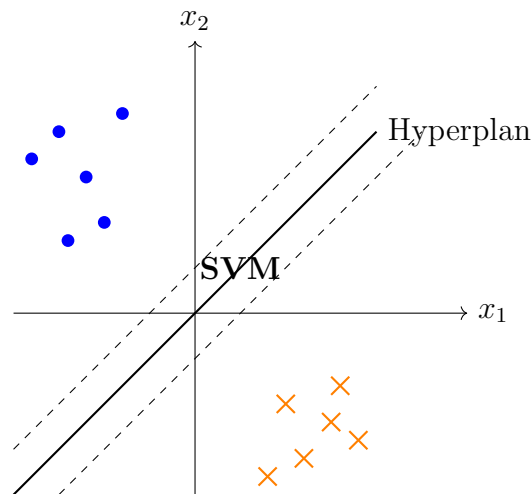


FIGURE 4.3 – Illustration du principe de séparation par SVM : l'hyperplan maximal sépare deux classes de données avec une marge maximale.

4.3.2 Réseaux de Neurones

Les réseaux de neurones artificiels sont des modèles inspirés du fonctionnement du cerveau humain, constitués de neurones interconnectés disposés en couches. Chaque neurone applique une fonction d'activation à ses entrées pondérées et transmet le résultat à la couche suivante. Cet empilement de transformations non linéaires confère aux modèles d'apprentissage en profondeur un immense pouvoir de représentation. Les réseaux de neurones sont capables d'apprendre des fonctions très complexes directement à partir de données brutes telles que des images, des vidéos, du son et du texte. Les réseaux neuronaux profonds, également appelés réseaux de neurones profonds, contiennent plusieurs couches cachées et peuvent être utilisés pour des tâches de classification et bien d'autres applications.

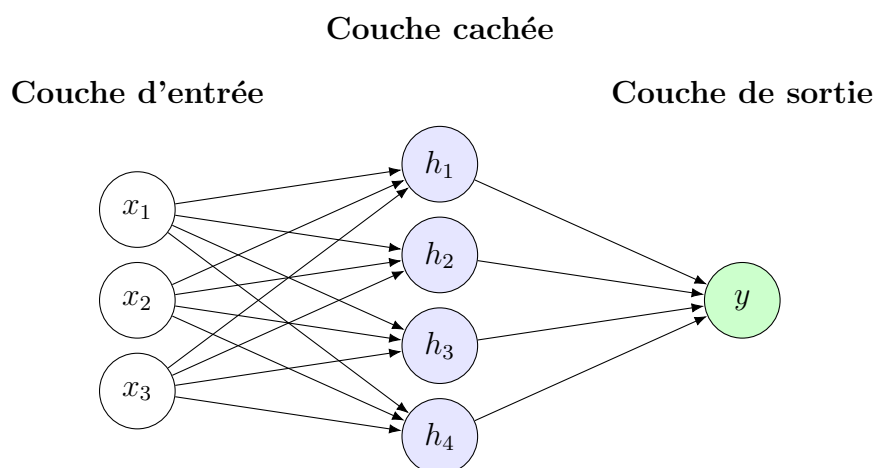


FIGURE 4.4 – Architecture d'un réseau de neurones artificiels (ANN) à une couche cachée.

Les Réseaux de Neurones Artificiels (ANN) peuvent être utilisés pour la localisation des défauts dans les lignes de transmission en exploitant leur capacité à apprendre des motifs et des relations complexes à partir des données.

Fonction d'activation

Une fonction d'activation introduit de la non-linéarité dans le modèle. Les choix courants incluent les fonctions sigmoïdes, tangente hyperbolique (\tanh) ou unité linéaire rectifiée (ReLU).

$$a_i^{(l)} = \text{Activation} \left(\sum_{i=1}^{N^{(l-1)}} w_{ij}^{(l)} \cdot a_i^{(l-1)} + b_j^{(l)} \right) \quad (4.8)$$

Couche de Sortie

La couche de sortie produit les prédictions finales. Pour une classification binaire, vous pourriez utiliser une fonction d'activation sigmoïde ; pour une classification multi-classe, une fonction d'activation softmax est courante.

$$\hat{y} = \text{output} \left(\sum_{i=1}^{N^{(l-1)}} w_{ij}^{(l)} \cdot a_i^{(l-1)} + b_j^{(l)} \right) \quad (4.9)$$

Entrées

x_i , avec $i = 1, 2, \dots, n$

Poids et Biases

- **Poids (Weights)** : Soient w_{ij} les poids associés aux connexions entre les neurones d'entrée (i) et les neurones de la couche cachée (j).
- **Biais (Biases)** : Soient b_j les biais associés aux neurones de la couche cachée (j).

$w_{ij}^{(l)}$ représente le poids provenant du nœud i dans la couche $(l-1)$ au nœud j dans la couche l

$b_j^{(l)}$ représente le biais pour le nœud j dans la couche l

La fonction de perte (Loss Function)

La fonction de perte mesure la différence entre la sortie prédite \hat{y} et les vraies étiquettes (y).

$$\text{Loss} = \text{Loss function}(\hat{y}, y) \quad (4.10)$$

Dans le cadre d'un réseau de neurones artificiels (ANN), la **fonction de perte** (Loss function) mesure l'erreur entre les prédictions du modèle (notées \hat{y}) et les vraies valeurs attendues (notées y). Elle est utilisée pour évaluer dans quelle mesure le modèle se trompe dans ses prédictions et constitue un indicateur essentiel à minimiser pour améliorer la performance du réseau.

Voici comment cela se décompose :

- \hat{y} : La prédiction faite par le réseau de neurones pour un exemple donné. Cela peut être une probabilité (dans le cas d'une classification) ou une valeur numérique (dans le cas d'une régression).
- y : La valeur réelle ou la "vérité terrain" associée à cet exemple.

Elle quantifie l'écart entre la prédiction et la réalité. Voici quelques exemples courants de fonctions de perte dans les ANN :

- **MSE (Mean Squared Error)** – utilisée pour les problèmes de régression :

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2$$

où n est le nombre d'exemples, \hat{y}_i est la prédiction pour l'exemple i , et y_i est la vraie valeur.

L'objectif de l'ANN est de minimiser la fonction de perte au cours de l'entraînement, ce qui est généralement fait en ajustant les poids du réseau à l'aide de techniques d'optimisation comme la descente de gradient et Levenberg-Marquardt.

Entrées

x_i , avec $i = 1, 2, \dots, n$

Poids et Biases

Regroupement K-means

K-means est un algorithme simple de regroupement non supervisé. Il partitionne les points de données en k groupes où chaque point appartient au groupe avec la moyenne la plus proche. K-means initialise aléatoirement les centres de groupe, puis met à jour itérativement les groupes en attribuant les points à leur centre le plus proche et recalcule les centroïdes. Il est scalable mais sensible à l'initialisation et aux valeurs aberrantes.

Méthodes de voisinage le plus proche (kNN)

Les méthodes kNN (k-Nearest Neighbors) attribuent une classe à un nouvel exemple en se basant sur les classes des exemples les plus proches dans l'espace des caractéristiques. L'algorithme kNN dépend du nombre k de voisins les plus proches à considérer.

Le calcul de la distance peut être effectué à l'aide de différentes méthodes : Euclidienne, Chebyshev, Minkowski (cubique), Mahalanobis, Cosinus, Corrélacion, Spearman, Hamming et Jaccard. L'algorithme k-NN est simple à mettre en œuvre et fonctionne efficacement avec des données bruitées et volumineuses, mais il dépend de la sélection appropriée de la valeur k (le nombre de voisins les plus proches), ce qui entraîne des coûts de calcul élevés.

Ce ne sont que quelques-uns des algorithmes utilisés en apprentissage automatique. De nombreuses autres techniques comme le Naïf Bayes, le KNN, l'ACP, les

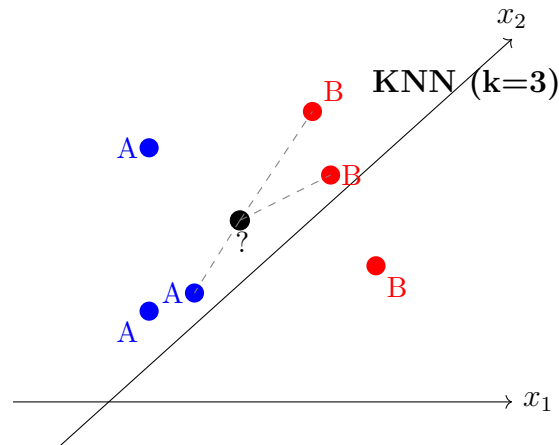


FIGURE 4.5 – Illustration du principe du classificateur K plus proches voisins (KNN). Le point inconnu est classé selon les 3 voisins les plus proches.

algorithmes d'apprentissage par renforcement et bien d'autres sont couramment appliquées. Le bon algorithme dépend du type de problème et des objectifs.

4.4 Définition de RPG

La Régression par Processus Gaussien (RPG) est une approche non paramétrique et bayésienne utilisée en apprentissage automatique pour les tâches de régression. Elle fournit un cadre probabiliste permettant de modéliser des relations complexes et non linéaires dans les données. Voici une vue d'ensemble de son fonctionnement :

4.5 Concepts Clés

- **Processus Gaussien (PG)** : Un processus gaussien est un ensemble de variables aléatoires dont toute sous-famille a une distribution conjointe gaussienne. Il peut être considéré comme une distribution sur des fonctions.
- **Fonction de noyau** : Un composant clé de la RPG est le noyau (ou fonction de covariance), qui définit la relation entre les points de données. Les noyaux populaires incluent le noyau à base radiale (RBF), les noyaux de Matérn, et les noyaux polynomiaux. Le choix du noyau détermine la régularité et d'autres propriétés de la fonction résultante.
- **Fonction de moyenne** : Par défaut, un processus gaussien suppose que la moyenne de la fonction est nulle. Cependant, une fonction de moyenne peut être ajoutée si nécessaire, en fonction des connaissances a priori sur les données.
- **Entraînement** : La RPG est entraînée en optimisant les hyperparamètres de la fonction de noyau. Cela se fait généralement en maximisant la log-vraisemblance marginale des données.
- **Prédictions** : Étant donné de nouvelles données en entrée, la RPG prédit la moyenne des valeurs cibles et fournit un intervalle de confiance (variance) autour de la prédiction. C'est un avantage clé par rapport aux méthodes de régression classiques, car la RPG offre une mesure d'incertitude.

4.6 Avantages

- **Quantification de l'incertitude** : Contrairement à de nombreux autres modèles de régression, la RPG fournit non seulement une prédiction, mais aussi une mesure d'incertitude (variance) autour de la prédiction.
- **Flexibilité** : Le choix de la fonction de noyau permet à la RPG de modéliser une grande variété de comportements dans les données (par exemple, des tendances lisses, périodiques ou linéaires).

La régression par processus gaussien (GPR) est une méthode non paramétrique d'apprentissage automatique utilisée pour la régression. Elle repose sur l'utilisation de processus gaussiens pour modéliser la fonction sous-jacente à partir des données.

4.7 Modèle Mathématique

Le GPR suppose que les valeurs de la fonction cible f pour un ensemble d'entrées $X = \{x_1, x_2, \dots, x_n\}$ sont distribuées selon un processus gaussien, ce qui peut être exprimé comme suit :

$$f(X) \sim \mathcal{N}(\mu(X), K(X, X)), \quad (4.11)$$

où :

- $f(X)$ est le vecteur des valeurs de la fonction à évaluer pour les points X ,
- $\mu(X)$ est la fonction moyenne, souvent supposée nulle : $\mu(X) = 0$,
- $K(X, X)$ est la matrice de covariance (ou noyau), définie par une fonction de covariance $k(x, x')$ qui mesure la similarité entre les points d'entrée x et x' .

Pour une nouvelle entrée x_* , le GPR prédit la distribution des valeurs cibles associées f_* comme suit :

$$\begin{pmatrix} f \\ f_* \end{pmatrix} \sim \mathcal{N} \left(\begin{pmatrix} \mu(X) \\ \mu(x_*) \end{pmatrix}, \begin{pmatrix} K(X, X) & K(X, x_*) \\ K(x_*, X) & K(x_*, x_*) \end{pmatrix} \right). \quad (4.12)$$

Ici, les éléments de la matrice de covariance sont définis par :

- $K(X, x_*)$ est le vecteur de covariance entre les points d'entraînement et le nouveau point x_* ,
- $K(x_*, X)$ est le vecteur de covariance entre le nouveau point x_* et les points d'entraînement,
- $K(x_*, x_*)$ est la variance du nouveau point x_* .

La prédiction du GPR pour le nouveau point x_* est donnée par :

$$f_* \sim \mathcal{N}(\mu_*, \sigma_*^2),$$

où μ_* et σ_*^2 sont respectivement la moyenne prédictive et la variance prédictive, calculées comme suit :

$$\mu_* = \mu(x_*) + K(x_*, X)K(X, X)^{-1}(f - \mu(X)), \quad (4.13)$$

$$\sigma_*^2 = K(x_*, x_*) - K(x_*, X)K(X, X)^{-1}K(X, x_*). \quad (4.14)$$

Le réglage des paramètres du noyau pour la Régression par Processus Gaussien (RPG) consiste à optimiser les hyperparamètres de la fonction de covariance (noyau), qui contrôle la flexibilité, la régularité, et d'autres propriétés du modèle. La méthode typique pour ajuster ces hyperparamètres est de maximiser la **log-vraisemblance marginale** des données.

4.8 Choix du Noyau

Le choix du noyau (ou fonction de covariance) est un aspect fondamental de la régression par processus gaussien (GPR). La fonction de noyau définit la relation entre les points de données et détermine la forme de la fonction que le modèle va apprendre. Voici quelques points clés concernant le choix du noyau :

4.8.1 Rôle du Noyau

- **Modélisation des Relations** : Le noyau capture la similarité entre les points de données. Il joue un rôle essentiel dans la manière dont le modèle apprend les relations sous-jacentes dans les données.
- **Smoothness** : Le choix du noyau influence la douceur de la fonction apprise. Par exemple, un noyau exponentiel peut produire des fonctions plus irrégulières, tandis qu'un noyau RBF (Radial Basis Function) tend à produire des fonctions plus lisses.

4.8.2 Types de Noyaux

Il existe plusieurs types de noyaux couramment utilisés en GPR :

- **Noyau RBF (Fonction de Base Radiale)** :

$$k(x, x') = \sigma^2 \exp\left(-\frac{\|x - x'\|^2}{2\ell^2}\right) \quad (4.15)$$

où σ^2 est la variance et ℓ est la longueur d'échelle. Ce noyau est très populaire en raison de sa capacité à modéliser des relations lisses.

- **Noyau Matérn** :

$$k(x, x') = \frac{2^{1-\nu}}{\Gamma(1-\nu)} \left(\frac{\sqrt{2\nu}\|x - x'\|}{\ell}\right)^\nu K_\nu\left(\frac{\sqrt{2\nu}\|x - x'\|}{\ell}\right) \quad (4.16)$$

où ν contrôle la douceur de la fonction apprise. Ce noyau est particulièrement utile lorsque des informations sur la régularité de la fonction sont disponibles.

- **Noyau Polynomiale** :

$$k(x, x') = (x^T x' + c)^d \quad (4.17)$$

où c est une constante et d est le degré du polynôme. Ce noyau est utilisé pour capturer des relations non linéaires entre les données.

4.8.3 Impact sur la Performance

- **Précision des Prédictions** : Le choix d'un noyau approprié peut considérablement améliorer la précision des prédictions. Un noyau mal choisi peut entraîner un sous-ajustement ou un sur-ajustement du modèle.
- **Complexité du Modèle** : Les noyaux plus complexes peuvent capturer des relations plus nuancées, mais ils peuvent aussi introduire plus de paramètres à optimiser, ce qui peut augmenter le temps de calcul et la complexité du modèle.

4.8.4 Optimisation des Hyperparamètres

- **Tuning** : Les noyaux possèdent souvent des hyperparamètres (comme σ^2 et ℓ pour le noyau RBF) qui doivent être optimisés. Cela se fait généralement par la maximisation de la vraisemblance marginale ou par des méthodes d'optimisation bayésienne.
- **Validation Croisée** : Une approche courante pour choisir le noyau et ses hyperparamètres consiste à utiliser la validation croisée pour évaluer la performance du modèle sur un ensemble de données de test.

4.9 Hyperparamètres du Noyau

La fonction de noyau $k(X, X')$ dépend d'un ensemble d'hyperparamètres θ . Par exemple, pour le noyau **Radial Basis Function (RBF)** (également appelé noyau exponentiel quadratique ou gaussien) :

Les hyperparamètres sont :

$$k(x, x') = \sigma^2 \exp\left(-\frac{\|x - x'\|^2}{2\ell^2}\right) \quad (4.15)$$

où :

- $k(x, x')$ est la valeur du noyau entre les points x et x' ,
- σ^2 est le terme de variance, qui contrôle l'échelle de la sortie,
- ℓ est la longueur d'échelle, qui contrôle la façon dont la similarité diminue avec la distance entre x et x' ,
- $\|x - x'\|$ est la norme Euclidienne entre les points x et x' .

4.10 Optimisation bayésienne

L'optimisation bayésienne (BO) repose sur un cadre mathématique bien défini qui combine l'apprentissage automatique et l'optimisation séquentielle pour trouver les minima d'une fonction coûteuse à évaluer. L'objectif de l'optimisation bayésienne est de minimiser une fonction inconnue $f : \mathcal{X} \rightarrow \mathbb{R}$, où \mathcal{X} est l'espace de recherche des paramètres. BO suit une approche séquentielle en modélisant f de manière probabiliste, généralement via un processus gaussien (GP), et utilise une fonction d'acquisition pour décider où effectuer la prochaine évaluation.

4.11 Concepts Principaux

- **Modèle Probabiliste** : Le processus gaussien (GP) est couramment utilisé pour modéliser la fonction objectif. Ce modèle fournit une estimation des valeurs de la fonction ainsi qu'une mesure de l'incertitude associée à cette estimation.
- **Fonction d'Acquisition** : Cette fonction décide du prochain point à évaluer en maximisant une métrique d'exploration et d'exploitation. Des fonctions d'acquisition populaires incluent l'amélioration espérée (Expected Improvement, EI) et la probabilité d'amélioration (Probability of Improvement, PI).

4.12 Étapes de l'Optimisation Bayésienne

1. **Initialisation** : Échantillonner quelques points de départ de la fonction objectif et créer un modèle probabiliste basé sur ces évaluations.
2. **Optimisation de la fonction d'acquisition** : Maximiser la fonction d'acquisition pour déterminer où évaluer ensuite la fonction objectif.
3. **Évaluation** : Évaluer la fonction objectif au point recommandé.
4. **Mise à jour du modèle** : Incorporer la nouvelle observation dans le modèle probabiliste.
5. **Répétition** : Répéter jusqu'à ce que l'optimum soit trouvé ou que les ressources disponibles soient épuisées.

4.13 Avantages

- **Efficacité** : L'optimisation bayésienne minimise le nombre d'évaluations nécessaires.
- **Exploration et Exploitation** : Elle équilibre entre explorer de nouvelles régions de l'espace de recherche et exploiter les régions déjà identifiées comme prometteuses.
- **Flexibilité** : Elle s'applique à des fonctions non convexes, bruitées, et sans formulation analytique.

