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

Mise en garde

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

Warning

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

UNIVERSITÉ DU QUÉBEC EN ABITIBI-TÉMISCAMINGUE

DÉTECTION CLASSIFICATION LOCALISATION ET PRÉDICTION DES DÉFAUTS ELECTRIQUES INTERNES SIMPLES ET MULTIPLES SUR LES RÉSEAUX ÉLECTRIQUES HYBRIDES

MÉMOIRE

PRÉSENTÉ

COMME EXIGENCE PARTIELLE

DE LA MAITRISE EN INGENIERIE

PAR

RIADH ZEMIRLINE

Juin 2026

Remerciements

Avant d'entamer ce rapport, c'est avec un grand plaisir que je réserve ces quelques lignes en signe de gratitude et de profonde reconnaissance à toutes les personnes qui, de près ou de loin, ont contribué à l'aboutissement de ce travail.

Je souhaite exprimer ma profonde gratitude envers mon directeur de recherche, le **Pr. FOUAD SLAOUI HASNAOUI**, pour sa guidance précieuse, sa motivation constante et le temps qu'il a généreusement consacré tout au long de cette période. Sans son soutien inestimable, ses judicieuses recommandations et ses précieux conseils, la réalisation de ce mémoire n'aurait pas été possible.

Je tiens également à témoigner toute ma reconnaissance au personnel ainsi qu'à la Direction de **l'UQAT** pour m'avoir offert l'opportunité de vivre cette expérience enrichissante. Merci pour l'excellent accueil qui m'a été réservé, ainsi que pour l'attention portée à mon intégration et au bon déroulement de mes études.

J'adresse aussi mes sincères remerciements à tous les professeurs du programme de **maîtrise en ingénierie, concentration en génie électrique**, pour la qualité de leur formation et leurs conseils précieux au quotidien. Leur contribution a grandement participé à la réussite de mon projet de recherche.

Mes remerciements s'adressent également aux membres du jury pour leur bienveillance et pour l'honneur qu'ils me font en acceptant d'évaluer ce travail. J'espère qu'ils trouveront dans ce mémoire les qualités de clarté, de rigueur et de motivation qu'ils attendent.

Enfin, un grand merci à ma famille pour l'amour qu'elle m'apporte au quotidien, pour ses conseils ainsi que pour son soutien inconditionnel, à la fois moral et économique, qui m'ont permis de poursuivre les études que j'ai toujours souhaité entreprendre.

Table des matières

Remerciements ii
Table des matières iii
Liste des figures ix
Liste des tableaux xii
Liste des abréviations xiii
Résume xiv
Abstract xv
Chapitre 1 1
Introduction générale 1
1.1 Contexte général 1
1.2 Problématique 2
1.3 Motivation et objectifs 4
1.3.1 Objectif général 4
1.3.2 Objectifs spécifiques 4
1.4 Originalité de la recherche 5
1.4.1 Ciblage des défauts internes simples et hybrides 5
1.4.2 Pipeline HHT → CNN intégré dans MATLAB 5
1.4.3 Optimisation native par POA appliquée au Bi-LSTM 6
1.4.4 Interprétabilité de (XAI) et génération automatique de rapports 6
1.4.5 Chaîne de maintenance prédictive unifiée 6
1.5 Hypothèses de recherche 7
1.6 Méthodologie de recherche 7
1.6.1 Revue de littérature 8
1.6.2 Collecte et acquisitions des données 8
1.6.3 Prétraitement et extraction HHT 9
1.6.4 Entérinement CNN–Bi-LSTM optimisé par POA 9
1.6.5 Explicabilité des décisions (XAI) 9
1.6.6 Implémentation du programme de détection 9

1.6.7 Validations et comparaison des résultats....9
1.7 Conclusion....10
Chapitre 2 11
Aperçu sur la détection et le diagnostic des défauts internes électriques 11
2.1 Réseau électrique....11
2.2 Système de Protection des équipements électriques....12
2.2.1 Rôle des protections internes 12
2.2.2 Comment protéger les générateurs et les machines électriques 13
2.2.3 Problèmes avec les protections classiques pour les défauts internes 14
2.3 Les défauts internes dans le réseau électrique....14
2.3.1 Types de défauts internes....15
2.3.2 Détection des défauts internes 15
2.3.3 Classification des défauts internes 16
2.3.4 Localisation des défauts internes....16
2.3.5 Prédiction des défauts internes....16
2.4 Techniques de diagnostic des défauts internes 17
2.4.1 Méthodes basées sur les grandeurs électriques....17
2.4.2 Méthodes basées sur l'analyse temps-fréquence....18
2.4.3 Facteurs influençant la précision du diagnostic 18
2.4.4 Méthodes basées sur l'intelligence artificielle 19
2.5 Conclusion....20
Chapitre 3 21
Identification et prédiction des défauts électriques internes par des méthodes intelligentes....21
3. 1 Introduction aux méthodes intelligentes....21
3.2 Description de réseau de neurones....22
3.2.1 Réseaux de neurones feedforward....23
3.2.2 Fonction de transfert/activation....24
3.3 Apprentissage et comment rendre les réseaux de neurones meilleurs 25
3.3.1 Apprentissage supervisé....26

3.3.2 Fonction de coût et minimisation de l'erreur 27
3.3.3 Sur apprentissage et capacité de généralisation 27
3.3.4 Transition vers les architectures avancées 28
3.4 Analyse et extraction des caractéristiques par la Transformée de Hilbert–Huang (HHT 28
3.4.1 Décomposition modale empirique (EMD) 29
3.4.2 Transformée de Hilbert ET représentation temps–fréquence 29
3.4.3 Intérêt de la HHT pour les défauts internes 30
3.5 Réseaux de neurones convolutifs (CNN) pour la classification des défauts internes.....30
3.5.1 Principe général des CNN 31
3.5.2 Couche de convolution et identification des motifs 32
3.5.3 Fonctions d'activation et non-linéarité.....32
3.5.4 Couche de Sous-échantillonnage (Pooling).....33
3.5.5 Classification avec des couches entièrement connectées 33
.....33
3.5.6 Adaptation des CNN aux signatures HHT.....33
3.5.7 Avantages et limites pour le diagnostic des défauts internes.....34
3.6 Réseaux récurrents et Bi-LSTM pour prédire les défauts internes....35
3.6.1 Limites des réseaux récurrents classiques (RNN) 35
3.6.2 Réseau Long Short-Term Memory (LSTM).....35
3.6.3 Réseau Bidirectionnel LSTM (Bi-LSTM) 36
3.6.4 Intérêt du Bi-LSTM pour la prédiction des défauts internes 38
3. 7 Optimisation des hyper-paramètres par l'algorithme POA.....38
3.7.1 Motivation de l'utilisation du POA 39
3.7.2 Principe général du Pélican Optimisation Algorithme 39
3.7.3 Les hyper-paramètres qui sont optimisés 40
3.7.4 Fonction objectif et critère d'évaluation.....40
3.7.5 Apport du POA dans la prédiction des défauts internes.....41
3.7.6 **Positionnement dans l'architecture globale**.....41

3. 8 Intelligence Artificielle Explicable (XAI) appliquée à l'identification et à la prédiction des défauts internes 41
3.8.1 Motivation de l'Intelligence Artificielle Explicable 41
3.8.2 Principe généraux de l'XAI 42
3.8.3 Comment l'XAI explique le fonctionnement du module CNN 42
3.8.4 Comment l'XAI explique le fonctionnement du module Bi-LSTM 43
3.8.5 Apport de l'XAI à la maintenance prédictive 43
3.8.6 Comment l'XAI s'intègre dans l'ensemble du système 44
3.9 Architecture globale proposée pour l'identification et la prédiction des défauts internes 44
3.9.1 Vue d'ensemble de l'architecture proposée 44
3.9.2 Acquisition et prétraitement des signaux 45
3.9.3 Extraction de caractéristiques par la HHT 45
3.9.4 Classification des défauts internes par CNN 45
3.9.5 Prédiction temporelle par Bi-LSTM ajusté par POA 46
3.9.6 L'intégration des modules d'intelligence artificielle explicable (XAI) ... 46
3.9.7 Sorties du système et aide à la décision 46
3.9.8 Apport global de l'architecture proposée 47
3.10 Conclusion 47
Chapitre 4 48
Présentation du réseau étudié et mise en place des scénarios de simulation 48
4.1 Introduction 48
4.2 Présentation du réseau IEEE-39 bus 49
4.2.1 Description détaillée du réseau IEEE 39 bus 50
4.2.2 Points positifs et limites du réseau IEEE 39 bus 51
4.2.3 Comparaison avec d'autres réseaux de test 51
4.2.4 Études précédentes et utilisation dans le milieu académique 52
4.3 Réseau hybride modifié et intégration des sources renouvelables 52
4.3.1 Pourquoi passer à un réseau hybride multi-sources 52
4.3.2 Modifications apportées au réseau IEEE 39 bus 53

4.3.3 Localisation des sources renouvelables et intérêt pour l'étude des défauts internes 55
4.3.4 Modélisation sur MATLAB/Simulink 57
4.3.5 Ce que le réseau hybride apporte à la détection et à la prédiction des défauts internes 57
4.4 Modélisation du réseau hybride avec MATLAB/Simulink 58
4.4.1 Architecture générale du modèle Simulink 58
4.4.2 Paramétrage électrique et cohérence des blocs 59
4.4.3 Modélisation des composants du réseau (bus, lignes, transformateurs, charges) 60
4.4.4 Intérêt du réseau hybride modifié pour étudier les défauts internes 62
4.4.5 Comment on mesure et enregistre les signaux (U, I, P) 62
4.4.6 Prétraitement des données avant HHT et apprentissage 63
4.5 Scénarios de simulation et protocole expérimental 63
4.5.1 Conditions nominales de référence 64
4.5.2 Variations naturelles de fonctionnement 65
4.5.3 Mise en œuvre des défauts internes simples 66
4.5.4 Défauts hybrides multi points (plusieurs endroits) 67
4.5.5 Protocole de génération du dataset 67
4.6 Mise en place détaillée des défauts internes simples 70
4.6.1 Types de défauts internes simples étudiés 71
4.6.2 Modélisation mathématique des défauts 71
4.6.3 Défaut sur un générateur synchrones 72
4.6.4 Défaut de l'éolienne : 73
4.6.5 Défaut photovoltaïque 73
4.6.6 Analyse des signatures électriques générées 75
4.6.7 Lien avec l'architecture intelligente 75
4.6.8 Construction des classes du dataset 76
4.7 Protocole d'évaluation et de validation 77
4.7.1 Séparation des données 77
4.7.2 Équilibrage du dataset 78

4.7.3 Métriques d'évaluation 78
4.7.4 Validation temporelle pour la prédiction 79
4.7.5 Optimisation des hyper-paramètres (POA) 79
4.7.6 Robustesse et tests supplémentaires 80
4.7.7 Intégration de l'XAI dans l'évaluation 80
4.8 Conclusion 81
Chapitre 5 82
5.1 Introduction 82
5.2 Revue de la littérature 83
5.3 Méthodologie et analyse expérimentale 86
5.4 Base des données de contingence 87
5.5 Application des défauts internes simples 89
5.5.1 Défauts sur les Machines Synchrones 89
5.5.2 Défauts sur le Système Photovoltaïque 95
5.5.3 Défauts sur les Éoliennes 97
5.5.4 Observations Générales 99
5.6 Réglage des hyperparamètres 100
5.7 Méthodes pour l'évaluation du modèle 100
5.8 Résultats 103
5.9 Conclusion 108
Chapitre 6 109
Détection classification localisation et prédiction des défauts internes hybrides (multiples) 109
6.1 Introduction 109
6.2 Revue de la littérature 110
6.3 Méthodologie et analyse expérimentale 111
6.4 Base des données de contingence 112
6.5 Application des internes multiples 115
6.6 Résultats 127
6.7 Discussion et comparaison des résultats 133
6.8 Conclusion 134

Conclusion générale 135
Bibliographie 137
ANNEXE A 145

Liste des figures

FIGURE 1-1 : DEMARCHE A SUIVRE. 8

FIGURE 2 - 1 : STRUCTURE GÉNÉRALE D'UN RÉSEAU ÉLECTRIQUE. 12
FIGURE 2 - 2 : EXEMPLE D'UN DISPOSITIF DE PROTECTION INTERNE D'UN ÉQUIPEMENT ÉLECTRIQUE. 13
FIGURE 2 - 3 : EXEMPLE DE RELAIS INTELLIGENT UTILISÉ POUR LA PROTECTION DES GÉNÉRATEURS ET DES MACHINES ÉLECTRIQUES. 13
FIGURE 2 - 4 : PRINCIPE DE L'INSPECTION VISUELLE BASÉE SUR L'INTELLIGENCE ARTIFICIELLE POUR LA DÉTECTION DES DÉFAUTS. 20

FIGURE 3 - 1 : ILLUSTRATION D'UN RÉSEAU DE NEURONES FEEDFORWARD. 22
FIGURE 3 - 2 : LA STRUCTURE DE BASE D'UN NEURONE. 24
FIGURE 3 - 3 : PRINCIPE GÉNÉRAL DE L'APPRENTISSAGE SUPERVISÉ. 26
FIGURE 3 - 4 : ILLUSTRATION DU SUR APPRENTISSAGE ET DE LA GÉNÉRALISATION. 28
FIGURE 3 - 5 : LA DÉCOMPOSITION EMD APPLIQUÉE À UN SIGNAL ÉLECTRIQUE. 29
FIGURE 3 - 6 : ARCHITECTURE GÉNÉRALE D'UN RÉSEAU DE NEURONES CONVOLUTIF (CNN). 31
FIGURE 3 - 7 : EXEMPLE ILLUSTRATIF D'UNE OPÉRATION DE CONVOLUTION ET DES CARTES DE CARACTÉRISTIQUES GÉNÉRÉES. 32
FIGURE 3 - 8 : CHAÎNE DE CLASSIFICATION DES DÉFAUTS INTERNES BASÉE SUR LA TRANSFORMÉE DE HILBERT–HUANG (HHT) ET UN RÉSEAU DE NEURONES CONVOLUTIF (CNN). 34
FIGURE 3 - 9 : SCHÉMA DE PRINCIPE D'UNE CELLULE LSTM. 35
FIGURE 3 - 10 : ARCHITECTURE D'UNE CELLULE LSTM ILLUSTRANT LE FLUX D'INFORMATION ET LE RÔLE DES PORTES D'OUBLI, D'ENTRÉE ET DE SORTIE. 36
FIGURE 3 - 11 : ARCHITECTURE D'UN RÉSEAU BI-LSTM BIDIRECTIONNEL 36
FIGURE 3 - 12 : ARCHITECTURE D'UN RÉSEAU LSTM BIDIRECTIONNEL (BI-LSTM) APPLIQUÉ À UNE SÉQUENCE TEMPORELLE. 37
FIGURE 3 - 13 : PRINCIPE DE FONCTIONNEMENT DU TRAITEMENT AVANT ET ARRIÈRE DANS UN RÉSEAU BI-LSTM. 38

FIGURE 4 - 1 : TOPOLOGIE DU RÉSEAU IEEE 39 BUS DE RÉFÉRENCE. 49
FIGURE 4 - 2 : REPRÉSENTATION DÉTAILLÉE DES BUS, LIGNES ET TRANSFORMATEURS DU RÉSEAU IEEE 39 BUS. 50
FIGURE 4 - 3 : SCHEMA DU RESEAU IEEE 39-BUS ENRICHI PAR L'INTEGRATION DES SOURCES ENERGIES RENOUVELABLES. 54
FIGURE 4 - 4 : POSITIONNEMENT DE LA SOURCE PHOTOVOLTAÏQUE AU BUS 17 DANS LE RESEAU IEEE 39 BUS MODIFIE. 55
FIGURE 4 - 5 : LOCALISATION ET RACCORDEMENT DE LA SOURCE ÉOLIENNE 1 (WIND FARM 1) AU BUS 9 DANS LE RÉSEAU IEEE 39 BUS MODIFIÉ. 56

FIGURE 4 - 6 : LOCALISATION ET RACCORDEMENT DE LA SOURCE ÉOLIENNE 2 (WIND FARM 2) AU BUS 24 DANS LE RÉSEAU IEEE 39 BUS MODIFIÉ. 56
FIGURE 4 - 7 : EXEMPLE DE BUS TRIPHASÉ (BUS 7) DANS LE MODÈLE MATLAB/SIMULINK, ASSURANT L'INTERCONNEXION DES LIGNES, TRANSFORMATEURS ET SOURCES DU RÉSEAU. 60
FIGURE 4 - 8 : EXEMPLE DE MODÈLE DE LIGNE TRIPHASÉE IMPLÉMENTÉ SOUS MATLAB / SIMULINK ET REPRÉSENTATION INTERNE DE SES PARAMÈTRES ÉLECTRIQUES. 61
FIGURE 4 - 9 : EXEMPLE DE TRANSFORMATEUR DANS SIMULINK ET SES PARAMÈTRES PRINCIPAUX. 61
FIGURE 4 - 10 : EXEMPLE DE CHARGE. 62
FIGURE 4 - 11 : SCHÉMA DÉTAILLÉ DU SOUS-SYSTÈME PHOTOVOLTAÏQUE (DPV) INTÉGRÉ AU RÉSEAU HYBRIDE SOUS MATLAB/SIMULINK. 75

FIGURE 5 - 1 : IMPACT D'UNE AUGMENTATION DE LA PUISSANCE NOMINALE DE G2. 90
FIGURE 5 - 2 : IMPACT D'UNE AUGMENTATION DE LA PUISSANCE NOMINALE DE G5. 90
FIGURE 5 - 3 : IMPACT D'UNE DIMINUTION DE LA PUISSANCE NOMINALE DE G6. 91
FIGURE 5 - 4: IMPACT D'UNE DIMINUTION DE LA PUISSANCE NOMINALE DE G7. 92
FIGURE 5 - 5: IMPACT D'UNE AUGMENTATION DE LA TENSION G1 93
FIGURE 5 - 6: IMPACT D'UNE AUGMENTATION DE LA TENSION DE G4. 93
FIGURE 5 - 7: IMPACT D'UNE DIMINUTION DE LA TENSION DE G7. 94
FIGURE 5 - 8: IMPACT D'UNE DIMINUTION DE LA TENSION DE G8. 95
FIGURE 5 - 9: ÉVOLUTION DE LA PUISSANCE ACTIVE P(T) DU SYSTÈME PHOTOVOLTAÏQUE LORS DE L'APPARITION D'UN DÉFAUT INTERPHASE AB. 96
FIGURE 5 - 10: ÉVOLUTION DE LA PUISSANCE ACTIVE P(T) DU SYSTÈME PHOTOVOLTAÏQUE LORS DE L'APPARITION D'UN DÉFAUT INTERPHASE BC. 96
FIGURE 5 - 11: ÉVOLUTION DE LA PUISSANCE ACTIVE P(T) DU SYSTÈME PHOTOVOLTAÏQUE LORS DE L'APPARITION D'UN DÉFAUT INTERPHASE CA. 97
FIGURE 5 - 12 : ÉVOLUTION DE LA TENSION U(T) ET LA PUISSANCE ACTIVE P(T) AU BUS 9 LORS D'UNE AUGMENTATION DE LA TENSION GÉNÉRÉE. 98
FIGURE 5 - 13 : ÉVOLUTION DE LA TENSION U(T) ET LA PUISSANCE ACTIVE P(T) AU BUS 9 LORS D'UNE AUGMENTATION DE LA PUISSANCE NOMINALE. 98
FIGURE 5 - 14 : ÉVOLUTION DE LA TENSION U(T) ET LA PUISSANCE ACTIVE P(T) AU BUS 24 LORS D'UNE DIMINUTION DE LA TENSION GÉNÉRÉE. 99
FIGURE 5 - 15 : ÉVOLUTION DE LA TENSION U(T) ET LA PUISSANCE ACTIVE P(T) AU BUS 24 LORS D'UNE DIMINUTION DE LA PUISSANCE NOMINALE. 99
FIGURE 5 - 16 : MATRICE DE CONFUSION. 101
FIGURE 5 - 17 : ÉVOLUTION DE LA FONCTION DE PERTE (LOSS) PENDANT L'ENTRAÎNEMENT ET LA VALIDATION DU MODÈLE. 103
FIGURE 5 - 18 : ÉVOLUTION DE L'ACCURACY ET DE LA FONCTION DE PERTE DU MODÈLE DE DÉTECTION DES DÉFAUTS. 104
FIGURE 5 - 19: ÉVOLUTION DE L'ACCURACY ET DE LA FONCTION DE PERTE (LOSS) POUR LA CLASSIFICATION DES TYPES DE DÉFAUTS. 105
FIGURE 5 - 20 : PRÉCISION, RAPPEL ET SCORE F1 POUR LA CLASSIFICATION DES TYPES DE DÉFAUTS (ENSEMBLE TEST). 105
FIGURE 5 - 21: ÉVOLUTION DE L'ACCURACY ET DE LA FONCTION DE PERTE (LOSS) POUR LA LOCALISATION DES DÉFAUTS PAR BUS. 106
FIGURE 5 - 22 : PRÉCISION, RAPPEL ET SCORE F1 POUR LA LOCALISATION DES DÉFAUTS PAR BUS (ENSEMBLE TEST). 107
FIGURE 5 - 23 : MATRICES DE CONFUSION POUR LA PRÉDICTION DES DÉFAUTS (TRAINING, VALIDATION ET TEST). 107

FIGURE 6 - 1 : ÉVOLUTION DU COURANT AU BUS 9 POUR LA CLASSE 28 (COMPARAISON ENTRE LE RÉGIME STABLE ET LE RÉGIME AVEC DÉFAUT HYBRIDE). 115
FIGURE 6 - 2 : VARIATION RELATIVE DU COURANT |ΔI| AU BUS 39 CLASSE28. 116
FIGURE 6 - 3 : ÉVOLUTION DU COURANT AU BUS 17 POUR LA CLASSE 29 (COMPARAISON ENTRE L'ÉTAT STABLE ET L'ÉTAT AVEC DÉFAUT HYBRIDE). 117
FIGURE 6 - 4 : ÉVOLUTION DE LA TENSION AU BUS 32 POUR LA CLASSE 29 (COMPARAISON ENTRE L'ÉTAT STABLE ET L'ÉTAT AVEC DÉFAUT HYBRIDE). 117
FIGURE 6 - 5 : ÉVOLUTION DU COURANT AU BUS 34 POUR LA CLASSE 30 (COMPARAISON ENTRE L'ÉTAT STABLE ET L'ÉTAT AVEC DÉFAUT HYBRIDE). 118
FIGURE 6 - 6 : ÉVOLUTION DU COURANT AU BUS 24 POUR LA CLASSE 30 (COMPARAISON ENTRE L'ÉTAT STABLE ET L'ÉTAT AVEC DÉFAUT HYBRIDE). 119
FIGURE 6 - 7 : IMPACT DU COURANT AU BUS 31 POUR LA CLASSE 31 (AUGMENTATION DE X_D' SUR G2). 119
FIGURE 6 - 8 : IMPACT DU COURANT AU BUS 38 POUR LA CLASSE 31 (AUGMENTATION DE X_D' SUR G9). 120
FIGURE 6 - 9 : COMPORTEMENT DU COURANT AU BUS 36 SOUS L'EFFET DU DÉFAUT HYBRIDE (CLASSE31). 120
FIGURE 6 - 10 : ÉVOLUTION DU COURANT AU BUS 35 POUR LA CLASSE 32 DIMINUTION DE K_E A G6. 121
FIGURE 6 - 11 : ÉVOLUTION DU COURANT AU BUS 37 POUR LA CLASSE 32 AUGMENTATION DE T_B. 122
FIGURE 6 - 12 : IMPACT DE LA VARIATION DE T_A DE L'AVR DE G10 SUR LA TENSION AU BUS 30. 122
FIGURE 6 - 13 : IMPACT DE LA VARIATION DE K_E DE L'AVR DE G4 SUR LE COURANT AU BUS 33. 123
FIGURE 6 - 14 : IMPACT DE LA VARIATION DE L_M DE WT1 SUR LE COURANT AU BUS 9. 123
FIGURE 6 - 15 : IMPACT DE LA VARIATION DE L'IRRADIANCE DU GÉNÉRATEUR PHOTOVOLTAÏQUE SUR LA TENSION AU BUS 17. 124
FIGURE 6 - 16 : ÉVOLUTION DU COURANT AU BUS 9 SOUS L'IMPACT DE LA DIMINUTION DE LA MAGNÉTISATION L_M DE WT1. 124
FIGURE 6 - 17 : ÉVOLUTION DE L'ERREUR RELATIVE DU COURANT AU BUS 24 SOUS L'EFFET DE L'AUGMENTATION DE LA RÉSISTANCE ROTORIQUE R_R DE WT2. 125
FIGURE 6 - 18 : ÉVOLUTION DU COURANT AU BUS 9 SOUS L'EFFET DE LA DIMINUTION ALÉATOIRE DE LA MAGNÉTISATION L_M DE WT1. 126
FIGURE 6 - 19 : ÉVOLUTION DU COURANT AU BUS 17 SOUS L'EFFET DE LA DIMINUTION ALÉATOIRE DE L'IRRADIANCE DU GÉNÉRATEUR PHOTOVOLTAÏQUE. 126
FIGURE 6 - 20 : ÉVOLUTION DE LA TENSION AU BUS 24 SOUS L'EFFET DE L'AUGMENTATION ALÉATOIRE DE LA RÉSISTANCE ROTORIQUE R_R DE WT2. 127
FIGURE 6 - 21 : ÉVOLUTION DE L'ACCURACY ET DE LA LOSS DU MODÈLE POUR LA DÉTECTION DES DÉFAUTS INTERNES HYBRIDES (MULTIPLES). 128
FIGURE 6 - 22 : ÉVOLUTION DE L'ACCURACY ET DE LA LOSS DU MODÈLE POUR LA CLASSIFICATION DES DÉFAUTS INTERNES HYBRIDES. 129
FIGURE 6 - 23 : PERFORMANCES DU MODÈLE SUR L'ENSEMBLE DE TEST EN TERMES DE PRÉCISION, RAPPEL ET F1 SCORE POUR LES DIFFÉRENTES CLASSES DE DÉFAUTS. 130
FIGURE 6 - 24 : PERFORMANCES DU MODÈLE SUR L'ENSEMBLE DE TEST EN TERMES DE PRÉCISION, RAPPEL ET SCORE F1 POUR LA LOCALISATION DES DÉFAUTS. 131
FIGURE 6 - 25 : MATRICES DE CONFUSION DU MODÈLE POUR LA LOCALISATION DES DÉFAUTS SUR LES ENSEMBLES D'ENTRAÎNEMENT, DE VALIDATION, DE TEST ET GLOBAL. 131
FIGURE 6 - 26 : ÉVOLUTION DE L'ACCURACY ET DE LA LOSS DU MODÈLE OPTIMISÉ POUR LA PRÉDICTION DES DÉFAUTS. 132
FIGURE 6 - 27 : MATRICES DE CONFUSION DU MODÈLE OPTIMISÉ POUR LA PRÉDICTION DES DÉFAUTS SUR LES ENSEMBLES D'ENTRAÎNEMENT, DE VALIDATION, DE TEST ET GLOBAL. 133

Liste des tableaux

TABLEAU 1 : FONCTIONS D'ACTIVATION. 25
TABLEAU 2: COMPARAISON ENTRE LES RESEAUX IEEE 14, 39 ET 118 BUS. 52
TABLEAU 3: DÉFINITIONS DE LA CONTINGENCE CORRESPONDENT AUX DÉFAUTS INTERNES SIMPLES. 88
TABLEAU 4 : BASE DE DONNÉES DE CONTINGENCE CORRESPONDENT AUX DÉFAUTS INTERNES HYBRIDES (MULTIPLES). 114
TABLEAU 5: COMPARAISON DE L'ACCURACY AVEC QUELQUES TRAVAUX DANS LA LITTÉRATURE. 134

Liste des abréviations

ANN: Artificial Neural Network.

AVR: Automatic Voltage Regulator.

BiLSTM: Bidirectional Long Short-Term Memory.

CNN: Convolutional Neural Network.

DNN: Deep Neural Network.

EMD: Empirical Mode Decomposition.

FFT: Fast Fourier Transform.

GAF: Gramian Angular Field.

HHT: Hilbert–Huang Transform.

IA: Intelligence Artificielle.

Ke: Gain de l'excitateur.

KNN: k-Nearest Neighbors.

Lm: Inductance de magnetisation.

LSTM: Long Short-Term Memory.

ML: Machine Learning.

MS: Multi-Source ou Multi-Scénario.

POA: Pelican Optimization Algorithm.

PV: Photovoltaïque.

Rr: Résistance rotorique.

Rs: resistance statorique.

SOC: State of Charge.

SVM : Support Vector Machine.

Ta : Constante de temps de l'AVR.

Tb : Constante de temps du système d'excitation.

Vit : Vision Transformer.

WT: Wind Turbine.

XAI: Explainable Artificial Intelligence.

Xd′: Reactance transitoire d'axe direct.

Résume

Ce mémoire présente une étude portant sur la détection, la classification, la localisation et la prédiction des défauts électriques internes simples et multiples dans les réseaux hybrides de production d'énergie. L'objectif principal de ce travail est de développer une approche intelligente et performante capable d'identifier rapidement les anomalies affectant les différentes sources du réseau hybride, tout en améliorant sa sûreté, sa stabilité et sa continuité de service.

Dans le cadre de cette recherche, un réseau hybride composé de générateurs hydroélectriques, d'éoliennes et d'une source photovoltaïque a été modélisé et simulé sous MATLAB/Simulink. Plusieurs scénarios de défauts internes ont été appliqués de manière ciblée sur les différentes composantes du réseau, tels que la variation de la puissance nominale, de la résistance statorique et rotorique, ainsi que certaines perturbations liées au système photovoltaïque. Ces simulations ont permis de constituer une base de données représentative des états sains et défaillants du système.

Afin d'extraire les caractéristiques significatives des signaux électriques, la transformée de Hilbert-Huang (HHT) a été exploitée, puis les informations obtenues ont été utilisées dans des modèles d'apprentissage profond, notamment les réseaux de neurones convolutifs (CNN) pour la détection et la classification des défauts. Pour la prédiction, une architecture BiLSTM optimisée par l'algorithme POA a été mise en œuvre afin d'améliorer les performances du modèle. En complément, l'approche XAI a été intégrée pour apporter une meilleure interprétabilité aux résultats obtenus.

Les résultats montrent que l'approche proposée permet de détecter efficacement les défauts internes, de distinguer leurs classes avec une bonne précision et d'anticiper leur évolution dans le temps. Ce travail met ainsi en évidence l'intérêt de la combinaison entre la modélisation des réseaux hybrides, le traitement avancé du signal et l'intelligence artificielle pour la supervision intelligente des systèmes énergétiques complexes.

Mots-clés : hybrid network, internal electrical faults, HHT, CNN, BiLSTM, POA, XAI, detection, classification, prediction, artificial intelligence, MATLAB/Simulink.

Abstract

This thesis presents a study on the detection, classification, localization, and prediction of simple and multiple internal electrical faults in hybrid power generation networks. The main objective of this work is to develop an intelligent and efficient approach capable of rapidly identifying anomalies affecting the various sources of the hybrid network, while improving its safety, stability, and continuity of service.

As part of this research, a hybrid network composed of hydroelectric generators, wind turbines, and a photovoltaic source was modeled and simulated using MATLAB/Simulink. Several internal fault scenarios were applied to the different network components, such as variations in rated power, stator and rotor resistance, as well as certain disturbances related to the photovoltaic system. These simulations allowed for the creation of a representative database of the system's healthy and faulty states.

To extract significant features from electrical signals, the Hilbert-Huang transform (HHT) was used, and the resulting information was then applied to deep learning models, including convolutional neural networks (CNNs), for fault detection and classification. For prediction, a BiLSTM architecture optimized by the POA algorithm was implemented to improve model performance. Additionally, the XAI approach was integrated to enhance the interpretability of the results.

The results demonstrate that the proposed approach effectively detects internal faults, distinguishes their classes with good accuracy, and predicts their evolution over time. This work thus highlights the value of combining hybrid network modeling, advanced signal processing, and artificial intelligence for the intelligent monitoring of complex energy systems.

Keywords: hybrid network, internal electrical faults, HHT, CNN, BiLSTM, POA, XAI, detection, classification, prediction, artificial intelligence, MATLAB/Simulink.

Chapitre 1

Introduction générale

Aujourd'hui, les secteurs de l'industrie et de l'énergie changent vite avec l'arrivée des nouvelles technologies numériques, de l'automatisation et de l'intelligence artificielle. Le but est surtout d'avoir des systèmes plus fiables, performants et sûrs, tout en baissant les coûts et en comptant moins sur l'homme. Dans le domaine de l'électricité, c'est très important car les réseaux électriques sont essentiels au développement économique et social.

Avec l'augmentation de la complexité des réseaux modernes, surtout avec l'ajout des énergies renouvelables et des appareils électroniques de puissance, il devient plus dur de surveiller et de gérer les problèmes. Si on ne les voit pas à temps, les défauts électriques peuvent causer des coupures, endommager le matériel et baisser la qualité de l'énergie. C'est pourquoi il est primordial de détecter et de prévoir les défauts tôt pour que les systèmes énergétiques continuent de fonctionner correctement et soient fiables.

Ce mémoire se penche sur ce sujet et cherche à créer une méthode intelligente pour détecter et prévoir les défauts dans les réseaux énergétiques. Ce chapitre va présenter le contexte général de l'étude, expliquer le problème scientifique, définir les objectifs et décrire comment la recherche a été menée.

1.1 Contexte général

Il est très important de surveiller et de gérer les systèmes électriques modernes pour que l'alimentation électrique soit fiable, les équipements soient en sécurité et le service continu sans interruption. Ces dernières années, les réseaux électriques ont beaucoup grandi et sont devenus plus compliqués, surtout avec l'intégration des énergies renouvelables et des réseaux intelligents [1], [2].

Les systèmes énergétiques actuels créent sans arrêt de grandes quantités de données à partir de capteurs, de systèmes SCADA et d'appareils de mesure avancés. Ces données montrent comment les équipements fonctionnent et donnent des infos utiles sur l'apparition et l'évolution des défauts. Mais comme elles changent avec le temps, qu'elles ne sont pas linéaires et qu'il y a souvent du bruit, il est difficile de les utiliser avec les méthodes classiques de surveillance et de diagnostic [3], [4].

Les défauts électriques sont inévitables dans les systèmes de production, de transport et de distribution d'énergie. Ils peuvent venir du vieillissement du matériel, des surcharges, des conditions météo ou d'erreurs humaines. S'ils ne sont pas détectés à temps, ces défauts peuvent entraîner de grosses pertes d'argent, rendre le réseau indisponible et baisser sa fiabilité générale [5]. C'est pourquoi il est indispensable de mettre en place des stratégies de maintenance préventive qui détectent et prévoient les défauts à l'avance.

Comme les méthodes traditionnelles, qui se basent sur des modèles physiques simplifiés ou des seuils fixes, ont leurs limites, les techniques d'apprentissage automatique et d'apprentissage profond intéressent de plus en plus le secteur des systèmes énergétiques intelligents [6], [7]. Ces méthodes permettent d'utiliser efficacement les grandes quantités de données disponibles et de comprendre les liens complexes entre les différentes mesures.

Parmi les modèles d'apprentissage profond, les réseaux de neurones récurrents de type Long Short-Term Memory (LSTM) ont montré qu'ils étaient capables d'analyser des données temporelles. Les LSTM classiques se servent surtout des informations du passé. Pour aller au-delà de ça, les réseaux Bidirectional Long Short-Term Memory (Bi-LSTM) ont été créés. Ils permettent de prendre en compte à la fois les événements passés et futurs [8], [9]. Des études récentes ont prouvé que les modèles Bi-LSTM sont plus performants pour détecter et prévoir les défauts dans les systèmes énergétiques et industriels complexes [10], [11].

1.2 Problématique

Les réseaux d'énergie hybrides sont un peu compliqués. Ils mélangent des sources d'hydroélectricité, d'éolien et de photovoltaïque, ce qui crée pas mal de variations dans leur fonctionnement. De plus, il y a différents types de problèmes qui peuvent survenir. Toute

cette complexité rend la surveillance du réseau difficile et les méthodes habituelles, avec leurs seuils fixes et leurs modèles simplifiés, ne sont pas toujours très efficaces [2], [4].

Dans ce contexte, les anomalies peuvent prendre différentes formes, allant de simples changements de paramètres à des défauts internes plus graves. Ces anomalies peuvent avoir un impact sur la puissance des générateurs, les caractéristiques électriques des machines tournantes ou les performances des systèmes photovoltaïques. Si on ne les détecte pas assez tôt, cela peut entraîner une baisse progressive des performances du réseau, des coûts de maintenance plus élevés et, dans le pire des cas, des coupures de courant.

Les méthodes de surveillance classiques, qui se basent sur l'analyse statique des signaux ou sur des règles préétablies, atteignent rapidement leurs limites face à la nature changeante et non linéaire des signaux provenant des réseaux hybrides. De plus, ces approches ne sont pas toujours très fiables face aux variations des conditions d'exploitation et aux perturbations, ce qui peut entraîner de fausses alertes ou la non-détection de certains défauts importants [4], [5].

C'est pourquoi les techniques d'apprentissage profond apparaissent comme des solutions intéressantes pour améliorer la surveillance des réseaux hybrides. En particulier, combiner des méthodes de traitement du signal avancées, comme la transformée de Hilbert–Huang (HHT), avec des réseaux de neurones convolutifs (CNN), permet d'extraire et de classer les caractéristiques des défauts à partir de signaux complexes [5], [7]. Mais la détection seule ne suffit pas pour bien gérer le réseau.

Il est important de pouvoir prédire comment les anomalies vont évoluer dans le temps afin de limiter les risques de panne et d'améliorer la maintenance. Les modèles récurrents, et plus particulièrement les réseaux Bidirectionnels Long Short-Term Memory (Bi-LSTM), sont capables de modéliser les dépendances temporelles passées et futures des signaux. On peut améliorer la précision des prédictions et réduire le nombre de fausses alertes en ajustant ces modèles à l'aide d'algorithmes métaheuristiques, comme le Pélican Optimisation Algorithme (POA) [3].

L'objectif principal de ce travail est donc de mettre au point une approche hybride et fiable pour détecter, classer et prédire rapidement les défauts dans un réseau d'énergie hybride.

Cette approche vise à comparer les performances des méthodes proposées avec celles des approches existantes, mais aussi à intégrer une dimension de maintenance prédictive compréhensible, afin de simplifier l'interprétation des décisions du modèle et de favoriser son utilisation dans des applications industrielles concrètes [6].

1.3 Motivation et objectifs

Cette recherche part du constat qu'il faut améliorer la surveillance des réseaux électriques hybrides. La variabilité des sources d'énergie (hydroélectricité, éolien, photovoltaïque) et la diversité des défauts peuvent perturber le système et augmenter les coûts de maintenance. L'objectif principal est donc de concevoir une approche performante pour détecter, classer et prédire les défauts internes, afin d'améliorer la fiabilité du fonctionnement et de soutenir la maintenance prédictive.

1.3.1 Objectif général

L'objectif général de ce travail est de rendre les réseaux électriques hybrides plus fiables et stables grâce à une nouvelle approche de détection, de classification et de prédiction des défauts internes. Cette approche se base sur la combinaison d'un traitement du signal avancé et de l'apprentissage profond.

1.3.2 Objectifs spécifiques

- ✓ Créer une chaîne complète HHT → CNN → Bi-LSTM (avec optimisation POA), entièrement sous MATLAB/Simulink, en utilisant des scripts (.m) et des modèles Simulink.
- ✓ Tirer parti de la transformée de Hilbert–Huang (HHT), en particulier de l'EMD (Empirical Mode Décomposition) et de l'analyse spectrale de Hilbert (HSA), pour identifier les caractéristiques associées à des défauts simples (par exemple, variation de puissance, variations des paramètres électriques des machines, paramètres PV).
- ✓ Développer un système de classification basé sur un réseau de neurones convolutifs (CNN) via la Deep Learning (Toolbox) pour classer automatiquement les états normal/défaut et les types de défaut à partir des informations issues de la HHT.

- ✓ Concevoir un module de prédiction basé sur un réseau Bi-LSTM optimisé par le Pélican Optimisation Algorithme (POA) pour
    - Modéliser l'évolution des anomalies
    - Réduire le nombre de fausses alertes en ajustant automatiquement les hyperparamètres.
- ✓ Valider l'approche sur des données simulées générées sous Simulink/Math power (ou équivalent) et évaluer les performances à l'aide d'indicateurs standards : précision, rappel, score F1, matrice de confusion, ainsi que le temps de calcul.

Automatiser l'ensemble du processus via un script principal unique capable de lancer la simulation, l'extraction des caractéristiques, l'entraînement/validation des modèles et la création d'un rapport de résultats (avec figures et tableaux).

1.4 Originalité de la recherche

Ce projet propose une façon nouvelle et pratique de trouver, classer et prédire les problèmes internes dans un réseau électrique hybride. Il combine un traitement avancé du signal, l'apprentissage profond et une façon d'optimiser les choses en essayant plusieurs solutions. Les idées proposées sont organisées autour de cinq points principaux, chacun étant lié aux recherches récentes.

1.4.1 Ciblage des défauts internes simples et hybrides

Ce travail ne se contente pas d'examiner les défauts internes simples comme (variation de puissance nominal, des paramètres électriques des machines, ou les problèmes liés au photovoltaïque). Il introduit aussi des scénarios hybrides où plusieurs problèmes peuvent survenir en même temps (par exemple, une variation de la puissance d'un générateur et une modification de l'ensoleillement). La prise en compte simultanée de ces défauts variés est rarement étudiée, alors qu'elle correspond davantage à ce qui se passe dans les réseaux hybrides [11].

1.4.2 Pipeline HHT → CNN intégré dans MATLAB

Le projet offre un système intégré dans MATLAB, basé sur la transformée de Hilbert–Huang (HHT) (EMD + analyse spectrale de Hilbert). Il permet d'extraire des informations

sur le temps et la fréquence des signaux provenant des réseaux hybrides [7]. Ces informations sont ensuite utilisées par un CNN simple, mis en place et entraîné avec la Deep Learning Toolbox, pour classer automatiquement les défauts simples et hybrides [10].

1.4.3 Optimisation native par POA appliquée au Bi-LSTM

Une idée importante est d'améliorer directement les réglages d'un modèle Bidirectional Long Short-Term Memory (Bi-LSTM) avec le Pelican Optimization Algorithm (POA). L'intégration directe de cette optimisation dans MATLAB permet d'automatiser le réglage des paramètres (comme le nombre de neurones, la vitesse d'apprentissage, la taille de la fenêtre temporelle, le dropout), tout en utilisant les informations passées et futures. L'objectif est d'améliorer la précision de la prédiction et de diminuer le nombre de fausses alertes, tout en réduisant le temps d'entraînement par rapport à un réglage manuel [3].

1.4.4 Interprétabilité de (XAI) et génération automatique de rapports

Pour que les résultats soient plus compréhensibles et acceptés dans l'industrie, le travail inclue une dimension d'intelligence artificielle explicable (XAI). Des outils de suivi sont prévus, comme des cartes d'activation pour le CNN et des indicateurs temporels pour le Bi-LSTM, pour justifier les décisions de détection et de prédiction. Cette approche est complétée par la création automatique de rapports avec des figures, des tableaux et des mesures de performance, fournissant ainsi un résultat prêt à l'emploi pour l'analyse et la communication des résultats [6].

1.4.5 Chaîne de maintenance prédictive unifiée

Enfin, l'approche proposée vise une maintenance prédictive unifiée, basée sur un script MATLAB unique qui gère toutes les étapes : création et acquisition des données, extraction HHT, classification par CNN, prédiction par Bi-LSTM optimisé par POA et module XAI. Cette intégration complète est associée à un système d'alertes et de tableaux de bord pour la surveillance en temps réel, ce qui aide à prendre des décisions plus rapidement et à améliorer la fiabilité du réseau [12].

