

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne démocratique et populaire

وزارة التعليم والبحث العلمي
Ministère de l'enseignement supérieur et de la recherche scientifique

جامعة سعد دحلب البليدة 1
Université SAAD DAHLAB de BLIDA1

كلية التكنولوجيا
Faculté de Technologie

قسم الآلية والإلكترونيات
Département d'Automatique et électrotechnique



Mémoire de Master

Filière: Électrotechnique
Spécialité: Machines électriques
présenté par

Abdoun Mourad

&

Betiché Hichem

Diagnostic des défauts dans les enroulements du transformateur de puissance en se basant sur la technique de l'analyse de la réponse fréquentielle

Proposé par: Dr. CHANANE Abdallah

Année Universitaire 2024-2025

REMERCIEMENT

وَمَنْ طَلَبَ الْعُلَى مِنْ غَيْرِ كَدٍّ
أَضَاعَ الْعُمْرَ فِي طَلَبِ الْمُحَالِ
المتنبي

« Vie tes rêves, ne rêve pas de ta vie... »

Proverbe Chinois

Nous tenons tout d'abord remercié Dieu tout puissant qui nous a donné la santé, le courage et la patience pour mener à bien ce modeste travail.

Nous exprimons toutes nos profondes reconnaissances à notre encadreur Dr. **CHANANE ABDALLAH** pour le temps consacré à nous écouter, nous orienter et nous corriger tout au long de notre projet. Nous remercions très chaleureusement **Dr. Belazzoug Messaoud** chef de spécialité de machines électriques d'avoir nous à soutenir dans le parcours universitaire, en particulier dans notre domaine.

Nous adressons également nos sincères remerciements à tous les membres des jurys d'avoir accepté de juger ce modeste travail. Nous souhaitons exprimer nos profondes gratitude à tous les enseignants qui nous ont formés dès la 1ère année jusqu'à la 5ème année à Université Saad Dahlab Blida 1.

En fin, nos remerciements vont aussi également à nos familles et nos amis surtout nos parents qui nous ont soutenu durant tout au long de notre parcours. Qu'il trouve ici nos profondes gratitude.

Dédicace

Je dédie ce travail à mes parents, pour leur soutien constant et leur présence discrète tout au long de mon parcours. Leur patience et leurs encouragements ont été une source de motivation dans la réalisation de cette mémoire.

À mes sœurs, pour leur soutien constant et leur présence précieuse tout au long de ce parcours

À ma chère nièce, "**CHAHD BAYAN**" encore au berceau,
que ce modeste travail soit un vœu d'espérance pour son avenir,
rempli de lumière, de paix et de réussite.

À la famille Abdoun et Lazouti, pour leur soutien constant et leur présence précieuse tout au long de mon parcours. Leur encouragement et leur bienveillance ont été une source de motivation dans la réalisation de ce mémoire.

A mon cher binôme BETICHE HICHEM pour son soutien moral, sa patience et sa compréhension tout au long de ce projet

ABDOUN MOURAD

Dédicace

Je dédie ce modeste travail, A l'être le plus cher de ma vie, ma mère, A celui qui m'a fait de moi un homme, mon père, De me soutenir dans les moments difficiles et qui ont su m'entourer de toute leur affection et leur amour pour que je puisse réussir. Que Dieu les protège, A mes chers frères , A toute personne qui occupe une place dans mon cœur, A mon cher binôme, ABDOUN MOURAD et a toutes ma famille.

BETICHE HICHEM

Résumé

Ce mémoire traite le diagnostic des défauts dans les enroulements des transformateurs électriques en utilisant deux approches. La première repose sur l'interprétation de la réponse en fréquence via des indicateurs mathématiques pour analyser les écarts entre l'état sain et défectueux. La seconde utilise la méthode de machine à vecteurs de support (SVM) pour classifier les états avec une grande précision. Les deux méthodes ont été testées sur des données réelles d'un transformateur, démontrant une efficacité notable dans la détection des défauts. Les résultats confirment la pertinence de ces approches pour soutenir la maintenance des transformateurs électriques.