4.14 Applications

Elle est couramment utilisée pour :

- Le réglage des hyperparamètres des modèles d'apprentissage automatique.
- L'optimisation de la conception en ingénierie.

4.15 Modélisation via un processus gaussien

Le processus gaussien $f(x) \sim \mathcal{GP}(\mu(x), k(x, x'))$ est une distribution sur les fonctions, définie par :

- une fonction moyenne $\mu(x)$, généralement initialisée à zéro : $\mu(x) = 0$,
- une fonction de covariance ou noyau $k(x, x')$, qui mesure la similarité entre deux points x et x' .

Pour un ensemble de points $\{x_1, x_2, \dots, x_n\}$, les valeurs de la fonction $f(x_1), f(x_2), \dots, f(x_n)$ sont supposées suivre une distribution gaussienne multidimensionnelle :

$$f(X) \sim \mathcal{N}(\mu(X), K(X, X)), \quad (4.18)$$

où :

- $X = \{x_1, x_2, \dots, x_n\}$ est l'ensemble des points d'évaluation,
 - $\mu(X)$ est le vecteur des moyennes associées à chaque x_i ,
 - $K(X, X)$ est la matrice de covariance dont les éléments sont donnés par $k(x_i, x_j)$.
- Le processus gaussien offre une estimation de la fonction $f(x)$ ainsi qu'une mesure d'incertitude à chaque point x .

4.16 Fonction d'acquisition

La fonction d'acquisition $a(x; \mathcal{D})$, où $\mathcal{D} = \{(x_i, f(x_i))\}_{i=1}^n$, guide l'optimisation en choisissant les prochains points à évaluer. Elle exploite les informations fournies par le processus gaussien pour balancer l'exploration (zones avec grande incertitude) et l'exploitation (zones où la fonction semble proche de son minimum).

Les fonctions d'acquisition les plus couramment utilisées sont :

- **Expected Improvement (EI)** : Maximiser l'amélioration espérée sur le meilleur point observé $f(x^*)$ jusqu'à présent. La fonction est donnée par :

$$a_{\text{EI}}(x) = \mathbb{E}[\max(0, f(x^*) - f(x))], \quad (4.19)$$

qui peut être réécrite en fonction de la moyenne $\mu(x)$ et de la variance $\sigma^2(x)$ du processus gaussien.

- **Upper Confidence Bound (UCB)** : Combiner la moyenne $\mu(x)$ et une fonction d'incertitude proportionnelle à l'écart type $\sigma(x)$ pour sélectionner le prochain point à évaluer :

$$a_{\text{UCB}}(x) = \mu(x) + \kappa\sigma(x), \quad (4.20)$$

où κ est un paramètre qui équilibre l'exploration et l'exploitation.

4.17 Étapes de l'Optimisation Bayésienne

L'optimisation bayésienne se déroule en plusieurs étapes :

1. **Initialisation** : Échantillonner un ensemble initial de points X_{init} et évaluer la fonction $f(x)$ à ces points.
2. **Modélisation** : Construire un modèle probabiliste, généralement un processus gaussien, basé sur les données $\mathcal{D} = \{(x_i, f(x_i))\}_{i=1}^n$.
3. **Optimisation de la fonction d'acquisition** : Trouver le prochain point à évaluer x_{n+1} en maximisant la fonction d'acquisition $a(x; \mathcal{D})$.
4. **Évaluation** : Évaluer la fonction objectif $f(x_{n+1})$ au point recommandé x_{n+1} .

5. **Mise à jour** : Mettre à jour les données \mathcal{D} avec la nouvelle observation $(x_{n+1}, f(x_{n+1}))$.
6. **Répétition** : Répéter les étapes 2 à 5 jusqu'à convergence.

4.18 Évaluation des Modèles d'Apprentissage Automatique

Les modèles d'apprentissage automatique sont évalués sur des données de test non vues pour mesurer les performances de généralisation. Certains indicateurs clés utilisés sont :

- Précision : Fraction de prédictions correctes utilisée pour la classification.
- Précision et rappel : La précision est la fraction de vrais positifs prédits, le rappel est la fraction de vrais positifs réels prédits.
- Erreur quadratique moyenne : Moyenne des carrés des différences entre les prédictions et les valeurs réelles utilisée pour la régression.
- Score F1 : Moyenne harmonique de la précision et du rappel, équilibre les deux mesures.

Des indicateurs supplémentaires tels que l'AUC-ROC pour les tâches de classement, l'erreur quadratique moyenne pour la régression, le score de silhouette pour le regroupement, etc. sont utilisés. La création de courbes d'apprentissage permet d'identifier les compromis entre biais et variance. Il est nécessaire de comparer les performances entre les ensembles d'entraînement, de validation et de test pour détecter le surajustement.

4.19 Défis de l'Apprentissage Automatique

Bien que l'apprentissage automatique ait conduit à des percées dans de nombreuses applications, il fait encore face à certains défis clés :

- Quantité et qualité insuffisantes de données d'entraînement.
- Difficulté à comprendre le comportement du modèle et à déboguer les échecs.
- Manque de transparence et d'interprétabilité algorithmique.
- Surajustement à des motifs futiles et aux biais dans les données.
- Adaptation aux changements dans les données au fil du temps.
- Mise à l'échelle de l'entraînement et du déploiement de modèles pour de grands ensembles de données.
- Quantification de l'incertitude et détection hors distribution.

La recherche en cours vise à résoudre ces problèmes grâce à des techniques telles que le transfert d'apprentissage, l'entraînement adversarial, la distillation, l'apprentissage profond bayésien et la modélisation causale. Les progrès en matière de puissance de calcul, de qualité des données et de surveillance humaine élargiront davantage les frontières de l'apprentissage automatique.

4.20 Le déroulement des opérations de la machine learning

Le développement d'un algorithme commence par des données qui décrivent notre système dans une série de conditions saines et défectueuses. Les données brutes sont prétraitées pour les mettre sous une forme permettant d'extraire des indicateurs d'état. Il s'agit de caractéristiques qui permettent de distinguer les conditions saines des conditions défectueuses. L'ensemble de ces étapes est résumé dans la **Figure 4.6**, qui illustre le déroulement typique allant de l'acquisition des données jusqu'à l'intégration du modèle.

Ensuite, en utilisant les caractéristiques extraites pour former un modèle d'apprentissage automatique qui peut :

- Détecter les anomalies
- Classifier les différents types de fautes

Enfin, nous déployons l'algorithme et l'intégrons dans nos systèmes de surveillance et de maintenance des machines.

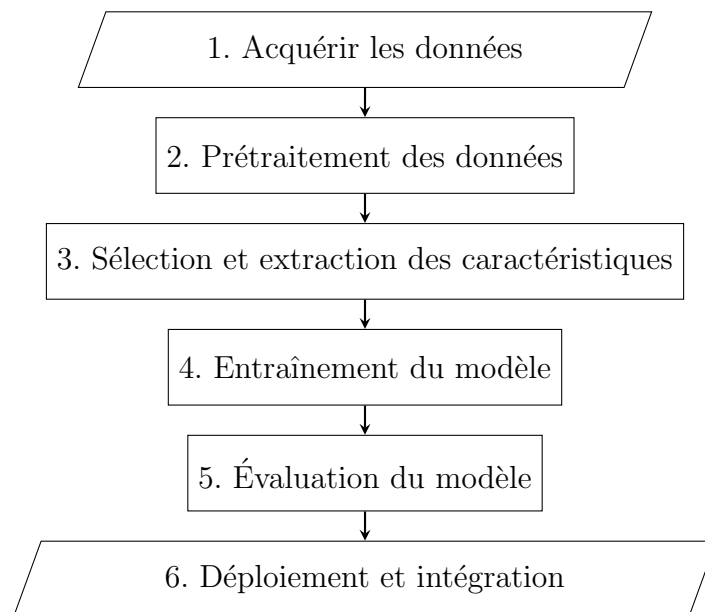


FIGURE 4.6 – Organigramme des étapes du processus de Machine Learning

4.20.1 1ère étape : Acquisition des données

La première étape consiste à collecter un grand nombre de données de capteurs représentant un fonctionnement sain et un fonctionnement défectueux. Il est important de collecter ces données dans des conditions de fonctionnement variables. Dans certains cas, il se peut que vous ne disposiez pas de suffisamment de données représentant un fonctionnement sain et un fonctionnement défectueux. Comme alternative, vous pouvez construire un modèle mathématique et estimer ses paramètres à partir des données des capteurs.

Vous pouvez ensuite simuler ce modèle avec différents états de défaut dans des

conditions de fonctionnement variées afin de générer des données de défaut. Ces données, également appelées des données synthétiques, complètent désormais les données du capteur. Vous pouvez utiliser une combinaison de données synthétiques et de données de capteurs pour développer votre algorithme de maintenance prédictive.

4.20.2 2ème étape : Prétraitement des données

Une fois que nous disposons des données, l'étape suivante consiste à les prétraiter pour les convertir en une forme à partir de laquelle les indicateurs de condition peuvent être facilement extraits. Le prétraitement comprend des techniques telles que l'élimination du bruit, des valeurs aberrantes et des valeurs manquantes. Parfois, un prétraitement plus poussé est nécessaire pour révéler des informations supplémentaires qui peuvent ne pas être apparentes dans la forme originale des données. Par exemple, ce prétraitement peut inclure la conversion des données du domaine temporel en domaine fréquentiel dans certains cas.

4.20.3 3ème étape : Sélection et extraction des caractéristiques

L'étape suivante consiste à identifier les caractéristiques pertinentes dont le comportement change de manière prévisible au fur et à mesure que le système se dégrade. Ces caractéristiques sont utilisées pour distinguer un fonctionnement sain d'un fonctionnement défectueux. L'une des étapes clés de l'élaboration d'un algorithme de maintenance prédictive consiste en la sélection et l'extraction de ces caractéristiques à partir des données système.

Ces caractéristiques vous aident à différencier un état normal d'un état défaillant. Elles sont extraites des données prétraitées du système et servent ensuite à la classification des défauts. MATLAB et Predictive Maintenance Toolbox™ offrent des outils pour concevoir ces caractéristiques en s'appuyant à la fois sur des approches fondées sur les signaux et sur des modèles. Vous pouvez notamment calculer des moments temps-fréquence afin de capturer les dynamiques évolutives souvent observées dans les données. Cela permet également de détecter les changements soudains dans les signaux collectés provenant de systèmes présentant un comportement ou des caractéristiques non linéaires.

4.20.4 4ème étape : Formation du modèle

Nous avons extrait de nos données des caractéristiques qui nous aident à comprendre le fonctionnement sain ou défectueux du système (lignes HVDC). Dans l'étape suivante, nous pouvons utiliser les caractéristiques extraites pour former des modèles d'apprentissage automatique afin de réaliser plusieurs choses :

- Détecter les anomalies : nous pouvons suivre les changements dans notre système pour déterminer la présence d'anomalies.
- Détecter les différents types de fautes grâce à la classification : nous pouvons savoir quelle partie du système nécessite une attention particulière.

4.20.5 5ème étape : Évaluation du modèle

L'évaluation du modèle est une étape cruciale dans le processus de développement d'un système d'apprentissage automatique. Elle permet de mesurer la performance du modèle entraîné et de s'assurer qu'il généralise bien sur de nouvelles données. Pour cela, le jeu de données est souvent divisé en trois sous-ensembles : entraînement, validation et test.

Les métriques d'évaluation varient selon la nature du problème :

- Pour les **problèmes de classification**, les métriques courantes incluent la précision, le rappel, la F-mesure, l'exactitude (accuracy), et l'aire sous la courbe ROC (AUC).
- Pour les **problèmes de régression**, on utilise généralement l'erreur quadratique moyenne (MSE), l'erreur absolue moyenne (MAE), et le coefficient de détermination R^2 .

L'utilisation de la **validation croisée** permet de renforcer la robustesse de l'évaluation en testant le modèle sur plusieurs sous-ensembles des données. Cela aide à détecter le surapprentissage (*overfitting*) ou le sous-apprentissage (*underfitting*).

L'analyse des résidus, la matrice de confusion ou encore les courbes de performance sont aussi des outils précieux pour comprendre les forces et limites du modèle. Une bonne évaluation guide les décisions sur l'optimisation, la sélection de variables ou le choix d'un autre algorithme plus adapté.

4.20.6 6ème étape : Déploiement et intégration

Après avoir développé notre algorithme, nous pouvons le rendre opérationnel en le déployant dans le cloud ou à la périphérie du système en temps réel. L'algorithme peut également être exécuté sur des dispositifs intégrés qui sont plus proches de l'équipement réel. Autrement dit, c'est pour l'implémentation et exécution en temps réel.

Ces algorithmes de classification par machine learning supervisée offrent différentes approches pour résoudre des problèmes de classification. Le choix de l'algorithme dépend de la nature des données, du nombre de classes, de la taille de l'ensemble de données et d'autres considérations spécifiques au problème.

4.20.7 Entraînement de modèles

Le processus d'entraînement d'un modèle d'apprentissage automatique à l'aide d'un ensemble de données étiquetées se déroule comme suit :

1. Collecte de données : Rassemblez un ensemble de données contenant des exemples avec des entrées (caractéristiques) et les étiquettes correspondantes (les réponses attendues).
2. Prétraitement des données : Effectuez des étapes de prétraitement telles que la normalisation, la standardisation, la gestion des valeurs manquantes, etc.
3. Division des données : Séparez l'ensemble de données en ensembles d'entraînement et de test. L'ensemble d'entraînement est utilisé pour entraîner le modèle tandis que l'ensemble de test est utilisé pour évaluer sa performance.

4. Choix du modèle : Sélectionnez un algorithme de modèle approprié pour le problème spécifique que vous essayez de résoudre.
5. Entraînement du modèle : Utilisez l'ensemble d'entraînement pour ajuster les paramètres du modèle. Cela se fait en minimisant une fonction de perte qui mesure la différence entre les prédictions du modèle et les étiquettes réelles.
6. Validation : Utilisez un ensemble de validation pour ajuster les hyperparamètres du modèle et éviter le surajustement.
7. Évaluation du modèle : Utilisez l'ensemble de test pour évaluer la performance finale du modèle sur des données qu'il n'a jamais vues auparavant.

4.20.8 Matrice de confusion

La matrice de confusion est un outil fondamental pour évaluer la performance des modèles de classification supervisée. Elle fournit un résumé des prédictions correctes et incorrectes effectuées par le modèle en les comparant aux classes réelles.

Une matrice de confusion est généralement structurée en quatre catégories :

- **VP (Vrais Positifs)** : le modèle prédit correctement la classe positive.
- **VN (Vrais Négatifs)** : le modèle prédit correctement la classe négative.
- **FP (Faux Positifs)** : le modèle prédit à tort une classe positive alors qu'elle est négative.
- **FN (Faux Négatifs)** : le modèle prédit à tort une classe négative alors qu'elle est positive.

4.20.9 Métriques d'évaluation

Voici quelques-unes des métriques couramment utilisées pour évaluer les modèles de diagnostic de défaillance :

$$\text{précision} = \frac{TP}{TP + FP} \quad (\text{Classe binaire}) \quad (4.21)$$

$$\text{précision} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.21)$$

Rappel (Sensibilité) :

$$\text{Rappel} = \frac{TP}{TP + FN} \quad (4.23)$$

F1-score :

$$\text{F1-score} = 2 \cdot \frac{\text{Précision} \cdot \text{Rappel}}{\text{Précision} + \text{Rappel}} \quad (4.24)$$

où :

- *True Positives (TP)* est le nombre d'observations correctement prédites comme positives.
- *True Negatives (TN)* est le nombre d'observations correctement prédites comme négatives.
- *False Positives (FP)* est le nombre d'observations incorrectement prédites comme positives.

- *False Negatives (FN)* est le nombre d'observations incorrectement prédites comme négatives.

Dans le cas des tâches de régression, plusieurs métriques standards sont utilisées pour quantifier l'erreur entre les prédictions du modèle et les valeurs réelles. Les principales métriques sont :

- **Erreur absolue moyenne (MAE) :**

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.25)$$

Elle mesure la moyenne des erreurs absolues entre les valeurs prédites \hat{y}_i et les valeurs réelles y_i . Elle est facile à interpréter et moins sensible aux valeurs extrêmes.

- **Erreur quadratique moyenne (MSE) :**

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4.26)$$

Elle pénalise fortement les grandes erreurs. Une valeur faible de MSE indique une bonne précision du modèle.

- **Racine de l'erreur quadratique moyenne (RMSE) :**

$$\text{RMSE} = \sqrt{\text{MSE}} \quad (4.27)$$

Elle est exprimée dans la même unité que la variable cible et est donc plus intuitive que la MSE.

- **Coefficient de détermination (R^2) :**

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4.28)$$

Il indique la proportion de la variance des données qui est expliquée par le modèle. Une valeur proche de 1 indique une bonne performance, tandis qu'une valeur négative signifie que le modèle est moins performant qu'une simple moyenne.

Ces métriques doivent être analysées conjointement pour avoir une vision globale de la performance du modèle. Le choix des métriques à privilégier dépend aussi du domaine d'application et du niveau de tolérance aux erreurs.

4.20.10 Validation croisée k-plis

Dans la validation croisée k-plis, l'ensemble de données est divisé en k sous-ensembles de taille égale. Le modèle est ensuite entraîné sur k - 1 plis et testé sur le pli restant. Ce processus est répété k fois (une fois pour chaque pli) et la performance est moyennée.

$$\text{Performance} = \frac{1}{k} \sum_{i=1}^k \text{performance}_i \quad (4.29)$$

4.21 Caractéristiques statistiques descriptives

TABLE 4.1 – Caractéristiques statistiques descriptives : définitions et formules

Caractéristique statistique	Description	Formule
Maximum	C'est la valeur maximale d'un ensemble de nombres donnés.	$x_{\max} = \max(x_i)$
Minimum	C'est la valeur minimale d'un ensemble de nombres donnés.	$x_{\min} = \min(x_i)$
Moyenne	C'est la moyenne d'un ensemble de nombres donnés.	$\mu = \frac{1}{N} \sum_{i=1}^N x_i$
Écart type	Il mesure la déviation des données par rapport à leur position moyenne.	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2}$
Variance	Il mesure jusqu'à quel point un ensemble de données s'étend à partir de sa moyenne.	$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2$
Médiane	C'est la valeur centrale d'un ensemble de nombres donnés.	$\bar{x} = \begin{cases} \frac{n+1}{2} & \text{si } n \text{ est impair} \\ \frac{n}{2} & \text{si } n \text{ est pair} \end{cases}$
Racine carrée moyenne (RMS)	C'est la moyenne arithmétique des carrés d'un groupe de valeurs.	$rms = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$
Asymétrie	Il mesure le degré d'asymétrie d'une distribution par rapport à sa moyenne.	$\gamma = \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \mu}{\sigma}\right)^3$
Kurtosis	Il décrit l'acuité de la distribution des données. Une kurtosis plus élevée signifie un pic plus aigu.	$\rho = \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \mu}{\sigma}\right)^4$

4.22 Ajustement de courbe et moindres carrés non linéaires

Dans le contexte de la localisation des défauts dans les systèmes VSC-HVDC, l'analyse des formes d'onde des courants, notamment les pics transitoires, permet de dériver des modèles empiriques reliant l'amplitude, le temps d'occurrence ou la pente de ces pics à la position du défaut. Pour modéliser cette relation, la technique d'ajustement de courbe (Curve Fitting) est particulièrement adaptée.