1.5 Hypothèses de recherche

Dans le cadre de ce travail, nous avons établi les hypothèses suivantes. Elles vont orienter notre démarche et structurer notre analyse des résultats :

- Signatures temps-fréquence des anomalies internes

Les anomalies internes créent des signatures temps-fréquence spécifiques dans les signaux électriques (tension U, courant I et puissance P). Ceci permet de les détecter et de les distinguer clairement des états de fonctionnement normal.

- Amélioration par POA :

L'ajustement des hyperparamètres avec le Pelican Optimisation Algorithme (POA) améliore la justesse et la stabilité du modèle. Cela réduit aussi le temps nécessaire à la mise en place, comparé à une configuration sans ajustement.

- Performance du modèle pour un diagnostic complet

Notre modèle (HHT → CNN → Bi-LSTM ajusté par POA) peut, à partir de données simulées, identifier avec précision le type d'anomalie, localiser le bus touché et prévoir comment l'anomalie va évoluer avec le temps.

- Interprétation et application industrielle

L'ajout d'un module d'intelligence artificielle interprétable (XAI) rend les décisions du modèle plus claires. Cela devrait encourager son utilisation dans l'industrie, car il fournit des explications claires sur les alertes générées.

1.6 Méthodologie de recherche

Notre méthode vise à détecter, classer et prévoir les anomalies internes dans un réseau électrique hybride. Elle suit une progression logique, inspirée des travaux en intelligence artificielle et en traitement du signal. Elle part de l'étude de ce qui existe déjà et se termine par la confirmation des résultats. Un schéma illustre les étapes de cette méthode.

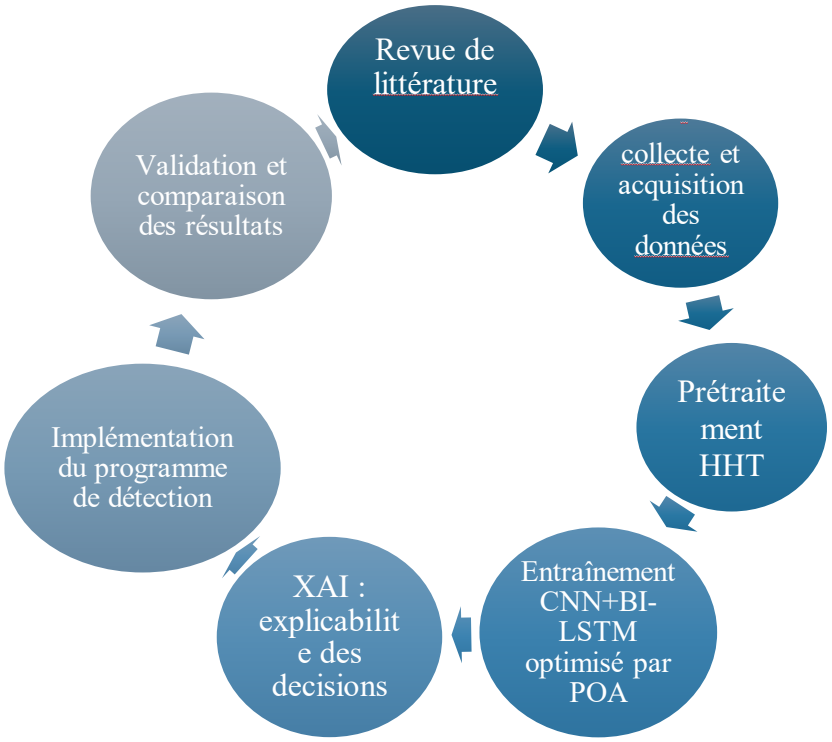

Figure 01-1 : Démarche à suivre.

La méthode se déroule en sept phases principales :

1.6.1 Revue de littérature

Nous avons commencé par examiner en détail les études scientifiques existantes : articles, conférences, ouvrages spécialisés. Le but était de connaître les approches actuelles pour détecter et prévoir les anomalies dans les réseaux électriques et les systèmes énergétiques hybrides. Nous avons aussi identifié leurs points faibles pour montrer l'originalité de notre approche.

1.6.2 Collecte et acquisitions des données

Dans un deuxième temps, nous avons créé et rassemblé des données à partir de simulations avec MATLAB/Simulink. Nous avons mesuré les signaux électriques (tension U, courant I et puissance P) à différents points du réseau hybride, en conditions de fonctionnement normales et avec anomalies.

1.6.3 Prétraitement et extraction HHT

Les données ont été préparées : suppression du bruit, normalisation des signaux et découpage des séries temporelles. La transformée de Hilbert-Huang (HHT), avec la décomposition EMD et l'analyse spectrale de Hilbert, a permis d'extraire des signatures temps-fréquence adaptées aux signaux non stationnaires.

1.6.4 Entérinement CNN–Bi-LSTM optimisé par POA

Les informations tirées de la HHT servent à mettre en place un réseau de neurones (CNN) pour la détection et le classement des anomalies. Ensuite, un modèle Bidirectionnel Long Short-Term Memory (Bi-LSTM) est utilisé pour prévoir l'évolution des anomalies. Les réglages du Bi-LSTM sont ajustés avec le Pélican Optimisation Algorithme (POA) pour améliorer la justesse et réduire les fausses alertes.

1.6.5 Explicabilité des décisions (XAI)

Nous avons cherché à rendre le modèle plus facile à comprendre grâce à des techniques d'intelligence artificielle interprétable (XAI). Des indicateurs et des graphiques expliquent les décisions prises par les modèles CNN et Bi-LSTM, aidant ainsi les opérateurs à comprendre les résultats.

1.6.6 Implémentation du programme de détection

Toutes les étapes sont regroupées dans des scripts MATLAB, qui automatisent le traitement des données, l'apprentissage et la prévision. Le but est de pouvoir exécuter le programme de détection de bout en bout.

1.6.7 Validations et comparaison des résultats

Pour finir, nous avons mesuré et confirmé les performances de notre approche avec des critères comme la justesse, le rappel, le score F1, la matrice de confusion et le temps de calcul. Nous avons comparé nos résultats avec ceux d'autres approches pour prouver que notre méthode est efficace et solide.

1.7 Conclusion

Ce chapitre a permis de présenter, l'introduction générale du sujet traité, d'exposé la problématique ainsi que les objectifs visé. J'ai aussi décrit ma méthode de recherche pour bien définir le cadre de ce travail. Les chapitres suivants se consacrés sur les études pour détecter et prédire les défauts internes, et analyser les résultats obtenus avec les réseaux de neurones artificiels, qui sont le cœur de ce mémoire.

Chapitre 2

Aperçu sur la détection et le diagnostic des défauts internes électriques

2.1 Réseau électrique

Un réseau électrique, c'est un ensemble d'installations connectées qui servent à produire, transporter, distribuer et consommer de l'électricité. C'est très important pour que les industries et la société fonctionnent bien, car ça assure que les gens aient toujours de l'électricité, et que ce soit fiable et de bonne qualité.

Différentes centrales, comme les centrales classiques et les sources renouvelables, produisent l'électricité. Ensuite, cette électricité est envoyée vers les endroits où elle est utilisée, via le réseau de transport, qui fonctionne souvent à haute tension pour éviter de perdre trop d'énergie. Enfin, le réseau de distribution réduit la tension et fournit l'électricité aux usagers industriels et aux particuliers.

Ces dernières années, les réseaux électriques ont pas mal changé avec l'ajout progressif des énergies renouvelables. Du coup, on a maintenant des réseaux électriques hybrides avec plusieurs sources, qui combinent l'hydroélectricité, l'éolien et le photovoltaïque. Même si ça rend le système électrique plus souple et durable, ça crée aussi des nouveaux problèmes liés aux variations de la production et à la complexité du réseau.

Dans ce contexte, il devient crucial de surveiller et d'analyser le réseau électrique pour s'assurer qu'il reste stable, fiable et qu'il fonctionne sans interruption. L'étude du réseau électrique est donc une base essentielle pour mettre en place des méthodes avancées de détection et de diagnostic des défauts internes, surtout dans les réseaux hybrides avec plusieurs sources.

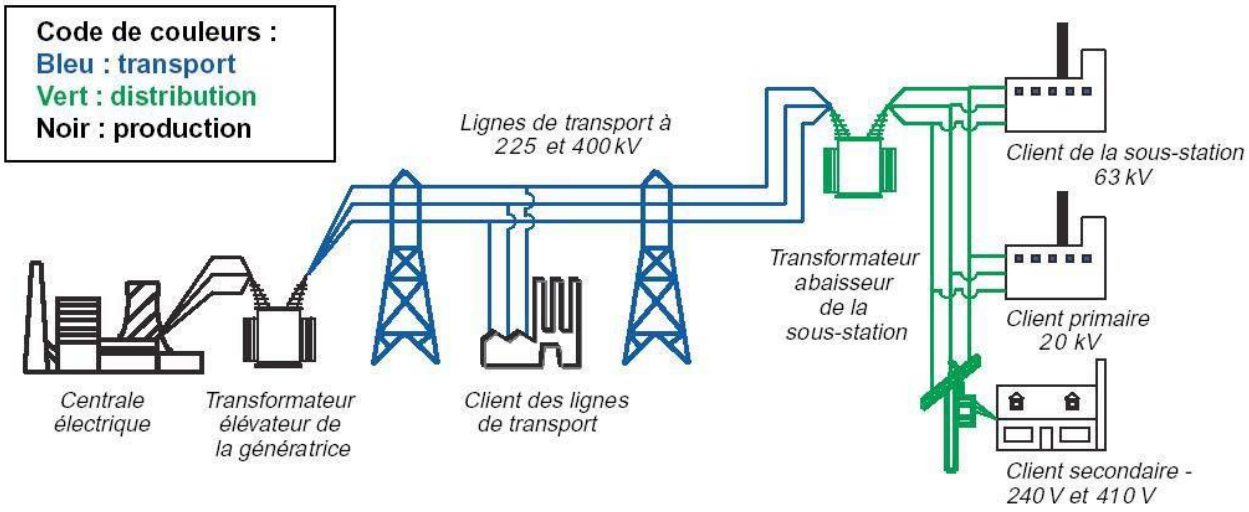

Figure 2 - 1 : Structure générale d'un réseau électrique.

2.2 Système de Protection des équipements électriques

La protection des équipements électriques est très importante pour le réseau électrique. Son but principal est de garder les installations sûres, de protéger les équipements et de faire en sorte que le service continue de fonctionner. Ici, on va surtout parler des protections à l'intérieur des équipements comme les générateurs, les machines électriques et les transformateurs, contrairement à la protection des lignes de transmission.

2.2.1 Rôle des protections internes

Le rôle des protections internes est de voir vite s'il y a des problèmes ou des défauts à l'intérieur des équipements électriques. Elles servent à isoler l'équipement qui ne marche plus avant que le problème ne s'aggrave ou n'endommage le reste du système. Ces protections surveillent en permanence des éléments électriques comme le courant, la tension, la puissance et la fréquence.



Figure 2 - 2 : Exemple d'un dispositif de protection interne d'un équipement électrique.

2.2.2 Comment protéger les générateurs et les machines électriques

Les générateurs et les machines électriques risquent beaucoup de subir des défauts internes, comme les courts-circuits, les surcharges, les problèmes d'isolation et les déséquilibres de phase. Pour éviter ces problèmes, on utilise des systèmes de protection comme les relais de surintensité, les relais différentiels, les protections thermiques et les protections contre les défauts à la terre.



Figure 2 - 3 : Exemple de relais intelligent utilisé pour la protection des générateurs et des machines électriques.

2.2.3 Problèmes avec les protections classiques pour les défauts internes

Bien qu'elles soient utiles pour les défauts importants, les protections classiques ont des problèmes pour détecter les défauts internes qui apparaissent lentement ou qui sont de faible importance. Ces défauts peuvent ne pas atteindre les niveaux nécessaires pour déclencher une alerte, ce qui retarde leur détection. De plus, il est difficile de régler les niveaux d'alerte dans les réseaux hybrides parce que les conditions de fonctionnement changent souvent.

C'est pourquoi il est nécessaire d'utiliser des méthodes plus modernes pour détecter et diagnostiquer les problèmes, en se basant sur l'analyse des signaux électriques et en utilisant l'intelligence artificielle, comme on le verra plus loin.

2.3 Les défauts internes dans le réseau électrique

Les perturbations internes sont une cause importante de la mauvaise qualité et du manque de fiabilité des réseaux électriques. Contrairement aux problèmes extérieurs, souvent liés aux lignes de transport ou aux soucis liés à l'environnement, les défauts internes se trouvent directement à l'intérieur des équipements électriques comme les générateurs, les machines électriques, les transformateurs et les convertisseurs de courant.

En général, on peut trouver des défauts internes dans les réseaux électriques normaux et dans les réseaux électriques mixtes. Cependant, dans les réseaux mixtes qui utilisent plusieurs sources d'énergie, les conditions de fonctionnement qui changent souvent et les différentes technologies utilisées rendent ces défauts plus difficiles à trouver et à diagnostiquer.

Les raisons des défauts internes sont nombreuses. Elles peuvent être liées à l'âge des composants, à l'isolation qui s'abîme, aux surcharges de chaleur, aux défauts d'enroulement, aux déséquilibres électriques ou aux changements anormaux des paramètres de fonctionnement. Ces défauts se développent souvent lentement et peuvent ne pas être vus pendant longtemps.

Un point important concernant les défauts internes est qu'ils ne sont pas stables et qu'on ne les remarque pas facilement. Les signes électriques associés à ces défauts se traduisent

généralement par de faibles changements des signaux de courant, de tension et de puissance, qui peuvent ne pas dépasser les limites de déclenchement des systèmes de protection habituels.

C'est pourquoi il est très important de trouver rapidement et de façon sûre les défauts internes pour assurer la continuité du service, améliorer la fiabilité des équipements et baisser les coûts de maintenance. L'analyse poussée des signaux électriques et l'utilisation de méthodes intelligentes montrent des possibilités intéressantes pour le diagnostic des défauts internes, surtout dans les réseaux électriques mixtes.

2.3.1 Types de défauts internes

Les défauts internes regroupent toutes les anomalies qui apparaissent à l'intérieur des équipements électriques et qui affectent directement leur fonctionnement. Dans les réseaux électriques, et en particulier dans les réseaux mixtes à plusieurs sources, ces défauts ont des comportements compliqués et peuvent être classés selon leur nature et leur façon d'évoluer.

Les défauts électriques internes sont liés à des courts-circuits internes, des défauts entre phases, des défauts phase-terre ou des déséquilibres électriques. Les défauts paramétriques correspondent à des changements anormaux des paramètres internes comme la résistance ou l'inductance. Enfin, les défauts progressifs sont liés à l'âge des composants et évoluent lentement avec le temps.

2.3.2 Détection des défauts internes

La détection des défauts internes se fait en surveillant en permanence le comportement des équipements électriques pour trouver tout changement par rapport à un fonctionnement normal. Le but est de trouver les problèmes à un stade précoce pour éviter qu'ils ne se propagent.

L'analyse des signaux électriques, notamment la tension (U), le courant (I) et la puissance (P), est une méthode couramment utilisée. Les défauts internes se manifestent par des changements faibles et souvent instables de ces grandeurs, ce qui rend leur détection difficile avec les méthodes classiques à seuil fixe.

2.3.3 Classification des défauts internes

La classification des défauts internes a pour but d'identifier la nature exacte du défaut trouvé. Elle peut être faite selon plusieurs critères, comme le type de composant touché, la nature du défaut ou son niveau de gravité.

Une classification fiable aide à prendre des décisions en matière de maintenance et à améliorer l'efficacité des stratégies de protection. Dans les systèmes modernes, cette étape est de plus en plus assurée par des méthodes intelligentes capables de traiter des données compliquées.

2.3.4 Localisation des défauts internes

La localisation des défauts internes consiste à identifier précisément l'équipement ou la zone du réseau où le défaut est apparu. Elle peut être faite par composant ou par bus dans le cas des réseaux électriques étendus.

La capacité à localiser les défauts internes est très intéressante pour la maintenance prédictive, car elle permet de réduire le temps d'intervention, de limiter les coûts de réparation et d'améliorer la disponibilité globale du réseau électrique.

2.3.5 Prédiction des défauts internes

La prédiction des défauts internes est une étape avancée de la surveillance des réseaux électriques, qui va au-delà de la simple détection et classification. Elle a pour but de prévoir l'apparition ou l'évolution d'un défaut avant qu'il n'atteigne un niveau critique pouvant entraîner une panne importante de l'équipement ou une interruption du service.

Dans les réseaux électriques modernes, et en particulier dans les réseaux mixtes à plusieurs sources, les défauts internes sont souvent progressifs. Ils se développent lentement à cause de l'âge des composants, des contraintes de chaleur, des surcharges répétées ou des changements des conditions de fonctionnement. Ces évolutions se traduisent par des modifications progressives des signaux électriques, comme des dérives de tension, de courant ou de puissance, qui sont difficiles à interpréter avec les méthodes habituelles.

La prédiction des défauts internes repose donc sur l'analyse temporelle de ces grandeurs électriques pour identifier des tendances anormales et estimer leur évolution future. Cette approche permet de passer d'une maintenance corrective ou préventive à une maintenance prédictive, où les interventions sont planifiées en fonction de l'état réel des équipements.

Cependant, la complexité et le caractère non linéaire des signaux associés aux défauts internes rendent la prédiction particulièrement délicate. Les méthodes classiques, basées sur des modèles fixes ou des seuils déterminés, montrent rapidement leurs limites. C'est pourquoi on utilise des méthodes intelligentes capables d'apprendre les dynamiques temporelles des défauts et de fournir des prédictions fiables, ce qui ouvre la voie aux approches basées sur les réseaux de neurones artificiels, qui seront développées dans le chapitre suivant.

2.4 Techniques de diagnostic des défauts internes

Le but du dépistage des pannes internes est de trouver, de comprendre et d'interpréter les problèmes qui touchent les équipements électriques à partir des informations mesurées. Contrairement aux systèmes de protection classiques, qui se contentent surtout d'isoler l'équipement qui ne fonctionne plus, le dépistage cherche aussi à donner des infos précises sur le type de panne, sa gravité et comment elle évolue avec le temps. Cette étape est très importante pour mettre en place des stratégies efficaces de maintenance, surtout dans les réseaux électriques récents [12], [13].

2.4.1 Méthodes basées sur les grandeurs électriques

Les méthodes qui regardent les grandeurs électriques sont les plus anciennes et les plus courantes pour trouver les pannes internes. Elles se servent directement des mesures de tension, de courant et de puissance pour voir s'il y a des différences par rapport au fonctionnement normal du système [14].

Les méthodes à seuil comparent les grandeurs mesurées à des valeurs de référence établies. Si un seuil est dépassé, un problème est signalé. Bien que ces méthodes soient faciles à mettre en place et pas chères, elles ont des limites face aux pannes internes qui s'aggravent lentement et aux conditions de fonctionnement qui changent [15].

Les méthodes basées sur des modèles physiques utilisent une représentation mathématique du comportement normal du système électrique. Le dépistage se fait en comparant les mesures réelles aux valeurs estimées par le modèle. Toute différence importante peut être le signe d'une panne interne. Ces méthodes sont plus précises que les méthodes à seuil, mais leur efficacité dépend de la qualité du modèle utilisé [16].

2.4.2 Méthodes basées sur l'analyse temps-fréquence

Les pannes internes ont souvent des caractéristiques qui ne sont pas stables et qui sont faibles, ce qui rend les méthodes purement temporelles ou fréquentielles moins efficaces. Les méthodes d'analyse temps-fréquence sont donc souvent utilisées pour trouver les pannes internes dans les équipements électriques [17].

La transformée de Fourier rapide (FFT) permet d'analyser le contenu fréquentiel des signaux, mais elle ne dit rien sur comment les composantes fréquentielles évoluent avec le temps. La transformée de Fourier à court terme (STFT) améliore cela en utilisant une fenêtre temporelle glissante, mais cela implique un compromis entre la précision temporelle et fréquentielle [18].

Les méthodes à ondelettes offrent une analyse qui s'adapte bien aux signaux non stables. Elles permettent de voir les changements locaux du signal qui sont liés à l'apparition de pannes internes. Cependant, le choix de la fonction ondelette est important car il influence les performances du dépistage [19].

La transformée de Hilbert-Huang (HHT), qui utilise la décomposition modale empirique (EMD) et l'analyse spectrale de Hilbert, est une approche puissante pour traiter les signaux non linéaires et non stables. Elle permet de repérer des signes précis des pannes internes et c'est une transition naturelle vers l'approche proposée ici [20].

2.4.3 Facteurs influençant la précision du diagnostic

La précision du dépistage des pannes internes dépend de plusieurs choses. Le bruit de mesure peut cacher les signes faibles des pannes progressives, et les conditions d'utilisation variables, comme les changements de charge, modifient les caractéristiques des signaux électriques [21].

Dans les réseaux hybrides, la variabilité des sources et les interactions entre les différentes unités de production rendent les comportements complexes et l'interprétation des signaux plus difficile. Il faut tenir compte de ces facteurs lors de la conception des méthodes de dépistage pour qu'elles soient fiables [22].

2.4.4 Méthodes basées sur l'intelligence artificielle

Les méthodes qui utilisent l'intelligence artificielle se sont développées rapidement ces dernières années pour le dépistage des pannes internes. Elles permettent de créer des modèles des relations entre les signaux électriques et les états de fonctionnement du système, sans avoir besoin d'un modèle physique précis [23].

Les techniques de systèmes experts utilisent des règles basées sur l'expérience humaine, tandis que les systèmes à logique floue gèrent l'incertitude des signaux électriques. Les approches basées sur l'apprentissage automatique, comme les réseaux de neurones, sont plus performantes pour repérer et classer les pannes internes [24].

Ces approches sont la base des méthodes utilisées ici. Les modèles basés sur les réseaux de neurones, et en particulier les architectures Bi-LSTM, seront expliqués en détail dans le chapitre suivant.

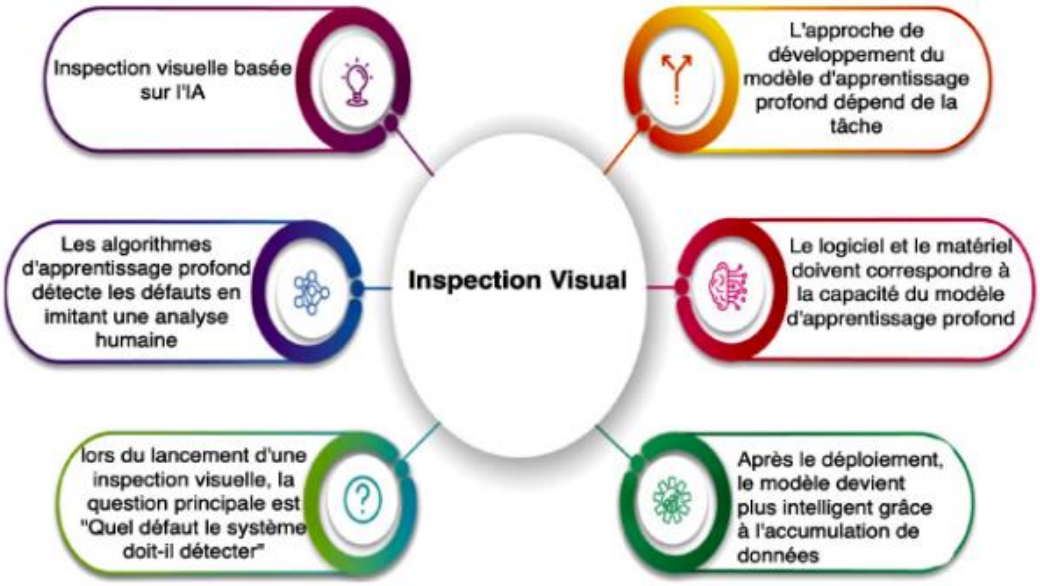

Figure 2 - 4 : Principe de l'inspection visuelle basée sur l'intelligence artificielle pour la détection des défauts.

2.5 Conclusion

Ce chapitre offre une vue d'ensemble des réseaux électriques et de leurs systèmes de protection, en se concentrant sur les défauts internes des équipements. On a regardé les différents types de défauts, comment ils se produisent, et les problèmes liés à leur détection, leur classification et leur localisation.

On a aussi parlé des principales techniques de diagnostic actuelles, des méthodes classiques basées sur les grandeurs électriques aux approches temps-fréquence et à celles basées sur l'intelligence artificielle. On a noté leurs points forts et leurs points faibles face à la complexité des réseaux modernes, surtout ceux qui sont hybrides et multi-sources.

Ces observations montrent qu'il faut des méthodes intelligentes plus efficaces pour identifier les défauts internes. Le prochain chapitre sera donc consacré à l'étude et à l'application des réseaux de neurones artificiels pour détecter et identifier ces défauts dans les réseaux électriques.

Chapitre 3

Identification et prédiction des défauts électriques internes par des méthodes intelligentes

3. 1 Introduction aux méthodes intelligentes

Les réseaux électriques actuels, surtout ceux qui combinent plusieurs sources d'énergie renouvelable, sont de plus en plus compliqués à gérer. Il devient difficile de surveiller les équipements, surtout pour détecter les défauts internes. Ces défauts ont des signes discrets, irréguliers et variables [25], [26].

Comme on l'a vu avant, les méthodes classiques de diagnostic, avec leurs seuils fixes ou leurs modèles rigides, ont du mal à faire face aux changements de conditions, au bruit des mesures et aux liens entre les différentes sources de production. Du coup, il est difficile de détecter rapidement et de prédire avec précision les défauts internes avec ces méthodes habituelles [27].

C'est là que les méthodes intelligentes, qui apprennent à partir des données, deviennent intéressantes. Elles permettent de créer des modèles pour les relations complexes entre les signaux électriques (tension, courant, puissance) et le fonctionnement des équipements, sans avoir besoin de modèles physiques compliqués. L'apprentissage automatique et profond, notamment les réseaux de neurones, sont très performants pour trouver les défauts internes et voir comment ils évoluent.

Ce chapitre va présenter les méthodes intelligentes que j'ai utilisées pour trouver et prédire les défauts internes. On va se concentrer sur l'analyse temps-fréquence avec la transformée de Hilbert-Huang pour repérer les signes distinctifs, les réseaux de neurones convolutifs pour classer les défauts, et les architectures récurrentes Bi-LSTM pour voir comment ils évoluent dans le temps. Pour finir, je parlerai de l'ajustement des paramètres avec l'algorithme POA pour améliorer les performances de l'ensemble [26], [28].

3.2 Description de réseau de neurones

Le réseau neuronal artificiel (RNA) est un modèle mathématique qui s'inspire du cerveau humain. Il essaie d'imiter sa façon d'apprendre et de traiter l'information. C'est un système qui s'adapte et change en fonction de ce qu'il apprend. Il réagit aux nouvelles situations en se basant sur son expérience. Sa capacité à apprendre les relations complexes entre ce qu'on lui donne et ce qu'il doit produire a poussé les chercheurs à l'utiliser pour résoudre des problèmes variés. Il est résistant au bruit et assez solide, ce qui fait que les approches basées sur les RNA sont moins sensibles aux changements de conditions que les méthodes classiques utilisées en ingénierie des systèmes électriques [29].

Un RNA est un ensemble de nœuds (neurones) connectés entre eux et organisés en couches. Chaque nœud reçoit des informations de la couche précédente et les combine en utilisant des poids (wi, j (i)). Chaque nœud a aussi un seuil d'activation (biais) bk (i). Lorsque la valeur d'entrée est proche de ce seuil, la valeur de sortie change beaucoup plus. Vous trouverez une description plus détaillée dans les références [30, 31]. La figure 3.1 présente la structure d'un RNA à propagation avant (feedforward) connu sous le nom de perceptron.

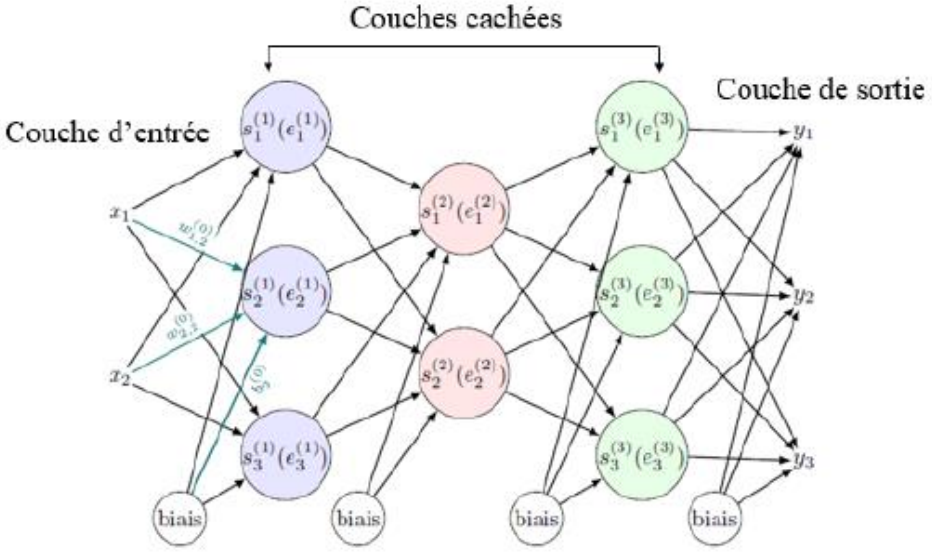

Figure 3 - 1 : Illustration d'un réseau de neurones feedforward.

Les réseaux neuronaux artificiels (RNA) ne sont pas programmés comme les systèmes experts. Ils apprennent en ajustant leurs paramètres internes (poids et biais) en fonction des données qu'on leur fournit. On peut donc dire qu'ils traitent l'information par l'exemple.

Grâce à leur aptitude à reconnaître des formes, beaucoup de chercheurs les emploient dans les systèmes électriques pour traiter des signaux, prendre des décisions, détecter, classifier et même localiser des défauts.

Un défi majeur avec les RNA est qu'il n'y a pas de règle claire pour choisir le nombre de couches cachées et de neurones par couche. Malgré ça, leur capacité à généraliser est un avantage clé. Ils sont particulièrement bons pour le calcul parallèle.

Ils sont conçus pour généraliser à partir des données qu'ils ont vues et donner la bonne réponse même si on leur présente quelque chose de nouveau [32], [33].

Un tournant important a été la création d'algorithmes d'apprentissage adaptatif. L'un des plus courants est la rétro propagation du gradient, où les poids des neurones sont ajustés pour minimiser l'erreur entre la sortie réelle et la sortie désirée. C'est ce qu'on appelle l'apprentissage supervisé, car on fournit une réponse attendue.

3.2.1 Réseaux de neurones feedforward

Il existe pas mal de types et de modèles de réseaux de neurones artificiels. On peut nommer les réseaux récurrents Elman [34], les réseaux auto-organisés (cartes de Kohonen) [35] et les réseaux de type extrême Learning machine [36]. Les réseaux feedforward sont les plus courants, car ils sont simples à utiliser. Dans ces réseaux, l'information va dans une seule direction : elle part des entrées, passe par les couches cachées, et arrive aux sorties. Il n'y a pas de boucles, ce qui explique pourquoi on les utilise.

En plus du type de réseau, il faut aussi choisir une fonction d'erreur et une fonction d'activation pour les neurones. Ces choix dépendent souvent des données que l'on traite.

Un réseau de neurones multicouche (MLP) classique a trois parties : une couche d'entrée, une couche de sortie et une ou plusieurs couches cachées. Chaque couche a un certain nombre de neurones.

Le neurone utilisé est un modèle standard. On additionne toutes les entrées, chacune étant multipliée par un poids (coefficient synaptique). On applique ensuite une fonction d'activation au résultat. La sortie est ensuite connectée à toutes les entrées de la couche suivante. La structure de base d'un neurone est présentée dans la figure 3.2.

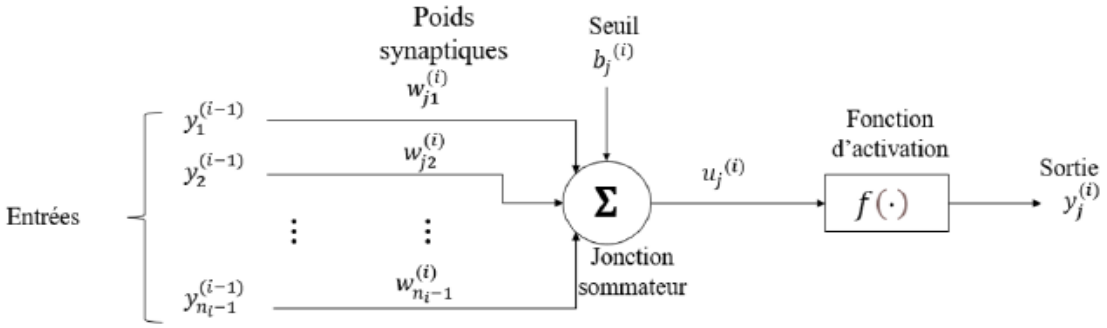

Figure 3 - 2 : La structure de base d'un neurone.

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

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

Où F représente la fonction de transfert (fonction d'activation) du neurone j.

i représente la couche cachée.

$Y^{(i-1)}$, k=1,…, n_{i-1}, représente les signaux d'entrée du neurone j et n nombre de neurones dans la couche cachée i, $W_{jk}^{(i)}$ représente les coefficients de poids de la connexion entre les entrées et le neurone *j*, $B_j^{(i)}$ est le biais (seuil) du neurone j.

3.2.2 Fonction de transfert/activation

Dans le domaine des réseaux de neurones artificiels, la fonction d'activation est une fonction mathématique appliquée à un signal en sortie d'un neurone artificiel. Une fois un seuil est atteint, le neurone donne une réponse. La fonction d'activation est souvent une fonction non linéaire. Le tableau ci-dessous regroupe les fonctions d'activation les plus utilisée pour les couches neuronales.

Tableau 1 : Fonctions d'activation.

Nom	Fonction Matlab	Graphe	Équation
Identité/Rampe	Purelin : Linéaire	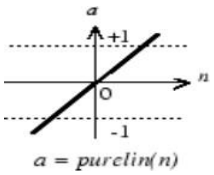 a = purelin(n)	$f(x) = x$
Marche/Heaviside Step	Heaviside Step	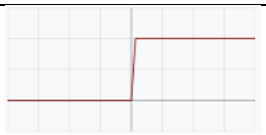	$f(x) = \{0 \text{ si } x < 0$ $1 \text{ si } x \geq 0$
Logistique ou sigmoïde	Losig	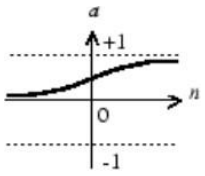 a = logsig(n)	$f(x) = \frac{1}{1 + e^{-x}}$
Tangente Hyperbolique	Tansig	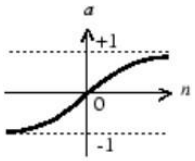 a = tansig(n)	$f(x) = \tanh(x) = \frac{2}{1 + e^{-2x}} -$
Unité de rectification linéaire Relu	Poslin : Positive linéaire	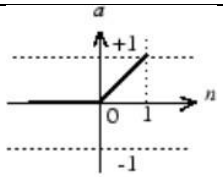 a = poslin(n)	$f(x) = \{0 \text{ si } x < 0$ $x \text{ si } x \geq 0$

3.3 Apprentissage et comment rendre les réseaux de neurones meilleurs

L'apprentissage est très important pour que les réseaux de neurones artificiels marchent. Cela aide à bien régler les éléments internes du réseau, comme les connexions et les ajustements, afin de se tromper le moins possible entre ce que le réseau sort et ce qu'on veut qu'il sorte. Pour trouver et prédire les problèmes dans les réseaux électriques, l'apprentissage doit pouvoir gérer des données qui sont un peu fausses, pas toujours cohérentes et parfois changeantes.

En général, on peut apprendre aux réseaux de neurones de trois manières : en leur montrant des exemples avec les réponses (supervisé), en les laissant découvrir par eux-mêmes (non supervisé) et en les récompensant ou en les punissant pour leurs actions (par renforcement). L'apprentissage supervisé est souvent choisi pour diagnostiquer et surveiller les systèmes électriques, car on utilise des données avec des étiquettes qui viennent de simulations ou de mesures.

3.3.1 Apprentissage supervisé

Avec l'apprentissage supervisé, on montre au réseau de neurones des données d'entrée avec les bonnes réponses. Le but est de se tromper le moins possible, en utilisant une formule qui mesure l'erreur entre la réponse réelle (y) et la réponse que le réseau donne (ŷ). C'est très utile pour classer et prédire les problèmes, car chaque situation du système correspond à une catégorie ou à un résultat attendu.
Dans les réseaux électriques, on peut donner au réseau des informations sur la tension, le courant et la puissance. Les réponses du réseau indiquent alors quel type de défauts il y a ou à la prédiction de son évolution temporelle.

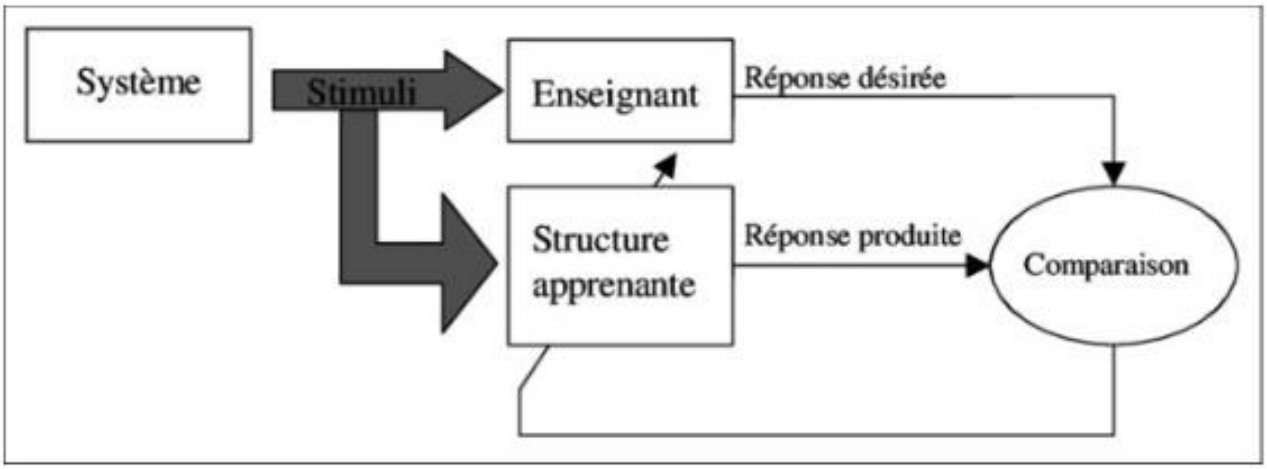

Figure 3 - 3 : Principe général de l'apprentissage supervisé.

3.3.2 Fonction de coût et minimisation de l'erreur

La fonction de coût sert à voir si le réseau fait bien son boulot durant l'apprentissage. On choisit la fonction selon le problème erreur quadratique moyenne pour la régression, entropie croisée pour la classification.

Pour un problème de régression, la fonction de coût peut être exprimée par l'équation suivante

$$J = \frac{1}{N}\sum_{k=1}^{N}(y_k - \hat{y}_k)^2 \qquad \textbf{(3.2)}$$

Où N représente le nombre d'échantillons, y_k la valeur réelle et $\hat{y}_k$ la valeur estimée par le réseau. La minimisation de cette fonction de coût est généralement réalisée par des algorithmes d'optimisation basés sur le gradient.

3.3.3 Sur apprentissage et capacité de généralisation

Le sur apprentissage, c'est quand le réseau apprend trop par cœur les données d'entraînement. Du coup, il n'arrive plus à s'adapter aux données nouvelles. Pour un diagnostic de défauts internes, ça peut planter la surveillance en temps réel.

Pour que le réseau s'adapte mieux, on peut utiliser un ensemble de validation, ajuster les poids, limiter la complexité du réseau, ou varier les données d'apprentissage.

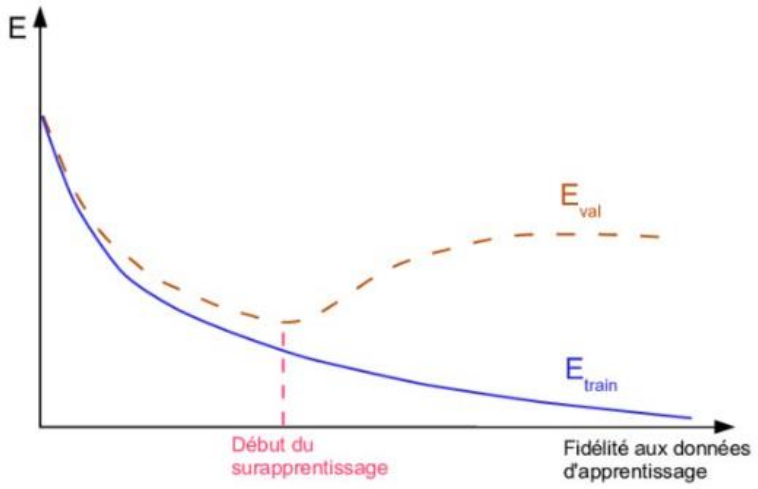

Figure 3 - 4 : Illustration du sur apprentissage et de la généralisation.

3.3.4 Transition vers les architectures avancées

Les réseaux classiques font le travail, mais ils coincent avec les signaux complexes, non linéaires et changeants comme ceux des défauts internes des réseaux électriques hybrides. D'où l'intérêt d'architectures plus pointues.

Ici, on sort les bonnes infos avec une analyse temps-fréquence basée sur la transformée de Hilbert–Huang. Puis, on identifie et on prédit les défauts avec des réseaux neurones convolutifs et récurrents qui seront détaillés dans les sections suivantes.

3.4 Analyse et extraction des caractéristiques par la Transformée de Hilbert–Huang (HHT)

Les signaux électriques des réseaux hybrides ont souvent des caractéristiques instables et non linéaires, surtout avec des défauts internes qui évoluent. Les méthodes classiques comme la transformée de Fourier (FFT) ne marchent pas bien, car elles supposent que les signaux sont stables. Elles ne peuvent pas capter les variations des défauts.

La Transformée de Hilbert–Huang (HHT) est une bonne solution pour analyser ces signaux. Proposée par Huang et al. [37], elle décompose le signal et offre une vue temps–fréquence précise, sans avoir besoin de connaître la linéarité ou la stabilité du signal.

3.4.1 Décomposition modale empirique (EMD)

La première étape de la HHT, c'est la Décomposition Modale Empirique (EMD). Elle décompose le signal en plusieurs fonctions appelées Intrinsic Mode Fonctions (IMF). Chaque IMF représente une oscillation du signal à un moment donné [38].

Mathématiquement, le signal peut être exprimé comme :

$$x(t) = \sum_{k=1}^{K} \mathrm{IMF}_k(t) + r(t) \tag{3.3}$$

Où r(t) représente le résidu final.

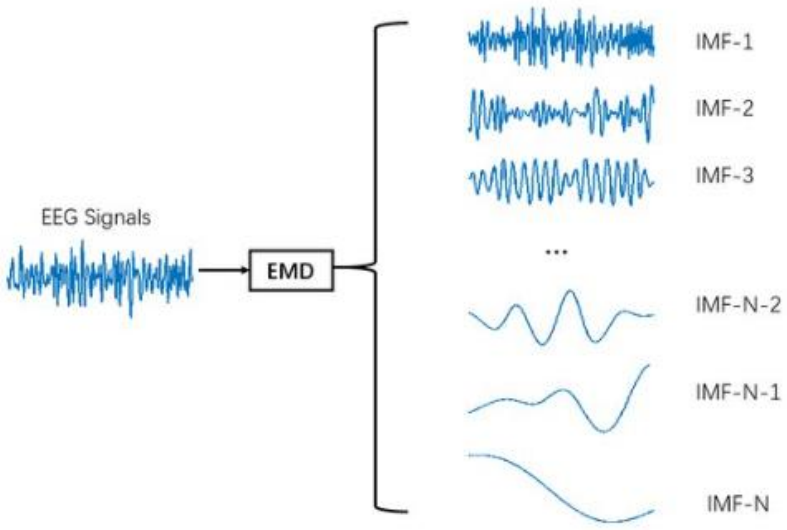

Figure 3 - 5 : la décomposition EMD appliquée à un signal électrique.