Mots-clés : Diagnostic, Transformateur, Indicateurs mathématiques, Machine Learning, SVM

Abstract

This thesis addresses the diagnosis of winding faults in power transformers using two detailed approaches. The first relies on interpreting the frequency response through mathematical indicators to analyze deviations between healthy and faulty states. The second uses the Support Vector Machine (SVM) algorithm to classify conditions with high accuracy. Both methods were tested on real data from a power transformer, demonstrating significant effectiveness in fault detection. The results confirm the relevance of these methods in supporting transformer maintenance.

Keywords: Diagnostic, Transformer, Mathematical Indicators, Machine Learning, SVM,

ملخص

تتناول هذه المذكرة تشخيص أعطاب لفات المحولات الكهربائية باستخدام نهجين حيث أن الأول يعتمد على تفسير استجابة التردد عبر مؤشرات رياضية لتحليل الانحرافات البيانية في الحالة السليمة و في حالة ثبوت عطب. أما النهج الثاني يستخدم خوارزمية SVM لتصنيف الحالات بدقة عالية. تم اختبار الطريقتين على بيانات حقيقية لمحول كهربائي، حيث أظهرت كل منهما فعالية كبيرة لكشف الأعطاب. تؤكد النتائج جدوى هذه الطرق في دعم و صيانة المحولات الكهربائية.

الكلمات المفتاحية: تشخيص، محول كهربائي، مؤشرات رياضية، تعلم آلي، آلة المتجهات الداعمة

Liste des figures

Figure I.1 — Symboles du transformateur triphasé	6
Figure I.2 — Transformateur de Type cuirassé	9
Figure I.3 — Transformateur à colonnes	10
Figure I.4 — Colonne en couches	11
Figure I.5 — Enroulement en galette.	11
Figure I.6 — Couplage de primaire	12
Figure I.7 — Couplage de secondaire	12
Figure I.8 — Représentations symboliques	13
Figure I.9 — Amorçage entre enroulements [15]	17
Figure I.10 — Amorçage entre spires, sans court-circuit [16]	18
Figure I.11 — Court-circuit entre spires [16]	18
Figure I.12 — Décharges partielles sur des cales [17]	19
Figure I.13 — Coupure suite à la fusion d'un Conducteur [16]	20
Figure I.14 — Déformation mécanique d'un Enroulement [16]	20
Figure II.1 — Modèle d'un enroulement de transformateur [31]	21
Figure II.2 — Principe de la FRA [31]	22
Figure II.3 — Schémas de connexion pour les mesures FRA [42]	24
Figure III.1 — Utilisation d'un indice numérique pour évaluer la situation mécanique du transformateur [44]	30
Figure III.2 — Points de résonance et d'antirésonance dans une trace FRA	35

Figure IV.1 — L’algorithme Support Vector Machine [85]	41
Figure IV.2 — La stratégie un-contre un [88]	42
Figure IV.3 — Organigramme générale de l’algorithme SVM	49
Figure V.1 — Étude comparative des indicateurs ED, SD, DABS et ASLE entre la référence (et les résultats obtenus par les méthodes K-means-FCCOA, algorithme d’évolution différentielle et algorithme génétique)	52
Figure V.2 — Étude comparative des indicateurs RMSE, σ , ρ et CC, entre la référence et les résultats obtenus par les méthodes K-means-FCCOA, algorithme d’évolution différentielle et algorithme génétique	52
Figure V.3 — Étude comparative des indicateurs SSE, SSRE et SMMRE entre la référence et les résultats obtenus par les méthodes K-means-FCCOA, algorithme d’évolution différentielle et algorithme génétique	53
Figure V.4 — Étude comparative des indicateurs IAD, MAD et IFD, entre la référence et les résultats obtenus par les méthodes K-means-FCCOA, algorithme d’évolution différentielle et algorithme génétique	53
Figure V.5 — Étude comparative des indicateurs MFD, Fa et FJ, entre la référence et les résultats obtenus par les méthodes K-means-FCCOA, algorithme d’évolution différentielle et algorithme génétique	54
Figure V.6 — Comparaison des valeurs ED pour différents niveaux de court-circuit	54
Figure V.7 — Comparaison des valeurs SD pour différents niveaux de court-circuit	54
Figure V.8 — Comparaison des valeurs DABS pour différents niveaux de court-circuit	55
Figure V.9 — Comparaison des valeurs $ \text{ASLE} $ pour différents niveaux de court-circuit	56
Figure V.10 — Comparaison des valeurs RMSE pour différents niveaux de court-circuit	58
Figure V.11 — Comparaison des valeurs σ pour différents niveaux de court-circuit	60
Figure V.12 — Comparaison des valeurs CC pour différents niveaux de court-circuit	61
Figure V.13 — Comparaison des valeurs ρ pour différents niveaux de court-circuit	63