L'ajustement de courbe vise à approximer un ensemble de données expérimentales (x_i, y_i) à l'aide d'une fonction analytique $f(x, \boldsymbol{\theta})$, paramétrée par un vecteur de paramètres $\boldsymbol{\theta}$. La méthode des **moindres carrés non linéaires** est utilisée lorsque f est une fonction non linéaire par rapport à ses paramètres. Elle consiste à minimiser l'erreur quadratique entre les valeurs observées et les valeurs estimées :

$$\min_{\boldsymbol{\theta}} \sum_{i=1}^n [y_i - f(x_i, \boldsymbol{\theta})]^2 \quad (4.30)$$

Dans le cadre de la localisation des défauts, on peut modéliser la position du défaut L en fonction du pic de courant détecté I_{peak} à un capteur donné, à l'aide d'un polynôme de degré n . Cette approche est plus flexible que le modèle exponentiel simple, notamment lorsqu'on cherche à capturer des relations complexes entre la distance au défaut et la réponse transitoire du courant. L'expression générale s'écrit :

$$L = a_0 + a_1 I_{\text{peak}} + a_2 I_{\text{peak}}^2 + \dots + a_n I_{\text{peak}}^n \quad (4.31)$$

où a_0, a_1, \dots, a_n sont les coefficients du polynôme à ajuster par une méthode d'optimisation non linéaire (comme region de confiance), en se basant sur un jeu d'exemples de défauts simulés ou mesurés. Cette stratégie permet un ajustement plus précis et personnalisable, en particulier dans les systèmes HVDC où les comportements transitoires sont fortement non linéaires.

L'intérêt de cette approche est qu'elle permet de capturer des relations complexes entre la signature du défaut et sa localisation, sans recourir nécessairement à un modèle physique exhaustif de la ligne. L'ajustement par moindres carrés est particulièrement efficace lorsque la relation entre le signal mesuré et la distance au défaut est monotone et continue, ce qui est souvent le cas dans les systèmes HVDC.

Dans le contexte de l'ajustement de courbe appliqué à la localisation des défauts dans les systèmes HVDC VSC, la résolution du problème d'optimisation non linéaire repose souvent sur des méthodes robustes comme celle des régions de confiance ou l'algorithme de Levenberg-Marquardt. Ces méthodes permettent de minimiser la fonction de coût – généralement l'erreur quadratique entre les valeurs mesurées (pics de courant) et le modèle de prédiction – même lorsque la relation entre les variables n'est pas linéaire.

La méthode des régions de confiance consiste à construire localement un modèle quadratique de la fonction objectif, valable dans une zone restreinte (la région de

confiance), puis à adapter dynamiquement cette région pour assurer la convergence vers un minimum. L'algorithme de Levenberg-Marquardt, quant à lui, combine les avantages de la descente de gradient et de la méthode de Gauss-Newton. Il introduit un facteur d'amortissement qui permet de régulariser le problème en cas de forte non-linéarité ou de mauvaise condition des données. Cette approche est particulièrement adaptée lorsque la courbe à ajuster dépend de paramètres physiques sensibles, comme c'est le cas pour les signaux transitoires analysés dans la localisation des défauts HVDC.

Toutes les formulations mathématiques détaillées et les algorithmes associés sont présentés dans l'**Annexe A** pour une meilleure compréhension technique et une possible reproduction des résultats.

4.23 Méthodologie

4.23.1 Étapes du Processus d'Ajustement de Courbe

Le processus d'ajustement de courbe implique les étapes suivantes :

1. **Collecte de Données** : Tout d'abord, les données pertinentes doivent être collectées. Cela peut inclure des mesures expérimentales ou des observations.
2. **Prétraitement des Données** : Avant l'ajustement, les données doivent être prétraitées. Cela peut inclure le nettoyage des données pour éliminer les valeurs aberrantes ou manquantes, ainsi que la normalisation pour mettre les données à la même échelle.
3. **Sélection du Modèle** : En fonction de la nature des données, un type de modèle d'ajustement de courbe doit être choisi. Cela peut être une régression linéaire, polynomiale, exponentielle, etc.
4. **Ajustement du Modèle** : À l'aide d'un algorithme approprié, le modèle est ajusté aux données. Cela implique souvent l'optimisation d'une fonction d'ajustement en minimisant l'erreur résiduelle.
5. **Évaluation du Modèle** : Une fois le modèle ajusté, il doit être évalué pour vérifier sa validité et son efficacité. Cela peut être fait en examinant des mesures telles que le coefficient de détermination (R^2) ou d'autres métriques appropriées.

$$R^2 = 1 - \frac{SSR}{SST} \quad (4.32)$$

où

- SSR est la somme des carrés des résidus (la somme des carrés des différences entre les valeurs prédites par le modèle et les valeurs réelles de la variable dépendante)
- SST est la somme totale des carrés (la somme des carrés des différences entre les valeurs réelles de la variable dépendante et sa moyenne).

Le coefficient de détermination varie de 0 à 1. Un R^2 proche de 1 indique que le modèle explique une grande partie de la variance de la variable dépendante, tandis qu'un R^2 proche de 0 indique que le modèle n'explique pas bien la variance de la variable dépendante.

4.24 Conclusion

Dans ce chapitre, nous avons exploré l'application de méthodes avancées de machine learning et l'optimisation pour la classification et la localisation des défauts dans les systèmes HVDC à source de tension (VSC). Les systèmes HVDC sont essentiels pour la transmission efficace de l'électricité sur de longues distances mais leur fiabilité peut être compromise par divers défauts. L'utilisation de techniques de machine learning permet de tirer parti des données opérationnelles pour identifier et classer ces défauts avec une grande précision. En parallèle, les techniques de curve fitting offrent des moyens robustes de modéliser le comportement dynamique des systèmes et de localiser les défauts avec une précision accrue.

En combinant ces approches, nous avons démontré que les modèles basés sur le machine learning peuvent apprendre à partir de données historiques pour fournir des prédictions fiables tandis que l'optimisation non linéaire permet d'ajuster les modèles de manière précise pour minimiser les erreurs et améliorer la localisation des défauts.

En conclusion, l'intégration de ces méthodes innovantes représente une avancée importante dans le domaine de la surveillance et de la maintenance des systèmes HVDC. L'application de ces techniques permet non seulement d'améliorer la résilience des réseaux électriques mais aussi de réduire les temps d'interruption et les coûts associés aux défauts. Ainsi, cette approche constitue une contribution précieuse à la poursuite de l'optimisation et de la sécurisation des infrastructures énergétiques modernes.

Le chapitre suivant présente en détail les résultats obtenus pour les tâches de classification et de régression à l'aide des modèles de machine learning. Une analyse comparative des performances permettra de mettre en évidence les algorithmes les plus efficaces pour l'identification et la localisation des défauts dans les systèmes HVDC.

Chapitre 5

Résultat et discussion de classification et régression par ML

5.1 Introduction

Ce chapitre présente une analyse détaillée des résultats obtenus concernant la classification et la localisation des défauts dans un système bipolaire de conversion de tension haute (VSC HVDC). Les systèmes VSC HVDC (Voltage Source Converter High Voltage Direct Current) jouent un rôle crucial dans le transport efficace de l'énergie électrique sur de longues distances et dans les réseaux de distribution intelligents. La détection, la classification et la localisation rapides et précises des défauts dans ces systèmes sont essentielles pour garantir une opération fiable et sûre.

Les sections suivantes décrivent les méthodologies utilisées pour détecter et classer les défauts ainsi que les algorithmes appliqués pour localiser les points de défaillance dans un système VSC HVDC bipolaire. Nous présentons également une discussion approfondie des résultats obtenus à partir de simulations, en mettant en évidence les performances des techniques proposées par rapport aux méthodes conventionnelles.

Les résultats sont analysés en termes de précision de classification, temps de réponse et exactitude de localisation des défauts. De plus, nous discutons des défis rencontrés et des solutions proposées pour améliorer la robustesse et la fiabilité des systèmes de protection basés sur l'intelligence artificielle et l'apprentissage automatique. Enfin, des recommandations sont formulées pour des travaux futurs afin d'optimiser davantage les performances des systèmes VSC HVDC en matière de gestion des défauts.

5.2 Emplacements des défauts

Les sections suivantes du chapitre 6 discutent brièvement des caractéristiques des défauts. Les trois cas de fautes déterminantes inclus dans le travail de thèse seront décrits. Tensions et courants dans la station HVDC pertinents pour le défaut avant et après l'apparition du défaut. Les survenus sont analysés.

Cette section décrit le défaut pôle à pôle du côté CC. Puisque ces deux défauts font face à des problèmes de courants transitoires, ils sont inclus dans ce qu'on appelle l'étude de courant transitoire. Le défaut monophasé à la terre sur le bus convertisseur (pôle positif et le pôle négatif) fait face à des problèmes de tensions transitoires donc inclus dans l'étude de tension transitoire. La figure 6.1 montre un schéma simplifié de système HVDC.




FIGURE 5.1 – Diagramme Schématique d'un Système Bipolaire VSC HVDC

Avant que le défaut monophasé du convertisseur ne se produise, le convertisseur fonctionne en régime permanent. La tension du bus du convertisseur est une tension triphasée symétrique. Peu après l'apparition du défaut, celui-ci est détecté par la protection et les vannes sont bloquées (diodes). La tension sur la phase en court-circuit tombe à zéro et les tensions sur les phases non défectueuses augmentent (surtension).

Puisque la tension des phases non défectueuses sur le bus du convertisseur augmente au-dessus de la valeur de la tension du courant continu, les vannes sont bloquées. La diode supérieure de chaque cellule des bras sains positifs sera dirigée vers l'avant et la diode supérieure sera dirigée vers l'arrière. Des bras sains positifs sont polarisés vers l'avant, ce qui entraîne un flux de courant qui charge la capacité côté courant continu, augmentant ainsi le niveau de tension dc positive.

La tension des phases saines sur le bus du convertisseur diminue également en dessous de la tension du pôle négatif, ce qui entraîne un flux de courant à travers les diodes inférieures sur les bras négatifs sains, chargeant le condensateur du pôle négatif et la capacité côté dc, diminuant encore la tension dc négative. Les condensateurs de cellule sur les bras positifs sains sont chargés lorsque la tension dc sur la borne dc positive moins la tension de phase sur le bus du convertisseur est supérieure à la somme des tensions de cellule à travers le bras. Les condensateurs de cellule sur les bras sains négatifs sont chargés lorsque la tension dc sur la borne dc négative plus la tension de phase sur le bus du convertisseur est inférieure à la somme des tensions de cellule aux bornes du bras.

5.2.1 Défaut de pôle à pôle

Là encore, le convertisseur est supposé fonctionner en régime permanent au moment où le défaut pôle à pôle se produit. La tension du bus du convertisseur est une tension triphasée symétrique. La tension symétrique du pôle DC atteint la tension nominale de $\pm 100\text{kV}$.

Lorsqu'un court-circuit se produit entre les pôles positif et négatif, les tensions des pôles tombent directement à zéro voir figure 6.10 . Un chemin de courant entre le




FIGURE 5.2 – Modèle de défaut pole-terre




FIGURE 5.3 – Modèle de défaut pole-pole

pôle positif et le pôle négatif est introduit, conduisant les courants du côté alternatif et provoquant des courants de défaut élevés à travers les bras supérieur et inférieur du convertisseur. Ce courant de défaut est illustré à la figure voir figure 6.9.

5.2.2 Défaut de pôle à terre

Dans le cas d'un défaut monophasé à la terre sur le bus du convertisseur, l'aspect critique est l'accumulation de surtension sur les bras du convertisseur aux bornes des bras non défectueux. Cette tension est dimensionnante pour les cellules, les condensateurs, les semi-conducteurs et les diodes voir figure 6.6 et figure 6.8 .

5.3 Résultats des simulations

Décrivez les étapes exactes suivies pendant les simulations, le logiciel de simulation utilisé :

- Définir le système d'essai dans Matlab/Simulink, simulation pendant $t = 3s$.
- Générer des scénarios d'erreur pour créer la base de données à $t = 2s$.
- Implémenter l'algorithme de détection de fautes (dans notre cas KNN machine learning).

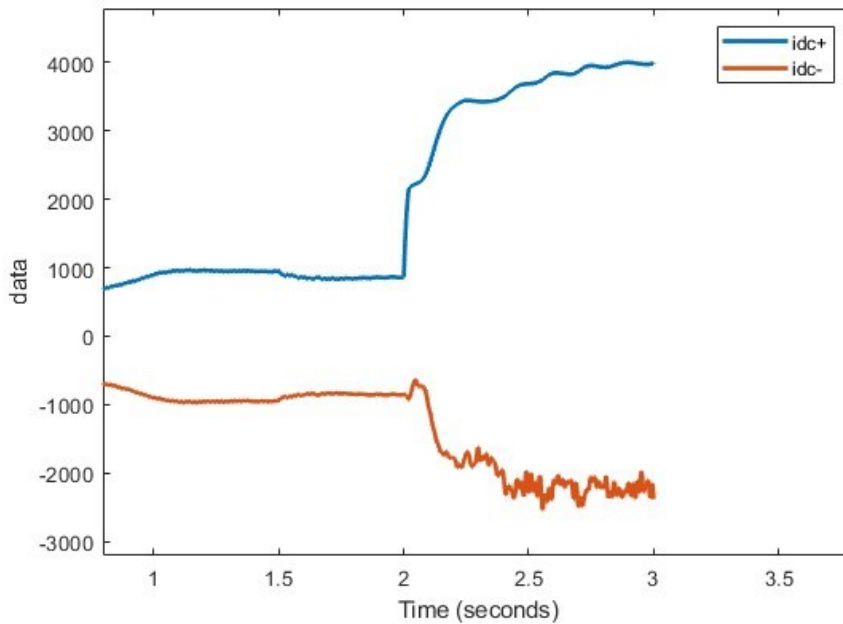


FIGURE 5.4 – signal du courant lors d'un défaut pole positif

— Évaluer la performance de détection.

5.3.1 Collecte des données

La première étape du diagnostic d'un système HVDC consiste à collecter des données pertinentes à partir de capteurs et d'équipements de surveillance. Ces données peuvent inclure des informations sur la tension et le courant. Les méthodes les plus courantes de collecte de données dans les systèmes HVDC comprennent l'utilisation de systèmes de surveillance à distance ou l'installation de capteurs et d'appareils de mesure directement du côté du redresseur. Nous allons capturer le signal défectueux (transitoire électrique CC).

Nous définissons notre base de données par l'ensemble des paramètres de tension et de courant en KA et KV respectivement du côté du redresseur en faisant varier la résistance de défaut R_f de 0.01 à 50 ohms sur les deux lignes pour finalement générer la base de données : ligne positive, ligne négative et ligne à ligne; ces dernières étant la sortie de notre base de données.

5.3.2 Extraction des caractéristiques

Une fois les données collectées, l'étape suivante consiste à extraire les caractéristiques pertinentes telles que les valeurs efficaces et les valeurs crête à crête de chaque paramètre $v(t)_{positif}$, $v(t)_{négatif}$, $i(t)_{positif}$, $i(t)_{négatif}$ pour les caractéristiques d'extraction. Ensuite, nous formerons cette base de données à l'aide d'une des méthodes d'apprentissage automatique supervisé appelée KNN.

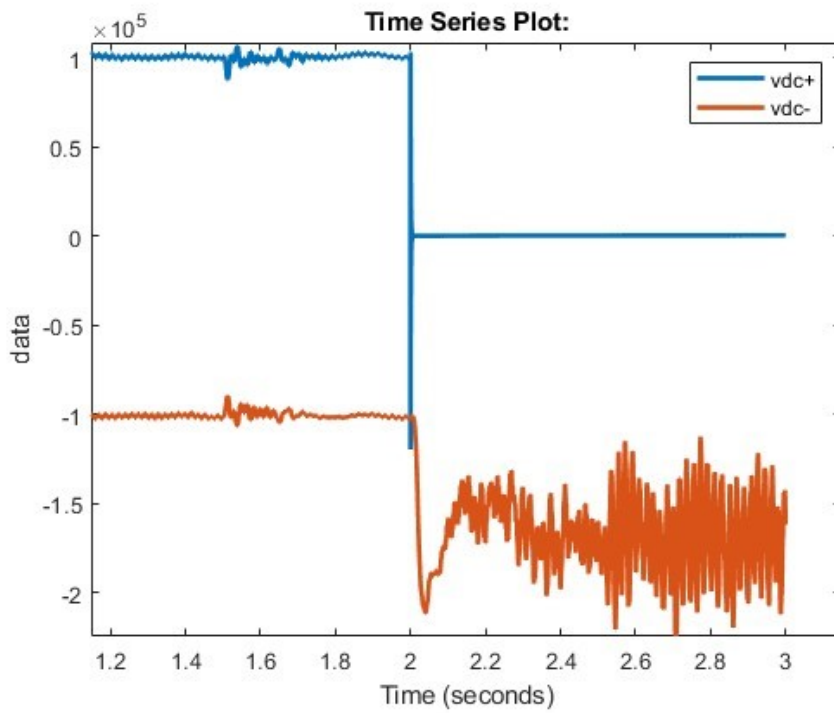


FIGURE 5.5 – signal de la tension lors d'un défaut pole positif

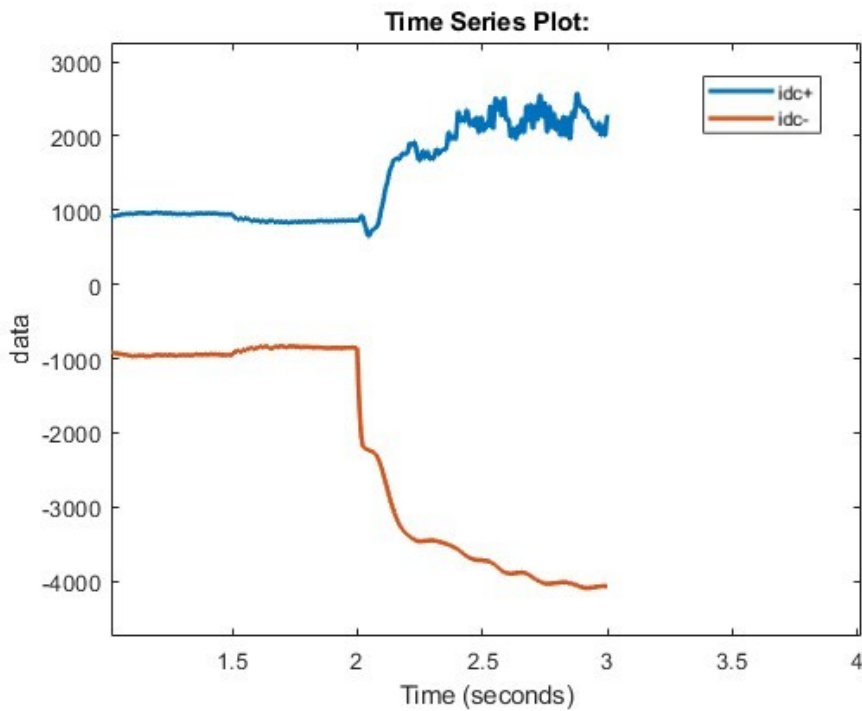


FIGURE 5.6 – signal du courant lors d'un défaut pole négatif




FIGURE 5.7 – signal de la tension lors d’un défaut pole négatif




FIGURE 5.8 – signal du courant lors d’un défaut bipole




FIGURE 5.9 – signal de la tension lors d’un défaut bipole

5.3.3 Le modèle des K-voisins les plus proches (KNN) dans le diagnostic des défauts

L’algorithme KNN, une technique de classification non paramétrique, est connu pour sa simplicité et son efficacité dans les tâches de reconnaissance des formes. En classant les instances en fonction de leur proximité avec les points de données voisins, le KNN peut discerner des variations subtiles indiquant des défauts dans les lignes HVDC. Cet article montre comment le modèle KNN peut être appliqué au diagnostic des défauts en tirant parti de la surveillance des données.