3.4.2 Transformée de Hilbert ET représentation temps–fréquence

Après l'extraction des IMF, chacune est analysée à l'aide de la transformée de Hilbert afin d'obtenir la fréquence instantanée et l'amplitude instantanée [39].

$$\hat{c}(t) = \frac{1}{\pi} \mathrm{P.V.} \int_{-\infty}^{+\infty} \frac{c(\tau)}{t-\tau} d\tau \tag{3.4}$$

Le signal analytique associé est alors donné par :

$$z(t) = c(t) + j\hat{c}(t) = a(t)e^{j\theta(t)} \quad \textbf{(3.5)}$$

Où :

a(t) est l'amplitude instantanée,

θ(t) est la phase instantanée,

La fréquence instantanée est définie par $\omega(t)=\frac{d\theta(t)}{dt}$.

Cette représentation permet une analyse fine de l'évolution fréquentielle du signal dans le temps.

3.4.3 Intérêt de la HHT pour les défauts internes

La transformée de Hilbert-Huang (HHT) est intéressante pour repérer les problèmes internes dans les réseaux hybrides, car :

* Elle s'adapte automatiquement aux signaux qui ne sont pas stables.

* Elle est très sensible aux problèmes qui apparaissent petit à petit.

* Elle permet d'extraire des infos importantes comme l'énergie, la fréquence instantanée et l'entropie.

Grâce à ces atouts, la HHT est un bon outil pour obtenir des infos qui peuvent ensuite être utilisées par des modèles intelligents comme les CNN et Bi-LSTM [40].

3.5 Réseaux de neurones convolutifs (CNN) pour la classification des défauts internes

Une fois que la HHT a permis d'extraire des infos sur le temps et la fréquence, l'étape suivante est d'identifier automatiquement le type de problème interne : paramétrique, électrique, progressif ou hybride. Les réseaux de neurones convolutifs (CNN) sont parfaits pour ça. Ils apprennent directement à partir des données (images ou matrices) et réduisent le besoin d'une extraction manuelle compliquée [41].

3.5.1 Principe général des CNN

Un CNN est un type d'apprentissage profond qui utilise plusieurs couches spécialisées :

- des couches de convolution,
- des fonctions d'activation non linéaires,
- des couches de pooling (sous-échantillonnage)
- des couches entièrement connectées pour prendre la décision finale.

Le but est d'extraire automatiquement des infos importantes à différents niveaux : des motifs locaux (bords, pics) jusqu'à des caractéristiques globales liées à un type de problème [42]. La Figure 3.6 montre une architecture générale d'un CNN.

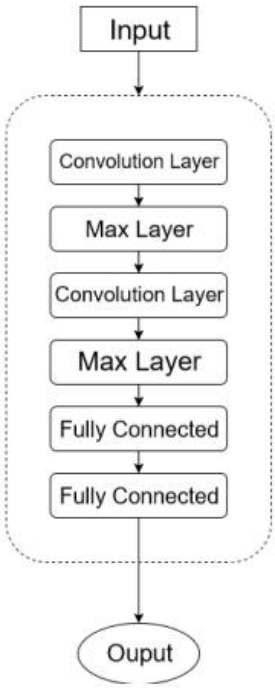

Figure 3 - 6 : Architecture générale d'un réseau de neurones convolutif (CNN).

3.5.2 Couche de convolution et identification des motifs

La convolution applique un filtre glissant sur l'entrée pour créer une carte de caractéristiques. Pour une entrée 2D X et un filtre K, la sortie Y est :

$$Y(i,j) = \sum_m \sum_n X(i+m, j+n)\, K(m,n) + b \tag{3.6}$$

Où :

b est un biais

Les filtres apprennent à trouver les motifs importants (changements d'énergie, bandes de fréquences, pics) dans les données de la HHT [43].

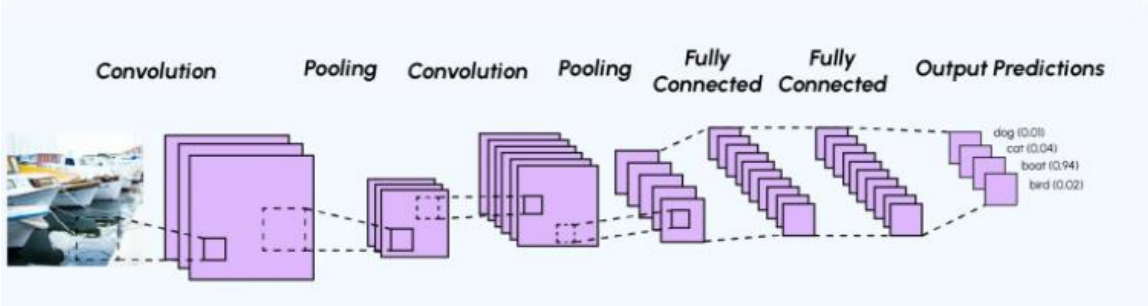

Figure 3 - 7 : Exemple illustratif d'une opération de convolution et des cartes de caractéristiques générées.

Pour simplifier les cartes de caractéristiques tout en conservant l'information essentielle, les couches de convolution sont généralement suivies de couches de sous-échantillonnage.

3.5.3 Fonctions d'activation et non-linéarité

Après la convolution, une fonction d'activation introduit la non-linéarité. La fonction ReLU est couramment utilisée en apprentissage profond :

$$\mathrm{ReLU}(x) = \max(0, x) \tag{3.7}$$

Elle accélère l'entraînement et réduit le risque de saturation observé avec certaines activations classiques [44].

3.5.4 Couche de Sous-échantillonnage (Pooling)

Les couches de pooling réduisent la taille des cartes de caractéristiques en gardant l'info importante. Le max-pooling, qui prend la valeur la plus haute dans une zone, est souvent utilisé. Ça simplifie le modèle, le rend moins sensible au bruit et diminue le risque de sur-apprentissage [45].

3.5.5 Classification avec des couches entièrement connectées

Les cartes de caractéristiques finales sont mises à plat et envoyées aux couches entièrement connectées, qui prennent les décisions. La couche de sortie utilise généralement la fonction Softmax pour donner une probabilité pour chaque type de défaut :

$$p_k = \frac{e^{z_k}}{\sum_c e^{z_c}} \tag{3.8}$$

Où :

P_k est la probabilité d'être dans la classe k.

Le modèle est entraîné en réduisant une fonction de coût (souvent l'entropie croisée) entre les vraies étiquettes et les probabilités devinées [44, 45].

3.5.6 Adaptation des CNN aux signatures HHT

Dans ce mémoire, les CNN servent à classer les défauts internes à partir des données de la HHT, comme :

- Matrice temps-fréquence (spectres HHT / spectre de Hilbert).
- Cartes d'énergie des IMF.
- Descripteur statistiques calcules sur les IMF (énergie, RMS, kurtosis, entropie).

Cette façon de faire transforme les signaux U-I-P en données bien structurées pour le CNN, ce qui aide à apprendre les signatures des défauts, même si les changements sont petits et variables [46, 47].

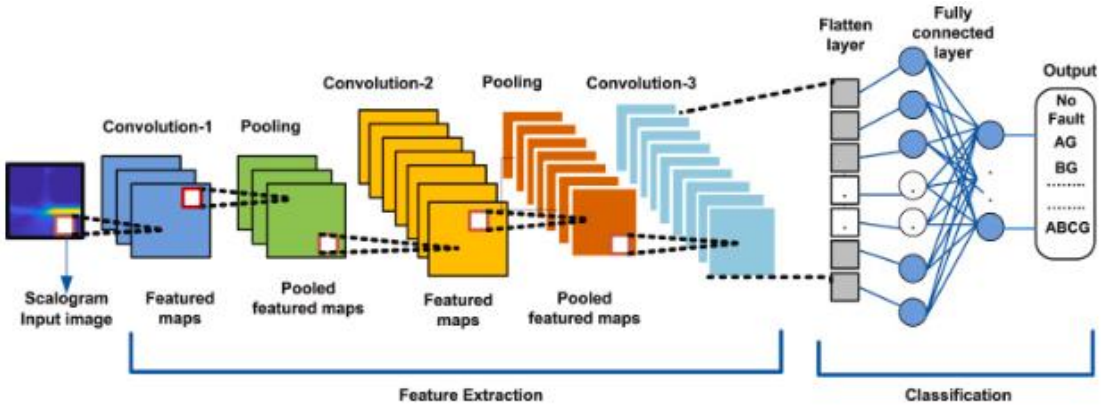

Figure 3 - 8 : Chaîne de classification des défauts internes basée sur la transformée de Hilbert–Huang (HHT) et un réseau de neurones convolutif (CNN).

3.5.7 Avantages et limites pour le diagnostic des défauts internes

Les réseaux de neurones convolutifs (CNN) offrent plusieurs avantages :

- Ils sont très performants pour faire la différence entre des données temps-fréquence.
- Ils résistent bien au bruit et aux variations locales.
- Ils apprennent tout seuls les caractéristiques importantes, sans qu'on ait besoin de les définir manuellement en détail.

Mais, les résultats d'un CNN dépendent beaucoup de la qualité et de la quantité des données dont on dispose, ainsi que de la façon dont on organise la validation (séparation des données en ensembles d'apprentissage, de validation et de test). Les résultats sont aussi influencés par les réglages des hyper paramètres (nombre de filtres, taille des noyaux, taux d'apprentissage, etc.). On tiendra compte de ces aspects dans la méthode d'évaluation présentée dans les chapitres suivants [48,49].

Transition : la section suivante présente les réseaux récurrents, et en particulier l'architecture Bi-LSTM, spécialement conçue pour prévoir comment les défauts vont évoluer au fil du temps. Cette étape complète le travail de classification effectué par les CNN.

3.6 Réseaux récurrents et Bi-LSTM pour prédire les défauts internes

Les soucis internes des équipements électriques changent souvent avec le temps avant de devenir graves. Il est très important de tenir compte du temps pour bien prédire ces problèmes, surtout avec les réseaux hybrides multi-sources. Les réseaux de neurones récurrents (RNN) et leurs versions améliorées sont de bons outils pour regarder les données qui changent avec le temps venant des signaux électriques [50-52].

3.6.1 Limites des réseaux récurrents classiques (RNN)

Les RNN normaux ont une boucle qui leur permet de se souvenir de ce qui s'est passé avant. Mais ils ont de gros problèmes avec le gradient qui disparaît ou explose, ce qui rend difficile d'apprendre les liens de temps longs [53]. Ces problèmes rendent plus difficile de prédire les problèmes internes qui empirent.

3.6.2 Réseau Long Short-Term Memory (LSTM)

Le réseau LSTM a été créé pour résoudre les problèmes des RNN normaux. Il fonctionne avec une cellule mémoire contrôlée par trois portes :

- la porte d'oubli (*Forget gate*).
- la porte d'entrée, (*input gate*).
- la porte de sortie, (*output gate*).

Ces portes permettent de gérer efficacement l'information temporelle [54]. Les LSTM sont souvent utilisés pour prédire les problèmes électriques et mécaniques à partir des signaux temporels [55].

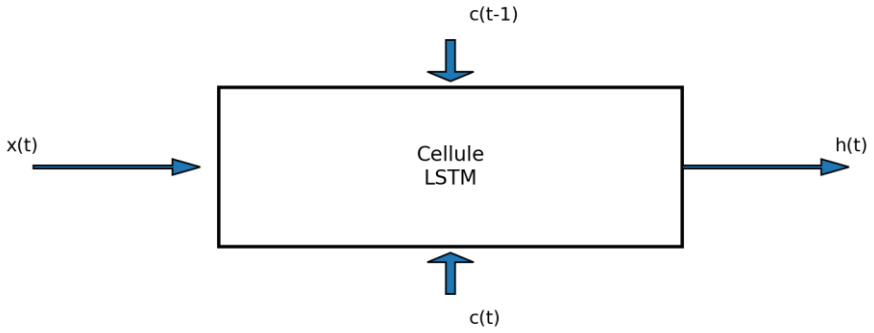

Figure 3 - 9 : Schéma de principe d'une cellule LSTM.

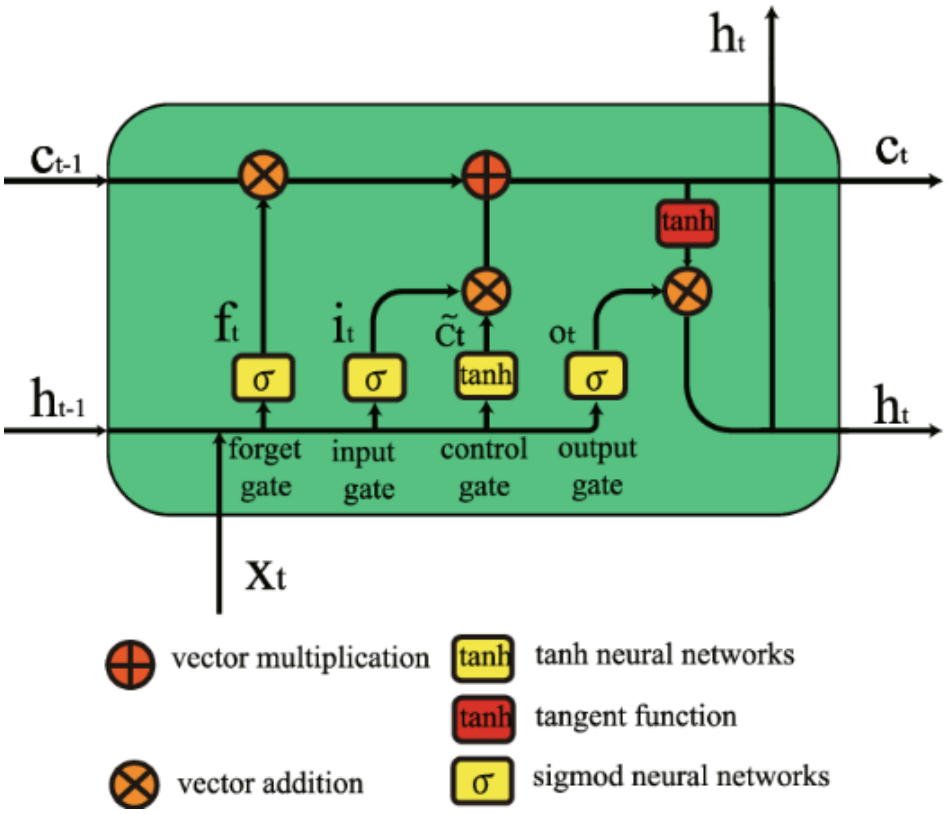

Figure 3 - 10 : Architecture d'une cellule LSTM illustrant le flux d'information et le rôle des portes d'oubli, d'entrée et de sortie.

3.6.3 Réseau Bidirectionnel LSTM (Bi-LSTM)

Le réseau Bi-LSTM constitue une extension du LSTM classique en exploitant simultanément les informations passées et futures d'une séquence temporelle. Cette architecture améliore la précision de la prédiction, en particulier lorsque l'évolution du défaut dépend de plusieurs états temporels corrélés [56-57].

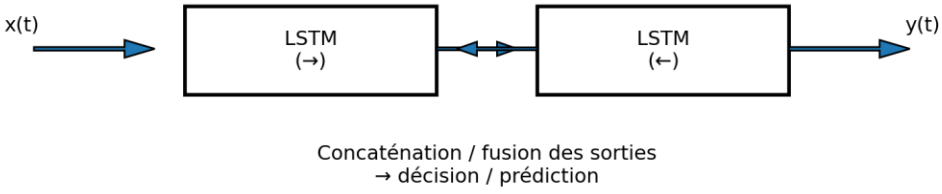

Figure 3 - 11 : Architecture d'un réseau Bi-LSTM bidirectionnel

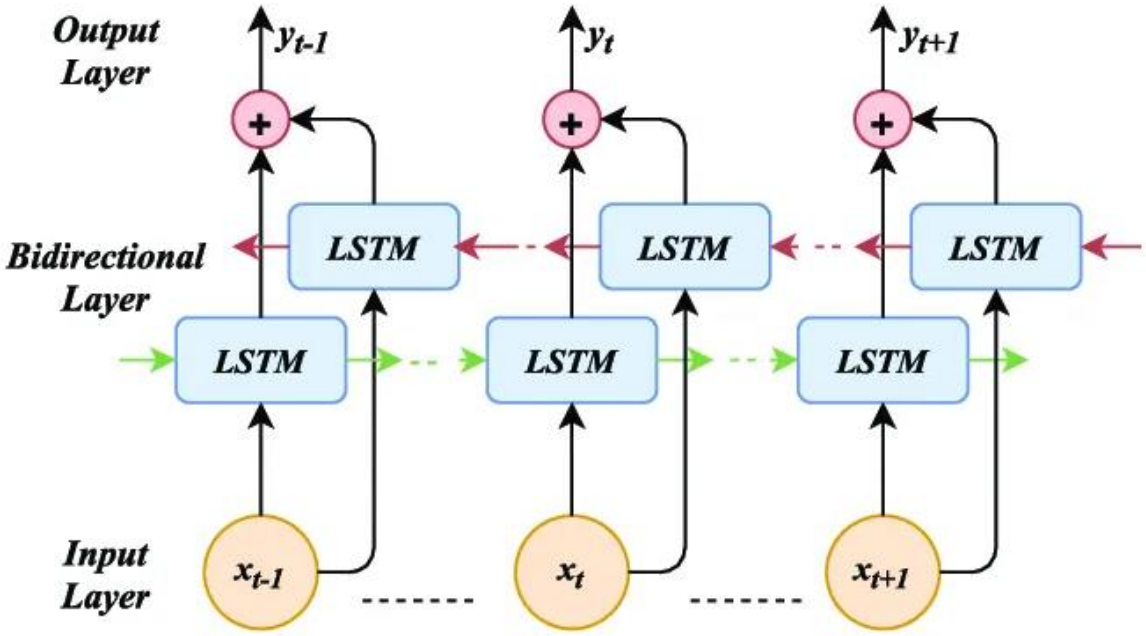

Figure 3 - 12 : Architecture d'un réseau LSTM bidirectionnel (Bi-LSTM) appliqué à une séquence temporelle.

Le réseau **Bi-LSTM (Bidirectional LSTM)** étend le principe du LSTM en traitant la séquence temporelle dans deux directions :

- une direction temporelle directe (passé → futur),
- une direction temporelle inverse (futur → passé).

Cette double lecture permet d'exploiter simultanément les informations passées et futures d'une séquence, améliorant ainsi la précision et la robustesse de la prédiction. Dans le cadre des défauts internes des réseaux électriques, cette approche est particulièrement pertinente pour capturer des signatures faibles, progressives et non stationnaires, souvent difficiles à détecter à l'aide de modèles unidirectionnels.

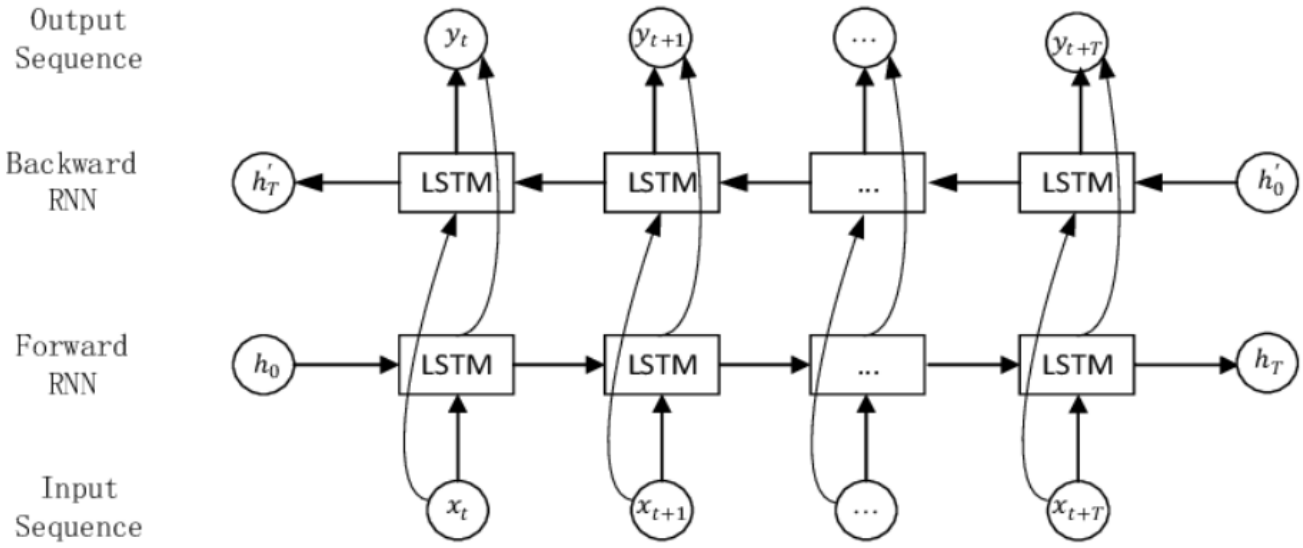

Figure 3 - 13 : Principe de fonctionnement du traitement avant et arrière dans un réseau Bi-LSTM.

3.6.4 Intérêt du Bi-LSTM pour la prédiction des défauts internes

L'utilisation du Bi-LSTM dans ce travail se justifie par :

- sa capacité à modéliser des dépendances temporelles complexes.
- sa robustesse face aux signaux non stationnaires.
- son aptitude à anticiper l'évolution future des défauts internes.

Combiné à l'extraction de caractéristiques par la HHT et à la classification assurée par les CNN, le Bi-LSTM constitue une brique centrale du système de détection, classification et prédiction des défauts internes proposé dans ce mémoire. Cette complémentarité améliore la capacité du modèle à détecter précocement les défaillances et à soutenir une stratégie de maintenance prédictive plus fiable et efficace [58-59]**.**

3. 7 Optimisation des hyper-paramètres par l'algorithme POA

Les modèles d'apprentissage profond comme les CNN et Bi-LSTM sont très sensibles au réglage de leurs hyper-paramètres pour bien détecter et prédire les défauts internes. Ces paramètres, qui ne sont pas appris directement à partir des données, ont un impact

important sur la façon dont le modèle peut s'adapter, sur sa vitesse d'apprentissage et sur sa résistance face aux perturbations et aux changements.

Habituellement, on ajuste ces hyper-paramètres à la main ou en testant toutes les combinaisons possibles, mais cela devient vite compliqué quand il y a beaucoup de possibilités. Pour régler ce problème, on propose d'utiliser un algorithme récent appelé Pélican Optimisation Algorithme (POA) pour ajuster automatiquement les hyper-paramètres du modèle Bi-LSTM.

3.7.1 Motivation de l'utilisation du POA

On a choisi le POA pour plusieurs raisons :

- Il est capable d'explorer des ensembles de possibilités complexes.
- Il n'a pas beaucoup de paramètres de contrôle comparé à d'autres algorithmes.
- Il apprend vite dans des différentes situations.
- Il est résistant aux erreurs locales.

Avec ces avantages, le POA est parfait pour ajuster les architectures profondes utilisées dans des environnements industriels compliqués, comme les réseaux électriques hybrides.

3.7.2 Principe général du Pélican Optimisation Algorithme

Le POA s'inspire de la façon dont les pélicans chassent en groupe. L'algorithme imagine un groupe d'agents (les pélicans), chacun représentant une solution possible pour les hyper-paramètres. L'optimisation se fait en deux étapes principales :

Première phase d'exploitation

Pendant cette étape, les pélicans cherchent différentes zones pour trouver les meilleures. Ils se déplacent de façon aléatoire, ce qui permet de trouver des solutions variées et d'éviter de se concentrer trop tôt sur des solutions moins bonnes.

En termes mathématiques, la position d'un agent est mise à jour en fonction de la meilleure solution trouvée jusqu'à présent, avec un élément aléatoire qui encourage l'exploration.

Deuxième phase d'exploitation

Une fois les meilleures zones trouvées, l'algorithme passe à une phase d'exploitation. Les agents se concentrent alors sur les meilleures solutions pour affiner les hyper-paramètres. Cela permet d'améliorer progressivement les solutions et de s'assurer qu'on arrive à la meilleure solution possible.

L'alternance entre l'exploration et l'exploitation est essentielle pour que le POA trouve un bon équilibre entre la diversité des solutions et la précision de l'optimisation.

3.7.3 Les hyper-paramètres qui sont optimisés

Dans ce travail, l'algorithme POA est utilisé pour ajuster automatiquement les hyper-paramètres importants du modèle Bi-LSTM, comme :

- Le nombre de couches Bi-LSTM.
- Le nombre de neurones par couche.
- Le taux d'apprentissage.
- La longueur des séquences temporelles d'entrée.
- Le nombre d'époques d'entraînement.
- Les coefficients de régularisation.

Chaque solution possible générée par le POA correspond à une configuration spécifique de ces hyper-paramètres, utilisée pour entraîner et tester le modèle Bi-LSTM.

3.7.4 Fonction objectif et critère d'évaluation

La qualité de chaque solution possible est évaluée à l'aide d'une fonction qui se base sur les performances de prédiction du modèle. Cette fonction peut prendre en compte :

- L'erreur de prédiction sur l'ensemble de validation
- Des indicateurs de performance comme la précision, le rappel ou le score F1
- Un élément qui pénalise le sur apprentissage

L'objectif du POA est de réduire cette fonction au minimum, tout en s'assurant que le modèle peut bien s'adapter à de nouvelles données.

3.7.5 Apport du POA dans la prédiction des défauts internes

L'intégration du POA dans la chaîne HHT → CNN → Bi-LSTM permet :

- Une amélioration de la précision de la prédiction des défauts internes.
- Une réduction du temps nécessaire pour régler les hyper paramètres.
- Une meilleure stabilité du modèle face aux variations.
- Une diminution du risque de sur apprentissage.

Dans le cas des défauts internes, qui sont souvent discrets et progressifs, cette optimisation automatique est un atout majeur pour une maintenance prédictive fiable.

3.7.6 **Positionnement dans l'architecture globale**

Le POA est un outil d'optimisation qui agit principalement sur le module Bi-LSTM, tout en influençant indirectement les performances globales du système de détection, de classification et de prédiction des défauts internes.

Cela permet de créer un système intelligent entièrement automatisé, capable de s'adapter aux données des réseaux électriques hybrides.

3. 8 Intelligence Artificielle Explicable (XAI) appliquée à l'identification et à la prédiction des défauts internes

3.8.1 Motivation de l'Intelligence Artificielle Explicable

Les méthodes d'apprentissage profond comme les CNN et les Bi-LSTM sont bonnes pour détecter, classer et prédire les défauts internes, mais on ne sait pas toujours comment elles arrivent à leurs conclusions. Ces modèles sont souvent comme des boîtes noires, ce qui rend difficile de comprendre exactement pourquoi ils prennent une décision ou font une prédiction.

Dans des secteurs importants comme les réseaux électriques hybrides, ce manque d'explication rend difficile l'adoption des solutions d'intelligence artificielle. Les opérateurs et les ingénieurs de maintenance doivent comprendre pourquoi une alerte est déclenchée, quelles informations ont été importantes et quand un défaut commence à se produire.

C'est là qu'intervient l'Intelligence Artificielle Explicable (XAI). L'objectif est de rendre les décisions des modèles intelligents plus faciles à comprendre et à justifier.

3.8.2 Principe généraux de l'XAI

L'XAI regroupe différentes méthodes d'explication du fonctionnement interne et des décisions des modèles d'apprentissage automatique. Au lieu de simplement faire des prédictions, l'XAI tente de répondre à des questions comme

- Quels éléments ont le plus influencé la décision du modèle ?
- Quels moments sont importants pour prédire un défaut?
- Le modèle se base-t-il sur des éléments physiquement cohérents?

Dans ce travail, l'XAI est utilisée comme un outil d'analyse supplémentaire pour renforcer la confiance dans les résultats de la chaîne HHT → CNN → Bi-LSTM.

3.8.3 Comment l'XAI explique le fonctionnement du module CNN

Pour la classification des défauts internes, l'XAI peut montrer les zones les plus importantes des représentations issues de la HHT. Les méthodes d'explication utilisées avec les CNN, comme les cartes de contribution ou de sensibilité, mettent en évidence les éléments temps-fréquence qui influencent le plus la décision finale.

Dans ce document, ces cartes explicatives permettent de:

- s'assurer que le CNN se base sur des éléments physiques pertinents.
- identifier les motifs liés aux différents types de défauts internes.

- diminuer le risque de décisions incorrectes basées sur du bruit ou des erreurs.

Ainsi, l'XAI aide à faire du réseau CNN non pas seulement un classificateur, mais un outil d'analyse que l'on peut interpréter.

3.8.4 Comment l'XAI explique le fonctionnement du module Bi-LSTM

Pour la prédiction temporelle, l'XAI est essentielle pour comprendre les résultats du Bi-LSTM. En analysant l'importance des moments passés et futurs dans la séquence temporelle, il est possible de comprendre comment le modèle prévoit l'évolution d'un défaut interne.

Les scores d'importance temporelle permettent de:

- repérer les périodes critiques qui précèdent l'apparition d'un défaut.
- analyser la façon dont les défaillances internes se développent.
- justifier les décisions de maintenance prédictive proposées par le modèle.

Cette explication temporelle est particulièrement utile pour les défauts internes, qui se développent lentement et sont difficiles à détecter avant qu'ils ne deviennent critiques.

3.8.5 Apport de l'XAI à la maintenance prédictive

L'utilisation de l'XAI dans l'architecture proposée offre plusieurs avantages:

- le système intelligent est plus clair.
- les opérateurs ont plus confiance dans les décisions automatisées.
- il est plus facile de valider les résultats pour une utilisation industrielle.
- elle aide à prendre des décisions éclairées en matière de maintenance prédictive.

En fournissant des explications claires et compréhensibles, l'XAI transforme un système purement prédictif en un outil d'aide à la décision intelligent et fiable.

3.8.6 Comment l'XAI s'intègre dans l'ensemble du système

Dans l'architecture proposée, l'XAI agit comme une couche transversale, interagissant avec les modules de classification (CNN) et de prédiction (Bi-LSTM). Elle ne change pas les performances du modèle, mais améliore considérablement la façon dont on peut l'interpréter et l'accepter.

Cette façon de faire permet de créer une approche complète, qui associe performance, prédiction et explication, répondant ainsi aux exigences actuelles des réseaux électriques hybrides intelligents [66-68].

3.9 Architecture globale proposée pour l'identification et la prédiction des défauts internes

Cette section détaille l'architecture complète du système intelligent que je propose pour détecter, classer, localiser et prédire les défauts internes dans les réseaux électriques hybrides.

Cette approche combine différentes techniques le traitement du signal, l'apprentissage profond, l'optimisation méta heuristique et l'intelligence artificielle explicable (XAI).

L'idée est de dépasser les limites des méthodes classiques de surveillance en offrant un système fiable, prédictif et facile à comprendre, adapté aux réseaux hybrides.

3.9.1 Vue d'ensemble de l'architecture proposée

L'architecture est organisée en plusieurs étapes :

a) Acquisition des signaux électriques.

b) Extraction de caractéristiques par la HHT.

c) Classification des défauts par CNN.

d) Prédiction temporelle par Bi-LSTM avec optimisation par POA.

e) Modules d'explicabilité (XAI).

f) Décisions pour la maintenance prédictive.

3.9.2 Acquisition et prétraitement des signaux

Les signaux électriques du réseau (tension, courant, puissance) sont les données de base du système. Ils sont recueillis à partir de différents points et équipements importants du réseau hybride.

Avant d'être utilisés, les données sont traitées pour :

- La normalisation des amplitudes.
- La segmentation les données dans le temps.
- L'élimination éventuelle du bruit.

Cela permet d'améliorer la stabilité et la convergence des modèles intelligents.

3.9.3 Extraction de caractéristiques par la HHT

Les signaux sont ensuite analysés avec la transformée de Hilbert–Huang (HHT). Cette méthode décompose les signaux en fonctions de mode intrinsèque (IMF), ce qui permet d'extraire des informations riches sur les fréquences et les moments où elles se produisent. Ces informations sont utiles pour identifier les défauts internes, qui sont souvent difficiles à voir avec les méthodes classiques.

3.9.4 Classification des défauts internes par CNN

Les informations extraites par la HHT sont ensuite utilisées par un réseau de neurones convolutifs (CNN). Le CNN classe automatiquement les défauts internes en identifiant des motifs spécifiques. Cela permet :

- d'identifier le type de défaut,
- de distinguer entre un fonctionnement normal et un défaut,
- de localiser le défaut dans le réseau.

3.9.5 Prédiction temporelle par Bi-LSTM ajusté par POA

Les résultats du CNN et les informations temporelles sont utilisés par un réseau Bi-LSTM, qui modélise l'évolution des défauts internes. Le Pélican Optimisation Algorithme (POA) ajuste automatiquement les paramètres du Bi-LSTM pour :

- améliorer la précision de la prédiction.
- réduire le sur apprentissage.
- améliorer la résistance aux variations de fonctionnement.

Cela permet d'anticiper l'évolution des défauts et d'aider à planifier la maintenance.

3.9.6 L'intégration des modules d'intelligence artificielle explicable (XAI)

Pour que les décisions du système soient compréhensibles, des modules XAI sont intégrés :

- au niveau du CNN, des cartes montrent les zones de fréquence et de temps qui ont le plus influencé la classification.
- au niveau du Bi-LSTM, des scores indiquent les moments clés pour prédire l'évolution des défauts.

L'XAI rend le système plus transparent, fiable et acceptable pour l'industrie.

3.9.7 Sorties du système et aide à la décision

Les résultats finaux du système sont :

- l'état du réseau (régime permanent et régime avec défauts).
- le type et l'emplacement du défaut.
- la prédiction de son évolution temporelle.
- des indicateurs explicatifs facilitant l'interprétation.

Ces informations aident les opérateurs à prendre des décisions éclairées pour intervenir de manière efficace.

3.9.8 Apport global de l'architecture proposée

Cette architecture offre plusieurs avantages :

- elle prend en compte les signaux qui varient dans le temps.
- elle détecte et prédit les défauts internes rapidement.
- elle est résistante aux variations des réseaux hybrides.
- elle rend les décisions compréhensibles grâce à l'XAI.

En résumé, c'est une solution complète et nouvelle pour surveiller intelligemment les réseaux électriques hybrides modernes [69-72].

3.10 Conclusion

Ce chapitre a présenté les méthodes utilisées pour la détection, la classification, la localisation et la prédiction des défauts internes dans un réseau hybride la HHT pour extraire les caractéristiques, le CNN pour la classification, le Bi-LSTM pour la prédiction, le POA pour ajuster les paramètres et l'XAI pour rendre les décisions compréhensibles. Tout cela est intégré dans une architecture cohérente.

Chapitre 4

Présentation du réseau étudié et mise en place des scénarios de simulation

4.1 Introduction

Les réseaux électriques actuels évoluent vite avec l'ajout de plus en plus d'énergies renouvelables (éolien, solaire, hydraulique). Cette transition fait apparaître des réseaux électriques hybrides avec plusieurs sources, ce qui rend leur fonctionnement plus variable et leur surveillance plus compliquée. Du coup, bien détecter, classer et anticiper les pannes internes devient crucial pour que ces systèmes électriques restent fiables et stables et continuent de fonctionner.

Pour bien tester les méthodes proposées ici, il faut un réseau électrique de base réaliste et assez complexe pour simuler un vrai comportement, tout en permettant des simulations détaillées et répétables. Le réseau IEEE-39 bus (aussi appelé réseau New England) est un bon choix car il est réaliste, pas trop compliqué et ne coûte pas trop cher en calcul.

Ce chapitre explique en détail le réseau électrique qu'on a choisi, pourquoi on l'a préféré à d'autres et comment on l'a modifié pour qu'il intègre plusieurs sources d'énergie renouvelable et devienne un réseau hybride. On décrira aussi les composants du réseau (générateurs, lignes, transformateurs, charges), comment on les a modélisés avec MATLAB/Simulink et comment le système est organisé.

Le but de ce chapitre est de poser un cadre clair pour générer les données des chapitres suivants. Les analyses des pannes internes (simples et combinées) et l'évaluation des méthodes seront présentées plus loin.

4.2 Présentation du réseau IEEE-39 bus

Choisir un réseau électrique de base est important pour étudier la surveillance et la détection des pannes, car cela influence la qualité des résultats et si les simulations sont possibles. Ici, on utilise le réseau IEEE-39 bus (New England) car c'est un bon compromis entre réalisme, complexité et coût de simulation. [73-76]

Le réseau IEEE-39 bus est souvent utilisé pour analyser la stabilité, tester des algorithmes de surveillance et évaluer des stratégies de protection. Il représente un système interconnecté de taille moyenne avec des bus, des lignes, des transformateurs, des charges et des unités de production, ce qui en fait un bon outil pour les études dynamiques et les applications basées sur les données. [75-78].

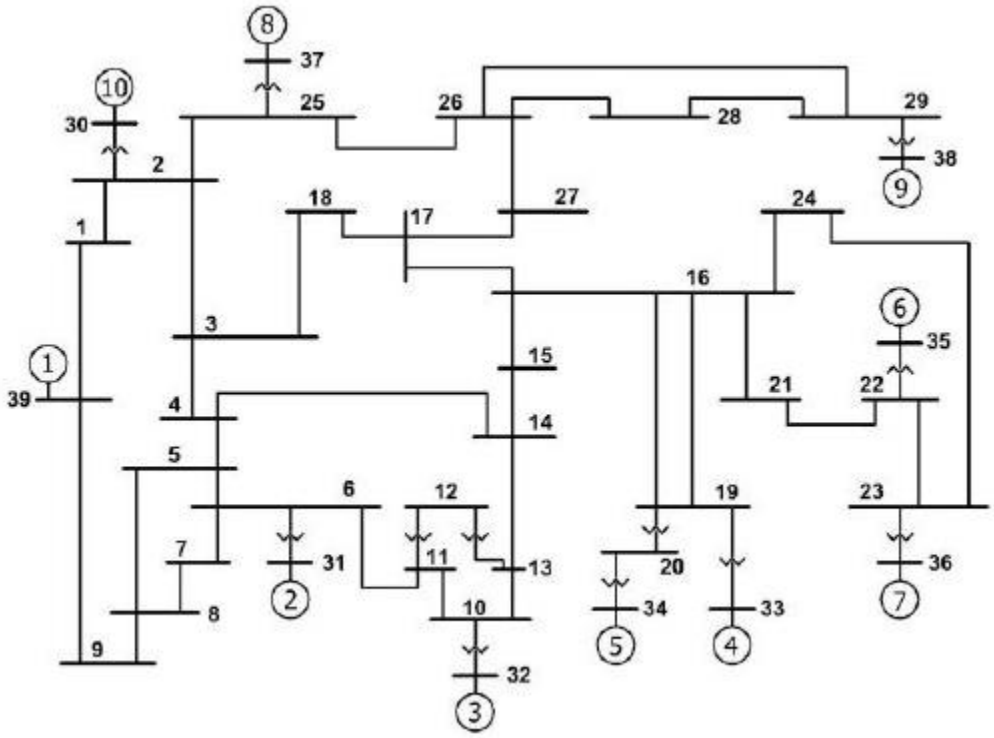

Figure 4 - 1 : Topologie du réseau IEEE 39 bus de référence.

4.2.1 Description détaillée du réseau IEEE 39 bus

Le réseau IEEE 39 bus est organisé en zones de production et de consommation, reliées par des lignes et des transformateurs. Chaque bus a des paramètres électriques (tension, puissances active/réactive) qui montrent comment les charges et les sources sont réparties. Les lignes sont modélisés avec leurs impédances pour simuler les chutes de tension et les transferts de puissance, et les transformateurs adaptent les tensions et répartissent les flux. [79-82]

Cette structure est assez complexe pour analyser les interactions entre les composants et voir l'impact d'une panne localement et globalement. C'est important si on veut localiser la panne par bus et évaluer les signaux électriques venant de différents endroits du réseau. [78-83].

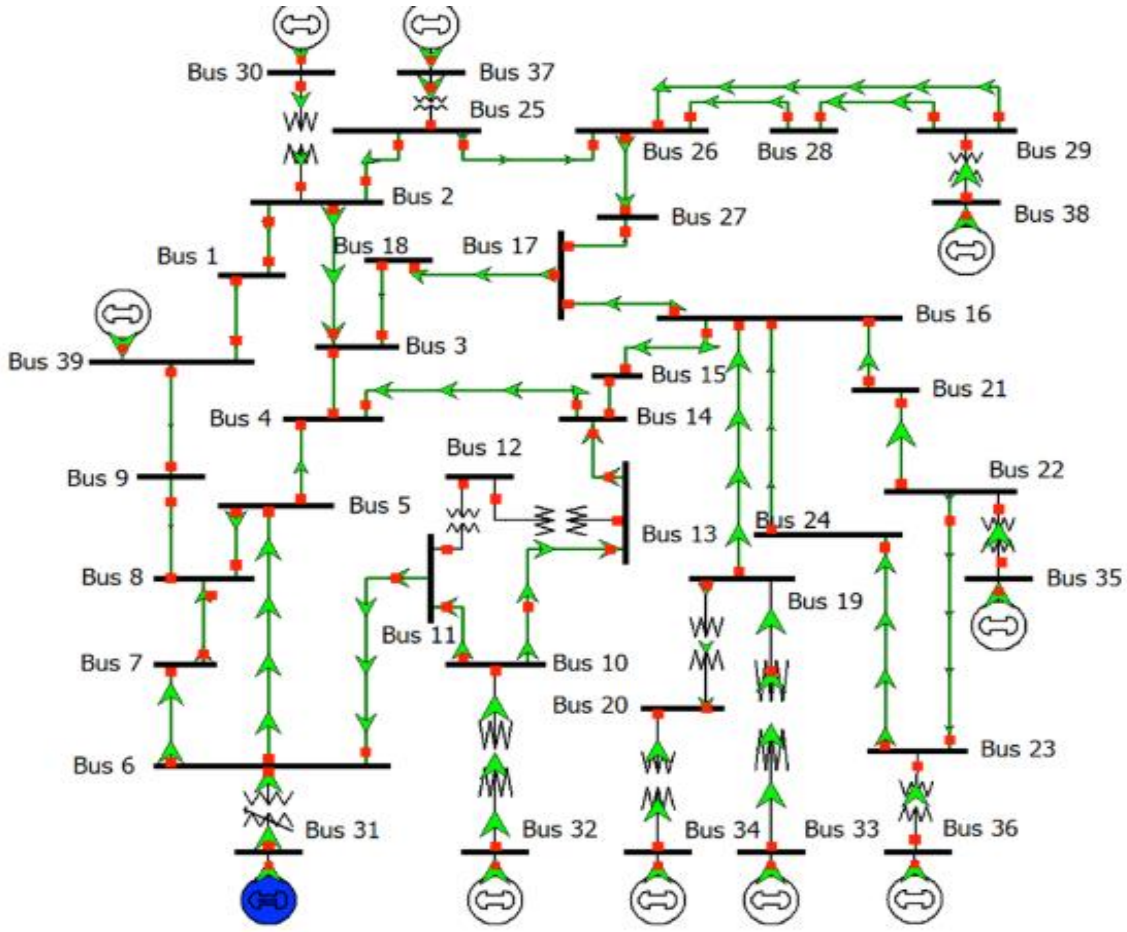

Figure 4 - 2 : Représentation détaillée des bus, lignes et transformateurs du réseau IEEE 39 bus.

4.2.2 Points positifs et limites du réseau IEEE 39 bus

L'avantage majeur du réseau IEEE 39 bus, c'est qu'il est d'une taille correcte. Il est plus complet qu'un petit réseau comme l'IEEE 14 bus, mais sa simulation reste moins chère qu'un grand réseau comme l'IEEE 118 bus. Du coup, on peut créer des données variées et en quantité suffisante pour l'apprentissage profond, avec un temps de simulation raisonnable pour bâtir des ensembles de données [84].

Par contre, dans sa version de base, le réseau 39 bus ne représente pas bien l'arrivée massive des énergies renouvelables, ni les changements que cela implique pour les réseaux hybrides d'aujourd'hui. Certaines dynamiques des très grands réseaux ne sont pas non plus complètement présentes. C'est pourquoi on a modifié le réseau de base, pour y ajouter des sources renouvelables et avoir un contexte multi-sources qui corresponde aux objectifs de ce travail [85].