Figure V.14 — Comparaison des valeurs $ SSE $ pour différents niveaux de court-circuit	65
Figure V.15 — Comparaison des valeurs SSRE pour différents niveaux de court-circuit	66
Figure V.16— Comparaison des valeurs SSMMRE pour différents niveaux de court-circuit	68
Figure V.17— Comparaison des valeurs IAD pour différents niveaux de court-circuit	769
Figure V.18— Comparaison des valeurs MAD pour différents niveaux de court-circuit	70
Figure V.19— Comparaison des valeurs IFD pour différents niveaux de court-circuit	72
Figure V.20— Comparaison des valeurs MFD pour différents niveaux de court-circuit	73
Figure V.21— Comparaison des valeurs F_a pour différents niveaux de court-circuit	74
Figure V.22— Comparaison des valeurs F_j pour différents niveaux de court-circuit	76
Figure V.23— Classification SVM avec frontière de décision entre l'état sain(classe 0) et court-circuit entre 0% et 25 % de bobinage(classe1)	77
Figure V.24— Matrice de confusion : Classe 0 vs Classe 1	79
Figure V.25— Classification SVM avec frontière de décision entre l'état sain(classe 0) et court-circuit entre 0% et 50 % de bobinage(classe 2).	80
Figure V.26— Matrice de confusion : Classe 0 vs Classe 2	81
Figure V.27— Classification SVM avec frontière de décision entre l'état sain(classe 0) et court-circuit entre 0% et 75% de bobinage(classe 3).	85
Figure V.28— Matrice de confusion : Classe 0 vs Classe 3	86
Figure V.29— Classification SVM avec frontière de décision entre l'état sain(classe 0) et court-circuit entre 25% et 50% de bobinage(classe 4).	88
Figure V.30— Matrice de confusion : Classe 0 vs Classe 4	89
Figure V.31— Classification SVM avec frontière de décision entre l'état sain(classe 0) et court-circuit entre 50% et 75% de bobinage(classe 5).	92
Figure V.32— Matrice de confusion : Classe 0 vs Classe5	93
Figure V.33— Classification SVM avec frontière de décision entre l'état sain(classe 0) et court-circuit entre 75% et 100% de bobinage(classe 6)	96

Figure V.34—Matrice de confusion : Classe 0 vs Classe 6	97
Figure V.35— Classification SVM avec frontière de décision :classe 0 vs classe 1 vs classe 2	100
Figure V.36— Matrice de confusion : classe 0 vs classe 1 vs classe 2 .	100
Figure V.37— Classification SVM avec frontière de décision :classe 0 vs classe 1 vs classe 2 vs classe3	103
Figure V.38— Matrice de confusion :classe 0 vs classe 1 vs classe 2 vs classe 3	104
Figure V.39— Classification SVM avec frontière de décision :classe 0 vs classe 1 vs classe 2 vs classe 3 vs classe 4	107
Figure V.39— Classification SVM avec frontière de décision :classe 0 vs classe 1 vs classe 2 vs classe 3 vs classe 4	108
Figure V.40— Matrice de confusion :classe 0 vs classe 1 vs classe 2 vs classe 3 vs classe 4	111
Figure V.41— Classification SVM avec frontière de décision :classe 0 vs classe 1 vs classe 2 vs classe 3 vs classe 4 vs classe 5	111
Figure V.42— Matrice de confusion :classe 0 vs classe 1 vs classe 2 vs classe 3 vs classe 4 vs classe 5	115
Figure V.43— Classification SVM avec frontière de décision :classe 0 vs classe 1 vs classe 2 vs classe 3 vs classe 4 vs classe 5 vs classe 6.	115
FigureV.44 — Matrice de confusion :classe 0 vs classe 1 vs classe 2 vs classe 3 vs classe 4 vs classe 5 vs classe 6	119