5.3.4 k-fold Cross Validation : Renforcer la fiabilité du modèle

Pour garantir la robustesse du modèle KNN, on utilise la validation croisée k-fold. Cette technique divise l’ensemble de données en k sous-ensembles, en utilisant k-1 d’entre eux pour la formation et le reste pour le test. Ce processus est itéré k fois, ce qui permet à chaque sous-ensemble de servir à la fois de données de formation et de données de test. En agrégeant les résultats, la validation croisée k-fold fournit une évaluation plus complète des performances du modèle.

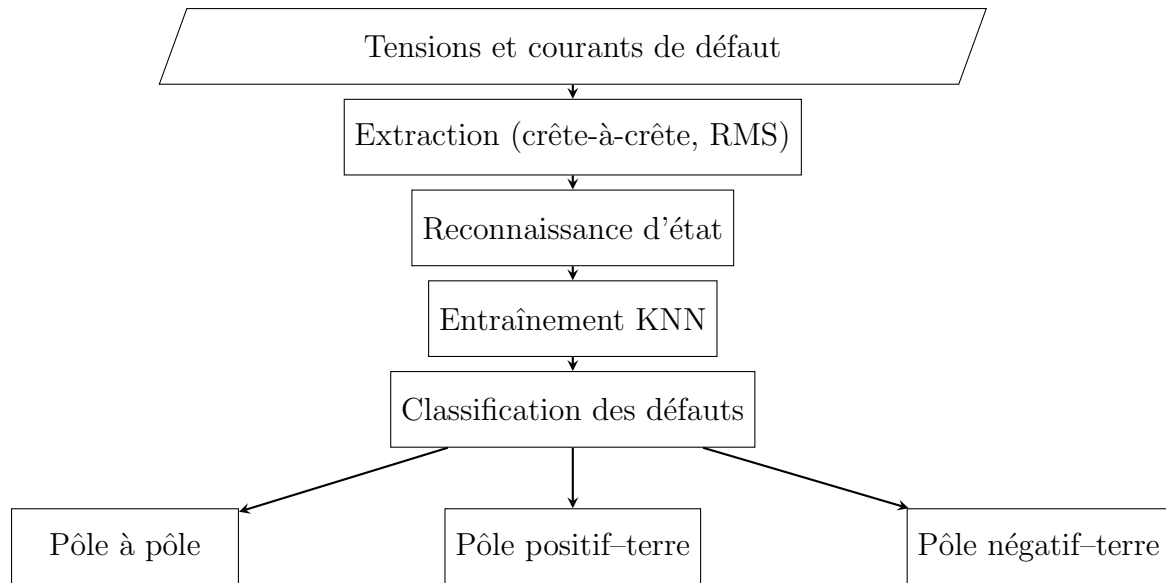


FIGURE 5.10 – Organigramme du processus de classification des défauts utilisant le modèle KNN

5.3.5 Résultat de classification

Model	1	2	3	4
KNN	100%	100%	100%	97.41%

TABLE 5.1 – Résultats de classification du modèle KNN




FIGURE 5.11 – Diagramme de dispersion entre les pics de Vpos et Vneg




FIGURE 5.12 – Diagramme de dispersion entre les pics de Ipos et Ineg




FIGURE 5.13 – Diagramme de dispersion entre les pics de rmsVpos et rmsVneg




FIGURE 5.14 – Diagramme de dispersion entre les pics de rms_lpos et rms_lneg




FIGURE 5.15 – Matrice du confusion pour les modèles 1,2,3

Model 3

	line to line		
True Class	line to line	27	1
	negatif line		1
	positif line		43
		line to line	negatif line
		Predicted Class	

FIGURE 5.16 – Matrice du confusion pour le modele4

Dans les figures présentées, il est impératif d'examiner les modèles de regroupement évidents dans les points de dispersion. Lorsque le système fonctionne dans des conditions défectueuses, il est essentiel de noter l'émergence de grappes clairement définies qui différencient nettement les états normaux des états anormaux. En outre, un algorithme fiable de détection des défaillances devrait révéler une corrélation solide entre les variables statistiques telles que le pic à pic et la racine carrée moyenne. L'étendue de la séparation observée entre ces groupes identifiés constitue une mesure essentielle pour évaluer l'efficacité de l'algorithme de détection des défaillances.

L'évaluation des performances de notre modèle de détection de défauts dans le système HVDC a été réalisée à l'aide d'une matrice de confusion. La matrice offre une vue détaillée des prédictions du modèle par rapport aux valeurs réelles pour chaque classe, ce qui nous permet d'analyser la précision et la fiabilité de notre approche.

5.3.6 Résultat de localisation

Les performances du système bipolaire VSC HVDC ont été simulées dans le cadre de ces spécifications de circuit. La puissance de transmission du système est de 2000 MVA à un niveau de tension de 230 KV. La fréquence nominale du système CA est de 50 Hz. La longueur du câble de transmission est de 75 km. Nous avons utilisé matlab pour modéliser le système HVDC et programmer la méthode précédente. Nous avons divisé l'impédance du câble CC en plusieurs éléments (20 impédances identiques) et nous avons créé des défauts à différentes positions (30,15 ,75 km) et ensuite nous avons collecté les données en capturant le signal en chaque point du câble (en prenant la valeur RMS de chaque potentiel) pour générer les ensembles de données.




FIGURE 5.17 – matrice du confusion1




FIGURE 5.18 – nuage des points pour rf 0.01 ohm

5.3.7 Impact de la résistance de défaut R_f

Afin d'examiner plus en détail la réponse de l'algorithme de localisation des défauts proposé, les études de cas présentées ont été répétées pour différentes valeurs de la résistance de défaut R_f . Des résultats toujours satisfaisants ont été obtenus sans augmentation significative de l'erreur moyenne, même pour des défauts hautement résistifs lorsque $R_f = 100$. On peut en conclure que le schéma de localisation des défauts proposé est relativement robuste face à des défauts hautement résistifs.




FIGURE 5.19 – matrice du confusion2

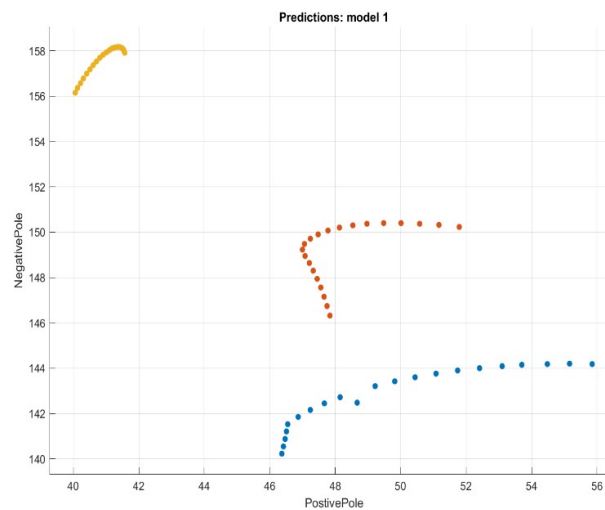


FIGURE 5.20 – nuage des points pour rf 10 ohm

5.4 Méthode hétérogène par ML et ajustement du courbe pour la classification et localisation des défauts

Notre motivation et nos contributions se composent de trois éléments principaux :

- Détermination de la fréquence d'échantillonnage optimale : Nous utilisons des techniques de traitement du signal pour déterminer la fréquence d'échantillonnage optimale pour capturer le comportement dynamique du système. En optimisant la fréquence d'échantillonnage, nous visons à garantir que les informations pertinentes concernant les caractéristiques des défauts sont capturées efficacement tout en minimisant la charge de calcul.
- Analyse des premiers courants de crête défectueux : Nous nous concentrons sur l'analyse des premiers courants de crête, qui présentent souvent des caractéristiques distinctives en présence de défauts. En analysant les caractéristiques




FIGURE 5.21 – matrice du confusion3

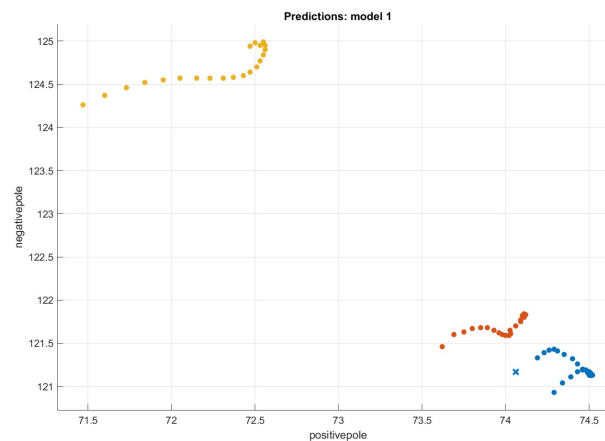


FIGURE 5.22 – nuage des points pour rf 100 ohm

temporelles et d'amplitude des premiers pics de courant, nous visons à développer des critères robustes pour la détection des défauts.

- Modèles d'ajustement de courbes avec apprentissage automatique : Nous utilisons des modèles d'ajustement de courbes, complétés par des algorithmes d'apprentissage automatique, pour saisir les relations complexes entre les variables du système et les conditions de défaillance. En entraînant des modèles d'apprentissage automatique sur des données historiques, nous visons à développer des modèles prédictifs capables d'identifier les signatures de défaut avec une grande précision.

5.4.1 Complexité et Non-linéarité du Modèle

a. Fort Couplage avec la Localisation du Défaut :

- La localisation du défaut l_f est fortement couplée avec les états du modèle dynamique. Cela signifie que la position du défaut influence et est influencée par le comportement dynamique du système, rendant ainsi le processus d'estimation plus complexe.

b. Forte Non-linéarité :

- Le modèle dynamique présente une forte non-linéarité. La non-linéarité, dans ce contexte, signifie que la relation entre les variables d'entrée (comme les courants de crête) et les variables de sortie (comme la localisation du défaut) n'est pas linéaire; elle implique plutôt des interactions complexes qui ne peuvent pas être représentées par une simple équation linéaire. Cela rend la résolution du modèle, que ce soit analytiquement ou par des méthodes computationnelles, plus difficile.




FIGURE 5.23 – Modèle à sections multiples en π

5.4.2 Impact de la fréquence d'échantillonnage sur le courant de crête

L'impact de la fréquence d'échantillonnage sur le courant de crête des défauts est évalué dans la littérature . Le bon fonctionnement et le contrôle d'un système HVDC dépendent fortement de la qualité des mesures de tension et de courant. La faisabilité et les avantages des mesures à grande vitesse (bus de processus) sont analysés sous trois angles : les technologies des capteurs de tension et de courant, la structure de communication des données et diverses applications HVDC. Il s'avère que la fréquence d'échantillonnage recommandée de 96 kHz par la norme IEC 61896-9 est adéquate pour la plupart des protections HVDC et des commandes de vannes. Toutefois, pour les applications de localisation des défauts, une fréquence d'échantillonnage plus élevée, supérieure à 200 kHz, est préférable [137] La détection des défauts dans les systèmes HVDC dépend fortement de la fréquence d'échantillonnage. Les fréquences plus élevées capturent des variations de signal plus détaillées, essentielles pour distinguer les défauts des perturbations transitoires telles que les coups de foudre. La réduction de la fréquence d'échantillonnage peut entraîner la perte de caractéristiques critiques du signal, ce qui fait que l'algorithme de détection des défauts identifie à tort les coups de foudre comme des défauts internes. Il est donc essentiel de maintenir une fréquence d'échantillonnage élevée pour garantir une détection précise et fiable des défauts [138]

La fréquence d'échantillonnage a un impact significatif sur la précision de la mesure du courant de crête du défaut et sur la qualité des données Des fréquences d'échantillonnage plus élevées sont nécessaires pour capturer avec précision les valeurs de crête des signaux continus et sinusoïdaux. La précision des calculs statistiques, tels que les valeurs de crête, est également influencée par la fréquence d'échantillonnage.

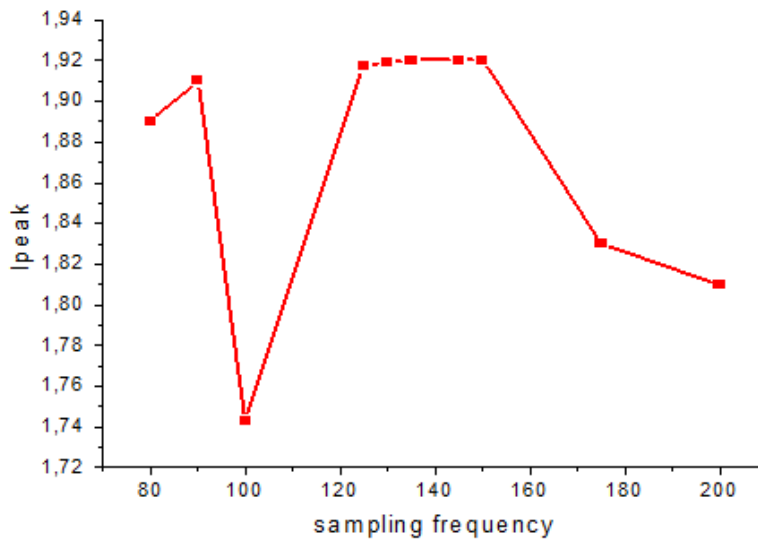


FIGURE 5.24 – I_{peak} en fonction de la fréquence d'échantillonnage

5.4.3 Obtention des données

Les données de formation ont été acquises par l'application de défauts de phase positifs (PPF), de défauts de phase à la terre (PGF) et de défauts de phase négatifs (NGF) le long des lignes de transmission illustrées à la Figure 6.1. Ces défauts ont été intentionnellement déclenchés en divers points des lignes d'alimentation, couvrant une large gamme de résistances de défaut (R_f) de $0,01 \Omega$ à 100Ω . La résistance de défaut désigne la résistance électrique associée au défaut, qui peut varier en fonction de sa nature et de sa gravité. En générant des schémas de défaut avec diverses résistances de défaut et à différents endroits de la ligne d'alimentation, un ensemble de données complet a été compilé. Cet ensemble de données sert de base au développement et à la validation d'algorithmes de localisation des défauts visant à identifier avec précision les types de défauts et à les localiser avec précision dans le réseau.

5.4.4 Méthode proposée

Catégories de classification des défauts de la première étape

La classification des défauts repose sur l'analyse des signatures de courant continu post-défaut, englobant des types potentiels tels que le défaut pôle à pôle (PPF), le défaut pôle à terre positif (PGF) et le défaut pôle à terre négatif (NGF). Ces classifications sont dérivées de la littérature scientifique pertinente traitant des défis associés aux défauts côté CC dans les systèmes HVDC à base de VSC.

Localisation des défauts au deuxième étage

Pour améliorer les techniques de localisation des défauts, les chercheurs utilisent l'ajustement de courbe, une approche mathématique visant à déterminer la courbe optimale qui englobe un ensemble de points de données. Dans cette étude spécifique, les moindres carrés non linéaires sont utilisés pour l'ajustement de courbe, avec pour objectif principal de minimiser la variance entre les valeurs prédites dérivées de la courbe et les points de données réels. En utilisant cette méthode, les chercheurs cherchent à déterminer la courbe la plus adaptée qui délimite la relation entre les signaux de défaut et les emplacements de défaut. En s'appuyant sur l'environnement MATLAB, le processus d'ajustement des courbes implique l'identification des paramètres d'une fonction mathématique capable de représenter avec précision la corrélation entre les courants de crête et les emplacements des défauts. L'objectif principal est de développer des courbes de défaut qui permettent des estimations précises des emplacements de défaut sur la base des courants de pointe de défaut fournis. Dans le respect des critères d'erreur minimale de localisation de défaut FLE, Le type de courbe le plus approprié est déterminé en s'efforçant de sélectionner celle qui minimise l'écart moyen entre les emplacements de défaut prédits et réels. La méthodologie proposée vise à atteindre un niveau élevé de précision de localisation des défauts, caractérisé par une erreur moyenne maximale (MAE) aussi faible que possible.

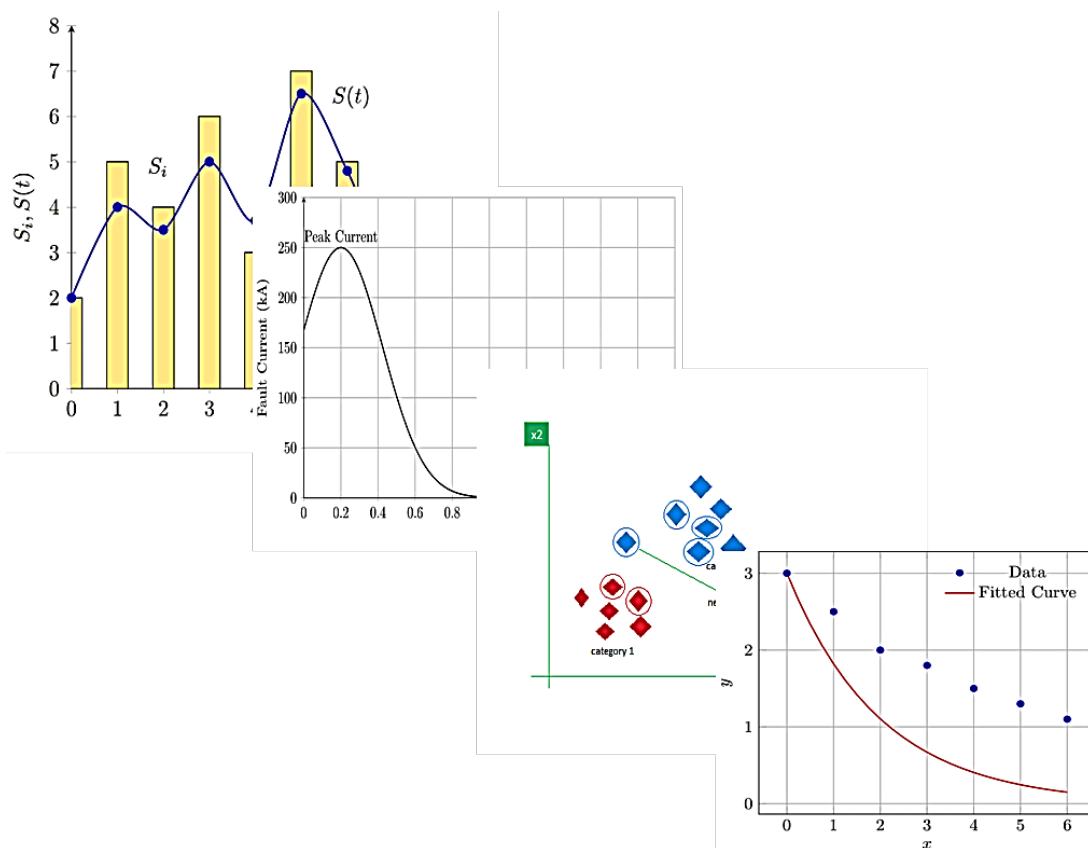


FIGURE 5.25 – Le cadre procédural utilisé dans notre étude

Le cadre d'apprentissage automatique hétérogène que nous proposons démontre une grande précision dans la classification simultanée de divers types de défauts, tels que les défauts positifs à la terre, les défauts négatifs à la terre et les défauts positifs à négatifs, dans les systèmes de courant continu à haute tension (HVDC), tout en quantifiant leur gravité pour faciliter des stratégies d'atténuation des défauts rapides et efficaces."