4.2.3 Comparaison avec d'autres réseaux de test

Les petits réseaux IEEE (comme le 14 bus) sont souvent utilisés pour commencer, mais leur structure simple empêche d'analyser des situations complexes avec une localisation précise, des sources variables et différents fonctionnements. À l'inverse, les grands réseaux (118 bus et plus) sont plus réalistes, mais leur simulation coûte cher. Ce n'est pas l'idéal si on veut générer beaucoup de cas pour l'apprentissage et la validation

Dans ce contexte, le réseau IEEE 39 bus est un bon compromis, il est assez riche pour montrer les interactions réalistes entre la production, le transport et les charges, tout en permettant de faire pas mal de simulations, ce qui est nécessaire pour créer et tester les méthodes intelligentes qu'on propose [86].

Tableau 2: Comparaison entre les réseaux IEEE 14, 39 et 118 bus.

Critère	IEEE 14 bus	IEEE 39 bus (New England)	IEEE 118 bus
Nombre de bus	14	39	118
Nombre de générateurs	5	10	54
Nombre de lignes	20	46	186
Complexité du réseau	Faible	Moyenne	Élevée
Temps de simulation	Très court	Modéré (acceptable)	Long
Représentativité industrielle	Limitée	Élevée	Très élevée
Adapté aux réseaux hybrides	✗	✓	⚠ (complexité élevée)
Adapté IA (HHT-CNN-Bi-LSTM)	✗	✓	⚠ (coût computationnel élevé)

4.2.4 Études précédentes et utilisation dans le milieu académique

Le réseau IEEE 39 bus a servi dans pas mal d'études sur la stabilité, la surveillance et l'évaluation des stratégies de diagnostic. Ses paramètres sont connus et sa structure de taille moyenne est réaliste. L'utiliser comme banc d'essai permet de comparer plus facilement les résultats avec ce qui existe déjà, tout en ayant une base solide pour aller vers des situations plus réalistes, comme l'ajout de sources renouvelables dans un contexte hybride [87].

4.3 Réseau hybride modifié et intégration des sources renouvelables

4.3.1 Pourquoi passer à un réseau hybride multi-sources

Le réseau IEEE 39 bus (New England) est souvent utilisé comme référence pour tester des méthodes d'analyse, de stabilité et de diagnostic. Il est intéressant car il offre un bon compromis entre complexité, réalisme et coût de simulation. Dans sa version de base, il utilise surtout des générateurs synchrones, ce qui représente un réseau classique [81-83].

Sauf que les réseaux modernes intègrent de plus en plus d'énergies renouvelables (éolien, photovoltaïque). Cela entraîne :

- une production irrégulière.
- des changements rapides des flux de puissance.
- des dynamiques différentes (convertisseurs, contrôles, etc.). Du coup, les défauts sont plus difficiles à identifier avec les méthodes classiques.

Dans ce travail, l'objectif est de détecter, classer et prédire les défauts internes dans un réseau hybride. Il est donc logique de modifier le réseau IEEE 39 bus pour créer un système multi-sources réaliste, tout en gardant une base connue pour pouvoir comparer les résultats [84-88].

4.3.2 Modifications apportées au réseau IEEE 39 bus

Le réseau hybride que l'on propose garde la structure principale du réseau IEEE 39 bus (bus, lignes, transformateurs), pour qu'il reste une référence. Les changements se concentrent surtout sur la production (ajout de sources renouvelables) et sur les conditions de fonctionnement (variabilité multi-sources).

Voici les principales modifications :

- ajouté deux éoliennes (générateurs éoliens) connectées à des bus différents, pour avoir une production variable et voir comment la localisation influence les défauts.
- ajouté une centrale photovoltaïque connectée au réseau via un convertisseur, pour injecter de la puissance localement et avoir des scénarios qui dépendent de l'ensoleillement.

On garde les générateurs synchrones d'origine, qui assurent la stabilité et permettent au réseau de se comporter de manière cohérente, et on a conservé le réseau de transport et de distribution interne (lignes, transformateurs) pour garder le contexte d'exploitation et la propagation réaliste des perturbations.

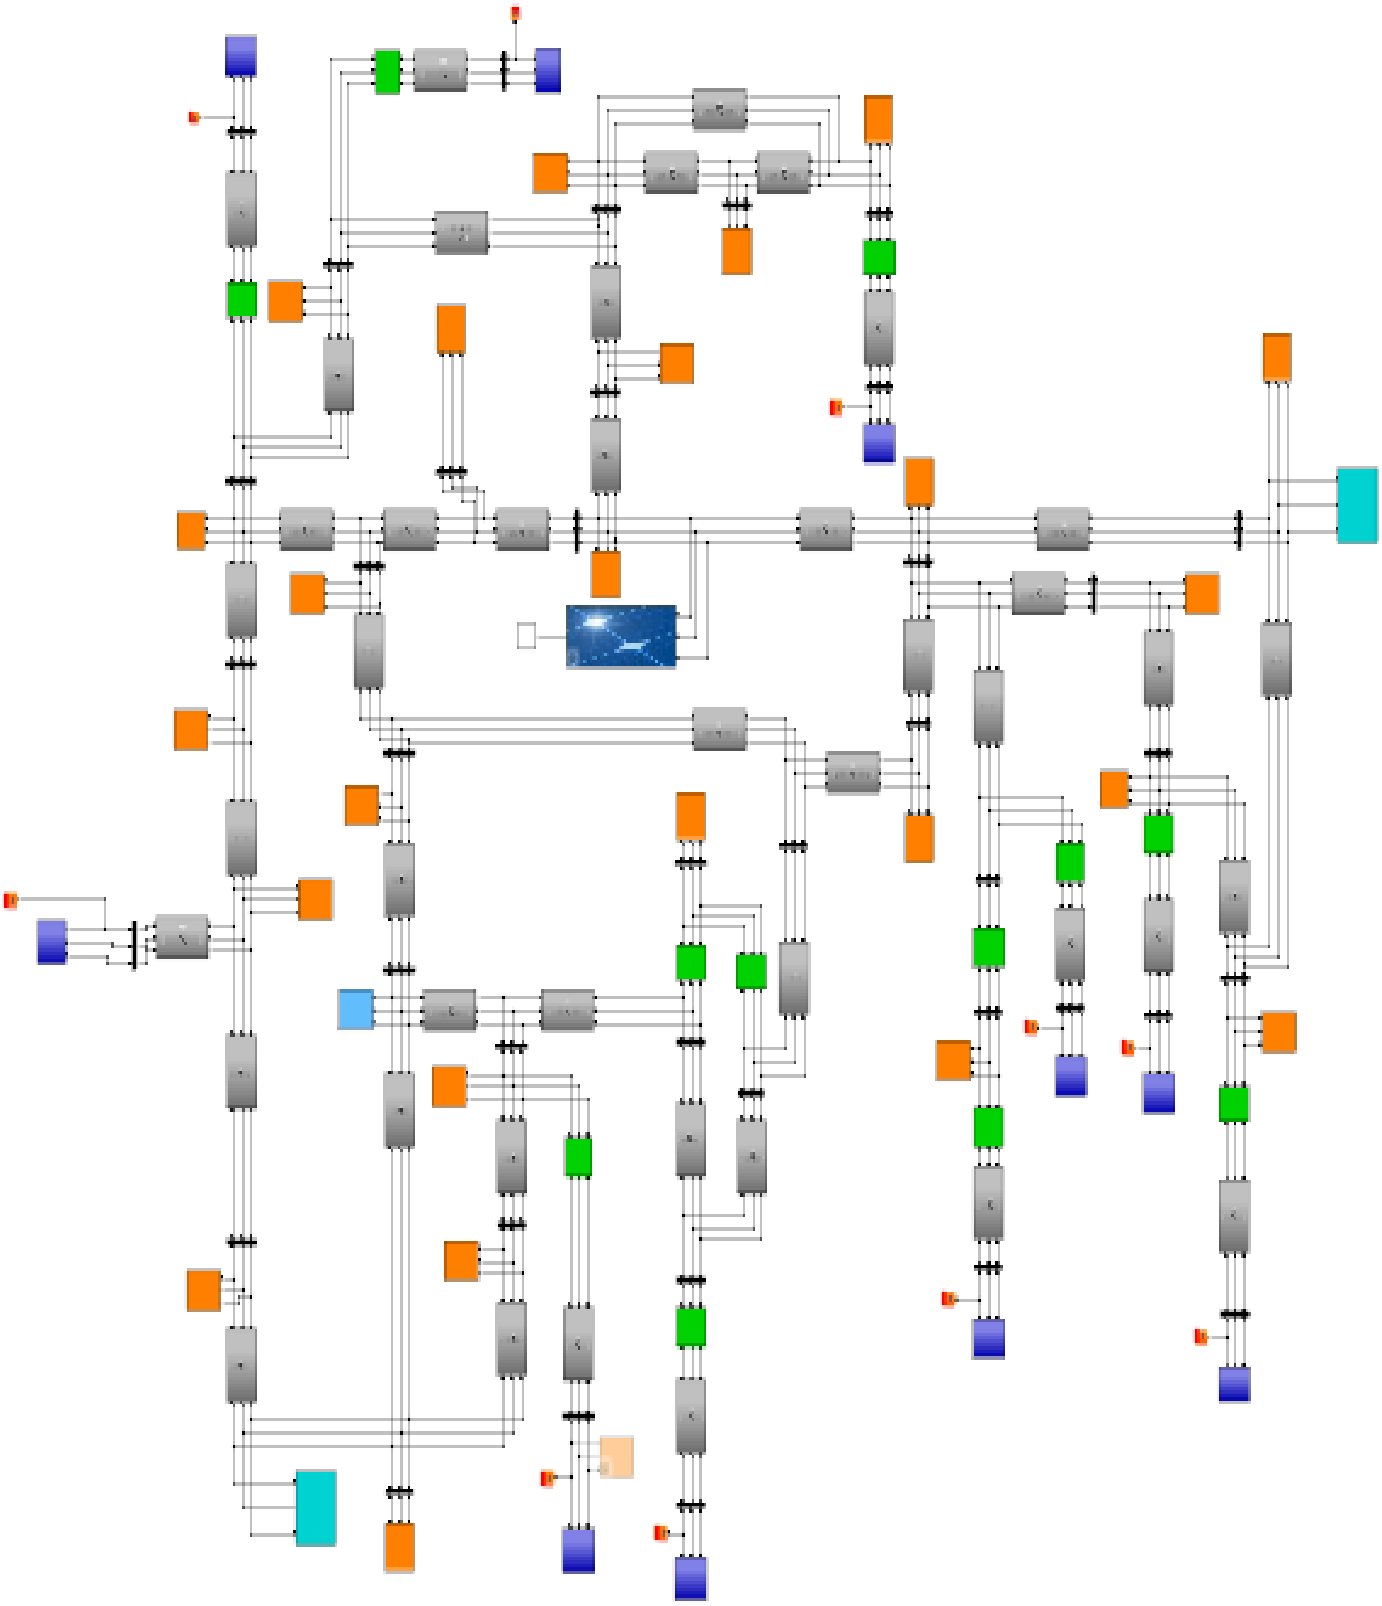

Figure 4 - 3 : Schéma du réseau IEEE 39-Bus enrichi par l'intégration des sources énergies renouvelables.

4.3.3 Localisation des sources renouvelables et intérêt pour l'étude des défauts internes

Le positionnement des sources renouvelables dans le réseau n'est pas un détail : il influence directement les flux de puissance, les profils de tension, et la manière dont un défaut interne peut se manifester dans les signaux mesurés (U, I, P). Ainsi, l'étude considère à la fois la dynamique locale (près de la source) et la propagation globale (effet réseau) [89].

Dans le cas réseau hybride IEEE-39 bus modifié, les sources sont intégrées de manière à obtenir:

- Une diversité spatiale (sources sur des bus différents).
- Une diversité technologique (synchrone + renouvelable).
- Une diversité temporelle (variabilité PV/éolien selon conditions).
- Un cadre adapté à la localisation des défauts par bus, puisque les signatures peuvent changer selon le point d'observation.

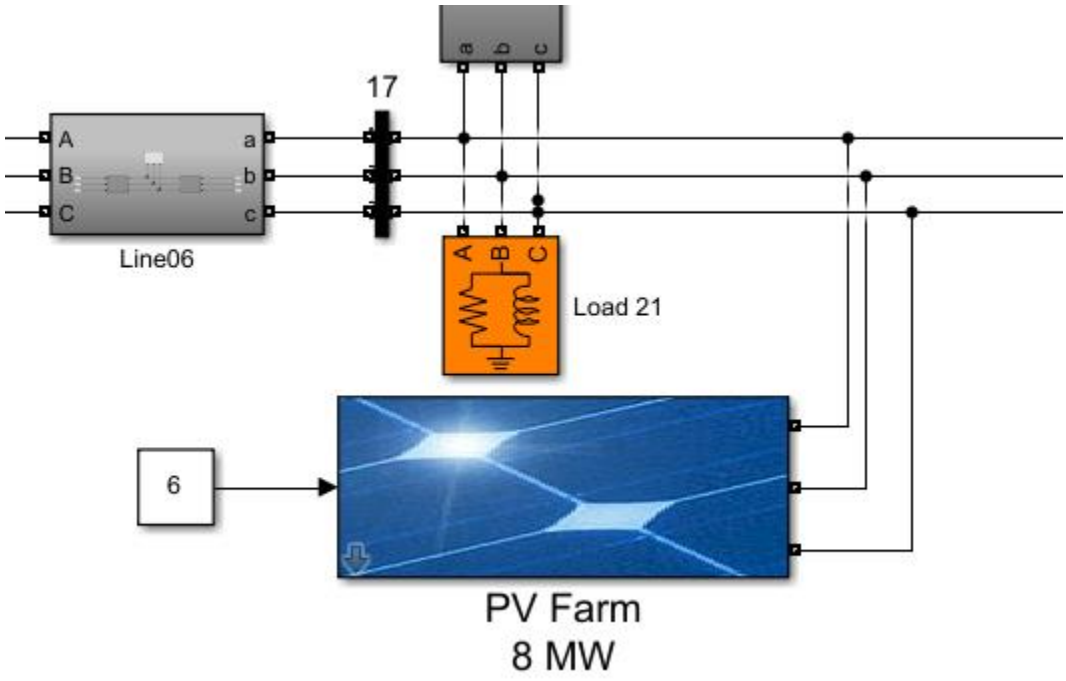

Figure 4 - 4 : Positionnement de la source photovoltaïque au bus 17 dans le réseau IEEE 39 bus modifié.

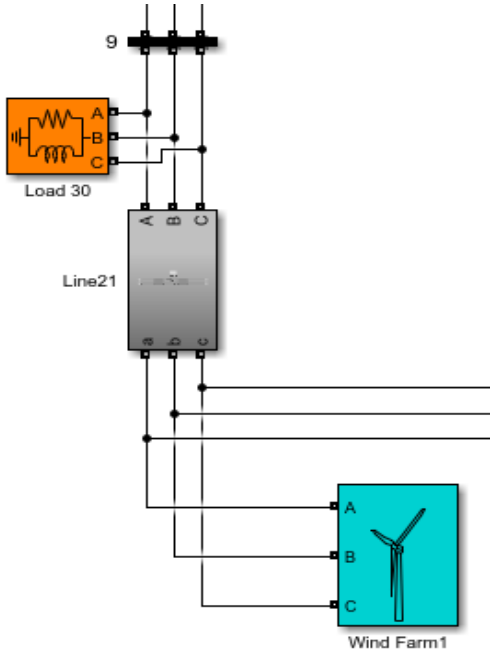

Figure 4 - 5 : Localisation et raccordement de la source éolienne 1 (Wind Farm 1) au bus 9 dans le réseau IEEE 39 bus modifié.

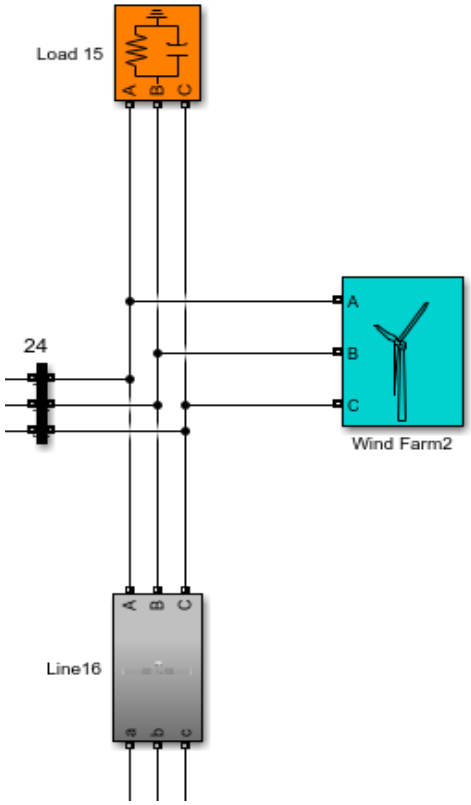

Figure 4 - 6 : Localisation et raccordement de la source éolienne 2 (Wind Farm 2) au bus 24 dans le réseau IEEE 39 bus modifié.

4.3.4 Modélisation sur MATLAB/Simulink

Le réseau hybride IEEE-39 bus modifie est implémenté sous MATLAB/Simulink car cet environnement :

- permet de modéliser la dynamique des composants électriques.
- permet la simulation transitoire.
- permet de générer de manière reproductible un ensemble de données pour l'apprentissage automatique.

La simulation nous donne une source de données contrôlée pour étudier les défauts internes en multipliant les scénarios [90]. Pour que les données générées soient cohérentes avec les méthodes intelligentes utilisées ensuite, le modèle est construit autour de trois blocs principaux.

- **Bloc réseau :** bus, lignes et transformateurs (réseau de base IEEE-39 bus).
- **Bloc production :** générateurs synchrones + éoliennes + PV.
- **Bloc mesures :** acquisition des signaux électriques (U, I, P) et des variables associées au diagnostic.

4.3.5 Ce que le réseau hybride apporte à la détection et à la prédiction des défauts internes

Les défauts internes (paramétriques, électriques, progressifs) peuvent être difficiles à voir si l'on ne regarde que des seuils statiques. Dans un réseau hybride, ce problème est pire à cause de la variabilité naturelle des sources renouvelables, qui peut cacher ou déformer les signes des anomalies. D'où l'intérêt de construire un réseau multi-sources pour tester la fiabilité des méthodes [91].

L'utilisation du réseau hybride IEEE-39 bus modifié permet alors de :

- Simuler différentes conditions de fonctionnement (charges, production, fluctuations).

- Produire des signaux non stationnaires favorables à l'analyse HHT.
- Générer un ensemble de données utile pour la classification par CNN (signatures HHT).
- Préparer des séquences temporelles pour la prédiction par Bi-LSTM (évolution des défauts).

Cette section est donc la base de la génération des données et des scénarios qui seront utilisés dans les chapitres suivants, où les défauts simples puis hybrides seront appliqués et étudiés [92].

4.4 Modélisation du réseau hybride avec MATLAB/Simulink

La modélisation du réseau électrique étudié dans ce mémoire a été faite avec MATLAB/Simulink, en utilisant surtout Simscape Electrical Specialized Power System (SPS).

L'objectif est d'avoir un modèle dynamique qui permette :

- La simulation en régime normal.
- L'introduction contrôlée de défauts internes (simples et hybrides).
- L'acquisition des signaux électriques (U, I, P) nécessaires à la détection, la classification et la prédiction.

4.4.1 Architecture générale du modèle Simulink

Le modèle est organisé de façon hiérarchique pour que la simulation soit facile à lire, à maintenir et à automatiser. La structure globale est organisée autour de blocs/sous-systèmes :

- Sous-système Réseau de base (IEEE-39 bus)

  Contient les bus, les lignes, les transformateurs, les charges et les générateurs classiques du réseau de référence.

- Sous-système «Sources renouvelables ajoutées»

  Contient les blocs éoliens et photovoltaïques (avec leur interface de connexion au réseau).

- Sous-système «Mesures et acquisition»

  Contient les capteurs de tension/courant et le calcul de puissance, ainsi que les blocs d'enregistrement.

- Sous-système «Scénarios défauts»

Gère l'activation des défauts (activation temporelle, niveau de défaut, bus cible, composant ciblé).

- Sous-système Post-traitement

  Permet un premier filtrage fenêtrage export vers Workspace pour la suite HHT→CNN→Bi-LSTM.

4.4.2 Paramétrage électrique et cohérence des blocs

Pour que l'ensemble soit cohérent sur le plan électrique, le modèle respecte les éléments suivants :

- **Base de calcul unités :** choix d'une base (MVA, kV) cohérente avec le réseau IEEE-39 bus.
- **Régime triphasé:** réseau triphasé équilibré (sauf en cas de défaut asymétrique).
- **Fréquence nominale :** 50Hz ou 60Hz selon le paramétrage retenu (en fixe une valeur et en reste cohérent partout).
- **Conditions initiales :** démarrage en régime stable avant d'appliquer les défauts (phase de stabilisation).

4.4.3 Modélisation des composants du réseau (bus, lignes, transformateurs, charges)

a) Bus et nœuds électriques

Les bus servent de points de connexion pour les générateurs, les charges, les lignes et les transformateurs. On les utilise aussi pour :

- Repérer où se produit les défauts (quel bus est en cause).
- Récupérer les données U/I/P par bus.
- Analyser différents scénarios avec plusieurs sources d'énergie.

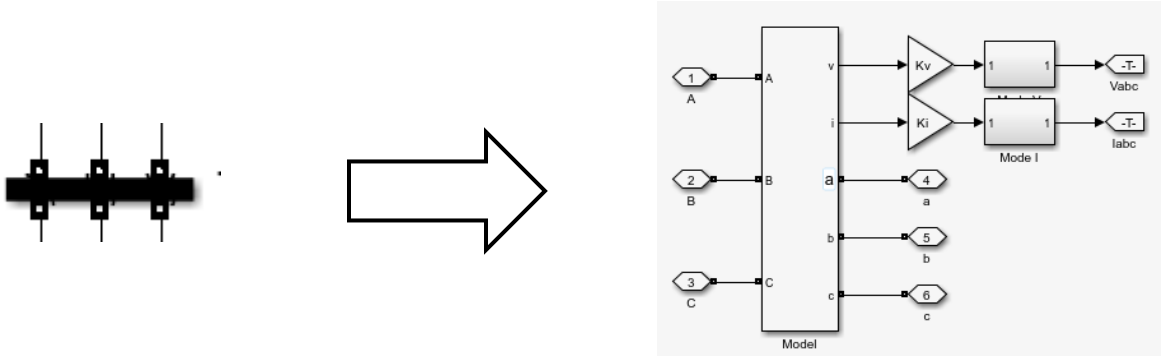

Figure 4 - 7 : Exemple de bus triphasé (bus 7) dans le modèle MATLAB/Simulink, assurant l'interconnexion des lignes, transformateurs et sources du réseau.

b) Lignes de transmission

Les lignes sont reproduites avec des paramètres répartis ou regroupés, selon le modèle choisi (R-L-C). Le but n'est pas de simuler des défauts sur les lignes, mais de s'assurer que le réseau reste réaliste, avec :

- Des baisses de tension.
- Des échanges de puissance.

- Des réactions dynamiques lors des changements brusques.

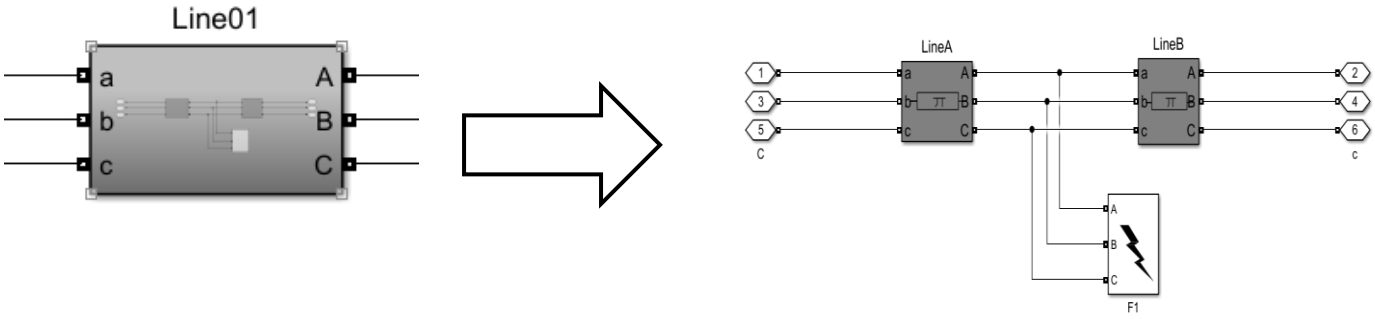

Figure 4 - 8 : Exemple de modèle de ligne triphasée implémenté sous MATLAB / Simulink et représentation interne de ses paramètres électriques.

c) Transformateurs

Les transformateurs jouent un rôle central (adaptation des niveaux de tension, couplage de sous-réseaux). Ils participent fortement aux signatures électriques observables lors des défauts internes.

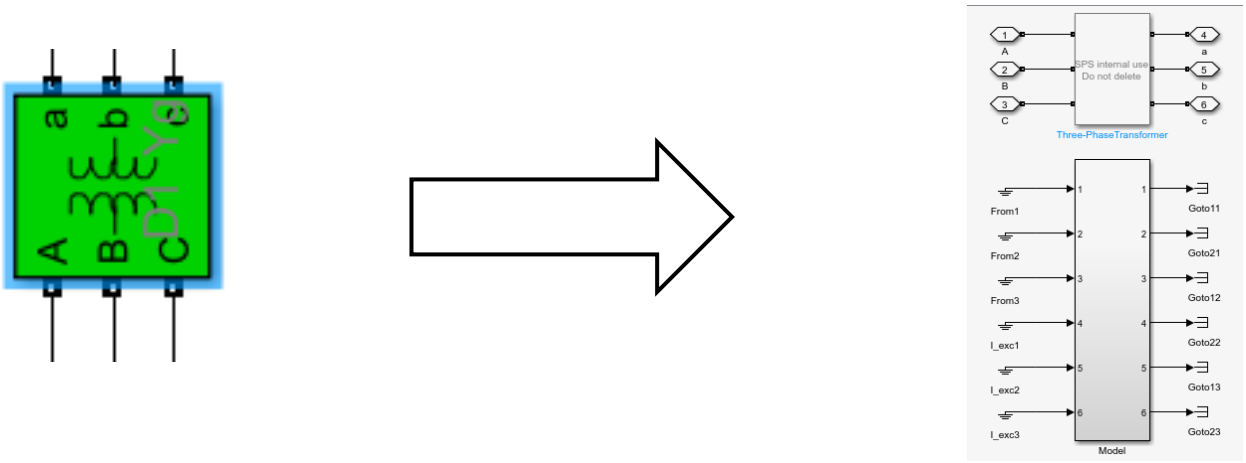

Figure 4 - 9 : Exemple de transformateur dans Simulink et ses paramètres principaux.

d) Charges

Les charges sont définies pour simuler différents fonctionnements (normal, variations, situations difficiles). Elles sont importantes pour :

- Créer des changements naturels sur U/I/P.

- vérifier la fiabilité des méthodes.

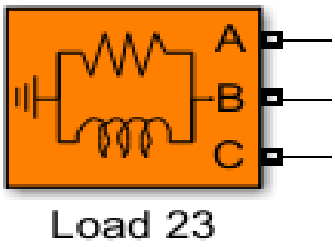

Figure 4 - 10 : exemple de charge.

4.4.4 Intérêt du réseau hybride modifié pour étudier les défauts internes

Le réseau IEEE 39 bus modifié est un bon choix pour plusieurs raisons :

- Il est assez grand pour ressembler à un réseau réel, mais sans demander trop de temps de simulation.
- Il a différentes sources de production, ce qui est bien pour étudier les défauts internes.
- Il est compatible avec MATLAB/Simulink, ce qui facilite la création de grandes quantités de données.

Contrairement aux réseaux plus petits (IEEE 14 bus), il permet une analyse détaillée, tout en restant plus facile à gérer que les très grands réseaux (IEEE 118 bus). C'est un bon équilibre entre complexité, réalisme et coût, parfait pour appliquer les méthodes HHT–CNN–Bi-LSTM.

4.4.5 Comment on mesure et enregistre les signaux (U, I, P)

a) Grandeurs mesurées

Les signaux extraits incluent typiquement :

- U(t) : tension instantanée.
- I(t) : courant instantané.
- P(t) : puissance active.

b) localisation des mesures

Les mesures sont placées :

- Aux bus qui nous intéressent.
- Autour des sources d'énergie renouvelable.
- Parfois près des transformateurs importants.

c) Enregistrement et exportation

Les signaux sont envoyés vers :

- L'espace de travail MATLAB (structure Résultats).
- Un fichier .mat.
- Ou des logs Simulink.

4.4.6 Prétraitement des données avant HHT et apprentissage

Avant d'utiliser HHT + CNN, on peut préparer les signaux en :

- Choisissant une période de temps après stabilisation et après l'apparition du défaut.
- Normalisant les valeurs (Min-Max ou z-score) pour aider CNN/Bi-LSTM.
- Appliquant un léger filtre si le signal est bruité, mais sans supprimer les informations importantes sur le défaut.
- Indiquant le type de défaut, le bus concerné et la source d'énergie touchée.

4.5 Scénarios de simulation et protocole expérimental

Dans cette partie, on explique en détail comment on simule les défauts pour créer les données qui serviront à identifier, classer, localiser et prédire les défauts internes dans le réseau hybride IEEE 39 bus modifié.

L'idée n'est pas juste de créer des défauts, mais de :

- Copier le comportement d'un réseau multi-sources.

- Créer des signaux électriques qui changent avec le temps et qui peuvent être analysés par HHT.
- Construire un ensemble de données fiable pour entraîner CNN et Bi-LSTM.
- Aider à ajuster les paramètres grâce au POA.
- Rendre les résultats compréhensibles grâce aux techniques XAI.

Les scénarios sont divisés en quatre catégories :

- Fonctionnement normal (état sain).
- Variations habituelles.
- Défauts internes simples.
- Défauts complexes à plusieurs endroits (défauts hybrides).

4.5.1 Conditions nominales de référence

Le scénario normal sert de base pour comparer tous les autres cas.

Paramètres considérés :

- Fréquence du système : 60 Hz.
- Tensions nominales aux bus selon le modèle IEEE 39-bus.
- Charges actives et réactives de base.
- Production thermique stable.
- Production éolienne normale (vent constant).
- Production photovoltaïque normale (ensoleillement d'environ 1000 W/m²).

Dans ces conditions :

$$P(t) = V(t) \cdot I(t) \quad \textbf{(4.1)}$$

Les signaux U(t), I(t) et P(t) :

- Un comportement quasi stationnaire.

- Une faible distorsion harmonique.
- Une stabilité angulaire des machines synchrones.

Ces données représentent la classe Sain dans l'ensemble de données (Dataset).

4.5.2 Variations naturelles de fonctionnement

Pour que le modèle n'apprenne pas seulement une situation fixe, on ajoute des changements réalistes.

a) Variation de charge

- ±10 %, ±20 %, ±30 %.
- Variation progressive (en pente).
- Variation brusque (en escalier).

Conséquences :

- Changement du flux de puissance.
- Modification des tensions locales.
- Changement des angles du rotor.

b) Variation d'irradiance photovoltaïque

On simule des profils dynamiques :

$$G(t) = G_0 + \Delta G(t) \quad \textbf{(4.2)}$$

Où :

- G_0 : ensoleillement normal.
- $\Delta G(t)$: variation aléatoire ou sinusoïdale.

Effets :

- Variation de la puissance injectée.
- Changement local de la tension.

c) Variation de la vitesse du vent

Modèle simplifié :

$$P_{wind} \propto v^3 \quad \textbf{(4.3)}$$

Où :

v est la vitesse du vent.

Une faible variation de vent produit une variation importante de puissance.

4.5.3 Mise en œuvre des défauts internes simples

Les défauts internes sont appliqués directement aux composants du réseau modifié.

Défauts étudies :

- Variation de la puissance normale.
- Variation de la tension générée.
- Augmentation de la résistance du stator.
- Augmentation de la résistance du rotor.
- Diminution de l'AVR (régulateur automatique de tension).
- Variation d'irradiance du champ photovoltaïque.
- Diminution de l'inductance de magnétisation Lm.
- Augmentation de l'axe de transitoire Xd.
- Diminution du gain exciteur Ke.
- Augmentation du constant de temps Tb.

Les défauts sont introduits progressivement :

$$R_{fault}(t) = R_0(1 + \alpha t) \quad \textbf{(4.4)}$$

Où :

- $R_{fault}(t)$: résistance de défaut à l'instant t.
- R_0 : résistance initiale du défaut.
- α : coefficient de croissance (s^{-1}) qui règle la vitesse d'augmentation du défaut

Cela permet de créer :

- des signaux qui changent avec le temps.
- des variations légères.
- des dérives graduelles qui peuvent être analysées par le Bi-LSTM.

4.5.4 Défauts hybrides multi points (plusieurs endroits)

Pour rendre le système plus compliqué et réaliste, on applique des défauts en même temps :

- variation de la puissance nominale plus variation irradiance.
- Augmentation de la résistance de stator plus le rotor
- Défaut dans sous système de PV plus variation de la puissance.
- Ke + Irradiance+ Ta+Lm

Cela permet de vérifier :

- si le CNN peut séparer les différents défauts.
- si le Bi-LSTM est fiable.
- si l'optimisation POA est stable.

4.5.5 Protocole de génération du dataset

La chaîne complète est :

Simulation → Acquisition → Prétraitement → HHT → CNN → Bi-LSTM (optimise par Poa) → XAI

Étape 1 : Simulation dynamique

- Résolution numérique via power gui

- Solveur discret
- Pas d'intégration adapté aux transitoires

Étape 2 : Acquisition des signaux

Signaux extraits :

- U(t)
- I(t)
- P(t)

Étape 3 : Fenêtrage

Les signaux sont segmentés :

$$X_i = \{x(t_k), \dots, x(t_{k+N})\} \quad \textbf{(4.5)}$$

Fenêtres glissantes avec recouvrement.

Étape 4 : Extraction HHT

La HHT comprend :

- Décomposition EMD :

$$\mathrm{X(t)} = \sum \mathrm{IMF_i(t)} + \mathrm{r(t)} \quad \textbf{(4.6)}$$

- Transformée de Hilbert :

$$\mathrm{H[IMF_i(t)]} \quad \textbf{(4.7)}$$

Permet d'obtenir :

- fréquence instantanée
- amplitude instantanée
- énergie locale

Ces caractéristiques alimentent le CNN.

Étape 5 : Classification CNN

Le CNN extrait :

- motifs locaux
- signatures temps-fréquence
- structures hiérarchiques

Étape 6 : Prédiction Bi-LSTM optimisée par POA

Le Bi-LSTM modélise :

$$h_t = f(x_t, h_{t-1}, h_{t+1}) \quad \textbf{(4.8)}$$

Le POA optimise :

- nombre de neurones
- taux d'apprentissage
- taille batch
- nombre d'époches

Étape 7 : Interprétabilité (XAI)

Des techniques d'explicabilité sont utilisées :

- Importance des caractéristiques
- Cartes d'activation CNN
- Contribution temporelle Bi-LSTM

Cela permet de justifier :

- pourquoi un défaut est détecté,
- quels bus sont affectés,
- quelles signatures ont dominé la décision.

4.5.6 Séparation des données

Dataset divisé en :

- 70 % entraînement
- 15 % validation
- 15 % test

Avec équilibrage des classes :

$$\text{Accuracy} = \frac{\text{TP+TN}}{\text{Total}} \quad \textbf{(4.9)}$$

$$\text{F1} = \frac{\text{2PR}}{\text{P+R}} \quad \textbf{(4.10)}$$

4.6 Mise en place détaillée des défauts internes simples

Cette section décrit de manière approfondie la méthodologie adoptée pour l'implémentation des défauts internes simples dans le réseau hybride IEEE 39 bus modifié.

Contrairement aux défauts externes (court-circuit de ligne, défaut phase-terre), les défauts internes présentent les caractéristiques suivantes :

- Une évolue progressivement.
- Une amplitude est initialement faible.
- Ils ne déclenchent pas immédiatement les protections classiques.
- Leurs signatures dans les signaux électriques sont subtiles et non stationnaires.

L'idée est de modéliser des détériorations réalistes pour permettre :

- L'analyse temps-fréquence via HHT.
- La classification automatique via CNN.
- La prédiction temporelle via Bi-LSTM.

- L'optimisation via POA.
- L'identification des causes via XAI.

4.6.1 Types de défauts internes simples étudiés

Les défauts simples que nous avons étudiés affectent un seul composant et un seul paramètre à la fois, Ils sont regroupés en trois catégories :

Défauts des générateurs :

- Variation de la puissance nominale
- Variation de la tension générée.

Défauts des éoliennes :

- Augmentation de la résistance du stator.
- Augmentation de la résistance du rotor.
- Variation de la tension générée.
- Variation de la puissance nominale.

Défauts des panneaux photovoltaïques :

- Diminution de la résistance série du transformateur
- Variation du rapport de transformation
- Diminution d'irradiance.

4.6.2 Modélisation mathématique des défauts

Un défaut interne est modélisé par :

$$\theta_{fault}(t) = \theta_0\big(1 + \alpha(t)\big) \quad \textbf{(4.11)}$$

Où :

- θ_0: valeur nominale
- (t): coefficient de dégradation

- (t): paramètre dégradé

Nous avons étudié deux types d'évolution :

Défaut brusque :

$$\alpha(t) = \alpha_0 H(t - t_f) \quad \textbf{(4.12)}$$

Où :

H : fonction de Heaviside

Défaut progressif :

$$\alpha(t) = kt \quad \textbf{(4.13)}$$

Ce modèle est particulièrement adapté à la maintenance prédictive.

4.6.3 Défaut sur un générateur synchrones

Implémentation Simulink, en prend un exemple de variation de la puissance nominale, dans le bloc (Synchrone Machine) :

- Modification du paramètre de la puissance nominal.
- Variation aléatoire de ± [10, 50] %.
    - Modélisation :

$$P_{new} = P_{nom}(1 + \delta) \quad \textbf{(4.14)}$$

    - Impact sur le système :
- Redistribution des flux de puissance
- Variation de la tension locale
- Variation de l'angle du rotor
- Changement des oscillations électromécaniques
    - Signature observée :
- Légère dérive de U(t)

- Variation de P(t)
- Composantes IMF spécifiques via HHT

4.6.4 Défaut de l'éolienne :

En prend un exemple de l'augmentation de la Rs ce défaut simule :

- Le vieillissement thermique
- La dégradation de l'isolation
- Un court-circuit partiel interne

$$R_s(t) = R_{s0}(1 + \beta) \quad \textbf{(4.15)}$$

  - Effets dynamiques :

- Augmentation des pertes Joule :

$$P_{loss} = I^2 R_s \quad \textbf{(4.16)}$$

- Modification du courant absorbé
- Faible variation harmonique

Ce défaut n'est généralement pas détecté par les protections classiques.

4.6.5 Défaut photovoltaïque

En vas prendre deux exemples appliqués :

a) Diminution d'irradiance :

$$G(t) = G_0(1 - \eta) \quad \textbf{(4.17)}$$

- Diminution simulée aléatoire de [30% à 80 %]

  - Effets :

- Baisse de la puissance injectée
- Variation de la tension locale

- Légère perturbation globale

b) Défaut interne entre phases dans le sous-système PV :

En plus des problèmes d'irradiance anormale localisée, nous avons modélisé un défaut électrique interne dans le sous-système photovoltaïque (PV) pour simuler une dégradation affectant l'équilibre triphasé du système.

Le générateur photovoltaïque triphasé est modélisé avec :

- Trois phases : A, B et C
- Des résistances équivalentes entre phases :
  - R_{AB}
  - R_{BC}
  - R_{CA}

Ces résistances représentent :

- Les chemins de couplage internes
- Les impédances parasites
- Les phénomènes de fuite interne

$$R_{AB}=R_{BC}=R_{CA}=R_0 \quad \textbf{(4.18)}$$

Où :

$R0$: est la valeur nominale équilibrée.

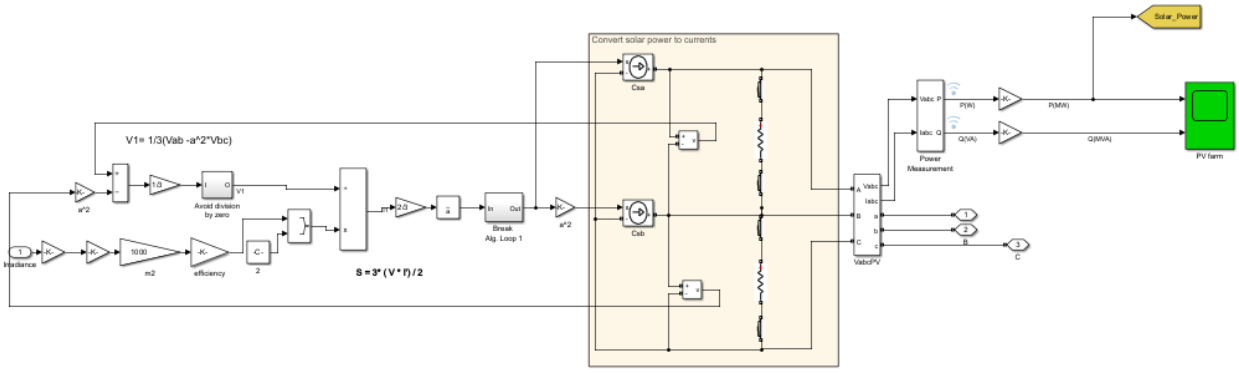

Figure 4 - 11 : Schéma détaillé du sous-système photovoltaïque (DPV) intégré au réseau hybride sous MATLAB/Simulink.

4.6.6 Analyse des signatures électriques générées

Les défauts internes simples produisent :

- de faibles variations d'amplitude
- des composantes non stationnaires
- des fréquences instantanées variables
- des dérives progressives

Ces propriétés justifient l'utilisation de la HHT.

La décomposition :

$$x(t) = \sum IMF_i(t) + r(t) \qquad \textbf{(4.19)}$$

Permet d'isoler les signatures faibles.

4.6.7 Lien avec l'architecture intelligente

Les défauts simples alimentent :

- HHT :

Extrait les informations temps-fréquence locales.

- CNN :

Apprend les signatures caractéristiques.

- Bi-LSTM :

Apprend la dynamique temporelle.

- POA :

Optimise automatiquement :

  - le nombre de neurones
  - le taux d'apprentissage
  - la taille des lots

- XAI :

Analyse :

  - l'importance des IMF
  - la contribution temporelle
  - le bus le plus touché

4.6.8 Construction des classes du dataset

Chaque défaut simple est associé à :

- une classe spécifique
- un bus spécifique
- un niveau de sévérité

Exemple :

Classe	Type	Bus	Sévérité
C1	Pn+10%	Bus 39	Faible
C2	Pn +30%	Bus 31	Moyenne
C28	(Rs et Rr)+20%	Bus 39 et 9	Moyenne

Cela permet :

- la classification multi-classe
- la localisation automatique
- la prédiction multi-niveaux

4.7 Protocole d'évaluation et de validation

Cette section décrit la méthodologie adoptée pour évaluer les performances du système HHT- CNN-Bi-LSTM optimisé par POA et interprété par XAI.

L'objectif est de s'assurer de :

- la fiabilité des résultats
- l'absence de sur-apprentissage
- la résistance aux variations de fonctionnement
- la reproductibilité scientifique

4.7.1 Séparation des données

Le dataset est divisé en trois sous-ensembles :

- Ensemble d'entraînement (Train) : 70 %
- Ensemble de validation (Validation) : 15 %

- Ensemble de test (Test) : 15 %

Rôle de chaque ensemble :

- Train : apprentissage des paramètres du CNN et du Bi-LSTM.
- Validation : réglage des hyper paramètres (POA).
- Test : évaluation finale indépendante.

Cette séparation permet d'éviter :

- le sur-apprentissage.
- la fuite d'information.
- la surestimation des performances.

4.7.2 Équilibrage du dataset

Les classes de défauts (simples et hybrides) sont équilibrées pour éviter un biais d'apprentissage.