Liste des tableaux

Tableau	Titre	Page
Tableau I.1	Causes de défaillances des transformateurs[10]	13
Tableau II.1	cas pratiques de mesure FRA [42]	26
Tableau II.2	Domaines typiques d'interprétation de la méthode FRA [31]	27
Tableau III.1	Abréviations des indices extraits directement des vecteurs FRA[44]	32
Tableau III.2	Abréviations des indices basés sur les points de résonance et d'anti-résonance [44]	35
Tableau IV.1	Matrice de confusion	47
Tableau V.1	Étude comparative des indicateurs ED,CD,SD,DABS,ASLE,RMSE, σ_Q , CC, SSE, SSRE, SSMRE, IAD , MAD, IFD, MFD, Fa et FJ entre la référence et les résultats obtenus par les méthodes K-means-FCCOA, algorithme d'évolution différentielle et algorithme génétique	54
Tableau V.2	valeurs de l'indice ED pour différents cas de test FRA	59
Tableau V.3	valeurs de l'indice SD pour différents cas de test FRA	60

Tableau V.4	valeurs de l'indice DABS pour différents cas de test FRA	62
Tableau V.5	valeurs de l'indice ASLE pour différents cas de test FRA	63
Tableau V.6	valeurs de l'indice RMSE pour différents cas de test FRA	65
Tableau V.7	valeurs de l'indice σ pour différents cas de test FRA	67
Tableau V.8	valeurs de l'indice CC pour différents cas de test FRA	68
Tableau V.9	valeurs de l'indice ρ pour différents cas de test FRA	70
Tableau V.10	valeurs de l'indice SSE pour différents cas de test FRA	71
Tableau V.11	valeurs de l'indice SSRE pour différents cas de test FRA	73
Tableau V.12	valeurs de l'indice SSMMRE pour différents cas de test FRA	75
Tableau V.13	valeurs de l'indice IAD pour différents cas de test FRA	76
Tableau V.14	valeurs de l'indice MAD pour différents cas de test FRA	76
Tableau V.15	valeurs de l'indice IFD pour différents cas de test FRA	77
Tableau V.16	valeurs de l'indice MFD pour différents cas de test FRA	79
Tableau V.17	valeurs de l'indice F_a pour différents cas de test FRA	80
Tableau V.18	valeurs de l'indice FJ pour	82

différents cas de test FRA

Tableau V.19	Définition des classes utilisées dans la classification	83
Tableau V.20	Rapport de classification du l'algorithme SVM entre classe 0 et classe 1	85
Tableau V.21	Rapport de classification du l'algorithme SVM entre classe 0 et classe 2	88
Tableau V.22	Rapport de classification du l'algorithme SVM entre classe 0 et classe 3	92
Tableau V.23	Rapport de classification du l'algorithme SVM entre classe 0 et classe 4	95
Tableau V.24	Rapport de classification du l'algorithme SVM entre classe 0 et classe 5	99
Tableau V.25	Rapport de classification du l'algorithme SVM entre classe 0 et classe 6	102
Tableau V.26	Rapport de classification du l'algorithme SVM : classe 0 vs classe 1 vs classe 2	106
Tableau V.27	Rapport de classification du l'algorithme SVM : classe 0 vs classe 1 vs classe 2 vs classe 3	109
Tableau V.28	Rapport de classification du l'algorithme SVM : classe 0 vs classe 1 vs classe 2 vs classe 3 classe 4	113