La méthode proposée pour la localisation des défauts dans les systèmes de convertisseurs de tension à courant continu à haute tension ("HVDC") s'appuie sur un cadre d'apprentissage automatique hétérogène. Ce cadre est conçu pour classer différents types de défauts et quantifier leur gravité afin de permettre des stratégies efficaces d'atténuation des défauts. Les types de défauts traités comprennent les défauts positifs à la terre, négatifs à la terre et positifs à négatifs

5.5 Méthodologie

La méthodologie comprend plusieurs étapes clés :

- Sélection de la fréquence d'échantillonnage optimale : L'étape initiale consiste à choisir la fréquence d'échantillonnage optimale pour garantir la saisie précise des caractéristiques des défauts. Cette étape est cruciale pour maintenir l'intégrité des données utilisées dans les analyses ultérieures.
- Acquisition des données : Les courants de crête de défaut d'une borne sont capturés sur une courte durée, généralement dans un intervalle de temps de 60 millisecondes. Ces données à haute résolution sont essentielles pour la classification et l'analyse précises des défauts.
- Classification par apprentissage automatique : Le classificateur d'apprentissage automatique est au cœur de la méthodologie. L'algorithme K-Nearest Neighbors (KNN) est utilisé à cette fin. Pour améliorer la robustesse et la fiabilité du modèle, la validation croisée k-fold est employée. Cette technique permet de réduire le surajustement et d'améliorer la généralisation du classificateur.
- Ajustement des courbes pour la prédiction des défauts : La dernière étape consiste à appliquer les meilleures techniques d'ajustement des courbes pour prédire la défaillance. Cette capacité de prédiction est cruciale pour une localisation rapide et précise des défauts, qui facilite à son tour des stratégies d'atténuation des défauts efficaces et opportunes.

5.6 Analyse des pointes de courant défectueuses

- Résistance de défaut : 0,01 Ohms La figure fournit une description détaillée du comportement du courant sous une résistance de défaut très faible de 0,01 ohms. Ce scénario représente une condition de quasi-court-circuit où l'impédance de défaut est minimale. Courant de crête : dans ce cas, le courant de crête est extrêmement élevé en raison de la résistance minimale qui entrave le courant de défaut.
- Résistance de défaut : 10 Ohms Avec une résistance de défaut accrue de 10 ohms, l'intensité du courant diminue par rapport au scénario de 0,01 ohms. Cette valeur de résistance représente une condition de défaut modérée. Courant de crête : le courant de crête dans ce scénario est plus faible que dans le cas de 0,01 ohms, mais reste suffisamment important pour être détecté par le système de protection.
- Résistance de défaut : 100 ohms À une résistance de défaut élevée de 100 ohms, le courant de défaut est considérablement réduit. Cette résistance élevée indique un défaut à haute impédance, qui est plus difficile à détecter en raison des niveaux de courant plus faibles.
- Courant de crête : le courant de crête est le plus faible dans ce scénario, d'où l'importance de disposer de mécanismes de détection sensibles pour identifier ces défauts. Observations détaillées
- Tendances du courant de crête : La figure montre que le courant de crête est inversement corrélé à la résistance du défaut. Lorsque la résistance augmente, le courant de crête diminue.
- Défis en matière de détection : Les défauts à haute résistance posent un défi important pour la détection en raison de leurs faibles pics de courant. Des techniques avancées de détection des défauts sont nécessaires pour identifier ces défauts avec précision. L'analyse des pics de courant de défaut sous différentes résistances montre que :
 - Faible résistance (0,01 Ohms) : Les courants de crête sont très élevés et facilement détectables.
 - Résistance modérée (10 Ohms) : Elle entraîne des courants de pointe modérés, détectables avec les méthodes standard.
 - Résistance élevée (100 Ohms) : Se traduit par des courants de pointe faibles, nécessitant des techniques de détection sensibles et avancées.

Ces informations sont cruciales pour la conception et l'étalonnage des systèmes de détection et de localisation des défauts dans les systèmes HVDC VSC afin de garantir un fonctionnement fiable dans diverses conditions de défaut.

TABLE 5.2 – Relation entre RF (Ohm) et Ipos peak (kA)

RF Ω	Ipos peak (kA)
0.01	2,172
10	1,929
100	1,271




FIGURE 5.26 – Courant de défaut dans différents scénarios 0,01, 10, 100 ohms

5.7 Résultat de la classification

Les figures suivantes présentent les résultats obtenus à l'issue de la phase de classification appliquée au système HVDC. Elles illustrent les performances des différents algorithmes d'apprentissage automatique déployés pour détecter et classifier les défauts.

Parmi ces résultats, les matrices de confusion jouent un rôle central : elles mettent en évidence les taux de classification des différents types de défauts. Chaque matrice compare les classes prédites aux classes réelles, permettant d'identifier précisément les cas correctement classés, les erreurs de classification, ainsi que les éventuelles confusions entre classes voisines.

En complément, des courbes d'ajustement sont également présentées dans la phase de localisation des défauts. Ces courbes permettent d'évaluer la précision des modèles de régression utilisés pour estimer la position exacte du défaut sur la ligne HVDC. Elles offrent une visualisation claire de la correspondance entre les valeurs estimées et les valeurs réelles, permettant ainsi d'analyser l'exactitude et la fiabilité de la méthode de localisation.

Ces représentations graphiques permettent d'évaluer la précision, la robustesse et la fiabilité des méthodes utilisées dans divers scénarios de test.




FIGURE 5.27 – gravité de la faille par ML




FIGURE 5.28 – Catégories de fautes par ML




FIGURE 5.29 – Ajustements des courbes pour des défauts de pôle positif dans des résistances de 0.01, 10 et 100 respectivement par l’optimisation de la région de confiance $R=0.99$.




FIGURE 5.30 – Ajustements des courbes pour des défauts de pôle négatif dans des résistances de 0.01, 10 et 100 respectivement par l’optimisation de la région de confiance $R=0.99$.




FIGURE 5.31 – Ajustements des courbes pour des défauts de pôle positif à négatif dans des résistances de 0.01, 10 et 100 respectivement par l’optimisation de la région de confiance $R=0.99$.

5.7.1 Analyse détaillée

- 1. ajustement de la série de Fourier L’application de l’ajustement de la série de Fourier avec différents termes démontre une grande précision dans la modélisation des conditions de défaillance. Plus précisément, il s’agit d’une série de Fourier à cinq termes : Série de Fourier à cinq termes : Cette méthode est employée pour les défauts de pôle positif à travers des résistances de 0,01, 10 et 100 ohms. L’ajustement a atteint un coefficient de corrélation (R) de 0,99, ce qui indique un ajustement presque parfait. La capacité à modéliser le défaut avec un nombre limité de termes suggère l’efficacité de la méthode. Série de Fourier à six termes : Appliquée aux défauts passant d’un pôle positif à un pôle négatif, cette approche a également donné une valeur R de 0,99. Le terme supplémentaire permet de capturer la dynamique de scénarios de défauts plus complexes sans compromettre la précision de l’ajustement.
- 2. ajustement polynomial L’étude a utilisé un ajustement polynomial du neuvième degré pour les défauts de pôle négatif, couvrant la même gamme de résistances (0,01, 10 et 100 ohms). La valeur R de 0,99 obtenue souligne la capacité de l’ajustement polynomial à modéliser les conditions de défaut avec précision.

- Cependant, le polynôme de degré supérieur indique un modèle plus complexe, ce qui peut impliquer un effort de calcul accru par rapport à la série de Fourier.
- 3. Ajustement gaussien L'ajustement de la série gaussienne à trois termes a été testé pour différentes conditions de défaut et différents niveaux de résistance. Comme les autres méthodes, il a atteint une valeur R de 0,99. Les performances du modèle gaussien suggèrent qu'il peut capturer efficacement les caractéristiques du défaut, offrant une alternative aux méthodes de Fourier et polynomiales, potentiellement avec des compromis de calcul différents.

La méthode d'optimisation de la région de confiance a joué un rôle crucial dans l'obtention de coefficients de corrélation élevés pour toutes les techniques d'ajustement. Cette méthode garantit que la solution converge vers un minimum local qui est le plus représentatif des caractéristiques sous-jacentes du défaut. La robustesse de l'approche de la région de confiance est évidente à partir des valeurs R constamment élevées, reflétant son aptitude à la modélisation de défauts complexes dans les systèmes HVDC.

5.8 Résultat de test

5.8.1 Pour une résistance de défaut de 0.01 ohm

TABLE 5.3 – Tableau des fautes à la terre positives

Positive ground fault (KA)	ACTUAL(KM)	Est(KM)	Error%
2,172	15	14.91	0.12
2,17	20	19.87	0.17
2,166	25	25.10	0.10
2,164	30	30.24	0.32
2,163	35	34.11	1.10
MAE% = 0.362			

TABLE 5.4 – Tableau des fautes à la terre négatives

Negative ground fault(KA)	ACTUAL(KM)	Est(KM)	Error%
2,18	15	14,97	0,1
2,177	25	24,96	0
2,171	30	30	0
2,17	35	34,92	0,06
2,175	40	39,95	0,05
MAE% = 0,04			

TABLE 5.5 – Tableau des fautes positives et négatives

Positive negative fault(KA)	ACTUAL(KM)	Est(KM)	Error%
3,737	15	15,03	0,04
3,732	20	19,81	0,12
3,728	25	25,36	0,48
3,724	30	29,57	0,57
3,719	35	35,20	0,26
MAE% = 0,294			

5.8.2 Pour une résistance de défaut de 10 ohm

TABLE 5.6 – Tableau des fautes à la terre positives

Positive ground fault(KA)	ACTUAL(KM)	Est(KM)	Error%
1,929	15	15	0
1,925	20	20	0
1,924	25	24,9	0,13
1,921	30	29,99	0,01
1,919	35	37,5	3,3
MAE% = 0,688			

TABLE 5.7 – Tableau des fautes à la terre négatives

Negative ground fault(KA)	ACTUAL(KM)	Est(KM)	Error%
1,937	25	24,89	0,1
1,935	30	30	0
1,933	35	35,75	1
1,932	40	38,68	1,69
1,929	45	46,5	1,88
MAE% = 0,934			

TABLE 5.8 – Tableau des fautes positives et négatives

Positive negative fault(KA)	ACTUAL(KM)	Est(KM)	Error%
3,301	20	19,91	0,12
3,296	25	25,11	0,14
3,291	30	29,69	0,41
3,286	35	35,34	0,45
3,281	40	39,48	0,69
MAE% = 0,362			

5.8.3 Pour une résistance de défaut de 100 ohm

TABLE 5.9 – Tableau des fautes à la terre positives

Positive ground fault(KA)	ACTUAL(KM)	Est(KM)	Error%
1,271	15	14,92	0,1
1,267	40	40	0,06
1,263	60	59,98	0
1,262	65	64,99	0,1
1,265	70	70,17	0
MAE% = 0,05			

TABLE 5.10 – Tableau des fautes à la terre négatives

Negative ground fault(KA)	ACTUAL(KM)	Est(KM)	Error%
1,271	25	25,2	0,26
1,268	35	35,12	0,16
1,267	40	39,94	0,08
1,269	45	44,99	0,01
1,262	60	59,99	0,01
MAE% = 0,104			

TABLE 5.11 – Tableau des fautes positives et négatives

Positive negative fault(KA)	ACTUAL(KM)	Est(KM)	Error%
1,686	20	20,02	0,02
1,685	25	24,98	0,02
1,684	30	29,98	0,02
1,679	40	39,99	0,01
1,676	45	45,01	0,01
MAE% = 0,016			

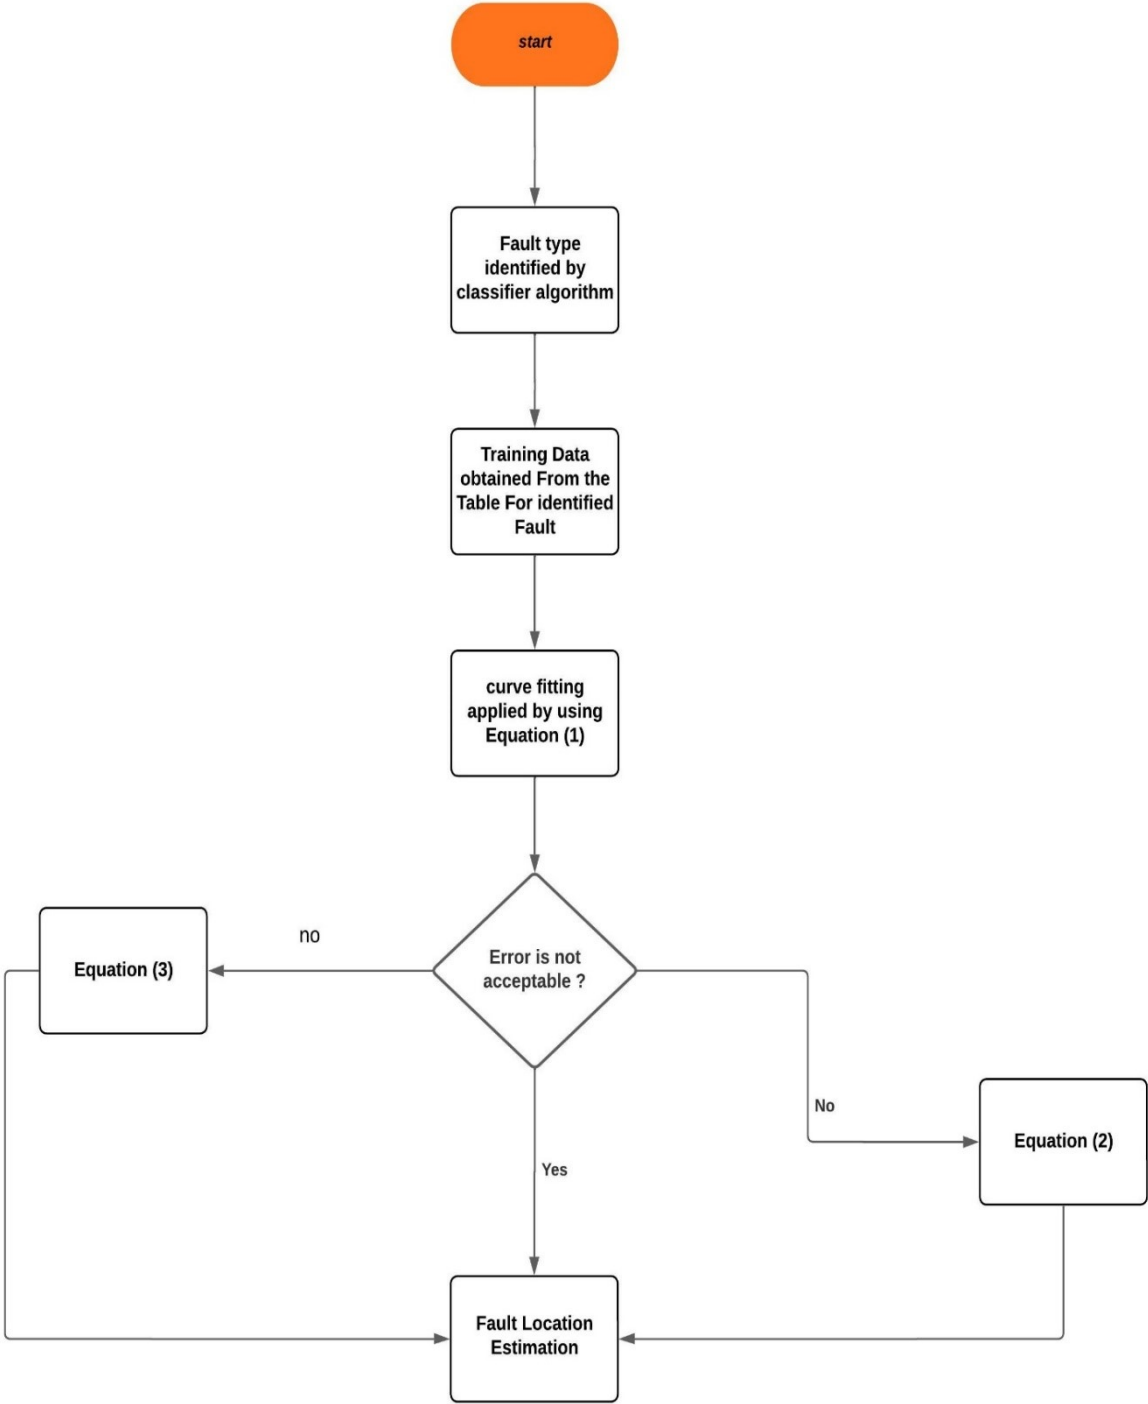


FIGURE 5.32 – Organigramme de la méthode proposé

5.9 Analyse comparative de la localisation des défauts proposée avec les méthodes existantes

TABLE 5.12 – Tableau des références et méthodes

Références	Algorithm	Signal Utilisée	Fs(kHz)	Error (%)
[139]	Voltage Distribution	Courant et tension	100	0.78
[140]	DWT	Tension	100	0.85
[141]	Wavelet	Courant	50–200	0.965
[142]	SSA	Tension	250	2.12
[143]	ANN	Tension	20	5.69
[144]	ANN	Tension de la gaine	2.5	0.88
[145]	Méthode proposée	peak courant	135	0.316

Le tableau fournit une analyse comparative de divers algorithmes de localisation des défauts en fonction de plusieurs paramètres : le type d’algorithme utilisé, le signal utilisé, la fréquence d’échantillonnage et le pourcentage d’erreur qui en résulte. Cette comparaison inclut à la fois des méthodes établies dans la littérature et une nouvelle méthode proposée. L’algorithme de distribution de tension (référence [139]) utilise des signaux de courant et de tension échantillonnés à 100 kHz et obtient un taux d’erreur de 0,78%. L’algorithme de transformée en ondelettes discrète (DWT) (référence [140]) repose sur des signaux de tension également échantillonnés à 100 kHz, avec un taux d’erreur légèrement plus élevé de 0,85%. Un autre algorithme d’ondelettes (référence [141]) utilise des signaux de courant avec une plage de fréquence d’échantillonnage plus large de 50-200 kHz, ce qui donne une erreur de 0,965%. L’Approche de Segmentation du Signal (SSA) (Référence [142]) utilise des signaux de tension échantillonnés à une fréquence élevée de 250 kHz, mais présente un taux d’erreur plus élevé de 2,12%. Les approches par réseau neuronal artificiel (ANN) (références [143] et [144]) varient en fonction des signaux et des fréquences d’échantillonnage. Une méthode utilise des signaux de tension à 20 kHz, ce qui entraîne une erreur significative de 5,69%, tandis qu’une autre utilise la tension de la gaine à une fréquence d’échantillonnage beaucoup plus basse de 2,5 kHz, ce qui permet d’obtenir un meilleur taux d’erreur de 0,88%. La méthode proposée se distingue par l’utilisation de signaux de courant échantillonnés à 135 kHz, ce qui donne le taux d’erreur le plus bas, à savoir 0,316%. Cela démontre une amélioration significative de la précision par rapport aux méthodes existantes, soulignant son efficacité potentielle dans les applications de localisation des défauts.