- Utilisons de deux stratégies.
- Génération du même nombre de scénarios par classe.
- Vérification de la distribution statistique avant l'entraînement.
- Un dataset déséquilibré aurait favorisé la classe majoritaire et réduit la précision globale.

4.7.3 Métriques d'évaluation

Pour évaluer la classification et la prédiction, nous utilisons plusieurs indicateurs :

- **Exactitude (Accuracy)**

$$\text{Accuracy} = \frac{\text{TP}+\text{TN}}{\text{TP}+\text{TN}+\text{FP}+\text{FN}} \quad \textbf{(4.20)}$$

Taux global de prédictions correctes.

- **Précision (Precision)**

$$\text{Precision} = \frac{\text{TP}}{\text{TP+FP}} \quad \textbf{(4.21)}$$

Fiabilité des prédictions positives.

- **Rappel (Recall)**

$$\text{Recall} = \frac{\text{TP}}{\text{TP+FN}} \quad \textbf{(4.22)}$$

Capacité à détecter correctement les défauts réels.

- **F1-score**

$$\text{F1} = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision+Recall}} \quad \textbf{(4.23)}$$

Moyenne entre précision et rappel.

- **Matrice de confusion**

Permet d'analyser :

- les erreurs entre classes proches.
- les confusions entre défauts simples et hybrides.
- la résistance du modèle.

4.7.4 Validation temporelle pour la prédiction

Pour la partie Bi-LSTM :

- Les séquences temporelles sont évaluées sur des scénarios non vus.
- On mesure la capacité à anticiper l'évolution du défaut.
- L'erreur temporelle moyenne (MAE ou RMSE) peut être utilisée.

4.7.5 Optimisation des hyper-paramètres (POA)

L'algorithme POA optimise :

- le nombre de filtres CNN

- la taille des noyaux
- le nombre de neurones LSTM
- le taux d'apprentissage
- la taille des lots

La fonction objective est :

$$\text{Min } (\text{Erreur}_{\text{validation}})$$

Le modèle final correspond à la meilleure solution trouvée par POA.

4.7.6 Robustesse et tests supplémentaires

Nous avons réalisé des tests complémentaires avec :

- Variation de charge.
- Variation d'irradiance.
- Variation de la résistance de stator et rotor.
- Variation de la puissance.

➢ **Objectif :**

- Vérifier que le modèle ne dépend pas d'un scénario unique.
- Tester la stabilité face aux perturbations.

4.7.7 Intégration de l'XAI dans l'évaluation

Grâce à l'explicabilité, nous pouvons :

- Identifier les composantes HHT qui influencent la décision
- Vérifier que le modèle ne se base pas sur du bruit
- Augmenter la confiance dans la prédiction

Des cartes d'importance (ex. Grad-CAM ou analyse des activations) sont utilisées pour :

- Interpréter les décisions du CNN
- Analyser la contribution des séquences temporelles

4.8 Conclusion

Dans ce chapitre, nous avons présenté le réseau IEEE 39 bus et les modifications apportées pour créer un réseau hybride multi-source adapté à l'étude des défauts internes. Nous avons choisi ce réseau car il offre un bon compromis entre complexité, représentativité industrielle et temps de simulation, ce qui en fait une base pertinente pour évaluer les méthodes intelligentes que nous proposons.

L'intégration des sources renouvelables (éoliennes et photovoltaïque), la modélisation sous MATLAB/Simulink et la définition rigoureuse des scénarios de simulation ont permis de créer un environnement réaliste pour générer les données. Les signaux électriques (U, I, P) obtenus constituent une base fiable pour extraire les caractéristiques par la HHT, détecter et classifier les défauts par CNN et prédire leur évolution via Bi-LSTM optimisé par POA.

Ce chapitre établit le cadre expérimental complet de ce mémoire. Le chapitre suivant sera consacré à l'analyse des défauts simples et à l'évaluation détaillée des performances du système proposé.

Chapitre 5
Analyse des défauts internes simples

5.1 Introduction

Les réseaux hybrides combinent souvent des sources renouvelables comme le solaire et l'éolien pour répondre aux besoins environnementaux et économiques. L'énergie solaire est une solution durable et propre, qui ne crée pas de déchets directs et qui peut être utilisée à différentes échelles [48], [49]. Cependant, l'efficacité des installations solaires dépend de leur environnement et de leur état.

Plusieurs choses peuvent réduire l'efficacité des panneaux solaires. La poussière ou la pollution qui s'accumule sur les panneaux peut réduire l'absorption du soleil et donc la production d'énergie [50], [51]. Certaines études montrent que la perte de puissance due à la poussière peut varier de 5 % à 30 % par an, selon l'endroit [52]. De plus, la neige, les excréments d'oiseaux, le ciment, l'ombre ou les fissures peuvent aussi réduire les performances et la durée de vie des panneaux [53], [54].

En plus des problèmes externes, les panneaux solaires peuvent avoir des problèmes internes comme des points chauds, des déséquilibres électriques, des problèmes de connexion ou du court-circuit. Si on ne les détecte pas à temps, ces problèmes peuvent endommager progressivement le panneau, voire le détruire complètement [56]. Il ne suffit donc pas de surveiller la production d'énergie pour trouver la cause du problème. Il faut des méthodes de diagnostic plus poussées.

Dans un réseau hybride, ces problèmes ne touchent pas que photovoltaïque, Les machines synchrones et les éoliennes peuvent aussi avoir des variations de puissance, de tension ou d'autres paramètres électriques, ce qui peut perturber l'équilibre du système. Ces défauts, même s'ils sont petits, peuvent créer des signaux électriques complexes qui se propagent dans le réseau.

Il est donc important de détecter rapidement les défauts internes pour assurer la stabilité du réseau hybride. Contrairement aux gros défauts externes, les petits défauts internes entraînent généralement des variations lentes ou partielles des grandeurs électriques (U, I, P), ce qui les rend plus difficiles à identifier.

Dans ce chapitre, nous allons étudier en détail les petits défauts internes qui touchent un seul point du réseau à la fois. Cela nous permettra d'identifier les signaux électriques propres à chaque problème avant d'analyser des situations plus complexes avec plusieurs problèmes en même temps, dans le chapitre suivant.

Au total, nous allons étudier vingt-sept types de défauts simples, répartis entre les machines synchrones, les panneaux solaires et les éoliennes du réseau hybride modifié. Pour cela, nous utiliserons une méthode qui combine l'extraction de données, la classification, la prédiction et l'interprétation des résultats, afin d'évaluer la capacité du système à détecter, classer et anticiper ces problèmes internes.

5.2 Revue de la littérature

La capacité à détecter les défauts électriques dans les réseaux hybrides est devenue indispensable, car on intègre de plus en plus de sources renouvelables. Avant, les systèmes de protection utilisaient des méthodes classiques comme la mesure de courant différentiel, les relais de distance et l'analyse directionnelle d'impédance. Ces techniques sont bonnes dans les réseaux classiques, mais moins dans les systèmes hybrides qui ont des signaux dynamiques et variables.

L'arrivée et le départ aléatoires des sources photovoltaïques et éoliennes créent des changements rapides de tension et de puissance, ce qui complique la tâche d'identifier les défauts internes qui se développent lentement. Les méthodes avec des seuils fixes peuvent

créer de fausses alertes ou cacher des anomalies de faible intensité. C'est pour ça qu'on a commencé à créer des méthodes d'analyse avancée basées sur le traitement adaptatif des signaux.

Parmi ces méthodes, la transformée de Hilbert–Huang (HHT) est devenue une option intéressante pour analyser les signaux non constants. Elle utilise la décomposition en modes intrinsèques (EMD) suivie d'une analyse spectrale, ce qui permet de récupérer des signaux de fréquence locaux adaptés aux environnements dynamiques des micros réseaux hybrides. Plusieurs études ont montré son avantage pour détecter les défauts à haute impédance et pour classer différents types de défauts dans les systèmes AC/DC.

En même temps, les réseaux de neurones convolutionnels (CNN) ont bien fonctionné pour classer automatiquement des signaux complexes provenant de signaux électriques ou de représentations temps-fréquence. Ils sont capables d'extraire des données de manière hiérarchique, ce qui les rend plus résistants au bruit et aux changements de charge. Cependant, les NN seuls ne montrent pas clairement l'évolution des anomalies au fil du temps.

Pour la prédiction, les architectures LSTM et Bi-LSTM ont été souvent utilisées dans les systèmes énergétiques pour suivre les dépendances temporelles sur le long terme. On a pu améliorer la stabilité et la précision des modèles de prédiction en intégrant des méta-heuristiques pour le réglage des hyper paramètres.

Malgré ces progrès, il reste des problèmes :

- La plupart des études traitent la détection et la prédiction séparément.
- Rares sont les études qui analysent en détail les défauts internes simples appliqués individuellement à un réseau hybride multi-sources complet.
- L'ajustement automatique des hyper paramètres reste limité.
- L'intégration de l'intelligence artificielle explicable (XAI) n'est pas encore très développée dans les applications de maintenance prédictive des réseaux électriques.

C’est pourquoi, une approche intégrée qui combine l’extraction adaptative (HHT), la classification profonde (CNN), la prédiction temporelle (Bi-LSTM réglé par POA) et l’interprétabilité (XAI) semble être une évolution logique pour répondre aux besoins de fiabilité et de maintenance prédictive.

Dans [13], les auteurs ont analysé les méthodes classiques de détection des défauts dans les systèmes hybrides, en comparant les techniques traditionnelles (courant différentiel, relais de distance) aux méthodes modernes basées sur l’analyse des signaux. Ils ont fait voir que les approches conventionnelles restent limitées face aux défauts progressifs et aux variations dynamiques causées par les sources renouvelables.

L’étude [29] propose une classification complète des anomalies qui peuvent toucher les systèmes énergétiques renouvelables. Les auteurs remarquent le manque d'uniformisation des ensembles de données et la difficulté de comparer objectivement la valeur des méthodes proposées dans les publications.

Concernant l’analyse des signaux non constants, l’article [48] montre l’utilisation de la transformée de Hilbert–Huang (HHT) pour la détection des défauts à haute impédance dans les micro réseaux. Les résultats des tests montrent une amélioration de la sensibilité par rapport aux méthodes linéaires classiques, avec moins de faux négatifs. De même, [68] utilise la HHT pour classer plusieurs types de défauts dans des micro-grids AC/DC, avec une précision de plus de 95 %. L’étude [19] montre aussi que la HHT est efficace pour extraire des signaux spectraux typiques des défauts internes dans les systèmes hybrides de stockage d’énergie.

Dans le domaine de la classification automatique, l’article [17] propose un modèle CNN léger pour la détection en temps réel des défauts électromécaniques. Les auteurs annoncent une précision supérieure à 92 % avec un temps de réponse inférieur à 50 ms, ce qui prouve la performance des réseaux convolutionnels pour l’analyse des signaux électriques complexes.

L’étude [10] combine un CNN avec un LSTM pour la détection de défauts sur une éolienne. Le système CNN–LSTM permet de récupérer les données spectro-temporelles et de

montrer leur évolution, avec un taux de détection global de 90,06 %. Cette approche met en évidence l'avantage de combiner l'extraction spatiale et la modélisation temporelle.

Dans [34], les auteurs proposent un LSTM réglé par des méta-heuristiques pour la prédiction des défauts dans un système solaire–hydrogène. Le réglage améliore la stabilité du modèle et réduit les faux positifs, ce qui montre l'importance du réglage automatique des hyper paramètres dans les systèmes de maintenance prédictive.

Enfin, l'étude [69] souligne l'importance grandissante de l'intelligence artificielle explicable (XAI) dans les applications industrielles. Les auteurs insistent sur la nécessité d'intégrer des méthodes d'interprétation pour améliorer la confiance des opérateurs et la transparence des décisions prises par les modèles profonds.

Cette architecture vise à fournir un cadre complet de détection, de classification et de prédiction des défauts internes simples dans un réseau hybride modifié, avant d'élargir l'analyse aux scénarios multi-défauts présentés au chapitre suivant.

5.3 Méthodologie et analyse expérimentale

Dans ce travail, on a créé avec MATLAB/Simulink une base de données des défauts internes simples à partir du réseau hybride IEEE 39 bus modifié. La base comprend 27 types de défauts simples, comme :

- Des changements de puissance nominale et de tension des machines synchrones,
- Des défauts entre phases au niveau du système photovoltaïque,
- Des changements internes appliqués aux éoliennes.

Chaque situation correspond à un seul point d'application. L'objectif est d'isoler clairement les signatures électriques propres à chaque anomalie.

Pour chaque type de défaut, on simule 50 expériences indépendantes, pour chaque classe de défauts. Cela devait donner un ensemble de données équilibré et qui représente bien les différents fonctionnements dynamiques du réseau.

5.4 Base des données de contingence

Nous avons créé une base de données des cas de panne simples en utilisant une version modifiée du réseau IEEE 39 bus avec MATLAB/Simulink. Cette base contient toutes les simulations de pannes sur un seul point du réseau à chaque fois.

En tout, nous avons défini 27 types de pannes, qui incluent :

- Les changements de puissance des machines synchrones.
- Les changements de tension des générateurs.
- Les défauts entre phases dans le système photovoltaïque.
- Les changements internes des éoliennes.

La **classe 0** représente le fonctionnement normal (régime permanent), sans panne, et sert de référence pour l'apprentissage.

Pour chaque type de panne, nous avons fait 50 simulations différentes, en changeant au hasard les paramètres et le moment où la panne survient. Cela nous donne des données équilibrées qui montrent bien comment le réseau réagit.

Au total, nous avons donc simulé :

$27 \times 50 = 1350$ cas de panne

Le **Tableau 5.1** montre en détail comment ces cas de panne sont organisés, en indiquant :

- La source concernée (machine synchrone, photovoltaïque, éolienne).
- La localisation du défaut.
- Le type de modification appliquée.
- L'intervalle de variation aléatoire utilisé.

Tableau 3: Définitions de la contingence correspondent aux défauts internes simples.

Nature du défaut	Nombre de Classe	Source	Localisation des défauts	Type de défaut interne	Variation aléatoire
Défauts simple (Un seul point d'application), Soit 27 différents défauts	Classe 0	Machine Synchrone (MS)	N/A	NA	NA
	Classe 1		G1	Augmentation de la puissance nominale (MVA)	[+10 à +50]
	Classe 2		G2		
	Classe 3		G3		
	Classe 4		G4		
	Classe 5		G5		
	Classe 6		G6	Diminution de la puissance nominale (MVA)	[-10 à -50]
	Classe 7		G7		
	Classe 8		G8		
	Classe 9		G9		
	Classe 10		G10		
	Classe 11		G1	Augmentation de la tension générée (KV)	[+10 à +50]
	Classe 12		G2		
	Classe 13		G3		
	Classe 14		G4		
	Classe 15		G5		
	Classe 16		G6	Diminution de la tension générée (KV)	[-10 à -50]
	Classe 17		G7		
	Classe 18		G8		
	Classe 19		G9		
	Classe 20		G10		
	Classe 21	Énergie Renouvelable (ER)	Photovoltaïque (PV)	Défaut AB (breakers 1 & 2 ouverts)	0,1
	Classe 22			Défaut BC (breakers 3 & 4 ouverts)	0,1
	Classe 23			Défaut CA (breakers 1 & 4 ouverts	0,1
	Classe 24		Éolienne 1	Augmentation de la puissance nominale (MVA)	[+20 a +50]
	classe 25		Éolienne 1	Augmentation de la tension générée (kv)	[+20 a+50]
	Classe 26		Éolienne 2	Diminution de la puissance nominale (MVA)	[-20 a -50]
	classe 27		Éolienne 2	Diminution de la tension générée (kv)	[-20 a -50]

5.5 Application des défauts internes simples

Pour bien cerner les signatures électriques de chaque anomalie, les défauts internes simples sont appliqués individuellement sur différents éléments du réseau hybride. Chaque défaut démarre à un moment précis de la simulation, avec des valeurs aléatoires comprises dans les intervalles définis au **Tableau 5.1** L'analyse est ensuite organisée selon le type de source concernée, afin d'isoler clairement les effets propres à chaque catégorie (machines synchrones, système photovoltaïque et éoliennes)

5.5.1 Défauts sur les Machines Synchrones

Les défauts étudiés sur les machines synchrones (MS) sont :

a) Augmentation de la puissance nominale.

b) Diminution de la puissance nominale.

c) Augmentation de la tension générée.

d) Diminution de la tension générée.

a) Augmentation de la puissance nominale (classe 1 à 5)

Dans ces classes, une augmentation de la puissance nominale (MVA) est simulée en ajustant directement le paramètre correspondant dans le modèle Simulink du générateur concerné. L'amplitude de variation est introduite aléatoirement dans l'intervalle défini au Tableau 5.1 donc une augmentation aléatoire entre +10% et +50% de la valeur nominal de générateur.

Conséquences observées :

- Augmentation de la puissance active fournie au réseau
- Modification du courant statorique
- Déséquilibre transitoire du flux de puissance
- Apparition d'oscillations au moment de l'injection du défaut

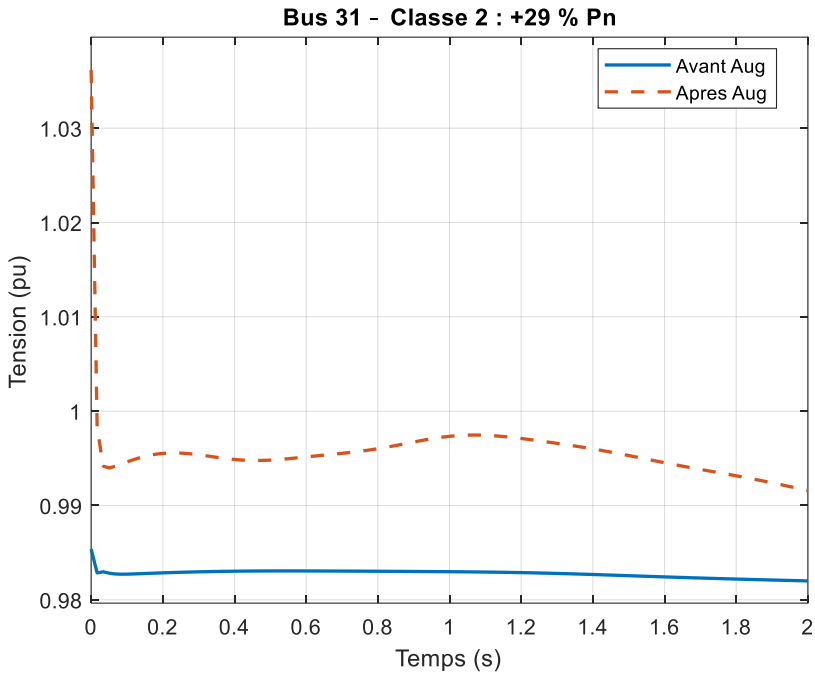

Figure 5 - 1 : Impact d'une Augmentation de la puissance nominale de G2.

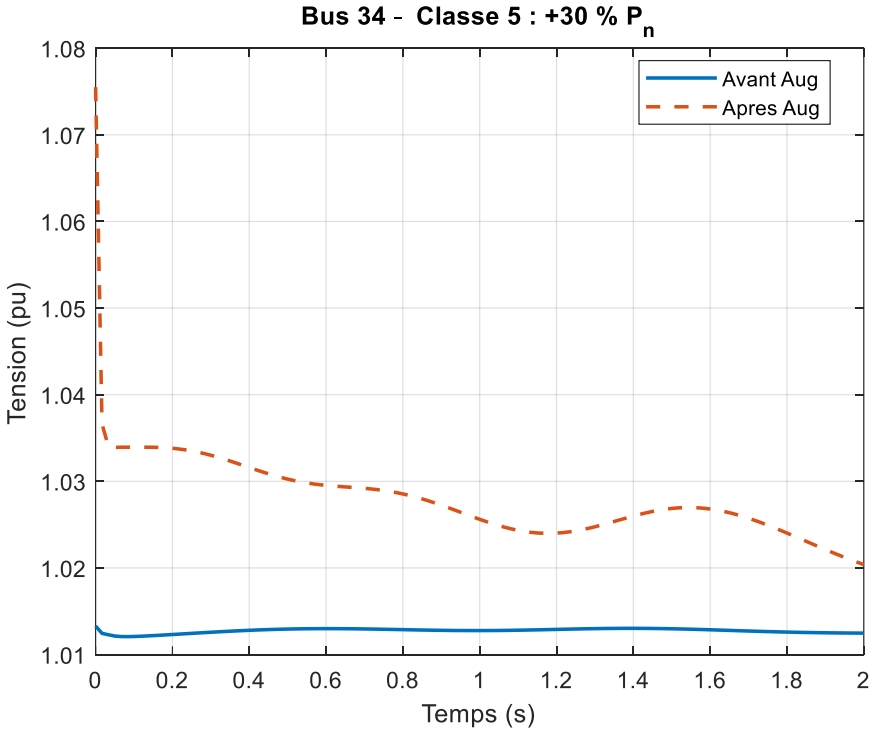

Figure 5 - 2 : Impact d'une Augmentation de la puissance nominale de G5.

b) Diminution de la puissance nominale (Classes 6 à 10)

Dans ces classes, la puissance nominale est réduite selon l'intervalle de variation prédéfini correspondant à une diminution aléatoire comprise entre **−10 % et −50 %** de la valeur nominale du générateur.

Effets observés :

- Baisse progressive de la puissance active injectée
- Réduction du courant délivré
- Modification de l'équilibre énergétique local
- Transitoires amortis après apparition du défaut

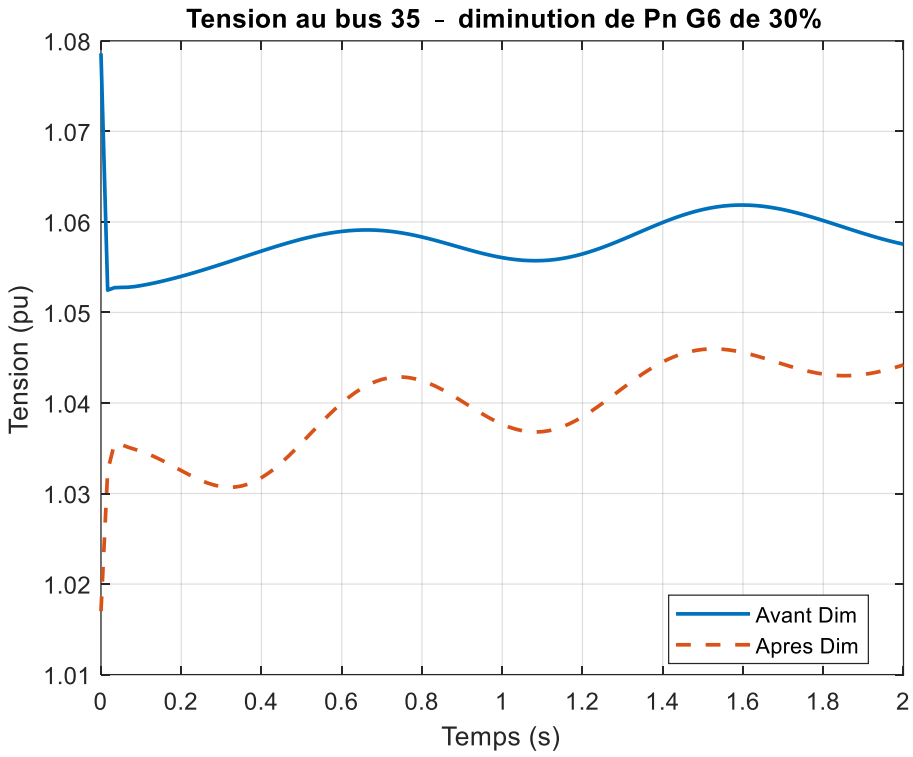

Figure 5 - 3 : Impact d'une diminution de la puissance nominale de G6.

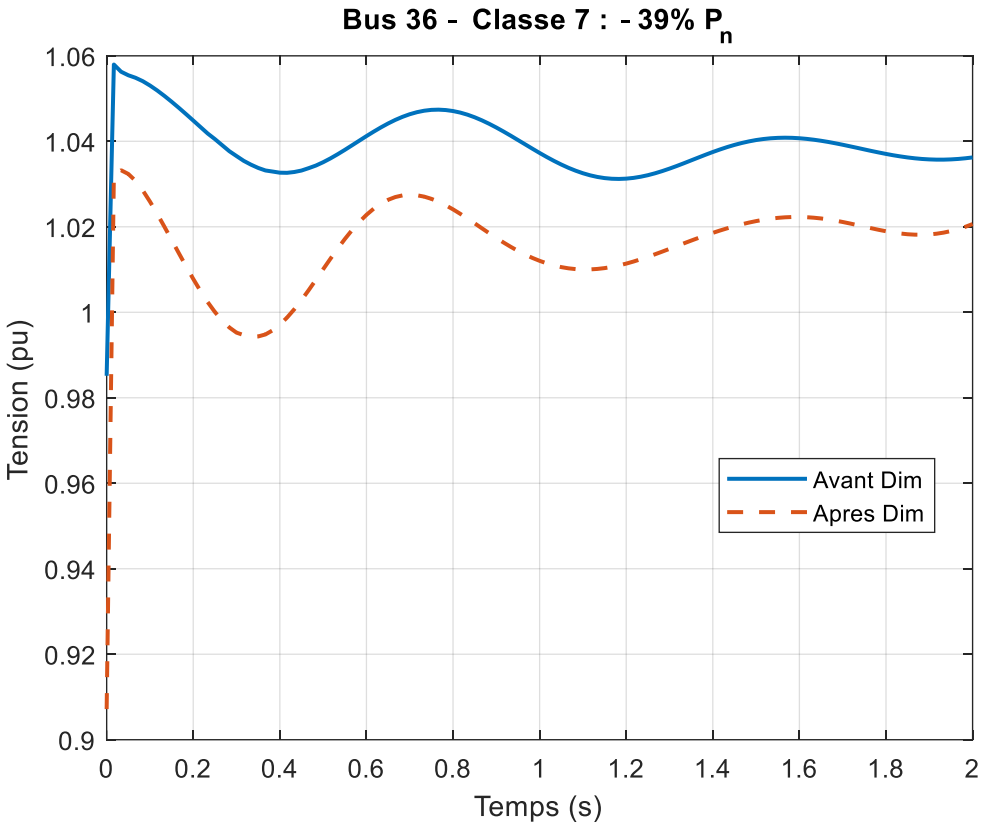

Figure 5 - 4: Impact d'une diminution de la puissance nominale de G7.

c) Augmentation de la tension générée (Classes 11 à 15)

Dans ces classes, en applique une augmentation aléatoire de la tension générée du paramètre du générateur. Donc une augmentation entre +10% et +50% de la valeur nominale de la tension.

Conséquences principales :

- Élévation du niveau de tension au bus concerné
- Variation de la puissance réactive
- Ajustement du courant injecté
- Oscillations transitoires initiales

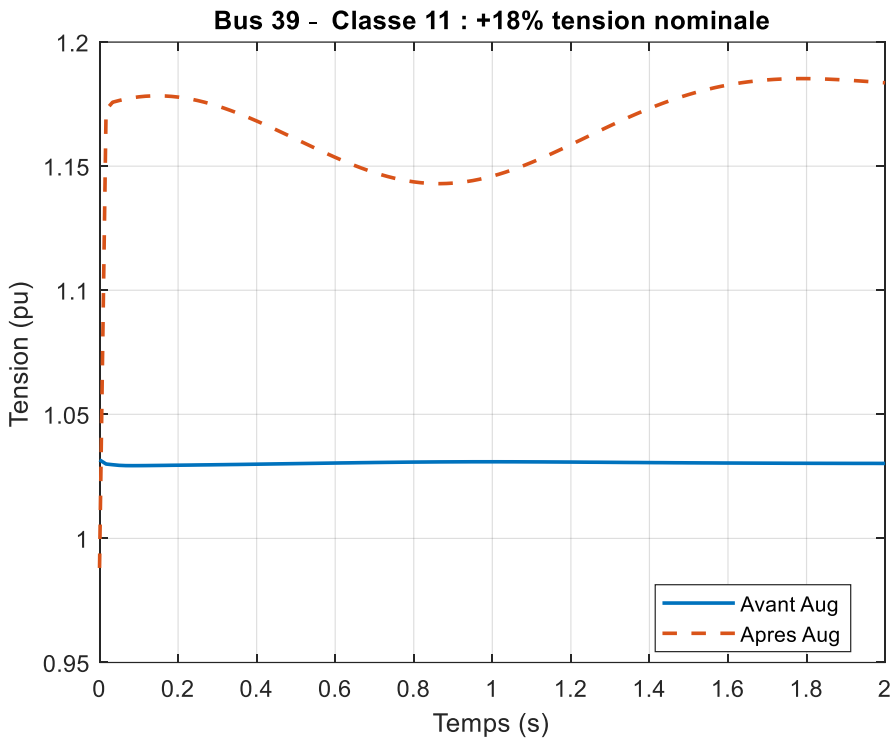

Figure 5 - 5: Impact d'une augmentation de la Tension G1.

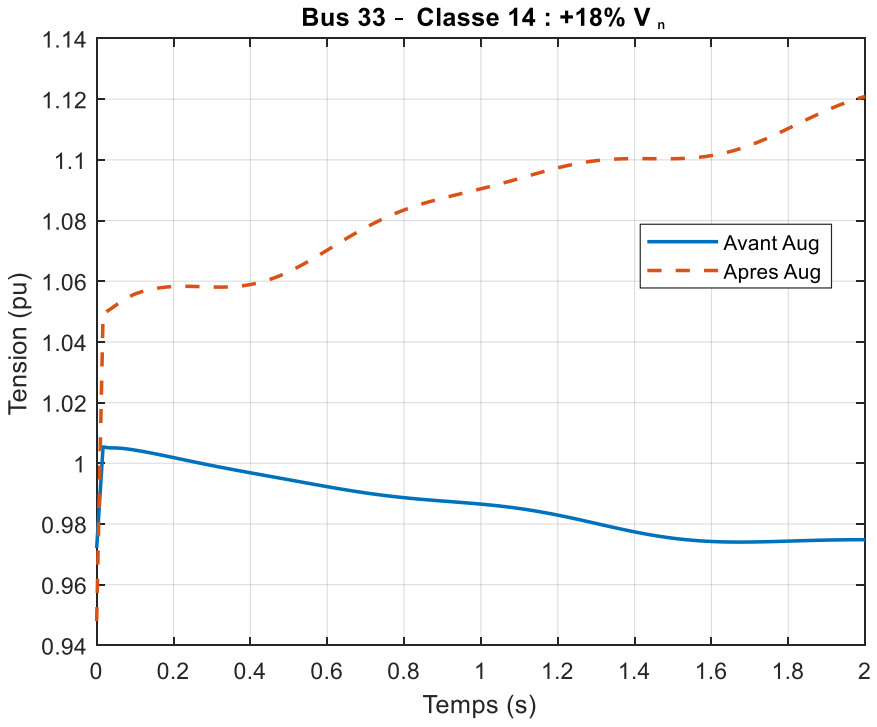

Figure 5 - 6: Impact d'une augmentation de la tension de G4.

d) Diminution de la tension générée (Classes 16 à 20)

Dans ces classes, la tension générée est diminuée de manière aléatoire dans l'intervalle compris entre -10% et -50% de sa valeur nominale.

Effets observés :

- Chute de tension locale
- Augmentation possible de la demande en puissance réactive
- Modification du profil de courant
- Comportement dynamique dépendant du niveau de sévérité

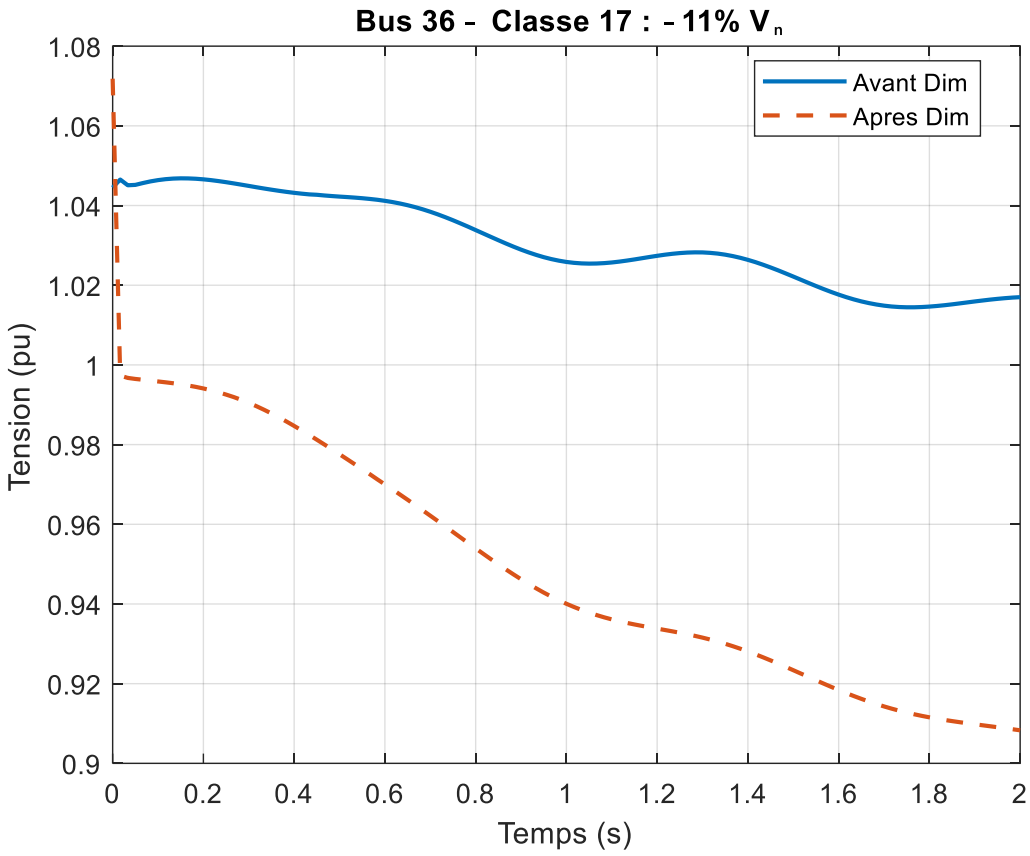

Figure 5 - 7: Impact d'une diminution de la tension de G7.

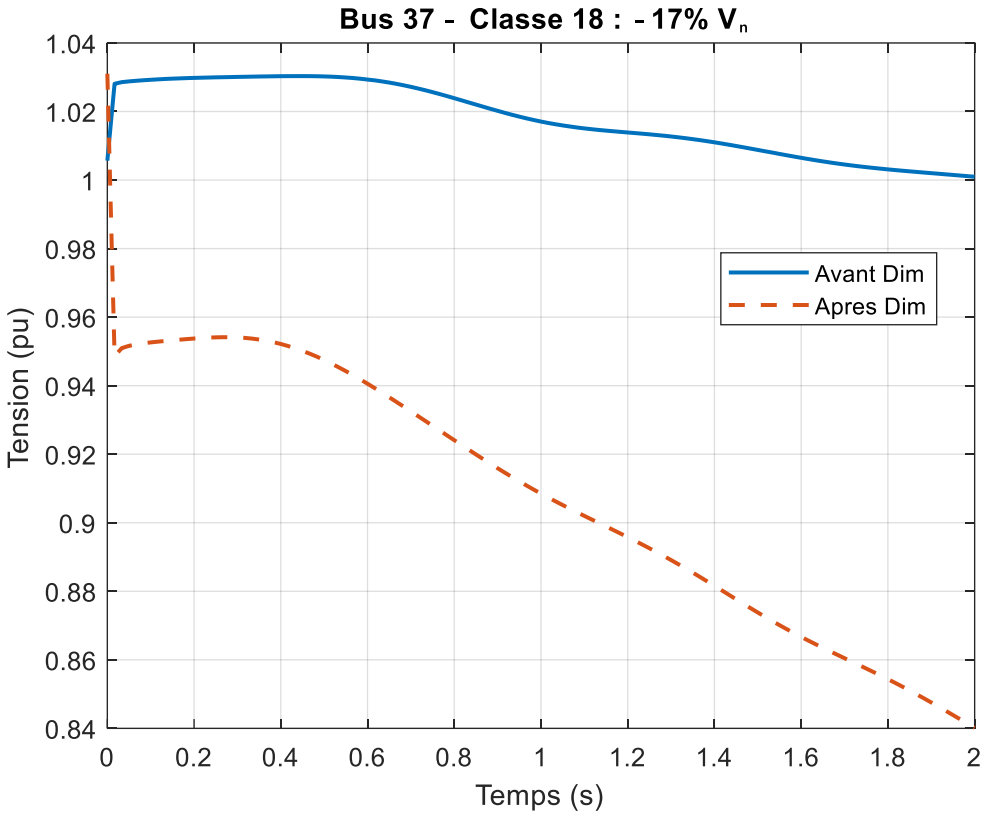

Figure 5 - 8: Impact d'une diminution de la tension de G8.

5.5.2 Défauts sur le Système Photovoltaïque

Dans le sous-système PV, on étudie les déséquilibres entre phases :

a) Défaut AB

b) Défaut BC

c) Défaut CA

On simule ces défauts en supprimant la résistance entre deux phases dans le modèle de sous-système du PV, en ouvre les disjoncteurs au bornes de la résistance, a t = [0.5s, 1s].

Conséquences :

- Déséquilibre des phases.
- Distorsion des courants.

- Changement brutal de la puissance.
- Apparition de composantes asymétriques.

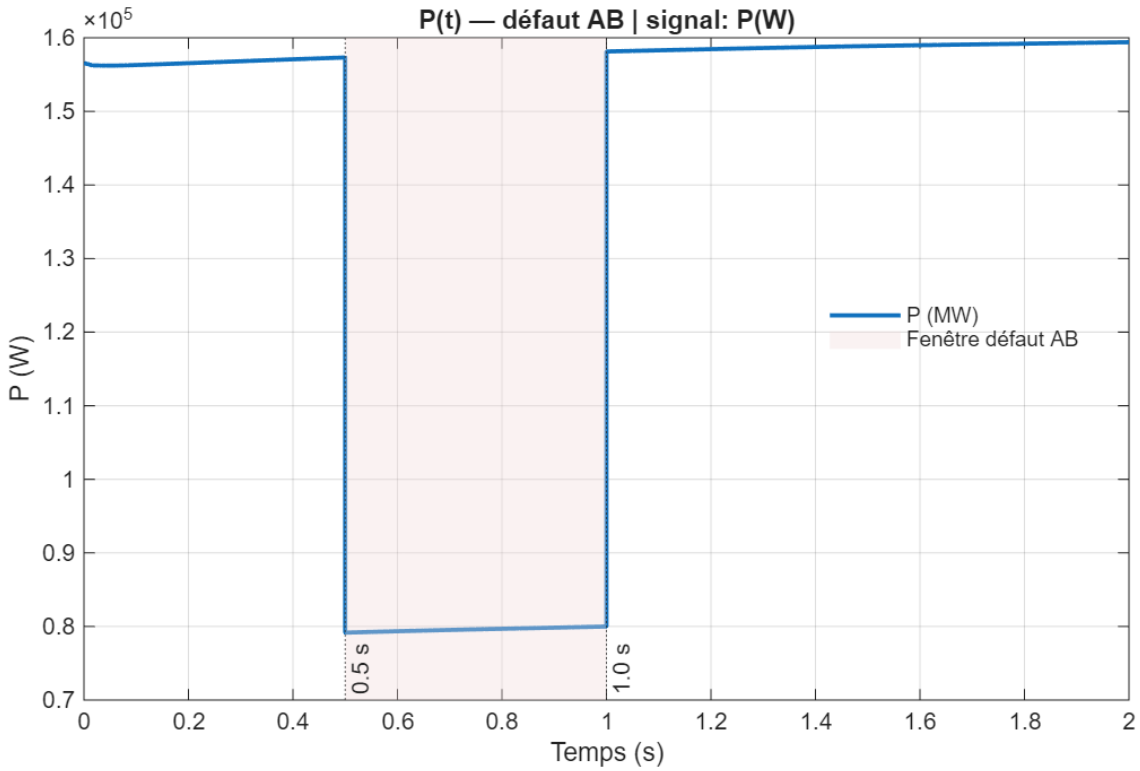

Figure 5 - 9: Évolution de la puissance active P(t) du système photovoltaïque lors de l'apparition d'un défaut interphase AB.

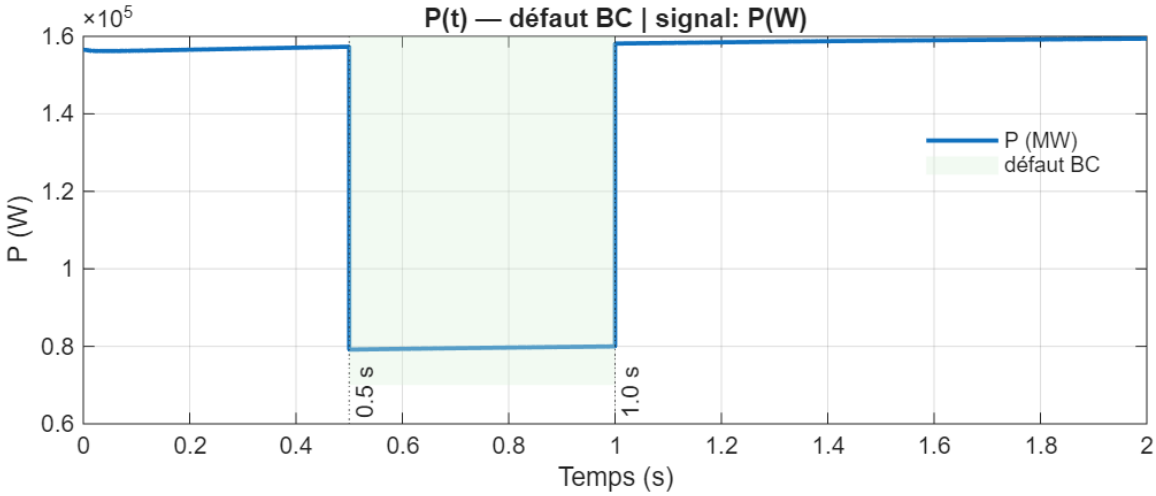

Figure 5 - 10: Évolution de la puissance active P(t) du système photovoltaïque lors de l'apparition d'un défaut interphase BC.

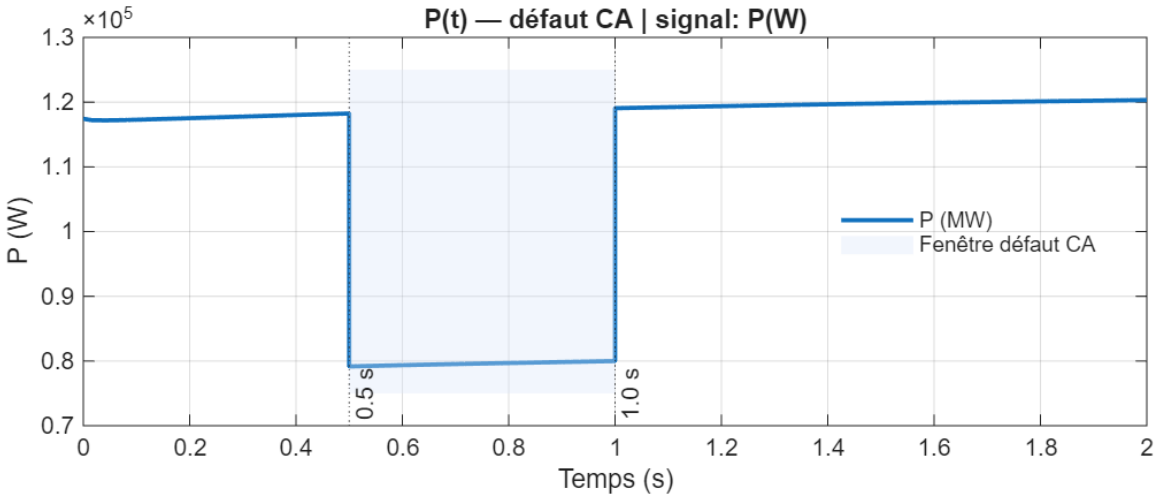

Figure 5 - 11: Évolution de la puissance active P(t) du système photovoltaïque lors de l'apparition d'un défaut interphase CA.