Tableau V.29	Rapport de classification du l'algorithme SVM : classe 0 vs classe 1 vs classe 2 vs classe 3 classe 4 vs classe 5	117
Tableau V.30	Rapport de classification du l'algorithme SVM : classe 0 vs classe 1 vs classe 2 vs classe 3classe4 vs classe 5 vs classe 6	120

Table des matières

INTRODUCTION GENERALE	1
- Contexte général.....	2
- Problématique	2
Objectif général.....	3
Objectif spécifique	3
Organisation du mémoire	3
CHAPITRE I : Les Transformateurs de Puissance	5
I.1 Introduction	6
I.2 Principe du fonctionnement d'un transformateur électrique	6
I.3 Technologies des transformateurs de puissance.....	7
I.4 Types de transformateurs.....	7
I.5 Constitution d'un transformateur de puissance	8
I.5.1 Dispositifs de protection	9
I.6 Technologies de bobinages.....	9
I.6.1 Cuirassé	9
I.6.2 Colonne	10
I.6.2.1 Colonne : en couches	11
I.6.2.2 Colonne : en galettes	12
I.7 Couplages d'un transformateur	13
I.7.1 Mode de couplage	13
I.8 Pertes dans un transformateur	14
I.8.1 Courant de Foucault.....	14
I.8.2 Pertes par effet joule	14
I.9 Isolation.....	14

I.10 Défauts des systèmes d'isolation électrique	15
I.11 Causes de défaillances des transformateurs de puissance.....	15
I.12 Défauts fréquents dans les transformateurs	16
I.12.1 Défaut d'isolement de la partie active.....	16
I.12.2 Amorçage diélectrique entre spires.....	17
I.12.3 Court-circuit entre spires	17
I.12.4 Décharges Partielles.....	17
I.12.5 Coupure du circuit électrique	18
I.12.6 Déformation géométrique des enroulements.....	19
I.14 Conclusion.....	19
ChapitreII : Analyse de la Réponse Fréquentielle (FRA)	20
II.1Introduction	21
II.2 L'Analyse de la Réponse en Fréquence (FRA)	21
II.3 Principe de la FRA	21
II.4 Objectifs de la FRA	23
II.5 Quand faut-il faire un test FRA [37,38]	23
II.6 Types de connexions FRA.....	24
II.7 Zones de fréquences d'analyse FRA.....	26
II.8 Interprétation de la méthode	27
II.9 Conclusion.....	28
Chapitre III: Interprétation des résultats FRA a l'aide des indicateurs mathématiques	29
III.1 Introduction	30
III.2 Les indicateurs mathématiques	30
III.2.1 Les indices extraits directement des vecteurs FRA.....	31
III.2.2 Les indices basés sur les points de résonance et d'anti-résonance.....	34
III.3 Avantages des indicateurs mathématiques[71,72]	37
III.4 Inconvénientsdes indicateurs mathématiques[73,74]	37
III.4 Conclusion.....	38

Chapitre IV: Diagnostic par apprentissage	39
IV.1 Introduction	40
IV.2 Machine Learning (Apprentissage Automatique).....	40
IV.3 Raison de l'utilisation de Machine Learning dans les interprétations FRA	41
IV.4 Support Vector Machine (SVM).....	41
IV.5 SVM multi-classes	42
IV.6 Noyaux dans la machine à vecteurs de support(Kernels in SVM)[89].....	43
IV.6.1 Types de noyau dans SVM[90].....	43
IV.6.2 Choix de noyaux.....	44
IV.6.3 Hyper-paramètres de RBF [85]	44
IV.7 Avantages et inconvénients des machines à vecteurs de support[85,92]	44
IV.8 Modèle SVM pour diagnostic les enroulements des transformateurs.....	45
IV.8.1 Préparation des données.....	45
IV.8.2 Division des données	45
IV.8.3 Extraction des caractéristiques statistiques de chaque échantillon	46
IV.8.4 Entraînement sur la base de SVM	46
IV.8.5 Évaluation des performances du modèle	46
IV.8.6 Outil utilisé.....	49
IV.9 Organigramme de SVM.....	49
IV.10 Conclusion.....	51
Chapitre V : Résultats et discussion	52
V.1 Introduction	53
V.2 Présentation du transformateur étudié [93]	53
V.3 Interprétation des résultats FRA à l'aide d'indicateurs mathématiques.....	53
V.3.1 Étude comparative des indicateurs en état sain : à partir des données mesurées et estimées	54
V. 3.2 Analyse du comportement des indices mathématiques dans différents scénarios de défaut du transformateur	58