5.10 Limites de La méthode de localisation de défauts basées sur l’apprentissage automatique et l’ajustement de courbe

Ces approches présentent plusieurs limitations majeures. Tout d’abord, elles sont fortement dépendantes des données : elles nécessitent de grands ensembles de

données variées pour garantir une bonne capacité de généralisation. Leur performance peut être considérablement réduite lorsqu'elles sont confrontées à des scénarios non rencontrés lors de l'entraînement.

De plus, elles sont sensibles au bruit : les perturbations de mesure et les transitoires, en particulier lors de la détection des pics, peuvent affecter leur précision et leur fiabilité.

5.11 Régression par Apprentissage Automatique pour la Localisation des Défauts dans les lignes HVDC VSC

Dans cette section, nous présentons les résultats obtenus à partir de plusieurs modèles de régression utilisant des techniques d'apprentissage automatique pour la localisation des défauts dans les lignes HVDC VSC. En plus des méthodes classiques, nous avons sélectionné de nouvelles features (caractéristiques) à partir des éléments suivants : V_{left} , V_{right} , et V_{min} , représentant respectivement les tensions à gauche, à droite, et la tension minimale dans la ligne HVDC. $x(\min(V))$ ce qui signifie que la position du défaut correspond à la valeur x où V atteint son minimum. Ces caractéristiques sont particulièrement importantes pour capturer les variations de tension en présence de défauts. La nouvelle caractéristique de défaut est représentée par l'aire à gauche, ΔV_{left} , et l'aire à droite et ΔV_{right} .




FIGURE 5.33 – Illustration des variations de tension et extraction des nouvelles caractéristiques.

Les expériences ont été menées en considérant un intervalle des résistances de défaut variant entre 0 et 9 ohms, permettant ainsi de simuler aussi bien des défauts de

faible impédance que de haute impédance. Cet intervalle a été utilisé pour tester l'efficacité des modèles dans différentes conditions de résistance de défaut, ce qui est crucial pour évaluer la performance des méthodes dans des scénarios réalistes de défauts dans les lignes HVDC.

De plus, nous allons localiser l'emplacement des défauts à 25%, 40%, 50%, 60% et 75% le long de la ligne, ce qui permettra d'évaluer la précision des modèles dans diverses positions de défaut. Les défauts seront capturés dans un intervalle de 50 ms, garantissant ainsi une analyse précise des dynamiques transitoires et permettant une meilleure évaluation de la performance des modèles dans des conditions réelles. Enfin, nous allons utiliser la validation croisée avec $K_{\text{plis}}=6$ pour assurer la robustesse des résultats obtenus.

Les modèles évalués incluent : Réseau de Neurones, Régression par Processus Gaussien, et BO-Régression par Processus Gaussien.

5.11.1 Validation et Test de ANN




FIGURE 5.34 – Validation du modèle ANN




FIGURE 5.35 – Test du modèle ANN

5.11.2 Validation et Test de GPR




FIGURE 5.36 – Validation du modèle GPR




FIGURE 5.37 – Test du modèle GPR

5.11.3 Validation et Test de BO-GPR




FIGURE 5.38 – Validation du modèle BO-GPR




FIGURE 5.39 – Test du modèle BO-GPR

5.12 Resultat et interprétation

Tableau des Résultats Les résultats de validation et de test pour différents modèles sont présentés ci-dessous :

TABLE 5.13 – Performance des modèles pour la localisation des défauts dans le systèmes HVDC VSC (validation) .

Modèle	RMSE (Validation)	MSE (Validation)	R ² (Validation)	MAE (Validation)
Réseau de Neurones	0.014757	0.000218	0.992155	0.010376
Régression par Processus Gaussien	0.016935	0.000287	0.989668	0.011041
BO-Régression par Processus Gaussien	0.013583	0.000185	0.993353	0.009249

TABLE 5.14 – Performance des modèles pour la localisation des défauts dans le système HVDC VSC (test).

Modèle	MAE (Test)	MSE (Test)	RMSE (Test)	R ² (Test)
Réseau de Neurones	0.005371	0.000041	0.006404	0.998586
Régression par Processus Gaussien	0.008981	0.000172	0.013101	0.994081
BO-Régression par Processus Gaussien	0.006089	0.000071	0.008426	0.997552

Le tableau présente les performances de trois modèles différents utilisés pour la localisation des défauts dans les systèmes HVDC VSC. Voici une analyse des résultats :

1. Réseau de Neurones : Ce modèle montre de très bonnes performances, avec un RMSE de validation de **0,014757** et un R² de validation de **0,992155**, indiquant une forte corrélation entre les prédictions et les valeurs réelles. Le modèle maintient également une excellente performance en phase de test avec un RMSE de **0,006404** et un R² de **0,998586**, ce qui montre une très grande précision sur des données non vues.

2. Régression par Processus Gaussien : La régression par processus gaussien présente des performances légèrement inférieures à celles du réseau de neurones, avec un RMSE de validation de **0,016935** et un R² de validation de **0,989668**. Bien que ses résultats de validation soient corrects, ses performances en phase de test sont plus faibles, avec un RMSE de **0,013101** et un R² de **0,994081**, ce qui suggère une moins bonne généralisation par rapport aux autres modèles.

3. BO-Régression par Processus Gaussien : Le modèle optimisé par Bayes pour la régression par processus gaussien (**BO-GPR**) surpasse la version standard du GPR, avec un RMSE de validation de **0,013583** et un R² de validation de **0,993353**, ce qui montre une meilleure capacité de modélisation que le GPR simple. En phase de test, le modèle montre également de bonnes performances avec un RMSE de **0,008426** et un R² de **0,997552**. Cela démontre que l'optimisation bayésienne a permis d'améliorer significativement la précision du modèle.

Interprétation des Résultats

Comparaison de la Précision : Le modèle de réseau de neurones artificiels (**ANN**) présente la plus faible erreur moyenne (0,5371 %) et erreur maximale (1,2642 %), ce qui en fait le modèle le plus précis pour la localisation des défauts sous les conditions de défaut frontal.

$$\text{Error} = \left(\frac{L_a - L_f}{L} \right) \times 100 \quad (5.1)$$

- L est la longueur totale de la ligne.
- L_a est la distance réelle du défaut.
- L_f est la distance du défaut estimée en utilisant l'approche proposée.

Quantification de l'Incertitude : Cependant, le modèle de régression par processus gaussien optimisé par Bayes (**BO-GPR**) avec une erreur moyenne de 0,6089 % et une erreur maximale de 1,0669 % peut être préféré dans les scénarios où la quantification de l'incertitude est nécessaire. En effet, **BO-GPR** tient compte de l'incertitude dans ses prédictions, offrant ainsi des résultats plus fiables dans des environnements complexes ou bruités. Bien que l'erreur moyenne de l'**ANN** soit légèrement inférieure, la quantification de l'incertitude fournie par **BO-GPR** ajoute de la robustesse à ses prédictions, ce qui en fait une option plus appropriée lorsque la confiance dans la précision des localisations est importante.

En conclusion, sous la quantification de l'incertitude, **BO-GPR** surpasse **ANN** en offrant des prédictions plus fiables et consistantes, même si l'erreur est légèrement plus élevée. En revanche, le modèle de **GPR** présente les taux d'erreur les plus élevés, ce qui le rend moins adapté à ces conditions. Ces résultats confirment l'efficacité des approches basées sur l'apprentissage automatique pour la détection et la localisation des défauts dans les systèmes HVDC VSC. L'utilisation de l'optimisation bayésienne (BO) dans la régression par processus gaussien a permis de raffiner davantage la précision des prédictions.

Les erreurs moyennes et maximales pour chaque modèle sont présentées ci-dessous :

TABLE 5.15 – Erreurs moyennes et maximales des modèles.

Modèle	Erreur moyenne (%)	Erreur maximale (%)
ANN	0,5371	1,2642
GPR	0,8981	2,8883
BO-GPR	0,6089	1,0669

5.13 Conclusion , Défis et orientations futures

Grâce à nos recherches, il devient évident que la fusion des méthodologies d'apprentissage automatique et d'ajustement des courbes fournit une solution robuste et adaptable pour la localisation des défauts dans les systèmes HVDC. L'utilisation conjointe de ces approches permet non seulement d'améliorer la précision de l'identification des défauts, mais aussi de mieux comprendre le comportement dynamique du système. Cette approche interdisciplinaire est prometteuse pour faire progresser les technologies de détection des défauts dans le domaine des systèmes HVDC, contribuant ainsi à la fiabilité et à l'efficacité des réseaux de transmission d'énergie.

Cependant, plusieurs défis se profilent à l'horizon dans la poursuite des progrès. L'impact des sources d'énergie renouvelables sur les algorithmes de localisation des défauts constitue un obstacle important. Alors que l'intégration des énergies renouvelables dans les réseaux électriques continue de croître, la nature intermittente de ces sources introduit des complexités que les méthodes traditionnelles de localisation des défauts peuvent avoir du mal à résoudre. Les algorithmes adaptatifs de localisation des défauts capables de prendre en compte la variabilité des apports d'énergie renouvelable seront essentiels pour garantir la fiabilité de la détection des défauts dans les futurs systèmes HVDC. En outre, le développement de méthodes hétérogènes d'apprentissage multi-machines pour les tests et la validation représente une autre voie à explorer. L'intégration de diverses techniques d'apprentissage automatique et l'exploitation de sources de données multiples peuvent améliorer la robustesse et la généralisation des modèles de localisation des défauts. Cependant, concilier la nature disparate de ces méthodes et valider efficacement leurs performances constitue un défi de taille.

Conclusion Générale

Cette thèse a exploré en profondeur la problématique de la classification et de la localisation des défauts dans les lignes de transmission HVDC VSC bipolaires, un sujet d'une importance croissante dans le contexte de la transition énergétique mondiale. À travers une approche méthodique, nous avons pu démontrer l'importance d'une détection précoce et d'une classification précise des défauts pour assurer la fiabilité et la durabilité de ces systèmes critiques.

Dans un premier temps, nous avons fourni un aperçu complet des systèmes HVDC, en mettant en lumière leurs principes de fonctionnement, leurs avantages et leurs défis. La modélisation des systèmes HVDC a permis d'établir une base solide pour comprendre les phénomènes physiques sous-jacents qui peuvent conduire à des défaillances. Ensuite, nous avons examiné les différentes méthodes de détection et de localisation des défauts, soulignant les techniques existantes ainsi que leurs limitations.

L'application de l'apprentissage automatique pour la classification des défauts a constitué une avancée significative dans notre étude. Les résultats obtenus montrent que ces méthodes peuvent améliorer considérablement la précision de la classification par rapport aux techniques traditionnelles. L'ajustement de courbe et les méthodes de moindres carrés non linéaires ont également joué un rôle crucial dans l'affinement des modèles de prédiction, démontrant ainsi l'importance de la modélisation mathématique dans le domaine des systèmes HVDC.

Les résultats et les discussions présentés dans cette thèse mettent en évidence les performances prometteuses des approches basées sur l'apprentissage automatique, ouvrant la voie à de futures recherches dans ce domaine. Ces travaux pourraient également avoir des implications significatives pour l'exploitation et la maintenance des infrastructures HVDC, contribuant à une gestion proactive des défauts et à l'amélioration de la fiabilité des réseaux électriques.

En ce sens, l'intelligence artificielle s'impose comme un outil stratégique pour répondre aux exigences de rapidité, de précision et d'adaptabilité des systèmes de protection modernes. Grâce à ses capacités d'apprentissage, de traitement massif de données et de prise de décision en temps réel, l'IA peut devenir un levier essentiel pour la détection intelligente, la classification automatique, et la protection efficace contre les défauts dans les réseaux HVDC complexes et dynamiques.

En somme, cette thèse représente une contribution significative à la compréhension et à l'amélioration des systèmes HVDC VSC bipolaires. Elle pave la voie à de nouvelles recherches et à des applications pratiques qui pourraient transformer la

manière dont nous gérons et optimisons ces systèmes essentiels pour la transition énergétique.

Bibliographie

Bibliographie

- [1] O. Peake, "The history of high voltage direct current transmission," *Aust. J. Multi-Discip. Eng.*, vol. 8, pp. 47–55, 2010.
- [2] G. Asplund, L. Carlsson, O. Tollerz, "50 years HVDC Part I ABB – from pioneer to world leader," *ABB Rev.*, vol. 4, pp. 6–13, 2003.
- [3] L. Haglöf, "HVDC Veterans' Presentations—The History of HVDC Part 1 : The Mercury Arc Valve Era," in *HVDC 50 years : Presentation at the Gotland seminar*, 6 May 2004, ABB, Zürich, Switzerland, 2004.
- [4] Z. Melhem, *Electricity Transmission Distribution and Storage Systems*, Oxford, UK : Woodhead Publishing, 2013.
- [5] M.H. Okba, M.H. Saied, M.Z. Mostafa, T.M. Abdel Moneim, "High voltage direct current transmission—A review part I," in *Proc. IEEE Energytech*, Cleveland, OH, USA, 2012, pp. 1–7.
- [6] Stan, A., Costinaş, S. and Ion, G., *Overview and Assessment of HVDC Current Applications and Future Trends*, *Energies*, vol. 15, no. 3, pp. 1–25, 2022. <https://doi.org/10.3390/en15031193>
- [7] G. Flisberg, C. Carlsson, R. Moni, A. Boveri, "Global Trends in Bulk Power Transmission," ABB Group, Ludvika, Sweden, 2009.
- [8] M. Bahrman, B. Johnson, "The ABCs of HVDC transmission technologies," *IEEE Power Energy Mag.*, vol. 5, pp. 32–44, 2007.
- [9] B. Andersen, C. Barker, "A new era in HVDC?" *IEEE Rev.*, vol. 46, pp. 33–39, 2000.
- [10] Z. Liu, F. Zhang, J. Yu, K. Gao, W. Ma, "Research on key technologies in 1100 kV ultra-high voltage DC transmission," *High Volt.*, vol. 3, pp. 279–288, 2018.
- [11] A. Meier, *Electric Power Systems*, 1st ed., Hoboken, NJ, USA : Wiley, IEEE Press, 2006.
- [12] J. Setréus, R. Eriksson, S. Karlsson, O. Swaitti, R. Leelaruji, L. Yu, "Study visit at the SwePol HVDC Link," Royal Institute of Technology (KTH), Stockholm, Sweden, 2006.
- [13] J. Skog, K. Koreman, B. Pääjärvi, T. Andersröd, "The Norned HVDC Cable Link—A Power Transmission Highway between Norway and The Netherlands," *ENERGEX*, Stavanger, Norway, 2006.
- [14] P. Pourbeik, M. Bahrman, J. John, W. Wong, "Modern countermeasures to blackouts," *IEEE Power Energy Mag.*, vol. 4, pp. 36–45, 2006.
- [15] H. Wang, M.A. Redfern, "The advantages and disadvantages of using HVDC to interconnect AC networks," in *Proc. 45th Int. Universities Power Engineering Conf. (UPEC)*, Cardiff, UK, 2010, pp. 1–5.

- [16] C. Dong, H. Zhang, Y. Li, W. Jiang, X. Gao, "Security and stability control strategy of Gaoling back-to-back HVDC project," *Dianwang Jishu Power Syst. Technol.*, vol. 39, pp. 1240–1245, 2015.
- [17] D. Retzmann, "HVDC Station Layout Equipment LCC VSC and Integration of Renewables Using HVDC," Cigré Tutorial, Paris, France, 2012.
- [18] H.V.D.C. Alstom, *HVDC for Beginners and Beyond*, Saint-Ouen, France : Alstom, 2010.
- [19] V.G. Csutar, S. Kallikuppa, L. Charles, *Introduction to HVDC Architecture and Solutions for Control and Protection*, Dallas, TX, USA : Texas Instruments, 2020.
- [20] T. Jonsson, "High Power Electronics for HVDC Power Transmission," TSTE19 Power Electronics Lecture, ABB Grid Systems, Västerås, Sweden, 2015.
- [21] R. Roy, M. Amin, "A paper of determination of controlling characteristics of the monopolar HVDC system," *Int. J. Hybrid Inf. Technol.*, vol. 7, pp. 105–120, 2014.
- [22] L. Brand, R. de Silva, E. Bebbington, K. Chilukuri, "GridWest Project HVDC Technology Review," EirGrid PSC Specialist Consultants for Electricity Industry, Dublin, Ireland, 2014.
- [23] A. Stan, S. Costinaş, and G. Ion, "Overview and Assessment of HVDC Current Applications and Future Trends," *Energies*, vol. 15, no. 3, p. 1193, 2022, doi : [10.3390/en15031193](https://doi.org/10.3390/en15031193).
- [24] Van Eeckhout, B., Van Hertem, D., Reza, M., Srivastava, K. et Belmans, R., *Economic comparison of VSCHVDC and HVAC as transmission system for a 300MW offshore wind farm*, *European Transactions on Electrical Power*, vol.20, no5, pp.661–671, 2009.
- [25] O. Heyman, L. Weimers, M. L. Bohl, « HVDC – a key solution in future transmission systems », ABB, 2010.
- [26] R. Sharma, « Electrical structure of future offshore wind power plants with HVDC transmission », DTU, 2012.
- [27] S. K. Chaudhary, « Control and protection of wind power plants with VSC-HVDC connection », Aalborg University, 2011.
- [28] D. Kong, « Advanced HVDC systems for renewable energy integration and power transmission : Modelling and control for power system transient stability », University of Birmingham, 2013.
- [29] A. Korompili, Q. Wu, and H. Zhao, "Review of VSC HVDC connection for offshore wind power integration," *Renewable & Sustainable Energy Reviews*, vol. 59, pp. 1405–1414, 2016. doi : [10.1016/j.rser.2016.01.064](https://doi.org/10.1016/j.rser.2016.01.064)
- [30] A. Hassanpoor, K. Ilves, S. Norrga, L. Ängquist, H.-P. Nee, "Tolerance band modulation methods for modular multilevel converters," , 2013.
- [31] M. Davies et al., "HVDC PLUS – basics and principle of operation," Siemens AG, 2008.
- [32] C. Du, *VSC-HVDC for Industrial Power Systems*, Dissertation, Chalmers University of Technology, Göteborg, 2007.
- [33] R. Grünbaum, B. Halvarsson, and A. Wilk-Wilczynski, "FACTS and HVDC LIGHT for power system interconnections," ABB, 2003. [Online]. Available : <http://www.abb.com/hvdc>