5.5.3 Défauts sur les Éoliennes

Les problèmes étudiés sont :

a) Variation de puissance nominale

b) Variation de tension générée

Ces changements sont apportés directement dans les paramètres internes du modèle de l'éolienne.

Conséquences :

- Fluctuations de puissance amplifiées
- Changement du courant injecté
- Plus grande sensibilité aux variations de charge
- Changement du comportement dynamique

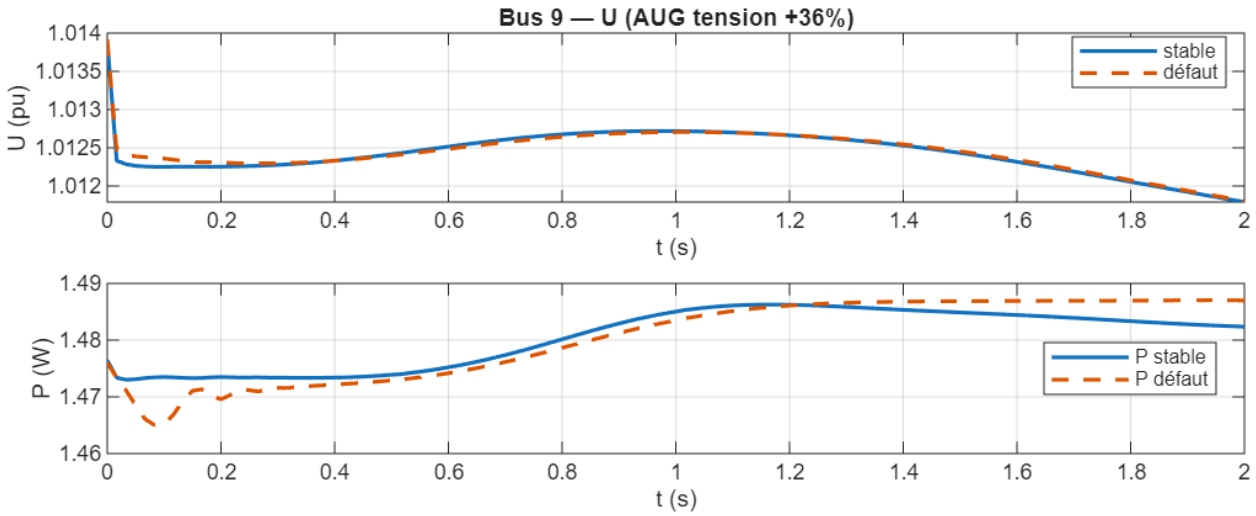

Figure 5 - 12 : Évolution de la tension U(t) et la puissance active P(t) au bus 9 lors d'une augmentation de la tension générée.

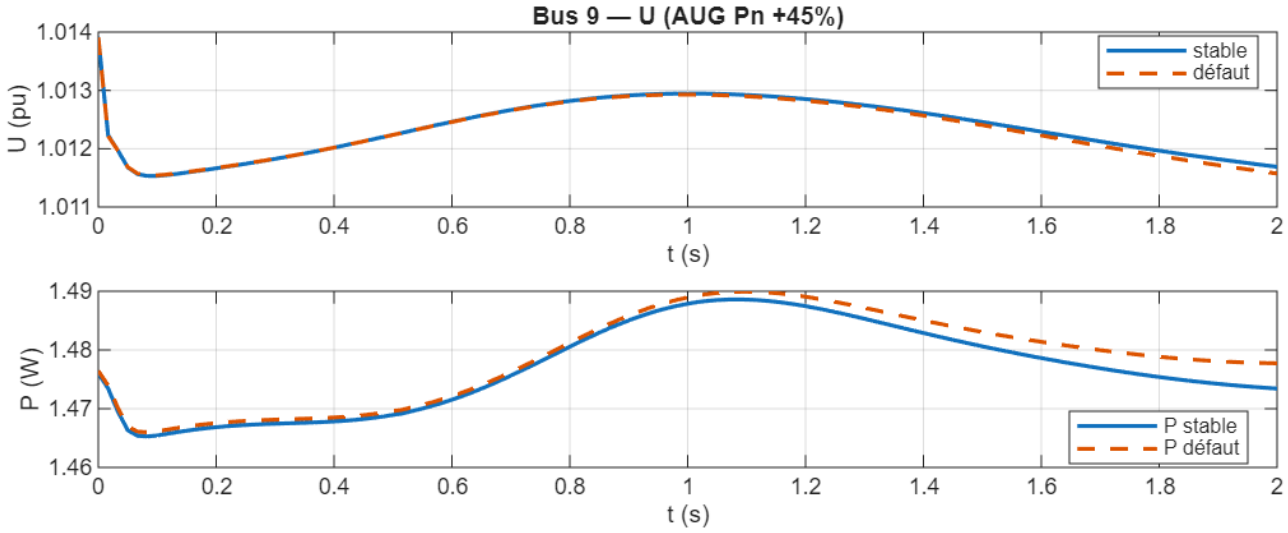

Figure 5 - 13 : Évolution de la tension U(t) et la puissance active P(t) au bus 9 lors d'une augmentation de la puissance nominale.

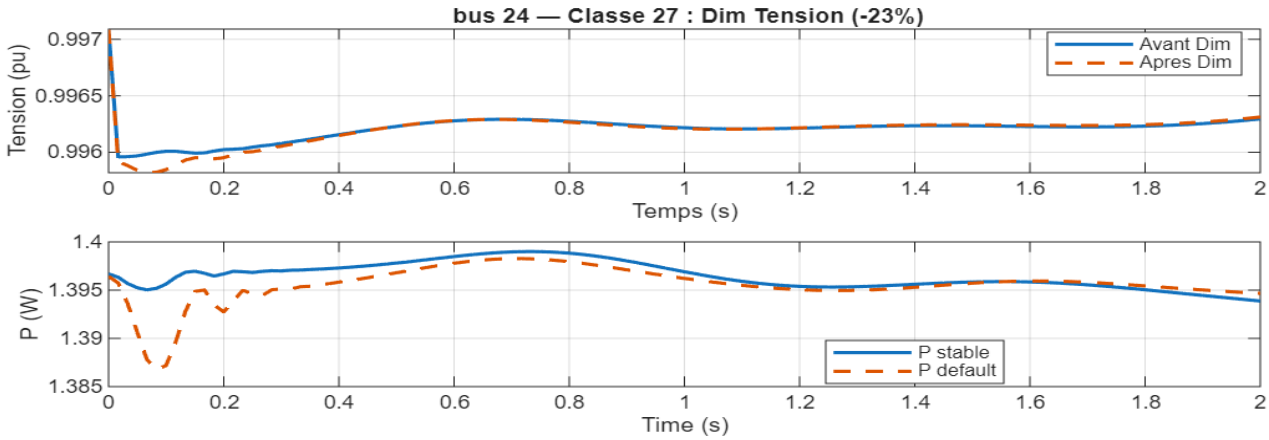

Figure 5 - 14 : Évolution de la tension U(t) et la puissance active P(t) au bus 24 lors d'une diminution de la tension générée.

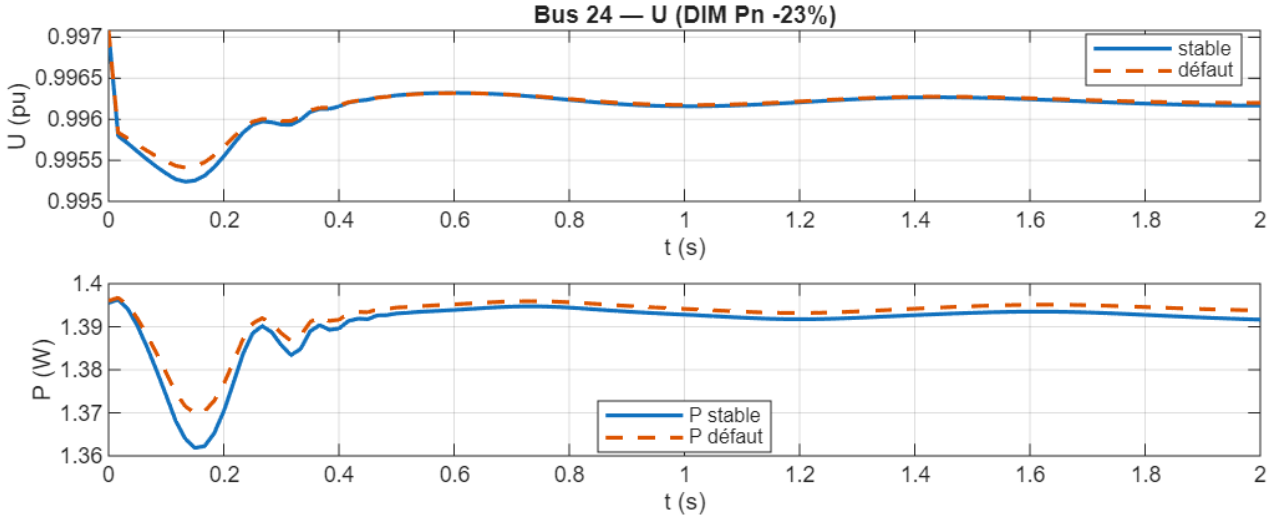

Figure 5 - 15 : Évolution de la tension U(t) et la puissance active P(t) au bus 24 lors d'une diminution de la puissance nominale.

5.5.4 Observations Générales

En comparant les défauts simples, on constate que :

- Les variations de tension et la puissance affectent surtout sur U(t)
- Les défauts entre phases créent de forts déséquilibres sur la puissance.
- Les signatures transitoires sont très visibles dans les premières millisecondes après l'apparition du défaut

Ces observations justifient l'emploi d'une méthode adaptative comme la HHT pour capter les variations non stationnaires, avant la détection, classification et localisation par CNN et la prédiction par Bi-LSTM.

5.6 Réglage des hyperparamètres

Pour ce projet, les différentes étapes de la méthode proposée ont été implémentées à l'aide des scripts développée sous Matlab. Ces scripts permettent d'automatiser tout incluant la génération des données, à l'extraction des caractéristiques via la transformée de Hilbert-Huang (HHT), en passant par l'entraînement et l'évaluation du modèle d'apprentissage profond.

La configuration de la structure du modèle de classification et ses paramètres d'apprentissage sont définis avec les fonctions de base de la Deep Learning Toolbox de MATLAB. Pour ce projet ces paramètres sont pas modifié manuellement, le nombre de couches du réseau ni certains paramètres internes. Mais utilisent la configuration par défaut que MATLAB propose pendant l'entraînement.

Les scripts MATLAB développes assurent principalement:

- L'importation et l'organisation des données générées par simulation.
- Le prétraitement des signaux électriques.
- l'extraction des caractéristiques par HHT.
- l'entrainement du modèle de classification.
- l'évaluation des performances avec les critères définis dans la section suivante.

Cette approche permet de garantir une procédure reproductible et cohérente pour l'analyse des défauts internes simples étudiés dans ce chapitre.

5.7 Méthodes pour l'évaluation du modèle

L'évaluation du modèle est une étape clé de ce travail. Elle permet de mesurer si le système proposé détecte et classe correctement les défauts dans le réseau hybride étudié. On

compare les résultats du modèle aux classes réelles du jeu de données tirées des simulations.

Pour évaluer le modèle, on se sert de plusieurs indicateurs. Ils servent à analyser la qualité du classement et à voir si le modèle distingue bien les différents types de défauts.

- **Matrice de confusion (Confusion Matrix)**

Pour évaluer la performance d'un modèle de classification, on compare ses prédictions avec les valeurs réelles. La matrice de confusion nous aide à voir où le modèle a bien fonctionné et où il s'est trompé, montrant ainsi les types d'erreurs faites.

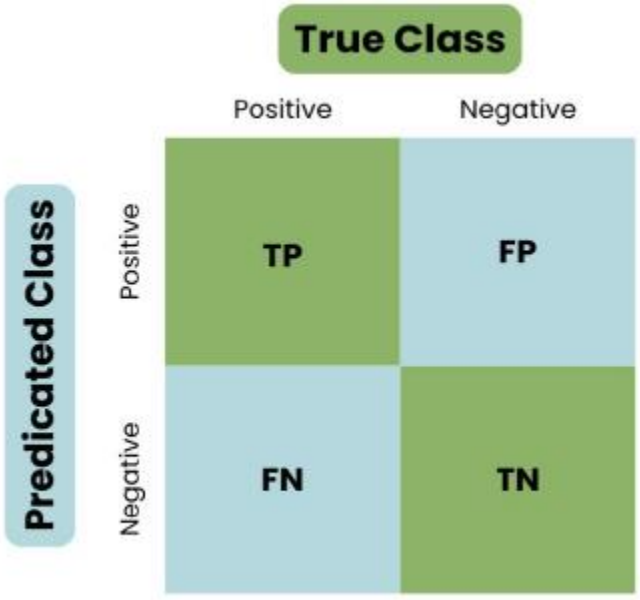

Figure 5 - 16 : Matrice de confusion.

La matrice de confusion généralement composée de quatre éléments principaux :

- **True Positive (Vrai positif):** Ce sont les prédictions qui forment un match avec la valeur réelle. C'est le cas équivaut à la situation suivante : la valeur réelle est : « il y'a un défaut » et la prédiction est : « il y'a un défaut ».

- **False Negative (Faux négatif) :** la prédiction est négative alors que la valeur réelle est négative. C'est le cas équivaut à la situation suivante : la valeur réelle est : « il y a un défaut » et la prédiction est : « il n'y a pas de défaut ».

- **False Positive (Faux positif) :** la prédiction est positive alors que la valeur réelle est négative. C'est le cas équivaut à la situation suivante : la valeur réelle est : « il n'y a aucun défaut » et la prédiction est : « il y'a un défaut ».

- **True Negative (Vrai négatif) :** La prédiction et la valeur réelle sont négatives. C'est le cas équivaut à la situation suivante : la valeur réelle est : « il n'y a aucun défaut » et la prédiction est : « il n'y a aucun défaut ».

➢ **Accuracy (Exactitude)**

L'exactitude est une façon répandue de voir si un modèle de classification fonctionne bien. Elle mesure combien de prédictions correctes le modèle fait sur le nombre total de prédictions. On la calcule ainsi :

$$\text{Accuracy} = \frac{\text{TP+TN}}{\text{TP+TN+FP+FN}} \quad \textbf{(5.1)}$$

Cette métrique permet d'évaluer la performance globale du modèle sur l'ensemble des classes étudiées.

➢ **Précision (Precision)**

La précision indique la justesse des prédictions positives du modèle. En d'autres termes, elle répond à la question : sur toutes les prédictions positives, combien étaient correctes ? Elle se calcule ainsi :

$$\text{Precision} = \frac{\text{TP}}{\text{TP+FP}} \quad \textbf{(5.2)}$$

➢ **Rappel (recall)**

Le rappel, ou sensibilité, évalue la capacité du modèle à identifier tous les défauts réels. Elle répond à la question : parmi tous les défauts existants, combien le modèle a-t-il correctement détectés ? Sa formule est :

$$\text{Recall} = \frac{\text{TP}}{\text{TP+FN}} \quad \textbf{(5.3)}$$

➢ **Loss (fonction de perte)**

La fonction de perte quantifie l'écart entre les prédictions du modèle et la réalité. On l'emploie pendant l'apprentissage pour affiner le modèle. Une baisse progressive de cette

fonction signifie que le modèle apprend bien à reconnaître les caractéristiques des différents types de défauts.

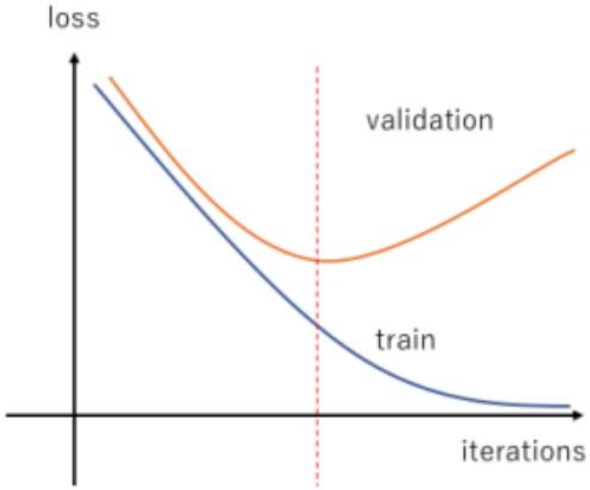

Figure 5 - 17 : Évolution de la fonction de perte (Loss) pendant l'entraînement et la validation du modèle.

5.8 Résultats

Cette partie présente les résultats de l'entraînement et de l'évaluation du modèle pour détecter, localiser, classer et prédire les défauts internes simples dans le réseau hybride étudié. L'analyse des performances du modèle est réalisée avec différentes mesures comme l'exactitude, la perte, la précision, le rappel et le score F1.

- **Détection des défauts**

La figure 5-18 présente l'évolution de l'erreur d'entraînement (training loss) et de la précision (accuracy) du modèle de détection au cours des itérations d'apprentissage. D'après les courbes obtenues, on observe que la fonction de perte diminue rapidement durant les premières itérations, indiquant que le modèle apprend progressivement les caractéristiques associées aux défauts présents dans le réseau hybride. Parallèlement, l'accuracy augmente progressivement et atteint une valeur élevée et stable après plusieurs itérations.

Ces résultats montrent une tendance claire vers l'amélioration de la performance du modèle, caractérisée par une réduction significative de l'erreur et une augmentation de la

précision de détection. La stabilisation des courbes d'accuracy et de loss indique que le modèle converge correctement et qu'il est capable d'identifier efficacement les signatures électriques associées aux défauts internes simples.

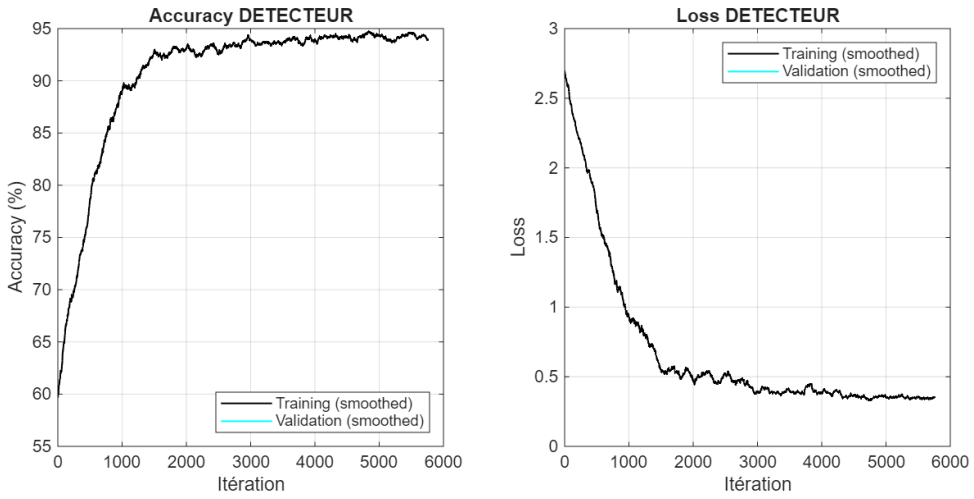

Figure 5 - 18 : Évolution de l'accuracy et de la fonction de perte du modèle de détection des défauts.

- **Classification des défauts**

La figure 5-19 présente l'évolution de la précision (accuracy) et de la fonction de perte (loss) du modèle utilisé pour la classification des types de défauts. On observe que la précision augmente progressivement au cours des itérations d'entraînement pour atteindre une valeur élevée et stable à la fin du processus d'apprentissage. Parallèlement, la fonction de perte diminue rapidement durant les premières itérations avant de se stabiliser, ce qui indique que le modèle apprend correctement les caractéristiques associées aux différentes classes de défauts. Cette convergence montre que le modèle est capable de distinguer efficacement les différents types de défauts internes présents dans le réseau hybride.

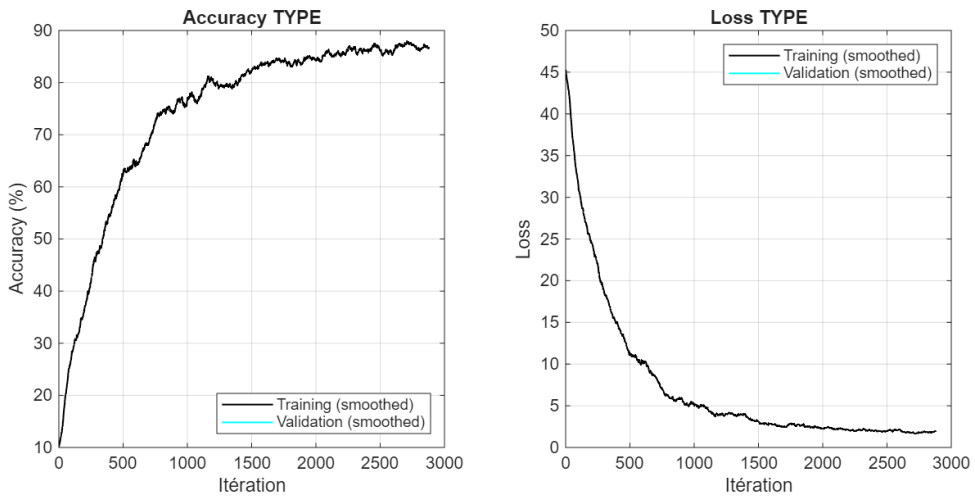

Figure 5 - 19: Évolution de l'accuracy et de la fonction de perte (Loss) pour la classification des types de défauts.

La figure 5-20 présente les métriques de performance obtenues pour chaque classe de défaut, notamment la précision (Precision), le rappel (Recall) et le score F1. Les résultats montrent que la majorité des classes présentent des valeurs élevées pour ces métriques, ce qui indique une bonne capacité du modèle à classifier correctement les différents types de défauts. Le score F1 confirme également l'équilibre entre la précision et le rappel pour la plupart des classes, ce qui traduit une performance globale satisfaisante du modèle de classification.

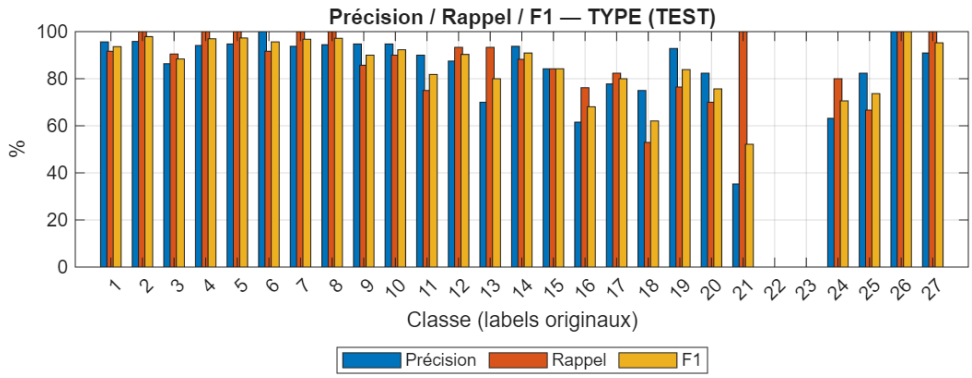

Figure 5 - 20 : Précision, rappel et score F1 pour la classification des types de défauts (ensemble TEST).

➢ **Localisation des défauts**

La figure 5-21 présente l'évolution de la précision (accuracy) et de la fonction de perte (loss) du modèle utilisé pour la localisation des défauts dans le réseau hybride. D'après les courbes obtenues, on observe que la précision augmente rapidement durant les premières itérations d'entraînement, atteignant progressivement une valeur proche de 100 %. Parallèlement, la fonction de perte diminue fortement au début de l'apprentissage avant de se stabiliser après plusieurs itérations. Cette évolution indique que le modèle converge correctement et qu'il est capable d'identifier avec une grande précision l'emplacement des défauts dans les différents bus du réseau.

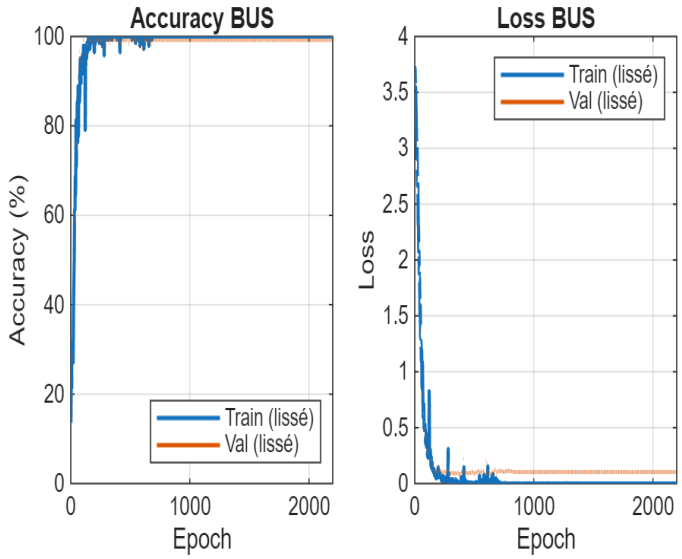

Figure 5 - 21: Évolution de l'accuracy et de la fonction de perte (Loss) pour la localisation des défauts par bus.

La figure 5-22 présente les métriques de classification obtenues pour chaque bus du réseau, notamment la précision (Precision), le rappel (Recall) et le score F1. Les résultats montrent que la majorité des classes présentent des valeurs élevées, généralement supérieures à 90 %, ce qui indique une bonne capacité du modèle à localiser correctement les défauts. Le score F1 confirme également la fiabilité du modèle en combinant les performances de précision et de rappel pour chaque classe.

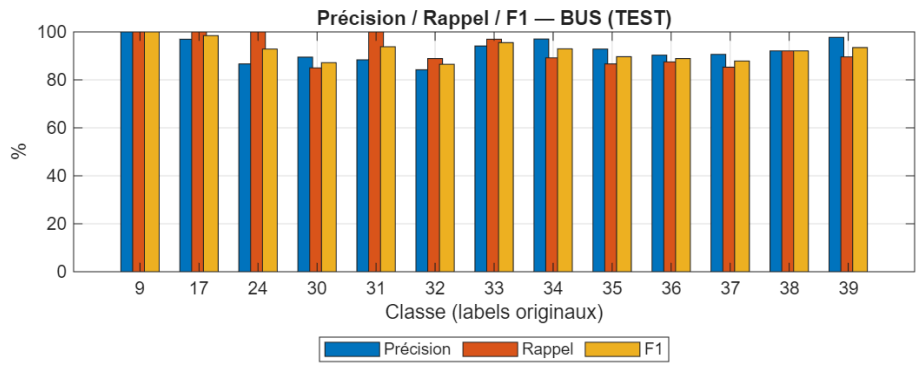

Figure 5 - 22 : Précision, rappel et score F1 pour la localisation des défauts par bus (ensemble TEST).

- **Prédiction des défauts**

La figure 5-23 présente les matrices de confusion obtenues lors de l'étape de prédiction des défauts. Les résultats sont présentés pour les ensembles d'entraînement, de validation et de test. On observe que la majorité des prédictions se situent sur la diagonale principale de la matrice, ce qui indique que les classes sont correctement identifiées par le modèle. Les résultats obtenus sur l'ensemble de test montrent une précision globale d'environ **95 %**, ce qui confirme la capacité du modèle à prédire correctement l'apparition des défauts à partir des signatures électriques extraites. La faible proportion d'erreurs de classification démontre également que le modèle possède une bonne capacité de généralisation et peut être utilisé efficacement pour la prédiction des anomalies dans le réseau hybride.

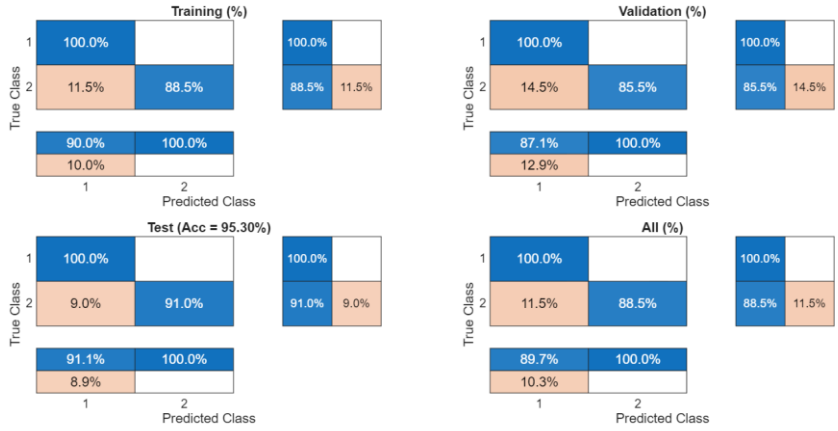

Figure 5 - 23 : Matrices de confusion pour la prédiction des défauts (training, validation et test).

5.9 Conclusion

Ce chapitre a présenté une méthode d'apprentissage approfondi pour trouver, classer, localiser et prédire les défauts internes simples dans un réseau hybride IEEE 39 bus modifié. Les données utilisées ont été créées à partir de simulations sous MATLAB/Simulink afin de représenter différents types de défauts appliqués à divers endroits du réseau.

Les résultats montrent que le modèle identifie bien les signatures électriques liées aux anomalies. Les courbes d'apprentissage montrent que le modèle converge de manière stable, avec une amélioration progressive de la précision et une diminution de la perte pendant l'apprentissage. De plus, les mesures d'évaluation comme la précision, le rappel et le score F1 confirment que le modèle est capable de classer correctement les différents types de défauts et de localiser leur position dans le réseau.

Cette étude prouve que cette méthode est une solution pour l'analyse des défauts internes simples dans les réseaux hybrides. Dans le prochain chapitre, nous allons étendre cette méthode à l'étude des défauts internes multiples, où plusieurs anomalies peuvent se produire en même temps à différents points du réseau.

Chapitre 6

Détection classification localisation et prédiction des défauts internes hybrides (multiples)

6.1 Introduction

Dans le dernier chapitre, nous avons surtout regardé les défauts internes simples, ceux où une seule chose cloche à un endroit précis du réseau. Cela nous a aidés à bien voir les signaux électriques propres à chaque type de défaut et à voir comment notre modèle se débrouillait pour détecter, classer, localiser et prédire les anomalies.

Mais voilà, dans la vraie vie, les réseaux électriques sont rarement aussi simples. Il arrive souvent que plusieurs problèmes surgissent en même temps, à différents endroits. Du coup, les signaux électriques se mélangent, et ça complique sérieusement l'analyse et l'identification des défauts. On appelle ça des défauts internes multiples.

Dans ce chapitre, on va donc regarder comment se comporte notre réseau hybride quand il y a plusieurs défauts internes en même temps, c'est-à-dire quand deux défauts ou plus apparaissent en même temps à différents endroits du système. Comme dans le chapitre précédent, on va faire des simulations avec MATLAB/Simulink à partir du modèle IEEE 39 bus modifié. On va créer une base de données spéciale pour représenter différentes combinaisons de défauts qui touchent plusieurs sources du réseau, comme les machines synchrones, les éoliennes et le système photovoltaïque.

Ensuite, on va regarder les données avec notre modèle d'apprentissage profond. L'idée, c'est de voir si le système est capable de détecter, classer, situer et anticiper les défauts multiples, même quand les signaux se mélangent à cause des différents problèmes.

En gros, ce chapitre va plus loin que le précédent en regardant des situations plus compliquées et plus proches de la réalité. On veut voir si notre approche est vraiment solide et fiable pour surveiller et entretenir les réseaux hybrides.

6.2 Revue de la littérature

La détection de plusieurs défauts dans les réseaux électriques hybrides est un vrai défi pour les systèmes d'énergie modernes. Contrairement aux pannes simples, plusieurs anomalies peuvent survenir en même temps à différents endroits du réseau, ce qui complique les signaux électriques. Cela rend la détection, classification, localisation et la prédiction des défauts plus difficiles, car les signaux électriques peuvent se superposer et cacher des éléments importants.

Dans cette étude [16], les auteurs ont regardé différentes méthodes de détection des problèmes dans les systèmes hybrides qui utilisent plusieurs sources d'énergie renouvelable. Les résultats montrent que l'ajout de sources comme l'énergie éolienne et solaire peut changer la façon dont le réseau se comporte, ce qui rend plus difficile la détection rapide et fiable des anomalies.

Dans cet article [48], les auteurs ont utilisé la transformée de Hilbert–Huang pour trier différents types de problèmes dans des micros réseaux hybrides AC/DC. Les caractéristiques extraites des composantes IMF ont été utilisées pour entraîner des modèles d'apprentissage automatique, ce qui a permis d'obtenir une précision de tri supérieure à 95%.

Dans cette étude [10], les auteurs ont suggéré une approche hybride qui combine les réseaux de neurones convolutionnels (CNN) et les réseaux LSTM pour détecter et trier différents types de problèmes dans les systèmes éoliens. Le CNN sert à extraire les caractéristiques des signaux, tandis que le LSTM modélise les dépendances dans le temps. Les résultats montrent que cette combinaison améliore la précision globale de la détection.

Dans cet article [65], un modèle CNN simple a été suggéré pour la détection en temps réel des problèmes électromécaniques à partir de signaux de surveillance. Les tests montrent que le modèle peut atteindre une précision supérieure à 92 %, tout en restant rapide, ce qui le rend adapté aux applications industrielles.

Malgré les progrès dans ce domaine, la plupart des travaux se concentrent sur la détection de problèmes simples ou de types spécifiques de problèmes. Peu d'études se penchent sur la question de la détection simultanée de plusieurs problèmes dans les réseaux hybrides, surtout lorsque plusieurs anomalies apparaissent à différents endroits du système.

Dans ce contexte, l'approche suggérée dans ce travail vise à regarder et à détecter les problèmes internes multiples dans un réseau hybride en combinant l'extraction de caractéristiques par HHT et l'apprentissage profond. Cela permet de mieux comprendre les interactions entre les différentes anomalies et d'améliorer la fiabilité du système de surveillance du réseau.

6.3 Méthodologie et analyse expérimentale

Dans cette étude, j'ai créé une base de données de défauts internes multiples en me servant du réseau hybride IEEE 39 bus modifié avec MATLAB/Simulink. Ici, contrairement au chapitre précédent où chaque défaut touchait un seul endroit, je regarde des situations où plusieurs problèmes arrivent en même temps à divers sources du système.

Les défauts sont appliqués à différentes sources comme les machines synchrones, les éoliennes et le système photovoltaïque. Chaque situation correspond à une combinaison particulière de défauts. Le but est d'analyser comment les différents problèmes interagissent et leurs effets sur les signaux électriques du réseau.

Pour avoir une base de données fiable, 50 simulations ont été réalisées par type de défaut multiple ça veut dire pour chaque classe. Les réglages des défauts sont appliques aléatoire dans des limites fixées pour reproduire diverses conditions de fonctionnement du réseau.

Les signaux électriques des simulations servent ensuite à étudier le comportement du système avec ces défauts multiples et pour évaluer la capacité du modèle proposée à détecter, classer, localiser et prédire ces anomalies.

6.4 Base des données de contingence

Dans cette section, nous avons créé une base de données des défauts internes multiples en utilisant le modèle modifié du réseau IEEE 39 bus sous MATLAB/Simulink. Contrairement au chapitre précédent où chaque défaut était appliqué à un seul point du réseau, cette base de données considère des **s**cénarios où plusieurs défauts apparaissent simultanément à différents points du système.

Au total, 8 classes de défauts hybrides ont été définies. Ces défauts correspondent à différentes combinaisons d'anomalies appliquées aux machines synchrones (MS) et aux sources d'énergie renouvelable (ER), notamment les éoliennes et le système photovoltaïque.

Les défauts considérés incluent par exemple :

- La modification de paramètres internes des machines synchrones.
- La variation de paramètres électriques des éoliennes.
- La variation de l'irradiance dans le système photovoltaïque.
- La combinaison simultanée de plusieurs défauts sur différentes sources du réseau.

Pour chaque type de défaut hybride, 50 simulations différentes ont été réalisées, en faisant varier aléatoirement les paramètres et le moment d'apparition du défaut. Cette approche permet d'obtenir une base de données équilibrée et représentative des différentes conditions de fonctionnement du réseau.

Au cours de chaque simulation, les signaux électriques principaux du réseau sont enregistrés afin d'analyser l'impact des défauts multiples. Les signaux récupérés correspondent principalement à :

- La tension (U)

- Le courant (I)
- La puissance active (P)

Ces signaux permettent d'extraire les signatures électriques associées aux différentes combinaisons de défauts et constituent les données utilisées pour l'analyse et l'apprentissage du modèle proposé.

Ainsi, le nombre total de scénarios simulés est :

$$8 \times 50 = 400$$

Le **Tableau 6.1** présente en détail l'organisation des différentes classes de défauts hybrides considérées dans cette étude, en indiquant :

• La source concernée (machine synchrone ou énergie renouvelable).
• La localisation des défauts dans le réseau.
• Le type de modification appliquée.
• L'intervalle de variation aléatoire utilisé.

Tableau 4 : Base de données de contingence correspondent aux défauts internes hybrides (multiples).

Nature du défaut	Nombre de Classe	Source	Localisation des défauts	Type de défaut interne	Variation aléatoire
Défauts Hybride (A partir de deux points d'application) Soit 8 défauts	Classe 28	MS+ER	G1, Éolienne 1	Aug Rs / Aug Rr	[+15 à +50]
	classe 29	MS+ER	G3, PV	Diminution de l'AVR et diminution d'irradiance	[-30 à -70]
	Classe 30	MS+ER	G5, Éolienne 2	Diminution de l'AVR/Dim de la Lm	[-30 à -70]
	classe 31	MS	G9, G7, G2	Augmentation de Xd′ (axe d transitoire)	[+50 a+120]
	Classe 32	MS	G8, G6	Diminution du gain exciteur Ke (G6) + augmentation de Tb (G8)	[-50 a-90], [+100 a+200]
	classe 33	MS	G10, G4, E1, PV	G4: Ta↑ (AVR) / G10: Ke↓ (AVR) / E1: Lm↓ / PV: Irradiance↓	[5 à 30], [-30 à -70]
	Classe 34	ER	Éolienne 1,2,	Diminution de la magnétisation Lm/Augmentation de la Rr	[-30 à -80], [+30 à +80]
	Classe 35	ER	Éolienne 1,2, PV	Diminution Lm/Augmentation Rr/Diminution d'Irradiance	[-30 à -80], [+30 à +80]

6.5 Application des internes multiples

Dans cette partie, on applique divers défauts en même temps à différents endroits du réseau hybride. Le but est de voir comment cela change son comportement. Au lieu d'étudier les défauts un par un comme avant, on regarde ici comment plusieurs éléments du réseau (machines synchrones, éoliennes, panneaux solaires) interagissent en cas de problème.

Pour chaque type de défaut, on observe les signaux électriques de tension (U), de courant (I) et de puissance active (P). Cela nous aide à repérer les caractéristiques propres à chaque situation de défaut.

- **Classe28**

Dans cette classe, un défaut hybride est appliqué simultanément **s**ur la machine synchrone G1 et l'éolienne 1**.** Le défaut correspond à une augmentation de la résistance statorique Rs et de la résistance rotorique Rr, avec une variation aléatoire dans l'intervalle [+15 % à +50 %]. Cette modification entraîne une perturbation dans le comportement dynamique du générateur et influence les grandeurs électriques du réseau. Les Figures 6-1 et 6-2 représentent l'impact de ce défaut hybride sur les signaux électriques du réseau. La Figure 6-1 montre l'évolution du courant au bus 9 en comparant l'état stable et l'état avec défaut. On observe une variation du courant après l'apparition du défaut, indiquant l'influence de la modification des paramètres internes sur la dynamique du réseau.

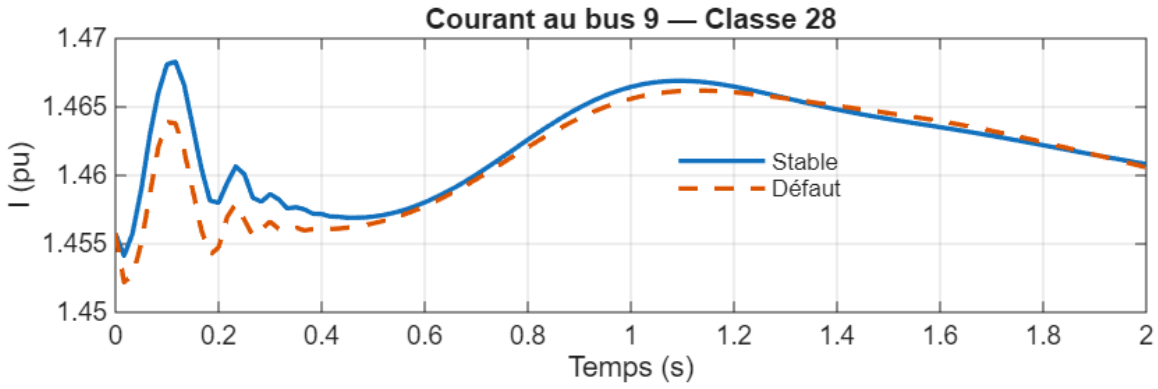

Figure 6 - 1 : Évolution du courant au bus 9 pour la classe 28 (comparaison entre le régime stable et le régime avec défaut hybride).

La **Figure 6-2** illustre l'évolution de la variation relative du courant |ΔI| au bus 39. On observe une augmentation de la variation du courant autour de l'instant d'apparition du défaut, ce qui confirme l'impact de ce défaut hybride sur le comportement électrique du système.

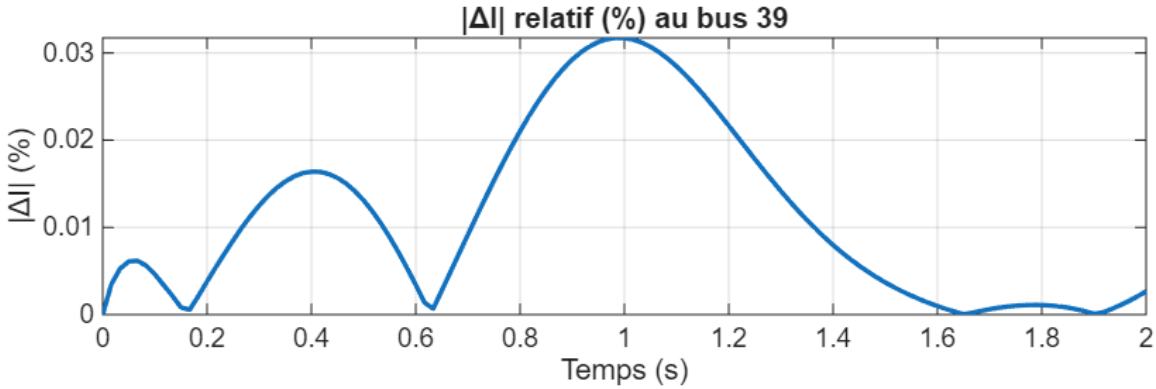

Figure 6 - 2 : variation relative du courant |ΔI| au bus 39 classe28.

- **Classe29**

Dans cette classe, la machine synchrone G3 et le système photovoltaïque (PV) subissent un défaut combiné. On simule une baisse du gain de l'AVR du générateur G3 en même temps qu'une diminution de l'ensoleillement du système photovoltaïque, avec un changement aléatoire entre -30 % et -70 %. Ce mélange de problèmes affecte la régulation de la tension du générateur et la production d'énergie du système photovoltaïque, ce qui perturbe les valeurs électriques du réseau. Les Figures 6-3 et 6-4 montrent l'effet de ce défaut combiné sur les signaux électriques du réseau.

La Figure 6-3 montre l'évolution du courant au bus 17, en comparant la situation normale avec la situation après le défaut. On voit que le courant change beaucoup après l'apparition du défaut, ce qui montre l'effet de la modification des paramètres du générateur et de la baisse de la production photovoltaïque.