V.4 Interprétation des résultats FRA par la méthode SVM	84
V.4.1 Raison du choix de SVM	84
V.4.2 Choix de C et gamma	84
V.4.3 Définition des classes utilisées	84
V.4.4 Stratégie de classification adoptée	85
V.4.5 Détection individuelle des défauts (classification binaire)	85
V.4.6 Discrimination entre défauts multiples (classification multi classes)	104
V.5 Conclusion.....	125
CONCLUSION GENERALE.....	126
BIBLIOGRAPHIE	128
ANNEXE	140

INTRODUCTION GENERALE

- Contexte général

La majorité des transformateurs de puissance dans le monde ont été installés dans les années 1980 et approchent donc maintenant de la fin de leur cycle de vie [1]. Plus d'une décennie après cette évaluation, il est devenu encore plus urgent d'évaluer l'état de ces transformateurs et d'effectuer des travaux de maintenance pour éviter les pannes imprévues et les interruptions de service. Les rapports des compagnies d'électricité et des institutions spécialisées indiquent une augmentation continue des défaillances des transformateurs de puissance, en particulier celles de nature catastrophique, qui provoquent non seulement des pannes de réseau mais aussi des dommages matériels considérables et des pertes économiques majeures pour les opérateurs [2].

Ces pannes peuvent également avoir un impact significatif sur la qualité de service, la sécurité des équipements et la stabilité du réseau électrique. De plus, le remplacement d'un transformateur de puissance est une opération coûteuse et complexe, nécessitant des ressources importantes en temps, en main-d'œuvre et en logistique. Par conséquent, la surveillance de l'état interne des transformateurs est devenue une priorité stratégique pour les gestionnaires de réseaux.

Selon les données publiées par le groupe de travail CIGRE, la déformation des enroulements constitue l'une des causes majeures de défaillance interne, représentant environ un tiers des cas de panne recensés [3]. Ce type de défaut est souvent lié à des efforts électrodynamiques excessifs lors de courts-circuits, ou à des contraintes thermiques et mécaniques cumulées au fil du temps. Pourtant, la détection de telles déformations reste un défi, notamment lorsqu'elles ne provoquent pas immédiatement une panne totale. Cette situation met en évidence la nécessité de développer des méthodes de diagnostic fiables et précoces pour détecter les défauts internes, notamment les déformations des enroulements. Parmi ces méthodes, l'analyse de la réponse en fréquence (FRA) combinée à des techniques avancées de traitement du signal et d'intelligence artificielle s'impose comme une approche prometteuse pour améliorer la fiabilité et la disponibilité des transformateurs de puissance.

- Problématique

La déformation d'enroulement, telles que l'inclinaison, le renflement forcé, le flambage libre, la tension du collier et le télescopage, sont causées par des forces électromagnétiques générées par le courant de court-circuit externe et le champ électromagnétique interne [4]. Elles peuvent également être provoquées par des séismes, un transport inapproprié, le vieillissement des isolants ou l'explosion de gaz inflammables dans l'huile du transformateur [5]. Au début, un enroulement déformé n'affecte pas les performances, mais si on le néglige, il peut transformer un

problème mineur en une panne grave, ce qui rend la détection et le diagnostic précoces essentiels [6].

L'analyse de la réponse en fréquence (FRA) constitue aujourd'hui l'une des principales méthodes de diagnostic de ces défauts. Afin de dépasser l'interprétation purement visuelle des courbes FRA et améliorer la précision de diagnostic, plusieurs techniques avancées sont employées, notamment des indicateurs mathématiques et des algorithmes d'apprentissage automatique tels que la machine à vecteurs de support (SVM).