- [34] Y. Jiang-Häfner, H. Duchén, K. Lindén, M. Hyttinen, P. Fischer de Toledo, T. Tulkiewicz *et al.*, “Improvement of subsynchronous torsional damping using VSC HVDC,” ABB, 2003. [Online]. Available : <http://www.abb.com/hvdc>
- [35] G. Asplund, “HVDC using voltage source converters - a new way to build highly controllable and compact HVDC substations,” ABB, 2003. [Online]. Available : <http://www.abb.com/hvdc>
- [36] M. P. Bahrman and B. K. Johnson, “The ABCs of HVDC transmission technology,” *IEEE Power and Energy Magazine*, vol. 5, pp. 32–44, 2007.
- [37] A. Lesnicar and R. Marquardt, “An innovative modular multilevel converter topology suitable for a wide power range,” in *Proc. IEEE Bologna PowerTech*, Bologna, Italy, Jun. 2003.
- [38] ABB, “HVDC LIGHT - Official resources,” 2008. [Online]. Available : <http://www.abb.com/hvdc>
- [39] Carlsson L. HVDC, a “firewall” against disturbances in high-voltage grids [Internet]. ABB, 2008. Available from : <http://www.abb.com/hvdc>
- [40] Papadopoulos C, Papageorgiou P, Stendius L, Åström J, Hyttinen M, Johansson S. Interconnection of Greek islands with dispersed generation via HVDC LIGHT technology [Internet]. ABB, 2008. Available from : <http://www.abb.com/hvdc>
- [41] Johansson SG, Asplund G, Jansson E, Rudervall R. Power system stability benefits with VSC DC-transmission systems [Internet]. ABB, 2008. Available from : <http://www.abb.com/hvdc>
- [42] Jiang-Häfner Y, Duchén H, Lindén K, Hyttinen M, Fischer de Toledo P, Tulkiewicz T, et al. Improvement of subsynchronous torsional damping using VSC HVDC [Internet]. ABB, 2003. Available from : <http://www.abb.com/hvdc>
- [43] P. Chen, B. Xu, and J. Li, “A traveling wave based fault locating system for hvdc transmission lines,” in 2006 International Conference on Power System Technology, Oct 2006, pp. 1–4.
- [44] J. Yang, J. E. Fletcher, and J. O’Reilly, “Short-circuit and ground fault analyses and location in vsc-based dc network cables,” *IEEE Transactions on Industrial Electronics*, vol. 59, no. 10, pp. 3827–3837, Oct 2012.
- [45] G. Song, X. Cai, S. Gao, J. Suonan, and G. Li, “Natural frequency based protection and fault location for vsc-hvdc transmission lines,” in 2011 International Conference on Advanced Power System Automation and Protection, vol. 1, Oct 2011, pp. 177–182.
- [46] H. Cui and N. Tu, “Hvdc transmission line fault localization base on rbf neural network with wavelet packet decomposition,” in 2015 12th International Conference on Service Systems and Service Management(ICSSSM), June 2015, pp. 1–4.
- [47] L. Bao-de and T. Jian-cheng, “Transient fault location for hvdc transmission lines based on voltage distribution and one-terminal information,” in 2014 China International Conference on Electricity Distribution(CICED), Sept 2014, pp. 508–510.
- [48] L. Yuansheng, W. Gang, and L. Haifeng, “Time-domain fault-location method on hvdc transmission lines under unsynchronized two-end measurement and uncertain line parameters,” *IEEE Transactions on Power Delivery*, vol. 30, no. 3, pp. 1031–1038, June 2015.

- [49] Y. Qiu, H. Li, L. Guo, J. Wu, and Y. Liang, "A fault location method for double-circuit hvdc transmission lines on the same tower based on mixed modulus," in 2015 IEEE Eindhoven PowerTech, June 2015, pp. 1–5.
- [50] B. Li, J. He, Y. Li, and B. Li, "A review of the protection for the multiterminal VSC-HVDC grid," *Protection Control Mod. Power Syst.*, vol. 4, no. 1, p. 21, Dec. 2019.
- [51] L. I. Bin, H. E. Jiawei, T. Jie, F. Yadong, and D. O. N. G. Yunlong, "DC fault analysis for modular multilevel converter-based system," *J. Mod. Power Syst. Clean Energy*, vol. 5, no. 2, pp. 275–282, 2017.
- [52] S. L. Blond, R. Bertho, D. V. Coury, and J. C. M. Vieira, "Design of protection schemes for multi-terminal HVDC systems," *Renew. Sustain. Energy Rev.*, vol. 56, pp. 965–974, Apr. 2016.
- [53] D. Jovcic, D. van Hertem, K. Linden, J.-P. Taisne, and W. Grieshaber, "Feasibility of DC transmission networks," in *Proc. 2nd IEEE PES Int. Conf. Exhib. Innov. Smart Grid Technol.*, Dec. 2011, pp. 1–8.
- [54] L. Tang and B.-T. Ooi, "Locating and isolating DC faults in multiterminal DC systems," *IEEE Trans. Power Del.*, vol. 22, no. 3, pp. 1877–1884, Jul. 2007.
- [55] J. Cheng, M. Guan, L. Tang, and H. Huang, "A fault location criterion for MTDC transmission lines using transient current characteristics," *Int. J. Electr. Power Energy Syst.*, vol. 61, pp. 647–655, Oct. 2014.
- [56] J. Liu, N. Tai, C. Fan, S. Chen, and P. Wu, "A fault detection method for DC lines in VSC-HVDC system based on current correlation," in *Proc. IEEE Power Energy Soc. Gen. Meeting (PESGM)*, Jul. 2016, pp. 1–5.
- [57] J. Sneath and A. D. Rajapakse, "Fault detection and interruption in an earthed HVDC grid using ROCOV and hybrid DC breakers," *IEEE Trans. Power Del.*, vol. 31, no. 3, pp. 973–981, Jun. 2016.
- [58] R. Li, L. Xu, and L. Yao, "DC fault detection and location in meshed multiterminal HVDC systems based on DC reactor voltage change rate," *IEEE Trans. Power Del.*, vol. 32, no. 3, pp. 1516–1526, Jun. 2017.
- [59] K. de Kerf, K. Srivastava, M. Reza, D. Bekaert, S. Cole, D. V. Hertem, and R. Belmans, "Wavelet-based protection strategy for DC faults in multiterminal VSC HVDC systems," *IET Gener., Transmiss. Distrib.*, vol. 5, no. 4, pp. 496–503, Apr. 2011.
- [60] O. M. K. Nanayakkara, A. D. Rajapakse, and R. Wachal, "Traveling wave-based line fault location in star-connected multiterminal HVDC systems," *IEEE Trans. Power Del.*, vol. 27, no. 4, pp. 2286–2294, Oct. 2012.
- [61] F. V. Lopes, D. Fernandes, and W. L. A. Neves, "A traveling-wave detection method based on Park's transformation for fault locators," *IEEE Trans. Power Del.*, vol. 28, no. 3, pp. 1626–1634, Jul. 2013.
- [62] S. Azizi, M. Sanaye-Pasand, M. Abedini, and A. Hasani, "A traveling wave-based methodology for wide-area fault location in multiterminal DC systems," *IEEE Trans. Power Del.*, vol. 29, no. 6, pp. 2552–2560, Dec. 2014.
- [63] J. Cheng, X. Chen, H. Huang, J. Xie, L. Tang, and M. Guan, "Paralleled multi-terminal DC transmission line fault locating method based on travelling wave," *IET Gener., Transmiss. Distrib.*, vol. 8, no. 12, pp. 2092–2101, Dec. 2014.

- [64] J. M. Johnson and A. Yadav, "Complete protection scheme for fault detection, classification and location estimation in HVDC transmission lines using support vector machines," *IET Sci., Meas. Technol.*, vol. 11, no. 3, pp. 279–287, May 2017.
- [65] Q. Yang, S. Le Blond, R. Aggarwal, Y. Wang, and J. Li, "New ANN method for multi-terminal HVDC protection relaying," *Electric Power Syst. Res.*, vol. 148, pp. 192–201, Jul. 2017.
- [66] J. I. Marvik, S. D'arco, and J. A. Suul, "Communication-less fault detection in radial multi-terminal offshore HVDC grids," in *Proc. 11th IET Int. Conf. AC DC Power Transmiss.*, Feb. 2015, pp. 1–8, doi : 10.1049/cp.2015.0050.
- [67] X. Sun, X. Tong, and J. Yin, "Fault diagnosis for VSC-HVDC using wavelet transform," in *Proc. Asia-Pacific Power Energy Eng. Conf.*, Mar. 2012, pp. 1–4.
- [68] J. Li, Y. Li, L. Xiong, K. Jia, and G. Song, "DC fault analysis and transient average current based fault detection for radial MTDC system," *IEEE Trans. Power Del.*, vol. 35, no. 3, pp. 1310–1320, Jun. 2020.
- [69] WendBenedo Arnaud Bienvenue ZOUNGRANA, mémoire, « Application des algorithmes d'apprentissage automatique pour la détection de défauts de roulements sur les machines tournantes dans le cadre de l'Industrie 4.0. », 2020.
- [70] Y. Xiang, K.L. Chen, Q. Xu, Z. Jiang, and Z. Hong, "A novel contactless current sensor for HVDC overhead transmission lines," *IEEE Sensors J.*, vol. 18, pp. 4725–4732, 2018.
- [71] D. Tzelepis, V. Psaras, E. Tsotsopoulou, S. Mirsaeidi, A. Dysko, Q. Hong, X. Dong, S.M. Blair, V.C. Nikolaidis, and V. Papaspiliotopoulos, "Voltage and current measuring technologies for high voltage direct current supergrids : A technology review identifying the options for protection, fault location and automation applications," *IEEE Access*, vol. 8, pp. 203398–203428, 2020.
- [72] H. Packard, "Traveling wave fault location in power transmission systems," *Application Note*, 1285, 1997.
- [73] M. A. Baseer, "Travelling waves for finding the fault location in transmission lines," *Journal of Electronic and Electrical Engineering*, vol. 1, no. 1, pp. 1–19, 2013.
- [74] X. Liu, A. H. Osman, and O. P. Malik, "Hybrid Travelling wave/boundary protection for Monopolar HVDC line," *IEEE Trans. Power Del.*, vol. 24, no. 2, pp. 569–578, 2009.
- [75] X. Liu, A. H. Osman, and O. P. Malik, "Real time implementation of a hybrid protection scheme for bipolar HVDC line using FPGA," *IEEE Trans. Power Del.*, vol. 26, no. 1, pp. 101–108, 2011.
- [76] O. M. K. K. Nanayakkara, A. D. Rajapakse, and R. Wachal, "Travelling wave based line fault location in star connected multiterminal HVDC systems," *IEEE Trans. Power Del.*, vol. 27, no. 4, pp. 2286–2294, 2012.
- [77] Y. Li, G. Y., and B. Jiang, "A novel traveling-wave-based directional protection scheme for MTDC grid with inductive DC terminal," *Electric Power Syst. Res.*, vol. 157, pp. 83–92, 2018.
- [78] W. Hao, S. Mirsaeidi, X. Kang, X. Dong, and D. Tzelepis, "A novel traveling-wave-based protection scheme for LCC-HVDC systems using Teager energy operator," *Int. J. Electr. Power Energy Syst.*, vol. 99, pp. 474–480, 2018.

- [79] M. Ikhide, S. B. Tennakoon, A. L. Griffiths, H. Ha, S. Subramanian, and A. J. Adamczyk, "A novel time domain protection technique for multi-terminal HVDC networks utilising travelling wave energy," *Sustainable Energy Grids and Networks*, vol. 16, pp. 300–314, 2018.
- [80] Z. Y. He, K. Liao, P. Li, X. Lin, J. W. Yang, and R. K. Mai, "Natural frequency-based line fault location in HVDC lines," *IEEE Trans. Power Del.*, vol. 29, no. 2, pp. 851–859, 2014.
- [81] G. W. Swift, "The spectra of fault-induced transients," *IEEE Trans. Power Apparatus and Systems*, vol. PAS-98, no. 3, pp. 940–947, 1979.
- [82] E. Styvaktakis, M. H. J. Bollen, and I. Y. Gu, "A fault location technique using high frequency fault clearing transients," *IEEE Power Eng. Rev.*, vol. 19, no. 5, pp. 58–60, 1999.
- [83] L. Yongli, Z. Yi, and M. Zhiyu, "Fault location method based on the periodicity of the transient voltage traveling wave," in *Proc. IEEE Region 10 Conference TENCN 2004, Thailand, 2004*, pp. 389–392.
- [84] S. F. Huang and X. G. Wang, "A fault location scheme based on spectrum characteristic of fault-generated high-frequency transient signals," in *Proc. IEEE Power Energy Society General Meeting, Canada, 2009*, pp. 1–5.
- [85] L. Y. Wu, Z. Y. He, and Q. Q. Qian, "A new single ended fault location technique using travelling wave natural frequencies," in *Proc. Asia-Pacific Power Energy Eng. Conf., China, 2009*, pp. 1–5.
- [86] S. Guobing, C. Xinlei, G. Shuping, S. Jiale, and L. Guang, "Natural frequency based protection and fault location for VSC-HVDC transmission lines," in *Proc. Int. Conf. Adv. Power Syst. Autom. Protection (APAP), Beijing, China, 2011*, pp. 177–182.
- [87] S. Guobing, C. Xu, C. Xinlei, G. Shuping, and R. Mengbing, "A fault location method for VSC HVDC transmission lines based on natural frequency of current," *Int. J. Electr. Power Energy Syst.*, vol. 63, pp. 347–352, 2014.
- [88] G. Song, J. Suonan, and Q. Xu, "Parallel transmission lines fault location algorithm based on differential component net," *IEEE Trans. Power Del.*, vol. 20, no. 4, pp. 2396–2406, 2005.
- [89] Suonan, J., Song, G., Xu, Q. (2006). Time-domain fault location for parallel transmission lines using unsynchronized currents. *Elect Power Energy Syst*, 28(4), 253–260.
- [90] X. Yang, M. Choi, S. Lee, C. Ten and S. Lim, "Fault location for underground power cable using distributed parameter approach," in *IEEE Transactions on Power Systems*, 23, 4, 1809–1816, 2008.
- [91] Suonan, J., Gao, S., Song, G., Jiao, Z., Kang, X. (2010). A novel fault location method for HVDC transmission lines. *IEEE Transactions on Power Delivery*, 25(2), 1203–1209.
- [92] Yuansheng, L., Gang, W., Haifeng, L. (2015). Time domain fault location method on HVDC transmission lines under unsynchronized two end measurement and uncertain line parameters. *IEEE Transactions on Power Delivery*, 30(3), 1031–1038.
- [93] Suonan, J., Zhang, J., Jiao, Z., Yang, L., Song, G. (2013). Distance protection for HVDC transmission lines considering frequency dependent parameters. *IEEE Transactions on Power Delivery*, 28(2), 723–732.

- [94] R. Polikar, The Wavelet Tutorial. [Online]. Available : <http://users.rowan.edu/~polikar/WAVELETS>.
- [95] Mallat, S. G. (1989). A theory for multiresolution signal decomposition : The wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11(7), 674–693.
- [96] Robertson, D. C., Camps, O. I., Mayer, J. S., Gish, W. B. (1996). Wavelets and electromagnetic power system transients. *IEEE Transactions on Power Delivery*, 11(2), 1050–1058.
- [97] Poularikas, A. D. (2010). *Transforms and applications handbook*. CRC press.
- [98] Littler, T. B., Morrow, D. J. (1999). Wavelets for the analysis and compression of power system disturbances. *IEEE Transactions on Power Delivery*, 14(2), 358–364.
- [99] Costa, F. B., Souza, B. A., Brito, N. S. D. (2010). Real-time detection of fault-induced transients in transmission lines. *IET Electron Lett*, 753–755.
- [100] Zhengyou, H., Shibin, G., Xiaoqin, C., Jun, Z., Zhiqian, B., Qingquan, Q. (2011). Study of a new method for power system transients classification based on wavelet entropy and neural network. *International Journal of Electrical Power Energy Systems*, 33(3), 402–410.
- [101] Gafoor, S. A., Rao, P. V. R. (2011). A transient current based busbar protection scheme using wavelet transforms. *International Journal of Electrical Power Energy Systems*, 33(4), 1049–1053.
- [102] Perera, N., Rajapakse, A. D. (2012). Development and hardware implementation of a fault transients recognition system. *IEEE Transactions on Power Delivery*, 27(1), 40–52.
- [103] Perez, F. E., Aguilar, R., Orduna, E., Jager, J., Guidi, G. (2012). High-speed non-unit transmission line protection using single-phase measurements and an adaptive wavelet : Zone detection and fault classification. *IET Generation Transmission and Distribution*, 6(7), 593–604.
- [104] Kerf, K. D., Srivastava, K., Reza, M., Bekaert, D., Cole, S., Hertem, D. V., Belmans, R. (2011). Wavelet based protection strategy for DC faults in multi-terminal VSC HVDC systems. *IET Generation Transmission and Distribution*, 5(4), 496–503.
- [105] Y. M. Yeap, and A. Ukil, "Wavelet based fault analysis in HVDC system," in *Proc. IECON 2014 - 40th Annual Conference of the IEEE Industrial Electronics Society*, Dallas, TX, USA, 2014, 2472–2478.
- [106] Cheng, J., Guan, M., Tang, L., Huang, H. (2014). A fault location criterion for MTDC transmission lines using transient current characteristics. *International Journal of Electrical Power Energy Systems*, 61, 647–655.
- [107] Niaki, S. H. A., Karegar, H. K., Monfared, M. G. (2015). A novel fault detection method for VSC HVDC transmission system of offshore wind farm. *International Journal of Electrical Power Energy Systems*, 73, 475–483.
- [108] Abu-Elanien, A. E., Elserougi, A. A., Abdel-Khalik, A. S., Massoud, A. M., Ahmed, S. (2016). A differential protection technique for multi-terminal HVDC. *Electric Power Systems Research*, 130, 78–88.
- [109] Abu-Elanien, E., Abdel-Khalik, A. S., Massoud, A. M., Ahmed, S. (2017). A non-communication based protection algorithm for multi-terminal HVDC grids. *Electric Power Systems Research*, 144, 41–51.