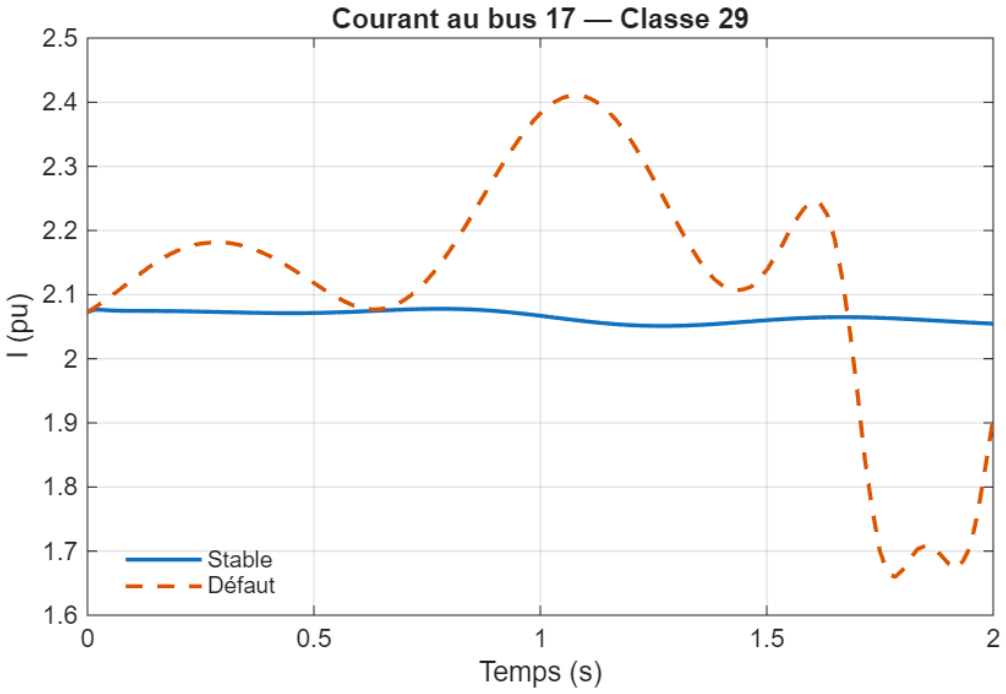

Figure 6 - 3 : Évolution du courant au bus 17 pour la classe 29 (comparaison entre l'état stable et l'état avec défaut hybride).

La Figure 6-4 montre comment la tension au bus 32 change. On remarque une baisse importante de la tension lorsque le défaut se produit, ce qui indique l'effet combiné de la diminution du gain de l'AVR et de la baisse de l'ensoleillement sur la stabilité du réseau.

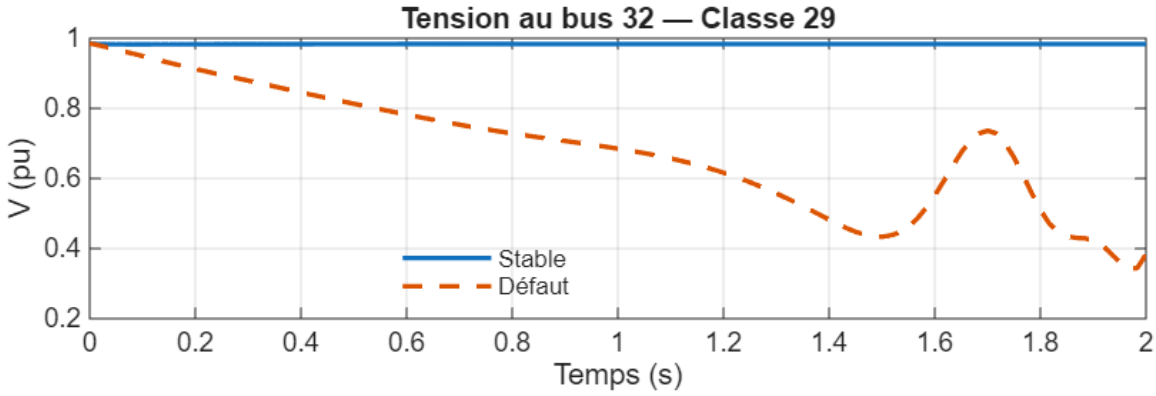

Figure 6 - 4 : Évolution de la tension au bus 32 pour la classe 29 (comparaison entre l'état stable et l'état avec défaut hybride).

- **Classe30**

Dans cette analyse, un défaut hybride est simultanément introduit sur la machine synchrone G5 et l'éolienne 2. Ce scénario se caractérise par une baisse du gain de l'AVR du générateur G5 associée à une réduction du coefficient de magnétisation Lm de l'éolienne 2, cette dernière variant aléatoirement entre -30 % et -70 %. Cette combinaison impacte simultanément la régulation de tension du générateur et le comportement électromagnétique de l'éolienne, provoquant des perturbations significatives dans les paramètres électriques du réseau.Les figures 6.5 et 6.6 illustrent les conséquences de ce défaut hybride sur les signaux électriques relevés.

La figure 6.5 présente l'évolution du courant au niveau du bus 34, comparant l'état stable à celui affecté par le défaut. Une variation notable du courant est observée dès l'apparition du défaut, caractérisée par des oscillations marquées et un écart important par rapport à la valeur stable.

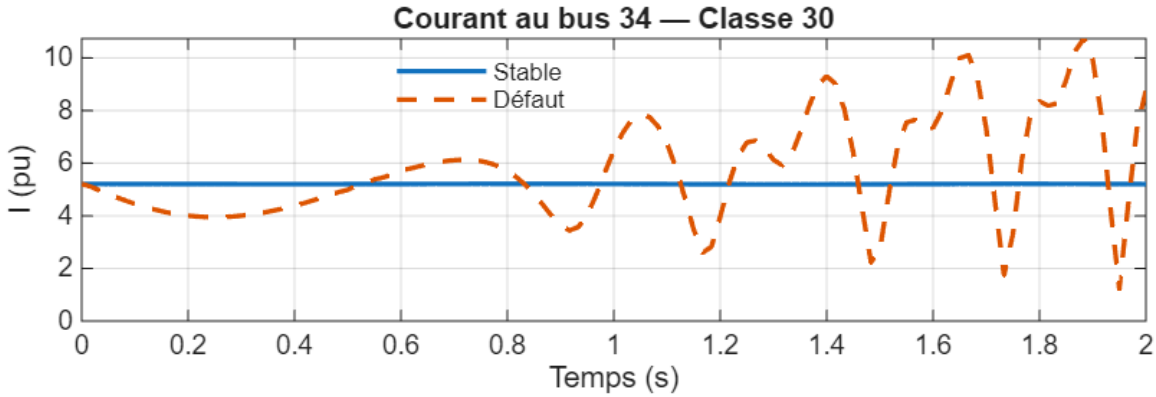

Figure 6 - 5 : Évolution du courant au bus 34 pour la classe 30 (comparaison entre l'état stable et l'état avec défaut hybride).

De manière similaire, la figure 6.6 montre l'évolution du courant au bus 24 pour cette même catégorie de défaut. Une divergence claire entre le régime stable et le régime perturbé est constatée, confirmant l'influence conjointe de la diminution du gain de l'AVR et de la baisse du coefficient de magnétisation sur la dynamique du réseau électrique.

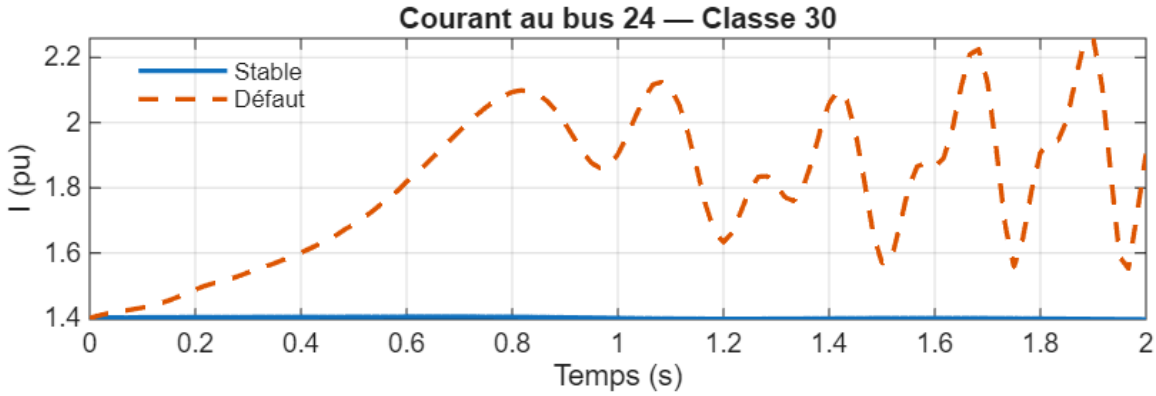

Figure 6 - 6 : Évolution du courant au bus 24 pour la classe 30 (comparaison entre l'état stable et l'état avec défaut hybride).

- **Classe31**

Dans cette classe, un défaut multiple est appliqué simultanément sur trois machines synchrones : G9, G7 et G2. Le scénario correspond à une augmentation du paramètre Xd′ (réactance transitoire selon l'axe direct) avec une variation aléatoire comprise dans l'intervalle [+50 % à +120 %]. Cette modification agit directement sur la dynamique électromagnétique des générateurs et influence leur réponse transitoire, ce qui provoque des perturbations mesurables sur les courants observés à différents bus du réseau. Les Figures 6.7, 6.8 et 6.9 représentent l'impact de ce défaut multiple sur les signaux de courant du réseau.

La Figure 6.7 montre l'évolution du courant au bus 31 pour le défaut appliqué sur G2. On observe une différence entre l'état stable et l'état avec défaut, traduisant l'effet de l'augmentation de Xd′ sur la réponse du générateur.

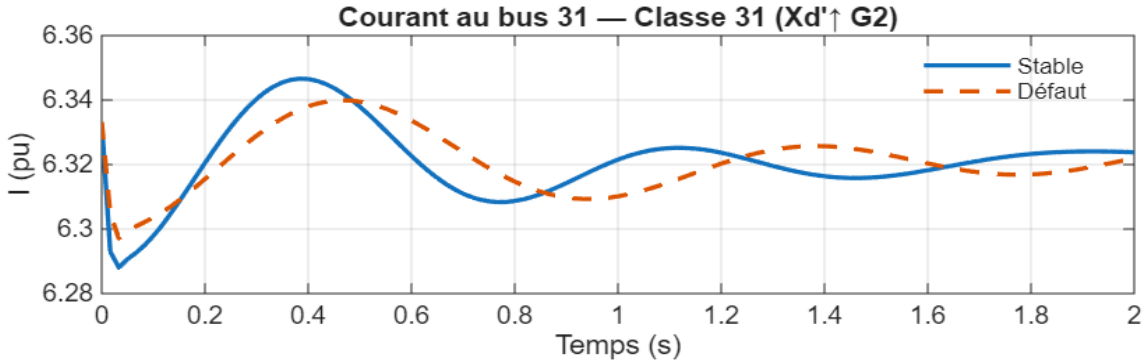

Figure 6 - 7 : Impact du courant au bus 31 pour la classe 31 (augmentation de Xd′ sur G2).

La Figure 6.8 illustre l'évolution du courant au bus 38 pour le défaut appliqué sur G9. On remarque également une déviation du courant par rapport au régime stable, ce qui confirme l'influence du défaut sur la dynamique du système.

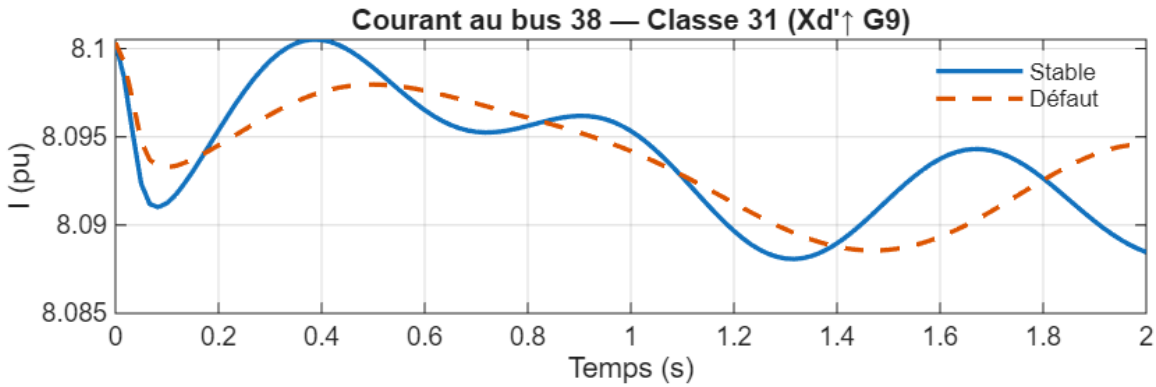

Figure 6 - 8 : Impact du courant au bus 38 pour la classe 31 (augmentation de Xd′ sur G9).

La Figure 6.9 présente l'évolution du courant au bus 36 pour le défaut appliqué sur G7. Les écarts observés entre les courbes stable et dégradée montrent que l'augmentation de Xd′ affecte de manière visible le comportement électrique du réseau, même lorsque plusieurs machines synchrones sont concernées simultanément.

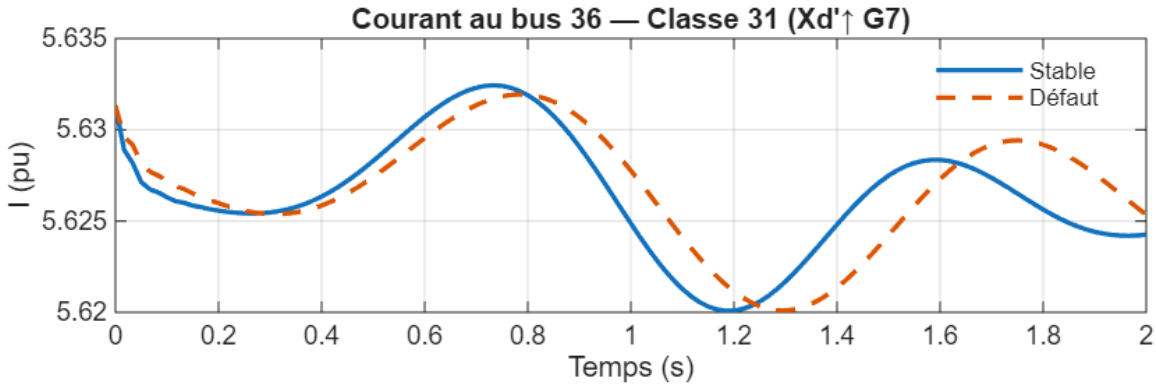

Figure 6 - 9 : Comportement du courant au bus 36 sous l'effet du défaut hybride (classe31).

- **Classe32**

Dans cette classe, un défaut multiple a été appliqué au réseau hybride en associant une diminution du gain de l'excitateur Ke du générateur G6 et une augmentation de la constante Tb du générateur G8. Les résultats obtenus montrent que cette combinaison influence clairement l'évolution temporelle du courant mesuré sur certains bus. Les figures 6.10 et 6.11 mettent en évidence une différence entre le régime stable et le régime défaillant, ce qui traduit l'effet du défaut sur le comportement dynamique du système. Cette variation confirme que les signaux de courant peuvent être exploités pour identifier ce type de défaut multiple.

La Figure 6-10 montre l'évolution du courant au bus 35 pour le défaut appliqué sur G6. On observe une différence entre l'état stable et l'état avec défaut, traduisant l'effet de la diminution de Ke sur la réponse dynamique du générateur.

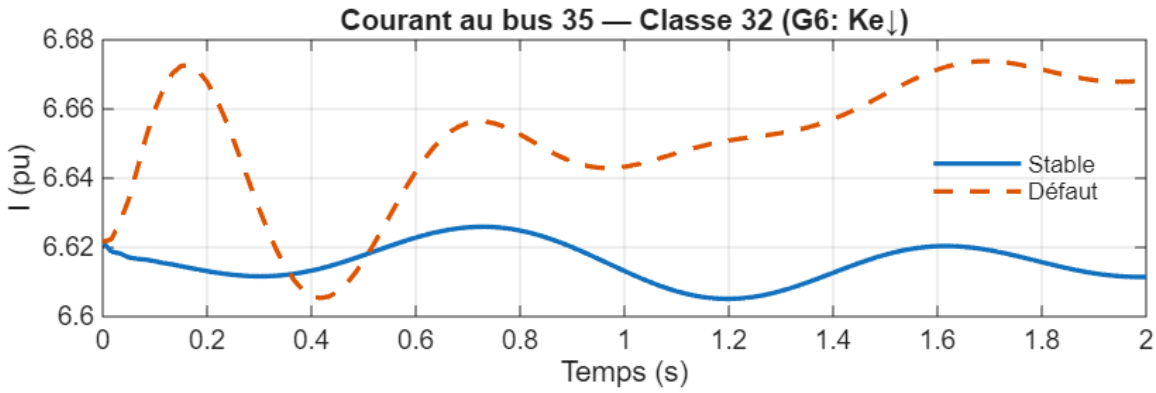

Figure 6 - 10 : Évolution du courant au bus 35 pour la classe 32 diminution de Ke a G6.

La Figure 6-11 montre l'évolution du courant au bus 37 pour le défaut appliqué sur G8. On observe une différence entre l'état stable et l'état avec défaut, traduisant l'effet de l'augmentation de Tb sur la réponse dynamique du générateur

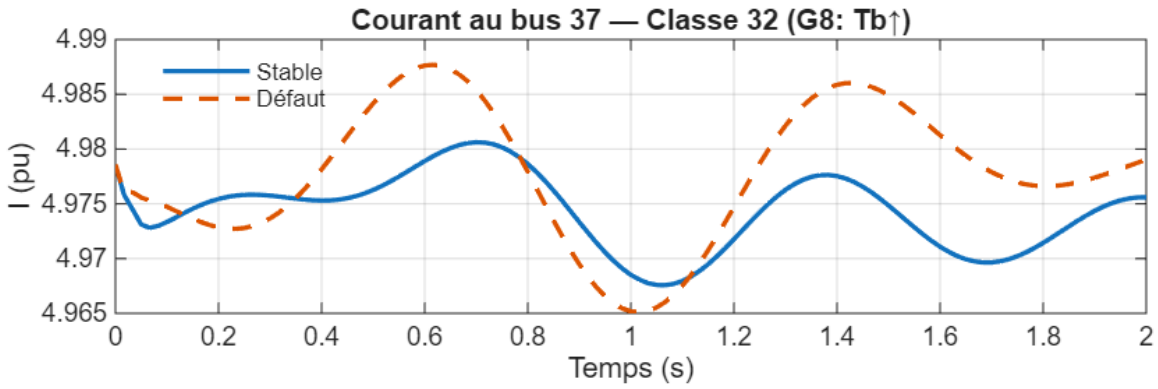

Figure 6 - 11 : Évolution du courant au bus 37 pour la classe 32 augmentation de Tb.

- **Classe 33**

Cette classe correspond à un défaut multiple (MS) impactant plusieurs sources du réseau, notamment G10, G4, E1 ainsi que le générateur photovoltaïque. Ces défauts se traduisent par des modifications respectives sur Ta de l'AVR, Ke de l'AVR, Lm et l'irradiance. L'analyse des résultats indique que ces perturbations provoquent des variations notables entre les conditions d'état stable et celles affectées par le défaut, observables sur les signaux de tension et de courant.

La Figure 6-12 montre l'évolution de la tension au bus 30 pour le défaut appliqué sur G10**.** On observe une différence entre l'état stable et l'état avec défaut, traduisant l'effet de la variation de Ta de l'AVR sur la réponse dynamique du générateur.

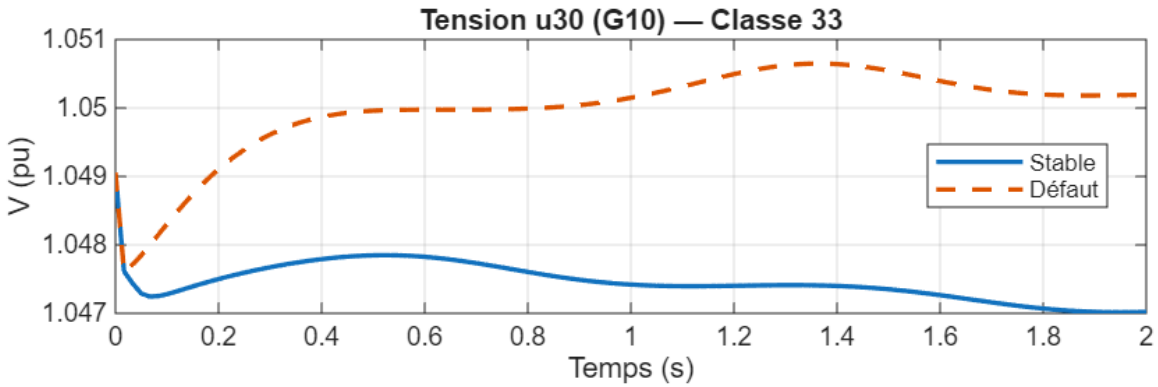

Figure 6 - 12 : Impact de la variation de Ta de l'AVR de G10 sur la tension au bus 30.

La Figure 6-13 montre l'évolution du courant au bus 33 pour le défaut appliqué sur G4. On observe une différence entre l'état stable et l'état avec défaut, traduisant l'effet de la variation de Ke de l'AVR sur la réponse dynamique du générateur.

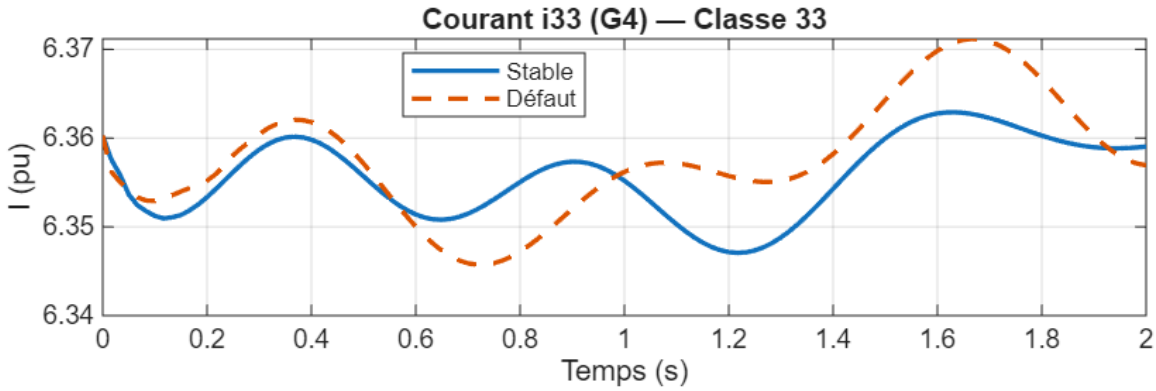

Figure 6 - 13 : Impact de la variation de Ke de l'AVR de G4 sur le courant au bus 33.

La Figure 6-14 montre l'évolution du courant au bus 9 pour le défaut appliqué sur WT1 (éolien 1). On observe une différence entre l'état stable et l'état avec défaut, traduisant l'effet de la variation de Lm sur la réponse dynamique de l'éolienne.

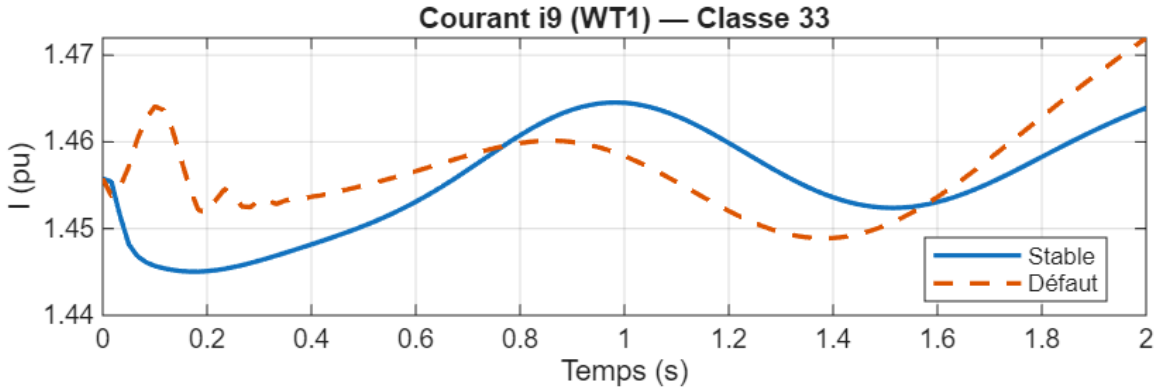

Figure 6 - 14 : Impact de la variation de Lm de WT1 sur le courant au bus 9.

La Figure 6-15 montre l'évolution de la tension au bus 17 pour le défaut appliqué sur le générateur photovoltaïque (PV). On observe une différence entre l'état stable et l'état avec défaut, traduisant l'effet de la variation de l'irradiance sur la réponse dynamique du générateur photovoltaïque.

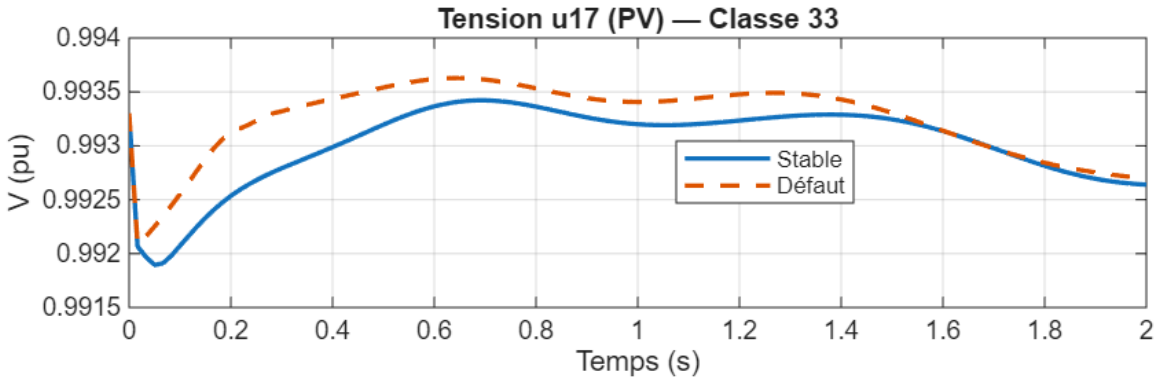

Figure 6 - 15 : Impact de la variation de l'irradiance du générateur photovoltaïque sur la tension au bus 17.

- **Classe 34**

Cette classe correspond à un défaut affectant les deux éoliennes du réseau, avec une diminution de la magnétisation Lm pour l'éolienne 1 et une augmentation de la résistance rotorique Rr pour l'éolienne 2. Les résultats montrent un écart entre l'état stable et l'état défaillant, ce qui met en évidence l'impact de ces variations paramétriques sur la réponse électrique du système.

La Figure 6-16 montre l'évolution du courant au bus 9 sous l'effet du défaut appliqué sur WT1. On observe une différence entre l'état stable et l'état avec défaut, traduisant l'impact de la diminution de la magnétisation Lm sur la réponse dynamique de l'éolienne.

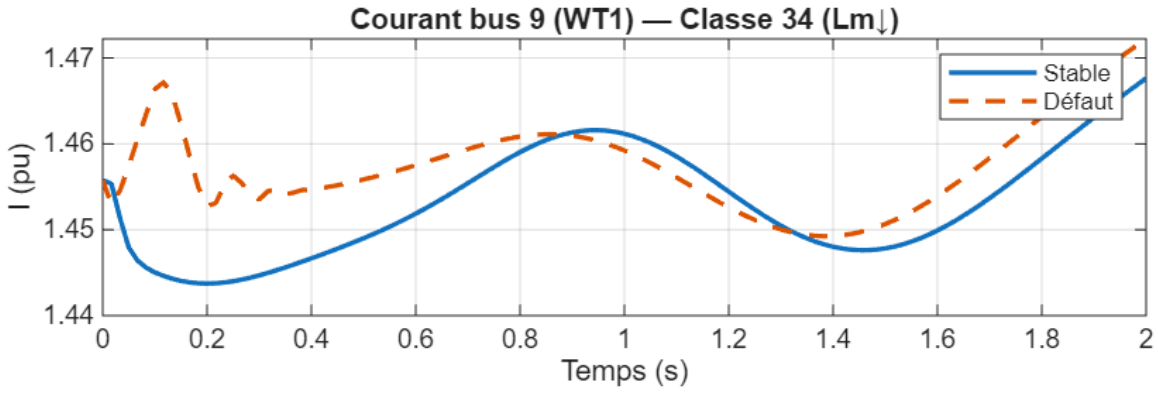

Figure 6 - 16 : Évolution du courant au bus 9 sous l'impact de la diminution de la magnétisation Lm de WT1.

La Figure 6-17 présente l'évolution de l'erreur relative du courant au bus 24 sous l'effet du défaut appliqué sur WT2. Les variations observées mettent en évidence l'impact de l'augmentation de la résistance rotorique Rr sur le comportement électrique de l'éolienne.

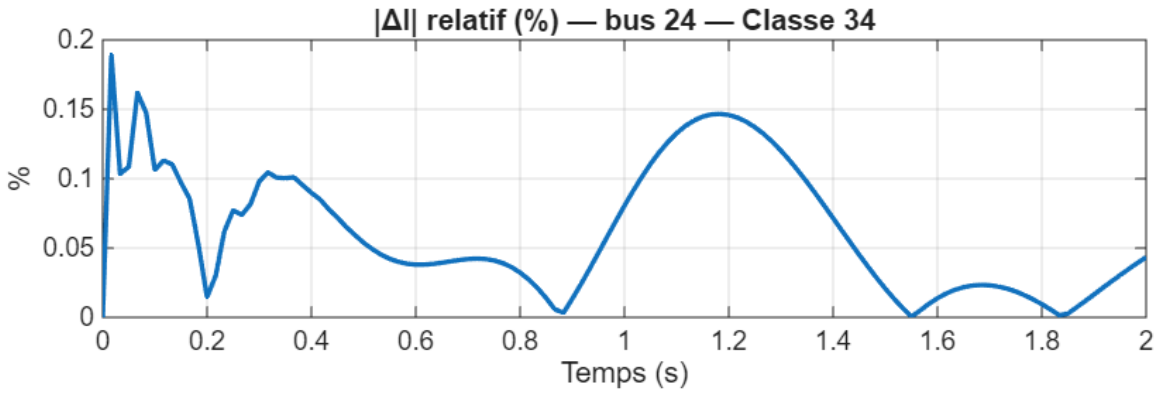

Figure 6 - 17 : Évolution de l'erreur relative du courant au bus 24 sous l'effet de l'augmentation de la résistance rotorique Rr de WT2.

- **Classe 35**

La classe 35 correspond à un défaut affectant les deux éoliennes et le générateur photovoltaïque. Dans cette classe, les variations des paramètres sont appliquées de manière aléatoire dans les intervalles de défaut fixés, avec une diminution de la magnétisation Lm pour WT1, une augmentation de la résistance rotorique Rr pour WT2, ainsi qu'une diminution de l'irradiance pour le PV. Les résultats montrent des écarts entre l'état stable et l'état défaillant, ce qui met en évidence l'influence de ces perturbations sur la réponse électrique du réseau.

La Figure 6.18 montre l'évolution du courant au bus 9 sous l'effet du défaut appliqué sur WT1. On observe une différence entre l'état stable et l'état avec défaut, traduisant l'impact de la diminution aléatoire de la magnétisation Lm dans l'intervalle de variation défini pour cette classe.

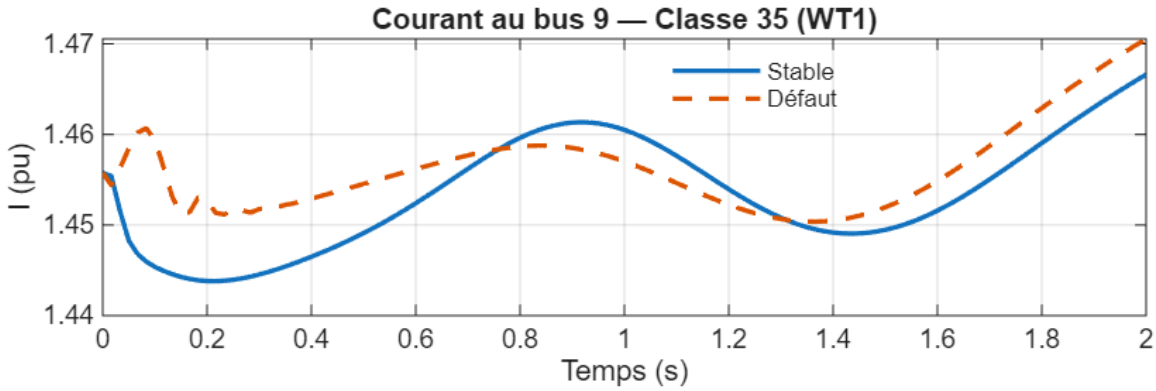

Figure 6 - 18 : Évolution du courant au bus 9 sous l'effet de la diminution aléatoire de la magnétisation Lm de WT1.

La Figure 6.16 montre l'évolution du courant au bus 17 sous l'effet du défaut appliqué sur le générateur photovoltaïque. On observe une différence entre l'état stable et l'état avec défaut, traduisant l'impact de la diminution aléatoire de l'irradiance dans l'intervalle de variation retenu.

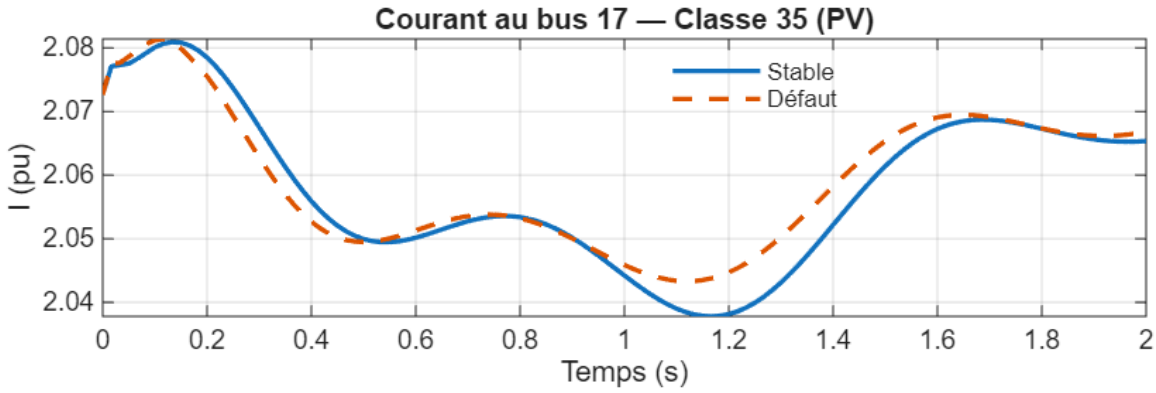

Figure 6 - 19 : Évolution du courant au bus 17 sous l'effet de la diminution aléatoire de l'irradiance du générateur photovoltaïque.

La Figure 6.17 montre l'évolution de la tension au bus 24 sous l'effet du défaut appliqué sur WT2. On observe une différence entre l'état stable et l'état avec défaut, traduisant l'impact de l'augmentation aléatoire de la résistance rotorique Rr dans l'intervalle de variation défini.

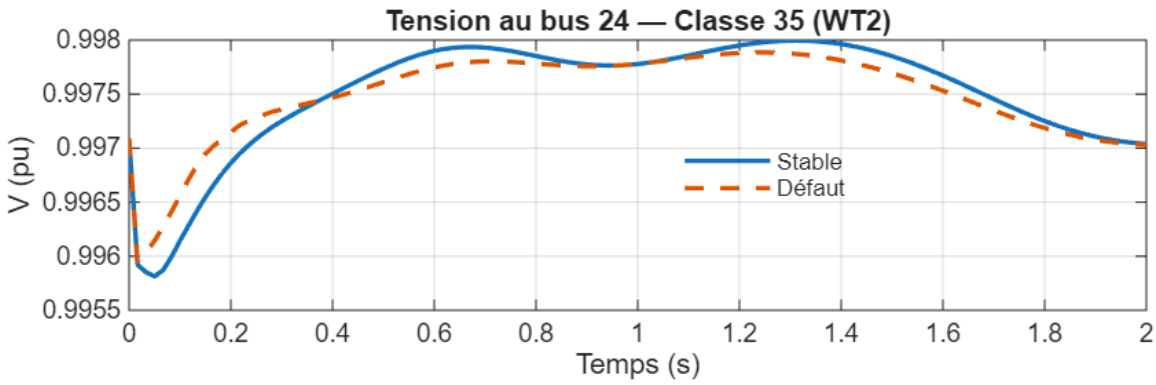

Figure 6 - 20 : Évolution de la tension au bus 24 sous l'effet de l'augmentation aléatoire de la résistance rotorique Rr de WT2.

6.6 Résultats

Cette section détaille les résultats issus de l'entraînement et de l'évaluation du modèle développé pour la détection, la classification, la localisation et la prédiction des défauts internes au sein du réseau hybride modifié. L'évaluation de ses performances s'appuie sur divers indicateurs tels que la précision, la fonction de perte, ainsi que les matrices de confusion et les métriques d'évaluation correspondantes. Ces résultats fournissent une appréciation claire de la capacité du modèle à identifier les signatures associées aux défauts, à différencier les catégories, à localiser précisément leur position dans le réseau et à prévoir leur évolution.

- **Détection des défauts hybrides**

La figure 6-21 illustre l'évolution des indicateurs de performance, à savoir l'exactitude (accuracy) et la fonction de coût (loss), du modèle DETECTEUR HYB au cours des différentes itérations d'apprentissage dédiées à la détection des défauts internes dans un réseau hybride. Les données montrent une augmentation rapide de l'exactitude dès les premières itérations : celle-ci passe d'environ 61 % en phase initiale à près de 98 % en fin

d'apprentissage. Cette évolution suggère que le modèle améliore efficacement sa capacité à différencier les états normaux des états défaillants.

Simultanément, la fonction de perte connaît une baisse significative en début d'apprentissage, reflétant une amélioration rapide des performances. La courbe associée à la phase de validation présente une tendance généralement décroissante, bien qu'elle affiche quelques légères oscillations, pour finalement atteindre une valeur basse à la fin de l'entraînement. La proximité entre les courbes d'accuracy pour les ensembles d'entraînement et de validation indique une bonne capacité du modèle à généraliser ses prédictions sur des données non vues.

L'ensemble de ces observations confirme que le modèle DETECTEUR HYB offre une détection fiable des défauts internes dans le contexte hybride, avec des performances élevées et une convergence stable tout au long du processus d'apprentissage.

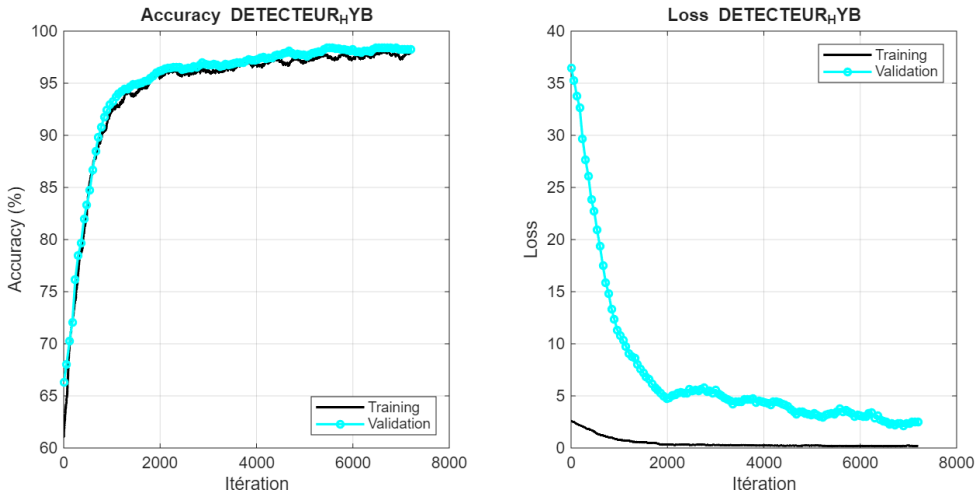

Figure 6 - 21 : Évolution de l'accuracy et de la loss du modèle pour la détection des défauts internes hybrides (multiples).

- **Classification des défauts hybrides**

Les figures 6-22,6-23 illustrent respectivement l'évolution de la précision et de la fonction de perte du modèle TYPE HYB durant le processus d'apprentissage, ainsi que les performances mesurées sur l'ensemble de test en termes de précision, rappel et score F1 pour les différentes catégories de défauts. L'analyse des courbes d'apprentissage révèle

une augmentation progressive de la précision, qui passe d'environ 30 % en phase initiale à plus de 95 % dans les phases avancées. Simultanément, la fonction de perte décroît rapidement au début, puis se stabilise à un niveau bas, indiquant une convergence satisfaisante du modèle.

Les résultats sur l'ensemble de test confirment la capacité du modèle à différencier de manière efficace les diverses classes de défauts internes hybrides. La majorité des catégories affichent des performances élevées en termes de précision, rappel et score F1, attestant de la robustesse du système de classification développé. Certaines classes, notamment les classes 28, 31 et 35, se démarquent par des scores particulièrement élevés, approchant des valeurs optimales. D'autres classes, telles que les classes 29 et 34, présentent des résultats légèrement inférieurs, mais restent dans des plages globalement satisfaisantes pour une utilisation fiable.

En synthèse, ces observations démontrent que le modèle TYPE HYB apprend de manière adéquate les caractéristiques spécifiques à chaque type de défaut et dispose d'une capacité de discrimination solide entre les différentes classes considérées dans l'étude.

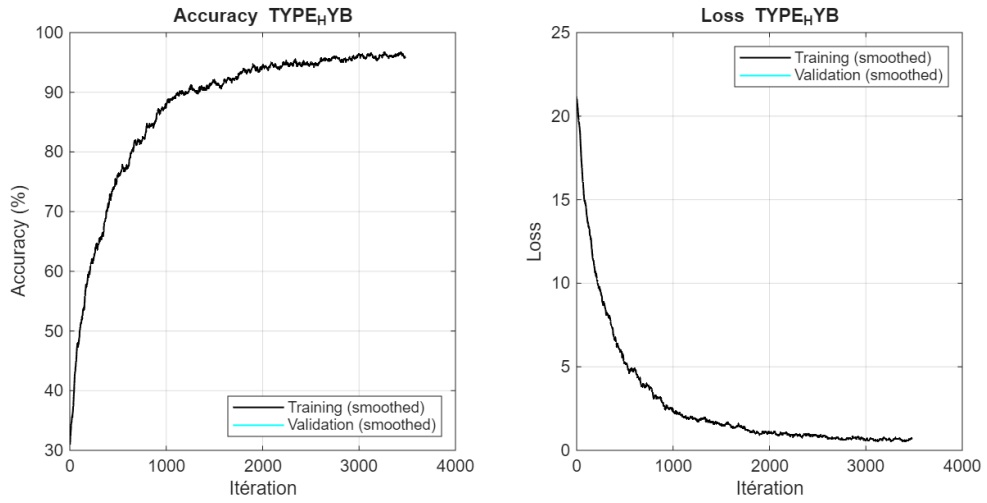

Figure 6 - 22 : Évolution de l'accuracy et de la loss du modèle pour la classification des défauts internes hybrides.

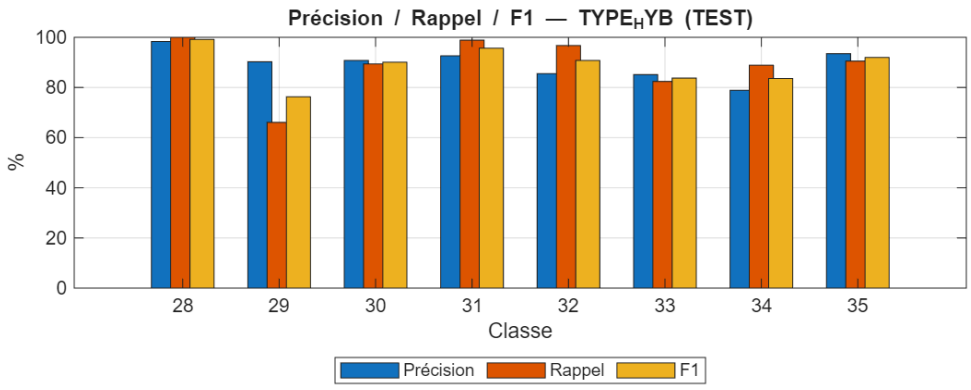

Figure 6 - 23 : Performances du modèle sur l'ensemble de test en termes de précision, rappel et F1 score pour les différentes classes de défauts.