Objectif général

L'objectif principal de cette étude est d'appliquer des indices mathématiques et des techniques d'apprentissage automatique, telles que la machine à vecteurs de support (SVM), pour diagnostiquer et évaluer l'état de dommage des enroulements des transformateurs de puissance, et ainsi détecter précocement les défauts, dans le but d'améliorer la précision du diagnostic et l'efficacité de la maintenance.

Objectif spécifique

- ✚ Prédiction des défauts d'enroulement de transformateurs en se basant sur des données FRA.
- ✚ Localisation des défauts dans les enroulements des transformateurs.
- ✚ Application d'indicateurs mathématiques pour l'évaluation de l'état des enroulements des transformateurs de puissance à partir des données de la réponse en fréquence (FRA).
- ✚ Analyser et évaluer l'efficacité de chaque indicateur mathématique.
- ✚ Entraînement d'un modèle de machine à vecteurs de support (SVM) pour classer les conditions de défaut avec une grande précision.
- ✚ Évaluation de l'efficacité de l'algorithme SVM pour distinguer les états sains et défectueux des enroulements de transformateur.

Organisation du mémoire

Cette mémoire est structurée en six chapitres, débutant par le présent chapitre et se terminant par une synthèse générale des travaux réalisés.

Le première chapitre de cette mémoire présente les transformateurs de puissance dans leur Ce deuxième chapitre présente les transformateurs de puissance dans leur globalité, en abordant leurs utilisations, leur constitution, ainsi que leurs principaux types. Il discute également des

Introduction générale

principales causes de défaillance et des défauts couramment rencontrés dans les transformateurs électriques.

Le deuxième chapitre présente les concepts fondamentaux liés à l'analyse de la réponse en fréquence (FRA), en expliquant ses principes et ses objectifs, ainsi que les méthodes classiques utilisées pour interpréter les résultats obtenus par cette technique.

Le troisième chapitre présente une organisation claire de l'utilisation des indicateurs mathématiques pour évaluer l'état des enroulements des transformateurs électriques. Il détaille le calcul de ces indicateurs, leur mode d'emploi ainsi que leurs avantages et inconvénients. L'objectif est de fournir une méthode structurée pour analyser efficacement les données des enroulements

Le quatrième chapitre présente l'utilisation de la méthode SVM pour la classification des défauts dans les enroulements des transformateurs de puissance, en expliquant le choix des caractéristiques, le processus d'entraînement du modèle, ainsi que l'évaluation de ses performances pour un diagnostic fiable.

Dans le cinquième chapitre, nous présentons les résultats des indicateurs mathématiques ainsi que ceux de la machine à vecteurs de support (SVM). Chaque indicateur est évalué individuellement afin de démontrer son efficacité. Par la suite, nous exploitons l'algorithme de la machine à vecteurs de support (SVM) pour effectuer une classification binaire entre l'état sain et l'état défectueux, ainsi qu'une classification multi-classes pour distinguer plusieurs niveaux de défauts. Cette approche permet d'analyser les performances de la SVM en termes de précision, de capacité de généralisation et de robustesse face à la complexité croissante des cas de défaillance.

CHAPITRE I : Les Transformateurs de Puissance

I.1 Introduction

Les transformateurs de puissance haute tension sont l'un des composants les plus importants et les plus critiques dans le réseau électrique. Ils sont utilisés pour modifier les tensions afin de répondre aux besoins des systèmes de transmission et de distribution de l'énergie électrique. Il est à noter qu'une majeure partie de ces machineries sont en fonctionnement depuis plusieurs années et pour différents types d'environnements électriques et mécaniques.

Bien que le transformateur est conçu pour fonctionner dans un milieu difficile avec des conditions de fonctionnement épuisantes, à mesure que le transformateur prend de l'âge, les composants et les matériaux d'isolation qui se trouvent à l'intérieur se dégradent et de plus en plus des risques de court-circuiter ces enroulements.