- [110] Costa, F. B., Monti, A., Paiva, S. C. (2017). Overcurrent protection in distribution systems with distributed generation based on the real-time boundary wavelet transform. *IEEE Transactions on Power Delivery*, 32(1), 462–473.
- [111] Zheng, X., Nengling, T., Guangliang, Y., Haoyin, D. (2012). A transient protection scheme for HVDC transmission line. *IEEE Transactions on Power Delivery*, 27(2), 718–724.
- [112] M. You, B. Zhang, and R. Cao, “Study of non-unit transient-based protection for HVDC transmission lines,” in *Proc. Asia-Pacific Power Energy Eng. Conf.*, 2009, 1–5.
- [113] S. Zhang, B. Zhang, M. You, and Z. Bo, “Realization of the transient-based boundary protection for HVDC transmission lines based on high frequency energy criteria,” in *Proc. Power Syst. Technol. Int. Conf.*, 2010, 1–7.
- [114] Kong, F., Hao, Z., Zhang, S., Zhang, B. (2014). Development of a novel protection device for bipolar HVDC transmission lines. *IEEE Transactions on Power Delivery*, 29(5), 2270–2278.
- [115] Dong, Z. X., Neng-Ling, T., Thorp, J. S., Guang-Liang, Y. (2012). A transient harmonic current protection scheme for HVDC transmission line. *IEEE Transactions on Power Delivery*, 27(4), 2278–2285.
- [116] J. Wang, B. Berggren, K. Linden, J. Pan, and R. Nuqui, ”multi-terminal DC system line protection requirement and high speed protection solutions,” in *Proceedings of the 2015 CIGRE Symposium, Cape Town, South Africa, 2015*, 26–30.
- [117] Seneath, J., Rajapakse, A. D. (2016). Fault detection and interruption in an earthed HVDC grid using ROCOV and hybrid DC breakers. *IEEE Transactions on Power Delivery*, 31(3), 973–981.
- [118] Li, R., Xu, L., Yao, L. (2017). DC fault detection and location in meshed multiterminal HVDC systems based on DC reactor voltage change rate. *IEEE Transactions on Power Delivery*, 32(3), 1516–1526.
- [119] Leterme, W., Beerten, J., Hertem, D. V. (2016). Non-unit protection of HVDC grids with inductive dc cable termination. *IEEE Transactions on Power Delivery*, 31(2), 820–828.
- [120] Zhang, Y., Tai, N., Xu, B. (2012). Fault analysis and traveling-wave protection scheme for bipolar HVDC lines. *IEEE Transactions on Power Delivery*, 27(3), 1583–1591.
- [121] Yang, J., Fletcher, J. E., O’Reilly, J. (2010). Multiterminal DC wind farm collection grid internal fault analysis and protection design. *IEEE Transactions on Power Delivery*, 25(4), 2308–2318.
- [122] Yang, J., Fletcher, J. E., O’Reilly, J. (2012). Short circuit and ground fault analyses and location in VSC based DC network cables. *IEEE Transactions on Industrial Electronics*, 59(10), 3827–3837.
- [123] Paily, B. ; Kumaravel, S. ; Basu, M. ; Conlon, M. Fault analysis of VSC HVDC systems using fuzzy logic. In *Proceedings of the 2015 IEEE International Conference on Signal Processing, Informatics, Communication and Energy Systems (SPICES)*, Kozhikode, India, 19–21 February 2015 ; pp. 1–5.
- [124] Zhou, G. ; Zhang, X. ; Han, M. ; Filizadeh, S. ; Geng, Z. Single-ended fault detection scheme using support vector machine for modular multilevel conver-

- ters based multi-terminal HVDC systems. *J. Mod. Power Syst. Clean Energy*, 2022; Early Access.
- [125] Johnson, J.M.; Yadav, A. Complete protection scheme for fault detection, classification and location estimation in HVDC transmission lines using support vector machines. *IET Sci. Meas. Technol.* 2017, 11, 279–287.
- [126] Muzzammel, R.; Raza, A. A Support Vector Machine Learning-Based Protection Technique for MT-HVDC Systems. *Energies* 2020, 13, 6668.
- [127] Jeff Laninga, Ali Nasr Esfahani, Gevindu Ediriweera, Nathan Jacob, and Behzad Kordi, *Monitoring Technologies for HVDC Transmission Lines*, *Energies*, vol. 16, no. 13, p. 5085, 2023. <https://doi.org/10.3390/en16135085>.
- [128] Zhu, K. and Lee, W. K., *A Noncontact Voltage Measurement Method Based on Electric Field Coupling for Power Transmission Lines*, *IEEE Sensors Journal*, vol. 19, no. 6, pp. 2185–2193, 2019. [10.1109/JSEN.2019.2892498](https://doi.org/10.1109/JSEN.2019.2892498).
- [129] Yuan, H. and Deng, D., *Development of a Wireless Sensor Network with Optical Electric Sensor for Electric Field Measurement*, *Wireless Personal Communications*, vol. 97, pp. 2191–2205, 2017. [10.1007/s11277-017-4603-7](https://doi.org/10.1007/s11277-017-4603-7).
- [130] Deng, D., Yuan, H., Cui, Y. and Ju, Y., *Energy Management of WSN-Based Charge Measurement System of Ultra High-Voltage Direct-Current Transmission Line*, *Wireless Networks*, vol. 24, pp. 1667–1681, 2018. [10.1007/s11276-016-1419-4](https://doi.org/10.1007/s11276-016-1419-4).
- [131] Johnson, J.M.; Yadav, A. Fault Detection and Classification Technique for HVDC Transmission Lines Using KNN. In *Information and Communication Technology for Sustainable Development*; Springer : Singapore, 2018; pp. 245–253.
- [132] Naik, S.; Koley, E. Fault detection and classification scheme using KNN for AC/HVDC transmission lines. In *Proceedings of the 2019 International Conference on Communication and Electronics Systems (ICCES)*, Coimbatore, India, 17–19 July 2019; pp. 1131–1135.
- [133] Mishra, M.; Nayak, J.; Naik, B.; Abraham, A. Deep learning in electrical utility industry : A comprehensive review of a decade of research. *Eng. Appl. Artif. Intell.* 2020, 96, 104000.
- [134] Pragati, A.; Gadanayak, D.A.; Parida, T.; Mishra, M. Data-Mining Techniques Based Relaying Support for Symmetric-Monopolar Multi-Terminal VSC-HVDC System. *Appl. Syst. Innov.* 2023, 6, 24.
- [135] Yousaf, M.Z.; Liu, H.; Raza, A.; Mustafa, A. Deep learning-based robust dc fault protection scheme for meshed HVdc grids. *CSEE J. Power Energy Syst.* 2022; Early Access.
- [136] Fu, H.; Wang, Y.; Liu, Q.; Zang, B.; Zhou, S.; Song, W.; Wang, C. Lightning Stroke Transient Identification Method for HVDC Transmission Line based on DBN. In *Proceedings of the 2022 IEEE/IAS Industrial and Commercial Power System Asia (ICPS Asia)*, Shanghai, China, 8–11 July 2022; pp. 1944–1949.
- [137] S. X. Jin and T. J. Stott, "EVALUATE HVDC PROTECTION AND CONTROL SCHEMES USING HIGH SPEED PROCESS BUS TECHNOLOGY," *The 17th International Conference on AC and DC Power-Transmission (ACDC 2021)*, Online Conference, 2021, pp. 144-149, doi : [10.1049/icp.2021.2459](https://doi.org/10.1049/icp.2021.2459).

- [138] Fault detection and classification of an HVDC transmission line using a heterogenous multi-machinelearning algorithm. IET Gener. Transm. Distrib. 15,2319–2332 (2021).<https://doi.org/10.1049/gtd2.1218>,Saber Ghashghaei ,Mahdi Akhbari
- [139] Suonan, J. ; Gao, S. ; Song, G. ; Jiao, Z. ; Kang, X. A Novel Fault-Location Method for HVDC Transmission Lines. IEEE Trans. Power Deliv. 2009, 25, 1203–1209.
- [140] Fayazi, M. ; Joorabian, M. ; Saffarian, A. ; Monadi, M. A single-ended traveling wave based fault location method using DWT in hybrid parallel HVAC/HVDC overhead transmission lines on the same tower. Electr. Power Syst. Res. 2023, 220, 109302.
- [141] Zhang, X. ; Tai, N. ; Zheng, X. ; Huang, W. Wavelet-based EMTR method for fault location of VSC-HVDC transmission lines. J. Eng. 2019, 2019, 961–966.
- [142] Farshad, M. ; Karimi, M. A Signal Segmentation Approach to Identify Incident/Reflected Traveling Waves for Fault Location in Half-Bridge MMC-HVdc Grids. IEEE Trans. Instrum. Meas. 2021, 71, 1–9.
- [143] Silva, A.S. ; Santos, R.C. ; Torres, J.A. ; Coury, D.V. An accurate method for fault location in HVDC systems based on pattern recognition of DC voltage signals. Electr. Power Syst. Res. 2019, 170, 64–71.
- [144] Seyed Hassan Ashrafi Niaki, Jalal Sahebkar Farkhani, Zhe Chen, Birgitte Bak-Jensen, Shuju Hu. An Intelligent Method for Fault Location Estimation in HVDC Cable Systems Connected to Offshore Wind Farms. Wind 2023, 3, 361–374. <https://doi.org/10.3390/wind3030021>
- [145] Flih, A., Ghomri, L., Souag, S., & Onen, A., *Heterogeneous machine learning curve fitting for accurate fault location in VSC HVDC bipolar system*, Volume 55, Issue 10, October 2024, pp. 18925, ISSN : 0084-5841. Disponible en ligne : https://www.researchgate.net/publication/388027392_Heterogeneous_machine_learning_curve_fitting_for_accurate_fault_location_in_VSC_HVDC_bipolar_system.

Annexe A

Algorithmes d'optimisation et Ajustement de Courbe

Paramètre	Valeur
Puissance nominale	200 MVA
Tension nominale	± 100 kV
L_{arm}	0.000159 H
R_{arm}	0.0139 Ω
Capacité	2.31×10^{-7} F
Longueur	75 km

Algorithme de la Méthode Proposée en utilisant ML et ajustement du courbe

L'algorithme de la méthode proposée peut être résumé comme suit :

[(1)]Mettre à jour Dataset $D_n = \{(x_1, y_1), \dots, (x_n, y_n)\}$ Entraîner le modèle ML (par exemple, KNN) Ajustement de courbe par optimisation de région de confiance **Initialisation** : Définir le point initial x_0 , le rayon de la région de confiance initiale Δ_0 , et les paramètres η (paramètre d'acceptation) et γ (facteur de mise à jour de la région de confiance). **Itération** k :[(a)]

3. (a) Calculer le gradient $\nabla f(x_k)$ et l'Hessien approximatif B_k
- (b) Résoudre le sous-problème de région de confiance pour trouver Δx_k
- (c) Évaluer le rapport ρ_k

$$\rho_k = \frac{f(x_k) - f(x_k + \Delta x_k)}{m_k(0) - m_k(\Delta x_k)}$$

- (d) Mettre à jour $x_{k+1} = x_k + \Delta x_k$ si $\rho_k \geq \eta$; sinon, définir $x_{k+1} = x_k$
 - (e) Ajuster le rayon de la région de confiance Δ_k
 - Si $\rho_k \geq \eta$, définir $\Delta_{k+1} = \min(\gamma \Delta_k, \Delta_{\text{max}})$
 - Si $\rho_k < \eta$, définir $\Delta_{k+1} = \gamma \Delta_k$
4. Utiliser le modèle optimisé pour déterminer l'emplacement des défauts entre les équations (1), (2) et (3), et calculer l'erreur de localisation du défaut en

utilisant l'équation correspondante.

$$\text{Erreur} = \left(\frac{L_a - L_f}{L} \right) \times 100$$

Ajustement de Courbe

1. Ajustement de courbe de Fourier :

$$y = a_0 + \sum_{i=1}^n (a_i \cos(wx) + b_i \sin(wx)) \quad (1)$$

2. Ajustement de courbe gaussienne :

$$y = a_1 \exp \left(- \left(\frac{x - b_1}{c_1} \right)^2 \right) \quad (2)$$

3. Ajustement de courbe polynomiale :

$$y = a_n x^n + a_{n-1} x^{n-1} + \dots + a_1 x + a_0 \quad (3)$$

4. Normalisation des données par z-score :

$$Z = \frac{x - \mu}{\sigma} \quad (4)$$

Formulation

Le sous-problème de la région de confiance vise à trouver une étape Δx qui minimise la fonction objective $f(x)$ sous réserve d'une contrainte de région de confiance qui limite la taille de l'étape en fonction de l'itération actuelle x .

Mathématiquement, le sous-problème de la région de confiance peut être formulé comme suit :

$$\min_{\Delta x} m(\Delta x) = f(x) + \nabla f(x)^T \Delta x + \frac{1}{2} \Delta x^T B \Delta x \quad (5.8)$$

où $\nabla f(x)$ est le gradient de la fonction objective évaluée à l'itération courante x et B est une matrice définie positive qui approxime la courbure locale de la fonction objective.

Contrainte de la région de confiance

Le sous-problème de la région de confiance est soumis à une contrainte de région de confiance qui limite la taille de l'étape Δx à une région de confiance spécifiée autour de l'itération actuelle x .

Mathématiquement, la contrainte de la région de confiance peut être exprimée comme suit :

$$\|\Delta x\| \leq \Delta \quad (5.9)$$

où Δ représente le rayon de la région de confiance qui définit la taille maximale autorisée du pas.

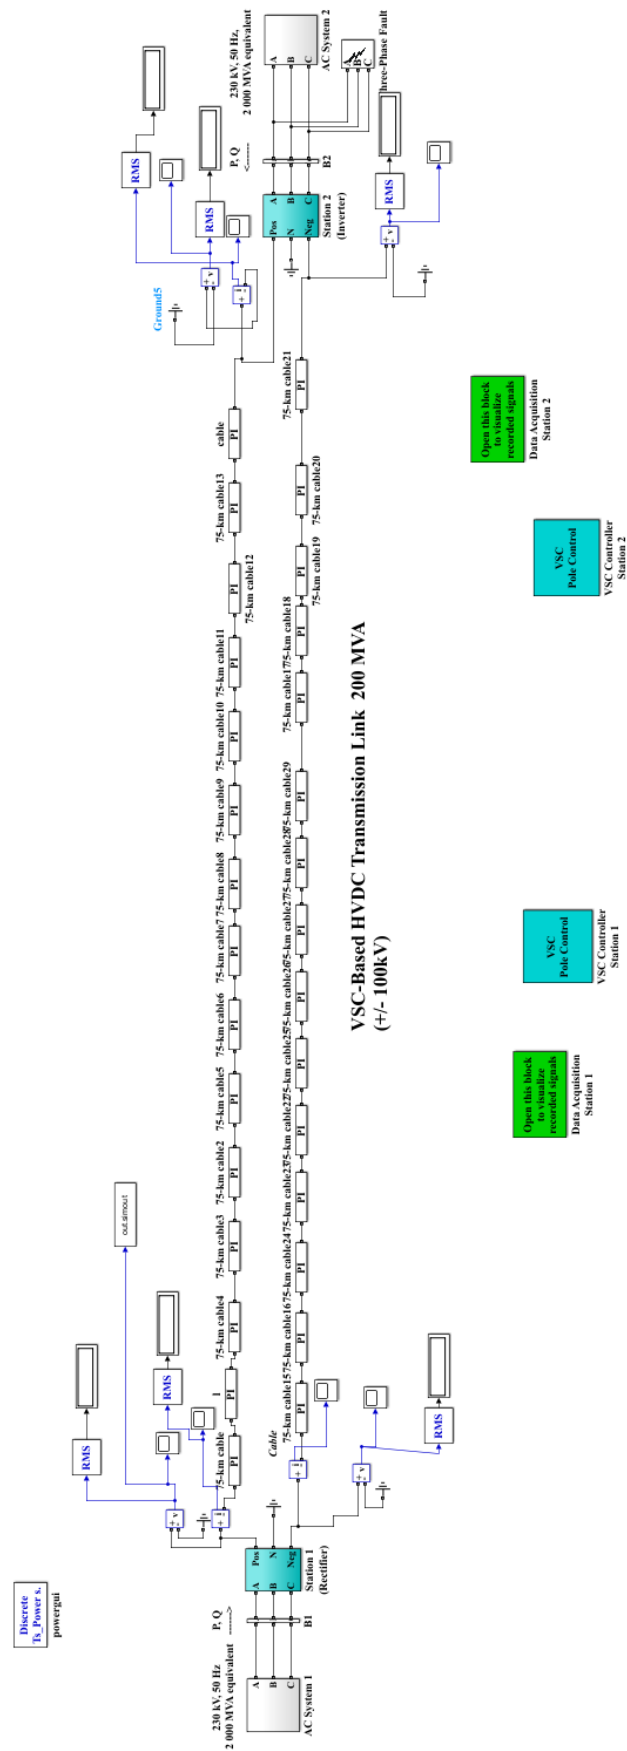


FIGURE A.1 – Schéma de bloc de la liaison HVDC vsc bipolaire utilisée

Abstract in English

This thesis addresses the critical issue of fault management in bipolar VSC-HVDC (Voltage Source Converter – High Voltage Direct Current) transmission systems. These systems are increasingly essential in the context of global energy transition due to their ability to integrate renewable energy sources and deliver power over long distances with high efficiency. The research aims to improve fault classification and localization using modern approaches such as machine learning and non-linear regression modeling.

The work is divided into five chapters : (1) an overview of HVDC systems, (2) modeling of VSC-HVDC systems, (3) detection and localization of faults, (4) fault classification using machine learning techniques, and (5) results and discussion. Throughout this study, synthetic data is generated and processed using MATLAB, which serves both as the simulation environment and the computational platform for data analysis and model training. Various stochastic optimization algorithms are applied to enhance regression accuracy, particularly Gaussian Process Regression (GPR), allowing for precise fault localization under different strategies.

Moreover, this work highlights the strong potential of integrating artificial intelligence (AI) into the protection and monitoring schemes of HVDC systems. By combining data-driven learning models with domain-specific knowledge, this research proposes advanced solutions to improve the reliability, precision, and resilience of future electrical transmission infrastructure.

VSC-HVDC, Fault Localization, Machine Learning, Gaussian Process Regression (GPR)

ملخص

تتناول هذه الرسالة مسألةً جوهريةً تتعلق بإدارة الأعطال في أنظمة نقل الطاقة ثنائية القطب VSC-HVDC (محول مصدر الجهد - تيار مستمر عالي الجهد). تتزايد أهمية هذه الأنظمة في سياق التحول العالمي في مجال الطاقة نظرًا لقدرتها على دمج مصادر الطاقة المتجددة ونقل الطاقة لمسافات طويلة بكفاءة عالية. يهدف البحث إلى تحسين تصنيف الأعطال وتحديد مواقعها باستخدام مناهج حديثة مثل التعلم الآلي ونمذجة الانحدار غير الخطي. ينقسم العمل إلى خمسة فصول: (1) نظرة عامة على أنظمة التيار المستمر عالي الجهد، (2) نمذجة أنظمة VSC-HVDC، (3) اكتشاف الأعطال وتحديد مواقعها، (4) تصنيف الأعطال باستخدام تقنيات التعلم الآلي، و(5) النتائج والمناقشة. خلال هذه الدراسة، يتم توليد ومعالجة البيانات التركيبية باستخدام MATLAB، الذي يعمل كبيئة محاكاة ومنصة حسابية لتحليل البيانات وتدريب النماذج. تُطبَّق خوارزميات تحسين عشوائية متنوعة لتعزيز دقة الانحدار، وخاصةً انحدار العملية الغوسية (GPR)، مما يسمح بتحديد دقيق لمواقع الأعطال باستخدام استراتيجيات مختلفة. علاوة على ذلك، يُسلط هذا العمل الضوء على الإمكانيات الكبيرة لدمج الذكاء الاصطناعي في أنظمة حماية ومراقبة أنظمة التيار المستمر عالي الجهد. من خلال الجمع بين نماذج التعلم القائمة على البيانات والمعرفة المتخصصة، يقترح هذا البحث حلولاً متقدمة لتحسين موثوقية ودقة مرونة البنية التحتية المستقبلية لنقل الكهرباء.

الكلمات الرئيسية: أنظمة VSC-HVDC، تحديد موقع الأعطال، التعلم الآلي، انحدار العملية الغوسية (GPR)