- **Localisation des défauts hybrides**

Les figures 6-24,6-25 illustrent les performances du modèle BUS HYB sur le jeu de données de test, en termes de précision, de rappel et de score F1, ainsi que les matrices de confusion associées aux ensembles d'entraînement, de validation, de test et à l'ensemble global. Ces analyses démontrent que le modèle est en mesure d'identifier avec une précision satisfaisante l'emplacement des défauts au sein des différents bus du réseau hybride.

L'évaluation des indicateurs par classe révèle que la plupart des bus affichent des valeurs élevées de précision, rappel et score F1, généralement supérieures à 85 %, certaines classes atteignant même le score maximal, comme le bus 39. Ces résultats attestent de la capacité du modèle à différencier correctement les signatures propres à chaque localisation de défaut. Toutefois, certaines classes, notamment les bus 32, 35 et 37, présentent des performances légèrement inférieures, ce qui peut être attribué à une similarité partielle entre certaines signatures électriques ou à une complexité accrue des défauts correspondants.

Les matrices de confusion corroborent cette aptitude à localiser les défauts, puisque la majorité des prédictions se concentrent sur la diagonale principale, indiquant une reconnaissance correcte des classes par le modèle. Sur l'ensemble de test, une précision globale de 93,49 % a été obtenue, traduisant une performance globalement satisfaisante

pour la localisation des défauts dans le réseau hybride. Les erreurs constatées restent limitées et concernent essentiellement des confusions entre classes proches.

En résumé, ces résultats démontrent que le modèle BUS HYB dispose d'une bonne capacité de généralisation et peut être employé efficacement pour identifier le bus affecté par un défaut interne dans le réseau hybride étudié.

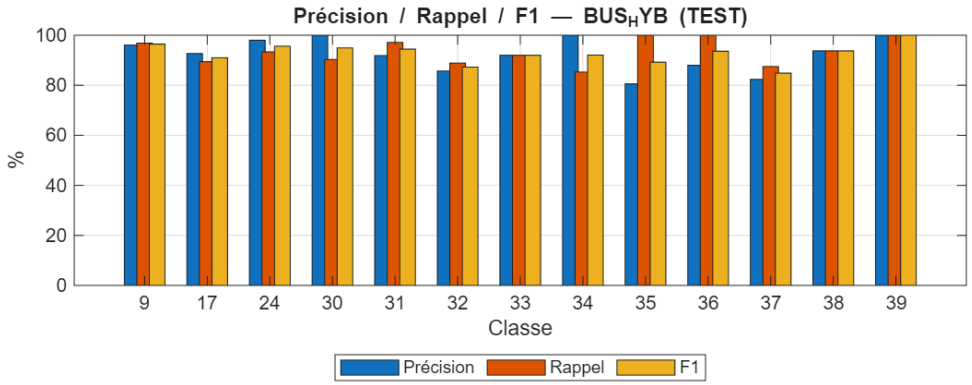

Figure 6 - 24 : Performances du modèle sur l'ensemble de test en termes de précision, rappel et score F1 pour la localisation des défauts.

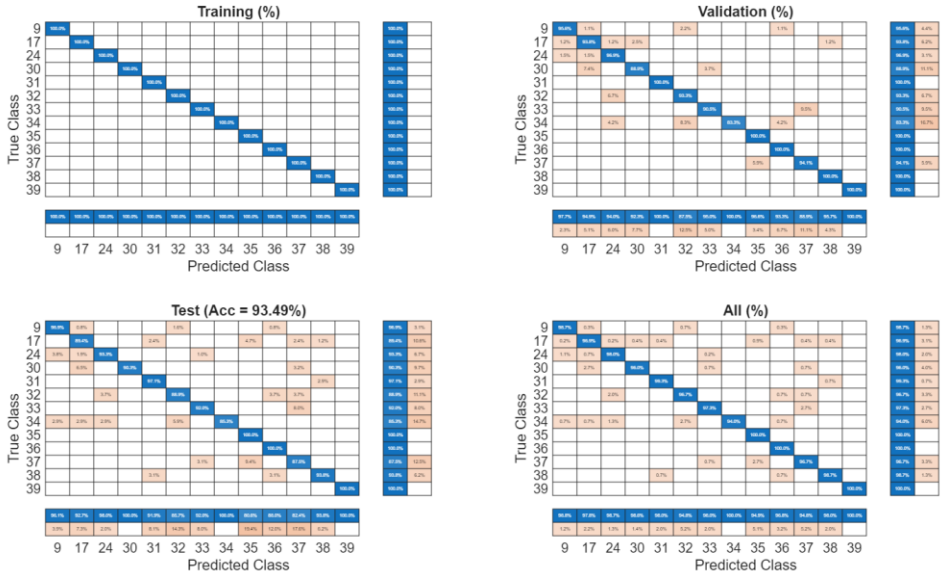

Figure 6 - 25 : Matrices de confusion du modèle pour la localisation des défauts sur les ensembles d'entraînement, de validation, de test et global.

- **Prédiction des défauts hybrides**

Les figures 6-26,6-27 illustrent respectivement l'évolution de la précision (accuracy) et de la fonction de perte (loss) du modèle optimisé durant la phase d'apprentissage, ainsi que les matrices de confusion correspondant aux ensembles d'entraînement, de validation, de test et global lors de la prédiction des défauts. Les courbes d'apprentissage révèlent une augmentation rapide de la précision dès les premières itérations, passant d'un niveau initial relativement bas à une valeur finale approchant 97 %. Parallèlement, la fonction de perte décroît progressivement pour atteindre un niveau très faible en fin de processus, ce qui indique une bonne convergence et une amélioration constante des performances du modèle.

L'examen des matrices de confusion corrobore la qualité des prédictions réalisées. La grande majorité des valeurs est positionnée sur la diagonale principale, confirmant que les classes sont correctement identifiées par le modèle. Sur l'ensemble de test, la précision globale atteint 97,00 %, témoignant d'une capacité significative du modèle à détecter les défauts à partir des signatures électriques extraites. Les taux d'erreur marginaux hors diagonale traduisent une occurrence limitée des confusions entre les classes.

Ces éléments montrent que le modèle optimisé présente une aptitude satisfaisante à généraliser et à anticiper efficacement les défauts dans le réseau hybride examiné. La cohérence des performances observée sur les différents ensembles d'apprentissage et de validation souligne par ailleurs la robustesse de la méthode adoptée.

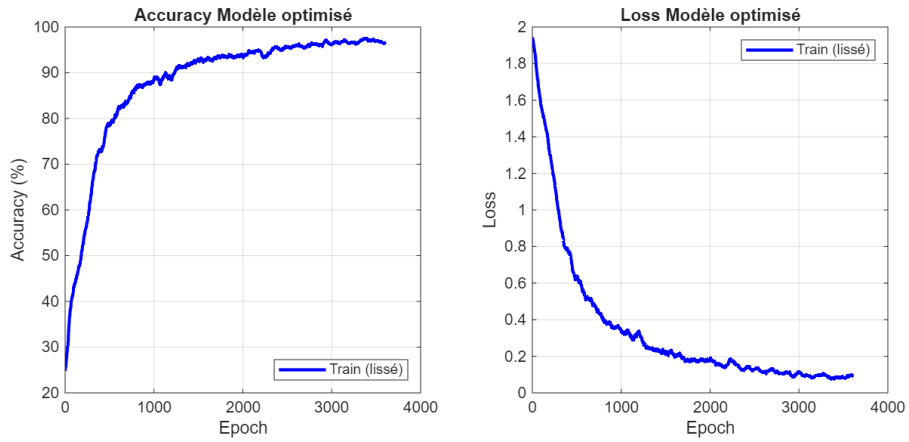

Figure 6 - 26 : Évolution de l'accuracy et de la loss du modèle optimisé pour la prédiction des défauts.

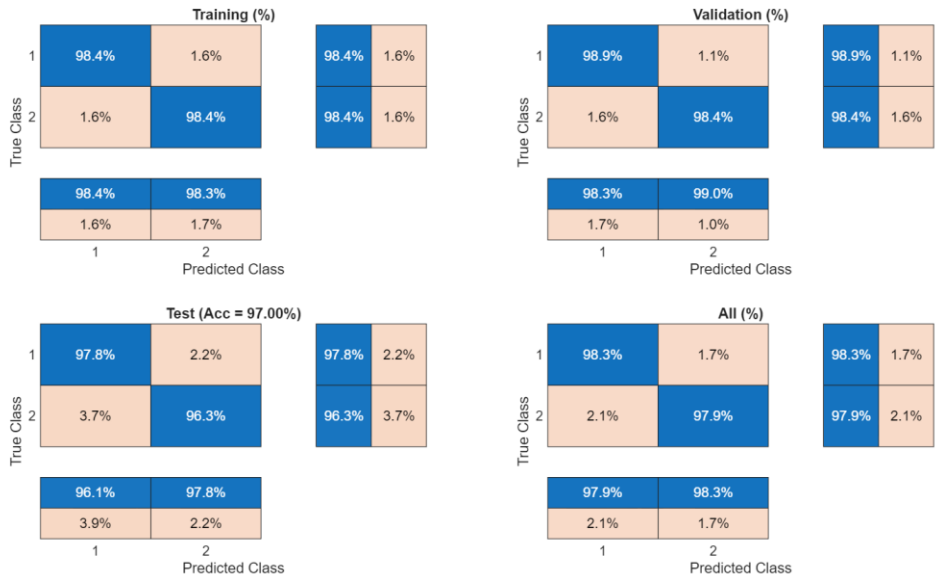

Figure 6 - 27 : Matrices de confusion du modèle optimisé pour la prédiction des défauts sur les ensembles d'entraînement, de validation, de test et global.

6.7 Discussion et comparaison des résultats

Cette section présente une analyse comparative des performances de la méthode proposée avec plusieurs études récentes issues de la littérature. L'objectif principal est d'évaluer l'efficacité du modèle développé face à d'autres approches employées pour le diagnostic des défauts dans divers systèmes énergétiques, tels que les micro-réseaux, les installations photovoltaïques, les éoliennes ainsi que les réseaux hybrides. Cette comparaison s'appuie principalement sur l'indicateur d'exactitude (accuracy), reconnu comme un critère pertinent pour mesurer la fiabilité globale des modèles en matière de détection et de classification.

Le tableau 6-1 présente une comparaison de l'accuracy obtenue par notre approche avec celles rapportées dans plusieurs travaux récents de la littérature.

Tableau 5: comparaison de l'accuracy avec quelques travaux dans la littérature.

Référence	Année	Contexte	Accuracy (%)
Vinayagam et al.	2025	Détection des défauts à haute impédance dans un microgrid intégré au photovoltaïque	98.75
Korkmaz et al.	2022	Classification des défauts et anomalies dans des systèmes photovoltaïques	93.51
Khan et al.	2024	Identification de défauts monophasés, biphasés et triphasés dans un microgrid	94.00
Pichika et al.	2022	Classification de défauts multiples dans une éolienne	92.00
Ce travail	**2026**	**Surveillance et prédiction des défauts internes simples et multiples dans un réseau hybride**	**97.00**

L'analyse de la littérature révèle que plusieurs études rapportent des taux de précision élevés, souvent avoisinant 98 à 99 %. Toutefois, ces résultats concernent majoritairement des défauts relativement simples, tels que des anomalies localisées sur des lignes ou des composants externes. Le **tableau 6.1** présente quelques exemples récents illustrant ces travaux. Il convient néanmoins de noter que ces recherches ne se concentrent généralement pas sur les défauts internes des générateurs dans le contexte d'un réseau hybride complet. Notre méthodologie se distingue par cette dimension spécifique, car la détection des défauts internes s'avère plus complexe et reste peu explorée. En intégrant l'analyse de ces défauts internes, notre contribution vise à offrir une surveillance plus approfondie et rigoureuse du réseau hybride, répondant ainsi à des enjeux techniques plus exigeants.

6.8 Conclusion

Ce chapitre a présenté les principaux résultats clés relatifs à la détection, la classification, la localisation et la prédiction des défauts internes dans le réseau hybride modifié. Les performances observées témoignent de l'efficacité de l'approche proposée, en soulignant notamment la capacité des modèles élaborés à exploiter efficacement les signatures électriques issues de divers scénarios de défauts. Globalement, ces résultats valident la méthodologie adoptée et suggèrent des perspectives prometteuses pour le développement d'une surveillance accrue, plus intelligente et plus fiable, des réseaux hybrides.

Conclusion générale

Ce travail de recherche est concentré sur l'analyse, la détection, la classification, la localisation et la prédiction des défauts internes au sein d'un réseau hybride intégrant diverses sources de production, telles que des générateurs hydroélectriques, des éoliennes et un champ photovoltaïque. L'objectif principal était de concevoir une méthode intelligente capable d'identifier avec précision les signatures électriques associées à différents types des défauts simple ou multiple, dans un contexte énergétique complexe.

Dans un premier temps, une modélisation dynamique du réseau hybride a été réalisée pour simuler son comportement sous différentes conditions opérationnelles. Par la suite, plusieurs scénarios de défauts internes ont été spécifiquement introduits sur chacune des sources du réseau. Cette démarche a permis de constituer une base de données représentative, contenant les signaux électriques nécessaires pour les phases d'analyse et d'apprentissage automatique.

Les résultats indiquent que les défauts internes affectant les générateurs hydroélectriques, les éoliennes et le système photovoltaïque entraînent des variations notables sur les grandeurs mesurées, notamment les courants, les tensions et les puissances ainsi que certaines erreurs relatives. Ces caractéristiques électriques ont facilité la distinction entre les états normaux et défaillants, ainsi que l'identification précise de la nature et de l'emplacement des défauts.

L'approche développée a démontré des bonnes performances sur l'ensemble des tâches évaluées. La détection a permis de différencier clairement les situations normales des anomalies. La classification s'est avérée capable de reconnaître avec une précision élevée les différentes catégories de défauts. La localisation a quant à elle permit d'identifier correctement la zone ou le bus affecté. Enfin, la prédiction a montré qu'il est envisageable d'anticiper l'apparition des défauts à partir des signatures extraites.

Une contribution majeure de ce travail réside dans le traitement des défauts internes, qui sont moins traités dans la littérature par rapport aux défauts externes ou ceux liés aux lignes. Par ailleurs, l'étude s'appuie sur un réseau hybride complet, incluant plusieurs types de

sources, ce qui renforce l'originalité et la pertinence pratique de l'approche proposée. Cette recherche apporte ainsi une contribution significative au développement de méthodes avancées de surveillance et de diagnostic adaptées aux réseaux énergétiques hybrides contemporains.

Plusieurs pistes d'approfondissement sont envisageables, notamment l'enrichissement de la base de données, l'intégration de conditions réalistes incluant bruit et incertitude, l'exploration de nouvelles architectures d'apprentissage profond, ainsi que la validation de la méthode sur des données expérimentales ou en temps réel. L'introduction de techniques explicables et adaptatives pourrait également améliorer l'interprétation des résultats et faciliter l'intégration dans des systèmes intelligents de supervision.

En conclusion, ce projet a validé la faisabilité et l'efficacité d'une approche intelligente pour le diagnostic des défauts internes dans un réseau hybride. Les résultats obtenus constituent une base solide pour le développement de systèmes de surveillance plus robustes, précis et adaptés aux exigences futures des réseaux énergétiques.

Bibliographie

[1] Hu, S., Fan, G., Zhou, J., Fan, J., Gan, M., & Chen, C. L. P. (2024). Hybrid network via key feature fusion for image restoration. *Engineering Applications of Artificial Intelligence, 137*, 109236. https://doi.org/10.1016/j.engappai.2024.109236

[2] Han, C., Zou, G., Yeh, H.-G., Gong, F., Shi, S., & Chen, H. (2025). Intelligent fault prediction with wavelet-SVM fusion in coal mine. *Computers & Geosciences, 194*, 105744. https://doi.org/10.1016/j.cageo.2024.105744

[3] He, S., Xu, X., Xie, J., Wang, F., Liu, Z., & Zhao, F. (2023). Fault detection and fault-tolerant control of autonomous steering system for intelligent vehicles combining Bi-LSTM and SPRT. *Measurement, 212*, 112708. https://doi.org/10.1016/j.measurement.2023.112708.

[4] Jin, R., Chen, Z., Wu, K., Wu, M., Li, X., & Yan, R. (2022). Bi-LSTM-based two-stream network for machine remaining useful life prediction. *IEEE Transactions on Instrumentation and Measurement, 71*, 3511110. https://doi.org/10.1109/TIM.2022.3167778.

[5] Li, J., Sun, W., Feng, X., von Deneen, K. M., Wang, W., Cui, G., & Zhang, Y. (2023). A hybrid network integrating convolution and transformer for thymoma segmentation. *Intelligent Medicine, 3*, 164–172. https://doi.org/10.1016/j.imed.2022.06.003.

[6] Praveen, J., & VijayaRamaraju, V. (2017). Materials for optimizing efficiencies of solar photovoltaic panels. *Materials Today: Proceedings, 4*, 5233–5238. https://doi.org/10.1016/j.matpr.2017.05.032.

[7] Ranawat, N. S., Prakash, J., Miglani, A., & Kankar, P. K. (2023). Performance evaluation of LSTM and Bi-LSTM using non-convolutional features for blockage detection in centrifugal pump. *Engineering Applications of Artificial Intelligence, 122*, 106092. https://doi.org/10.1016/j.engappai.2023.106092.

[8] Shadi, M. R., Mirshekali, H., & Shaker, H. R. (2025). Explainable artificial intelligence for energy systems maintenance: A review on concepts, current techniques, challenges, and prospects. *Renewable and Sustainable Energy Reviews, 216*, 115668. https://doi.org/10.1016/j.rser.2025.115668

[9] Yang, D., Liu, H., Xu, B., Tang, C., & Cheng, T. (2024). A hybrid network with DNN and WGAN for supercontinum prediction. *Optical Fiber Technology, 85*, 103816. https://doi.org/10.1016/j.yofte.2024.103816.

[10] Alhanaf, A. S., Balik, H. H., & Farsadi, M. (2025). Enhanced fault classification, detection, and location estimation in the IEEE 14-bus smart grid using a hybrid CNN-LSTM algorithm with adaptive learning rate. *Arabian Journal for Science and Engineering*. https://doi.org/10.1007/s13369-025-10676-y

[11] Joddy, S. (2025). Comparative analysis of CNN, LSTM, and CNN-LSTM for Indonesian stock prediction. *JURNAL EMACS (Engineering, MAthematics and*

Computer Science), 7(3), 283–289. https://doi.org/10.21512/emacsjournal.v7i3.14326.

[12] Joseph Mampilly, B., & Sheeba, V. S. (2024). An empirical wavelet transform based fault detection and hybrid convolutional recurrent neural network for fault classification in distribution network integrated power system. *Multimedia Tools and Applications, 83*, 77445–77468. https://doi.org/10.1007/s11042-024-18335-4.

[13] Massaoudi, M., Abu-Rub, H., Refaat, S. S., Chihi, I., & Oueslati, F. S. (2021). Deep learning in smart grid technology: A review of recent advancements and future prospects. *IEEE Access, 9*, 54558–54578. https://doi.org/10.1109/ACCESS.2021.3071269.

[14] Radman, A., & Suandi, S. A. (2021). BiLSTM regression model for face sketch synthesis using sequential patterns. *Neural Computing and Applications, 33*, 12689–12702. https://doi.org/10.1007/s00521-021-05916-9.

[15] Saucedo-Dorantes, J. J., Delgado-Prieto, M., Osornio-Rios, R. A., & Romero-Troncoso, R. de J. (2020). Industrial data-driven monitoring based on incremental learning applied to the detection of novel faults. *IEEE Transactions on Industrial Informatics, 16*(9), 5985–5995. https://doi.org/10.1109/TII.2020.2973731.

[16] Yan, Y., Wang, Y., Gao, W.-C., Zhang, B.-W., Yang, C., & Yin, X.-C. (2018). LSTM2: Multi-label ranking for document classification. *Neural Processing Letters, 47*, 117–138. https://doi.org/10.1007/s11063-017-9636-0

[17] Yuan, W., Li, Z., He, Y., Cheng, R., Lu, L., & Ruan, Y. (2022). Open-circuit fault diagnosis of NPC inverter based on improved 1-D CNN network. *IEEE Transactions on Instrumentation and Measurement, 71*, 3510711. https://doi.org/10.1109/TIM.2022.3166166.

[18] Yussif, A.-F. S., Seini, T., & Wilson, B. E. (2025). Pelican optimization algorithm (POA)-based method for solving the optimal capacitor integration (OCI) problem. *Andalasian International Journal of Applied Science, Engineering and Technology, 5*(3), 264–277. https://doi.org/10.25077/aijaset.v5i3.233.

[19] Droege, F., Guilhem, A., Ricard, N., Spiekerkoetter, E., Hermann, R., Rossi, E., Bailly, S., Dupuis-Girod, S., Clancy, M., & Friday, C. (2025). Executive summary of the 15th HHT international scientific conference. *Angiogenesis, 28*, 61. https://doi.org/10.1007/s10456-025-09997-1

[20] Abboud, L., Cozza, A., & Pichon, L. (2012). A matched-pulse approach for soft-fault detection in complex wire networks. *IEEE Transactions on Instrumentation and Measurement, 61*(6), 1719–1732. https://doi.org/10.1109/TIM.2012.2187246.

[21] Chang, Y., Ma, J., Sun, L., Ma, Z., & Zhou, Y. (2024). Vessel traffic flow prediction in port waterways based on POA-CNN-BiGRU model. *Journal of Marine Science and Engineering, 12*(11), 2091. https://doi.org/10.3390/jmse12112091.

[22] Habibi, M. R., Baghaee, H. R., Dragičević, T., & Blaabjerg, F. (2021). Detection of false data injection cyber-attacks in DC microgrids based on recurrent neural networks. *IEEE Journal of Emerging and Selected Topics in Power Electronics, 9*(5), 5294–5310. https://doi.org/10.1109/JESTPE.2020.2968243.

[23] Pham, D.-A., & Han, S.-H. (2025). Advanced machine learning model based on Bi-LSTM and attention mechanism for fault detection in wind turbine systems. *Journal of Electrical Engineering & Technology, 20*, 5429–5442. https://doi.org/10.1007/s42835-025-02373-5

[24] Stratigakos, A., Camal, S., Michiorri, A., & Kariniotakis, G. (2022). Prescriptive trees for integrated forecasting and optimization applied in trading of renewable energy. *IEEE Transactions on Power Systems, 37*(6), 4696–4708. https://doi.org/10.1109/TPWRS.2022.3152667.

[25] Trojovský, P., & Dehghani, M. (2022). Pelican optimization algorithm: A novel nature-inspired algorithm for engineering applications. *Sensors, 22*(3), 855. https://doi.org/10.3390/s22030855.

[26] Wang, G., & Li, G. (2024). D-PoA: A consensus algorithm for medical data sharing based on dynamic scoring. In *2024 IEEE International Conference on Web Services (ICWS)* (pp. 251–258). IEEE. https://doi.org/10.1109/ICWS62655.2024.00044.

[27] Alimi, O. A., Ouahada, K., & Abu-Mahfouz, A. M. (2020). A review of machine learning approaches to power system security and stability. *IEEE Access, 8*, 113512–113531. https://doi.org/10.1109/ACCESS.2020.3003568

[28] Dong, Z., Tian, M., & Ding, L. (2021). A framework for modeling and structural vulnerability analysis of spatial cyber-physical power systems from an attack–defense perspective. *IEEE Systems Journal, 15*(1), 1369–1380. https://doi.org/10.1109/JSYST.2020.3013959.

[29] Gautam, P., Piya, P., & Karki, R. (2021). Resilience assessment of distribution systems integrated with distributed energy resources. *IEEE Transactions on Sustainable Energy, 12*(1), 338–348. https://doi.org/10.1109/TSTE.2020.2994174.

[30] Khan, M. N., Rahman, H. U., Almaiah, M. A., Khan, M. Z., Khan, A., Raza, M., Al-Zahrani, M., Almomani, O., & Khan, R. (2020). Improving energy efficiency with content-based adaptive and dynamic scheduling in wireless sensor networks. *IEEE Access, 8*, 176495–176512. https://doi.org/10.1109/ACCESS.2020.3026939

[31] Khodabux, K., Bhujun, B. S., & Naidu, R. C. (2022). Overview of major faults in wind turbine components. In *2022 7th International Conference on Environment Friendly Energies and Applications (EFEA)* (pp. 1–6). IEEE. https://doi.org/10.1109/EFEA56675.2022.10063795.

[32] Leon, J. I., Dominguez, E., Wu, L., Marquez, A., Reyes, M., & Liu, J. (2021). Hybrid energy storage systems: Concepts, advantages, and applications. *IEEE Industrial Electronics Magazine, 15*(1), 26–41. https://doi.org/10.1109/MIE.2020.3016914

[33] Prema, V., Bhaskar, M. S., Almakhles, D., Gowtham, N., & Uma Rao, K. (2022). Critical review of data, models and performance metrics for wind and solar power forecast. *IEEE Access, 10*, 239–274. https://doi.org/10.1109/ACCESS.2021.3137419

[34] Restrepo, C. E. (2007). Arc fault detection and discrimination methods. In *Proceedings of the 53rd IEEE Holm Conference on Electrical Contacts* (pp. 115–122). IEEE. https://doi.org/10.1109/HOLM.2007.4318203

[35] Sharma, M., & Sikka, R. (2022). An impact on structural model upon renewable energy data science and continuing to improve the energy conservation mindset for environmental sustainability. In *2022 11th International Conference on System Modeling & Advancement in Research Trends (SMART)* (pp. 1–6). IEEE. https://doi.org/10.1109/SMART55829.2022.10046940

[36] Song, D., Ma, T., Li, Y., & Xu, F. (2022). Data and decision level fusion-based crack detection for compressor blade using acoustic and vibration signal. *IEEE Sensors Journal, 22*(12), 12209–12218. https://doi.org/10.1109/JSEN.2022.3173924

[37] Vinayagam, A., Balaji, S. S., R, M., Mishra, S., Alshamayleh, A., & C, B. (2025). Discrimination of high impedance fault in microgrids: A rule-based ensemble approach with supervised data discretisation. *Processes, 13*(6), 1751. https://doi.org/10.3390/pr13061751

[38] Korkmaz, D., & Acikgoz, H. (2022). An efficient fault classification method in solar photovoltaic modules using transfer learning and multi-scale convolutional neural network. *Engineering Applications of Artificial Intelligence, 115*, 104959. https://doi.org/10.1016/j.engappai.2022.104959

[39] Khan, W., Yousaf, M. Z., Singh, A. R., Khalid, S., Bajaj, M., & Zaitsev, I. (2024). Rotor angle stability of a microgrid generator through polynomial approximation based on RFID data collection and deep learning. *Scientific Reports, 14*, 28033. https://doi.org/10.1038/s41598-024-80033-w

[40] Pichika, S. V. V. S. N., Rajesh, K. N., & Kumar, B. S. (2022). Multi-component fault classification of a wind turbine gearbox using integrated condition monitoring and hybrid ensemble method approach. *Applied Acoustics, 195*, 108814. https://doi.org/10.1016/j.apacoust.2022.108814

[41] Furse, C. M., Kafal, M., Razzaghi, R., & Shin, Y.-J. (2021). Fault diagnosis for electrical systems and power networks: A review. *IEEE Sensors Journal, 21*(2), 888–906. https://doi.org/10.1109/JSEN.2020.2987321

[42] Gao, W., & Wai, R.-J. (2021). Series arc fault detection of grid-connected PV system via SVD denoising and IEWT-TWSVM. *IEEE Journal of Photovoltaics, 11*(6), 1493–1510. https://doi.org/10.1109/JPHOTOV.2021.3098376

[43] Sanduleac, M., Ciornei, I., Toma, L., Plămănescu, R., Dumitrescu, A.-M., & Albu, M. M. (2022). High reporting rate smart metering data for enhanced grid monitoring and services for energy communities. *IEEE Transactions on Industrial Informatics, 18*(6), 4039–4048. https://doi.org/10.1109/TII.2021.3095101

[44] Zografopoulos, I., Ospina, J., Liu, X., & Konstantinou, C. (2021). Cyber-physical energy systems security: Threat modeling, risk assessment, resources, metrics, and case studies. *IEEE Access, 9*, 29775–29818. https://doi.org/10.1109/ACCESS.2021.3058403

[45] Ali, M. H., El-Rifaie, A. M., Youssef, A. A. F., Tulsky, V. N., & Tolba, M. A. (2023). Techno-economic strategy for the load dispatch and power flow in power grids using peafowl optimization algorithm. *Energies, 16*(2), 846. https://doi.org/10.3390/en16020846

[46] Khekare, U., & Vedaraj, I. S. R. (2026). Optimized multi agent reinforcement learning algorithms with hybrid BiLSTM for cost efficient EV

charging scheduling. *Frontiers in Artificial Intelligence, 8*, 1700664. https://doi.org/10.3389/frai.2025.1700664

[47] Liu, Y.-J., Chen, C.-I., Fu, W.-C., Lee, Y.-D., Cheng, C.-C., & Chen, Y.-F. (2023). A hybrid approach for low-voltage AC series arc fault detection. *Energies, 16*(3), 1256. https://doi.org/10.3390/en16031256

[48] Luque, J., Anguita, D., Pérez, F., & Denda, R. (2020). Spectral analysis of electricity demand using Hilbert–Huang transform. *Sensors, 20*(10), 2912. https://doi.org/10.3390/s20102912

[49] Ramakanth, S., Soundarresan, S., Arumuganainar, D., Mamgain, R., & Kumaraswamy, H. V. (2021). Extraction of jet engine parameters from micro-Doppler signatures using continuous wavelet transform. *IET Radar, Sonar & Navigation, 15*(2), 194–207. https://doi.org/10.1049/rsn2.12029

[50] Su, Y., Gan, H., & Ji, Z. (2024). Research on multi-parameter fault early warning for marine diesel engine based on PCA-CNN-BiLSTM. *Journal of Marine Science and Engineering, 12*(6), 965. https://doi.org/10.3390/jmse12060965

[51] Zhang, B.-B., Gao, S., Chen, C.-B., Li, J.-C., & Bi, X.-Q. (2020). A semiconductor bridge electrical explosive device online firing quality identification algorithm. *Mathematical Problems in Engineering, 2020*, 1638705. https://doi.org/10.1155/2020/1638705

[52] Ambarita, E. E., Karlsen, A., & Hasan, A. (2025). Joint actuator and sensor fault diagnosis in wind turbine systems. *Wind Energy, 28*, e70059. https://doi.org/10.1002/we.70059

[53] Kijanowski, K., Barszcz, T., & Dao, P. B. (2025). A cluster-based filtering approach to SCADA data preprocessing for wind turbine condition monitoring and fault detection. *Energies, 18*(22), 5954. https://doi.org/10.3390/en18225954

[54] Lu, S.-D., Wu, C.-C., & Sian, H.-W. (2024). A novel fault diagnosis method for PV arrays using convolutional extension neural network with symmetrized dot pattern analysis. *IET Science, Measurement & Technology, 18*, 49–64. https://doi.org/10.1049/smt2.12166

[55] Meng, Q., Zhu, S., Wang, D., Fan, Z., Zheng, C., Gao, X., & Cen, K. (2026). An enhanced fault classification method for photovoltaic modules using texture features. *Energies, 19*(1), 131. https://doi.org/10.3390/en19010131

[56] Tao, L., Qian, S., Zhang, Y., & Shi, H. (2019). Abnormal detection of wind turbine based on SCADA data mining. *Mathematical Problems in Engineering, 2019*, 5976843. https://doi.org/10.1155/2019/5976843

[57] Tang, M., Hu, J., Kuang, Z., Wu, H., Zhao, Q., & Peng, S. (2020). Fault detection of the wind turbine variable pitch system based on large margin distribution machine optimized by the state transition algorithm. *Mathematical Problems in Engineering, 2020*, 9718345. https://doi.org/10.1155/2020/9718345

[58] Wu, P., Liu, Y., Ferrari, R. M. G., & van Wingerden, J.-W. (2021). Floating offshore wind turbine fault diagnosis via regularized dynamic canonical correlation and Fisher discriminant analysis. *IET Renewable Power Generation, 15*(18), 4006–4018. https://doi.org/10.1049/rpg2.12319

[59] Zhang, W., Tang, R., Wu, J., Chen, Y., Yang, C., & Zhang, S. (2025). Generalized Lissajous trajectory image learning for multi-load series arc fault

detection in 220 V AC systems considering PV and battery storage. *Energies, 18*(22), 5916. https://doi.org/10.3390/en18225916

[60] Abo ElKheir, E.-S. I., Abd-Allah, M. A., Hussien, S. A., & Omar, A. I. (2026). Real-time microgrid fault management: Leveraging hybrid deep learning for superior detection and classification performance. *IEEE Access, 14*. https://doi.org/10.1109/ACCESS.2026.3654266

[61] Amin, N., Kim, Y.-W., Kang, C., & Byun, Y.-C. (2026). ResViT-Solar: A hybrid residual-transformer for photovoltaic panel fault and cleanliness detection. *IEEE Access, 14*. https://doi.org/10.1109/ACCESS.2026.3661638

[62] Zakir, M., Arshad, A., Sher, H. A., & Al-Durra, A. (2022). Design and implementation of a fault detection method for a PV-fed DC-microgrid with power control mechanism. *IET Electric Power Applications, 16*, 1057–1071. https://doi.org/10.1049/elp2.12212

[63] Bharath Kumar, N., Vijay Babu, A. R., Anil Kumar, M. B., Sai Kumar, T., & Ganesh Babu, V. (2025). Hybrid digital twin-based fault diagnosis framework for PMSMs in electric vehicle applications. *Franklin Open, 12*, 100328. https://doi.org/10.1016/j.fraope.2025.100328

[64] Khoshbakht, S., Moosavi, S. M. M., & Cruz, S. M. A. (2025). Hybrid CNN–Transformer approach for rotor interturn short-circuit fault detection in doubly fed induction generators at synchronous speed. *IET Electric Power Applications, 19*, e70123. https://doi.org/10.1049/elp2.70123

[65] Kumar, P. (2026). Hybrid multi-scale CNN and transformer model for motor fault detection. *Machines, 14*(1), 113. https://doi.org/10.3390/machines14010113

[66] Moradi, E., Elsisi, M., Mahmoud, K., Lehtonen, M., & Darwish, M. M. F. (2025). Robust deep neural network-based internet of things for power transformer fault diagnosis under imbalanced data and uncertainties. *International Journal of Electrical Power & Energy Systems, 168*, 110731. https://doi.org/10.1016/j.ijepes.2025.110731

[67] Sarhan, M. A., Barczentewicz, S., & Lerch, T. (2024). Hybrid islanding detection method using PMU-ANN approach for inverter-based distributed generation systems. *IET Renewable Power Generation, 18*(Suppl. 1), 4453–4464. https://doi.org/10.1049/rpg2.13123

[68] Taheri, B., Hosseini, S. A., & Sedighizadeh, M. (2025). Novel hybrid fuzzy-SVR model for fault detection in VSC-HVDC transmission lines. *International Journal of Electrical Power & Energy Systems, 172*, 111222. https://doi.org/10.1016/j.ijepes.2025.111222

[69] Ali, S., Abuhmed, T., El-Sappagh, S., Muhammad, K., Alonso-Moral, J. M., Confalonieri, R., Guidotti, R., Del Ser, J., Díaz-Rodríguez, N., & Herrera, F. (2023). Explainable Artificial Intelligence (XAI): What we know and what is left to attain trustworthy artificial intelligence. *Information Fusion, 99*, 101805. https://doi.org/10.1016/j.inffus.2023.101805

[70] Gupta, N., Seethalekshmi, K., & Datta, S. S. (2021). Wavelet based real-time monitoring of electrical signals in distributed generation integrated system. *Engineering Science and Technology, an International Journal, 24*(1), 218–228. https://doi.org/10.1016/j.jestch.2020.07.010

[71] Li, D., Liu, Y., Huang, J., & Wang, Z. (2023). A trustworthy view on explainable artificial intelligence method evaluation. *Computer, 56*(4), 50–60. https://doi.org/10.1109/MC.2022.3233806

[72] Haddadi, A., Gérin-Lajoie, L., Rezaei-Zare, A., Hassani, R., & Mahseredjian, J. (2020). A modified IEEE 118-bus test case for geomagnetic disturbance studies—Part II: Simulation results. *IEEE Transactions on Electromagnetic Compatibility, 62*(3), 966–975. https://doi.org/10.1109/TEMC.2019.2920259

[73] Pena, I., Brancucci Martinez-Anido, C., & Hodge, B.-M. (2018). An extended IEEE 118-bus test system with high renewable penetration. *IEEE Transactions on Power Systems, 33*(1), 281–289. https://doi.org/10.1109/TPWRS.2017.2695963

[74] Thomas, J. B., Chaudhari, S. G., K. V., S., & Verma, N. K. (2023). CNN-based transformer model for fault detection in power system networks. *IEEE Transactions on Instrumentation and Measurement, 72*, 2504210. https://doi.org/10.1109/TIM.2023.3238059

[75] Zhang, R., Zhang, Q., Wang, Z., & Sun, H. (2021). Detection of false data injection attack in smart grid based on iterative Kalman filter. In *2021 China Automation Congress (CAC)* (pp. 6083–6088). IEEE. https://doi.org/10.1109/CAC53003.2021.9728537

[76] Pujara, D., Ramirez, D., Tepedelenlioglu, C., Srinivasan, D., & Spanias, A. (2024). Real-time PV fault detection using embedded machine learning. In *2024 IEEE 7th International Conference on Industrial Cyber-Physical Systems (ICPS)* (pp. 1–6). IEEE. https://doi.org/10.1109/ICPS59941.2024.10640018

[77] Yousif, H., & Al-Milaji, Z. (2024). Fault detection from PV images using hybrid deep learning model. *Solar Energy, 267*, 112207. https://doi.org/10.1016/j.solener.2023.112207

[78] Bishal, M. R., Ahmed, S., Molla, N. M., Mamun, K. M., Rahman, A., & Hysam, M. A. A. (2021). ANN based fault detection & classification in power system transmission line. In *2021 International Conference on Science & Contemporary Technologies (ICSCT)* (pp. 1–4). IEEE. https://doi.org/10.1109/ICSCT53883.2021.9642410

[79] Krishna, G., Raj, J., & Chandran, L. R. (2021). Transmission line monitoring and protection with ANN aided fault detection, classification and location. In *2021 2nd International Conference on Smart Electronics and Communication (ICOSEC)* (pp. 883–889). IEEE. https://doi.org/10.1109/ICOSEC51865.2021.9591911

[80] Raza, A., Benrabah, A., Alquthami, T., & Akmal, M. (2020). A review of fault diagnosing methods in power transmission systems. Applied Sciences, 10*(4), 1312. https://doi.org/10.3390/app10041312*

[81] Ogar, V. N., Hussain, S., & Gamage, K. A. A. (2023). The use of artificial neural network for low latency of fault detection and locali*sation in transmission line*. *Heliyon, 9*(2), e13376. https://doi.org/10.1016/j.heliyon.2023.e13376

[82] Jamil, M., Sharma, S., & Singh, R. (2015). Fault detection and classification in electrical power transmission lines using artificial neural network. SpringerPlus, 4*, 334*. https://doi.org/10.1186/s40064-015-1080-x

[83] Assala, P. D. S., Chen, H., & Ji, T. (2013). Power system overvoltage identification using feedforward neural network. *In* 2013 IEEE Power & Energy *Society General Meeting*. IEEE. https://doi.org/10.1109/PESMG.2013.6672091

[84] Raval, P. D., & Pandya, A. S. (2022). A hybrid PSO-ANN-based fault classification system for EHV transmission lines. IETE Journal of Research, 68*(4),* 3086–3099. https://doi.org/10.1080/03772063.2020.1754299

[85] Sokolović, Ž., & Žarković, M. (2025). Fault detection, classification and localization in HV power transmission lines using ANN. Electric Power Systems *Research, 248*, 111927. https://doi.org/10.1016/j.epsr.2025.111927

[86] Pansari, D., & Yadav, A. (2026). Adaptive fault diagnosis in renewable integrated microgrids using hybrid machine learning approach. Electric Power *Systems Research, 251*, 112297. https://doi.org/10.1016/j.epsr.2025.112297

[87] Jamal, R., Khan, N. H., Ebeed, M., Zeinoddini-Meymand, H., & Shahnia, F. (2025). An improved pelican optimization algorithm for solving stochastic optimal power flow problem of power systems considering uncertainty of renewable energy resources. Results in Engineering, 26*, 104553.* https://doi.org/10.1016/j.rineng.2025.104553

[88] Sagor, A. R., Talha, M. A., Ahmad, S., Ahmed, T., Alam, M. R., Hazari, M. R., & Shafiullah, G. M. (2024). Pelican Optimization Algorithm-Based Proportional–Integral–Derivative Controller for Superior Frequency Regulation in Interconnected Multi-Area Power Generating System. Energies, 17*(13), 3308.* https://doi.org/10.3390/en17133308

[89] Machlev, R., Heistrene, L., Perl, M., Levy, K. Y., Belikov, J., Mannor, S., & Levron, Y. (2022). Explainable Artificial Intelligence (XAI) techniques for energy and power systems: Review, challenges and opportunities. Energy and AI*, 9*, 100169. https://doi.org/10.1016/j.egyai.2022.100169

[90] Chan, H. T. J., Rubeša-Zrim, J., Pichler, F., Salihi, A., Mourad, A., Šimić, I., Časni, K., & Veas, E. (2025). Explainable Artificial Intelligence for State of Charge Estimation of Lithium-Ion Batteries. Applied Sciences, 15*(9), 5078.* https://doi.org/10.3390/app15095078

[91] Henao, F., Edgell, R., Sharma, A., & Olney, J. (2025). *A*I in power systems: A systematic review of key matters of concern. Energy Informatics, 8*, 76.* https://doi.org/10.1186/s42162-025-00529-1

[92] Zhang, C.-L., Zhang, B.-X., Xu, J.-H., Chen, Z.-L., Zheng, X.-Y., Zhu, K.-Q., Xie, H., Bo, Z., Yang, Y.-R., & Wang, X.-D. (2025). Fault diagnosis and removal for hybrid power generation systems based on an ensemble deep learning diagnostic method with self-healing strategies. International Journal of Hydrogen Energy, 109*, 1297–1313.* *https://doi.org/10.1016/j.ijhydene.2025.02.078*

ANNEXE A

EXPLOITATION DE LA BASE DES DONNÉES

La base de données, créée à partir des simulations Matlab, est stockée dans un fichier Excel.

La capture d'écran ci-dessous présente une section de la base des données utilisé dans Le chapitre 5.

	FP	FQ	FR	FS	FT	FU	FV	FW	FX	FY	FZ	GA	GB
1	stable_46	U_stable_47	U_stable_48	U_stable_49	U_stable_50	U_stable_51	U_stable_52	U_stable_53	U_stable_54	U_stable_55	U_stable_56	U_stable_57	U_stable
2	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308
3	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308
4	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308
5	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308
6	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308
7	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308
8	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308
9	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308
10	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308
11	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308
12	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308
13	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308
14	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308
15	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308
16	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308
17	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308
18	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308
19	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308
20	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308
21	1.0305264	1.030559659	1.030591369	1.030621409	1.030649662	1.030675888	1.030700207	1.03072238	1.030742407	1.030760288	1.030775905	1.030789137	1.0308

Cette base de données est utilisée dans le chapitre 6. Voici une capture d'écran Montrant une section de cette base des données.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q
1	Cas	Classe	Bus	Fs	Variation_pct	Temps_ 1	Temps_ 2	Temps_ 3	Temps_ 4	Temps_ 5	Temps_ 6	Temps_ 7	Temps_ 8	Temps_ 9	Temps_10	Temps_11	Temps_12
2	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337
3	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337
4	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337
5	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337
6	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337
7	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337
8	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337
9	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337
10	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337
11	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337
12	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337
13	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337
14	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337
15	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337
16	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337
17	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337
18	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337
19	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337
20	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337
21	1	1	39	60	22	0	0.016666668	0.033333335	0.050000001	0.06666667	0.083333336	0.100000001	0.116666667	0.13333334	0.150000006	0.166666672	0.183333337