I.2 Principe du fonctionnement d'un transformateur électrique

L'idée fondamentale à l'origine des transformateurs découle des avancées de Michael Faraday, qui a établi un lien entre l'électricité et le magnétisme [7]. Sa théorie a suggéré que la variation du champ magnétique peut générer de l'électricité, formant ainsi le principe essentiel sur lequel reposent les transformateurs électriques.

Les transformateurs modifient les niveaux de tension en manipulant les propriétés électriques. Tout changement de magnétisme génère une tension dans les circuits électriques, provoquant un flux d'électricité dans les fils à proximité.

Les transformateurs électriques fonctionnent comme suit : l'électricité à haute tension traverse les bobines enroulées autour d'un noyau, induisant un magnétisme alternatif. Ce magnétisme fluctuant génère un courant dans un fil de sortie enroulé avec moins de bobines [7].

I.3 Symboles électriques du transformateur

Le transformateur peut être représenté par l'un des symboles reportés sur la figure 1.1.




Figure I.1 Symboles du transformateur triphasé

I.3 Technologies des transformateurs de puissance

Un transformateur est un dispositif statique basé sur l'induction électromagnétique. Il est composé de deux enroulements (appelés bobines), conçus pour transformer un système de tensions et courants alternatifs en un autre système de valeurs différentes, mais avec la même fréquence et la même forme d'onde. L'objectif principal d'un transformateur est de transmettre l'énergie électrique d'un circuit à un autre par un champ magnétique, tout en régulant la tension et le courant dans le cours du processus.

La structure de base d'un transformateur de puissance se compose de deux parties principales : le circuit magnétique et le circuit électrique [12].

I.4 Types de transformateurs [18]

Il existe plusieurs **types de transformateurs de puissance**, chacun adapté à des usages et contextes spécifiques. Voici les principaux :

- **Transformateur élévateur (Step-up):**
Utilisé principalement dans les centrales électriques pour augmenter la tension produite par les alternateurs, facilitant ainsi le transport de l'électricité sur de longues distances avec moins de pertes.
- **Transformateur abaisseur (Step-down):**
Réduit la tension pour la rendre compatible avec la consommation domestique ou industrielle. On les trouve dans les postes de distribution.

- **Transformateur de distribution:**

Généralement de faible à moyenne puissance, ils sont utilisés pour distribuer l'électricité aux utilisateurs finaux (logements, bâtiments, etc.).

- **Transformateur de puissance de sous-station:**

Présent dans les postes électriques, ce type gère la connexion entre les réseaux de transport et de distribution.

- **Autotransformateur:**

Possède un seul enroulement agissant comme primaire et secondaire à la fois. Il est plus compact et économique, souvent utilisé dans les réseaux interconnectés.

- **Transformateur triphasé:**

Conçu pour les réseaux industriels, il permet de traiter simultanément trois phases d'électricité, avec un meilleur rendement.

- **Transformateur de mesure:**

Inclut les transformateurs de courant (TC) et de tension (TT), utilisés pour la protection et la mesure dans les réseaux électriques.

- **Transformateur à réglage en charge (OLTC):**

Permet d'ajuster la tension secondaire en fonction de la variation de la charge sans interrompre le service.

I.5 Constitution d'un transformateur de puissance

Un transformateur de puissance est généralement constitué des éléments suivants :

Noyau magnétique : le noyau est généralement fabriqué en tôles d'acier au silicium pour réduire les pertes par courants de Foucault. Il sert à canaliser le flux magnétique généré par les enroulements.

Enroulements :

Enroulement primaire : Reçoit l'énergie électrique du circuit d'entrée.

Enroulement secondaire : Fournit l'énergie électrique transformée au circuit de sortie.

Les enroulements sont généralement fabriqués en cuivre à cause de leur conductivité électrique élevée.

Isolation : les enroulements et le noyau sont isolés pour éviter les court-circuit et assurer la sécurité. L'isolation peut être réalisée avec des matériaux tels que le papier imprégné d'huile, la résine époxy, ou d'autres matériaux diélectriques.

Réservoir d'huile : L'huile sert à la fois d'isolant et de refroidissement. Il aide à dissiper la chaleur générée par les pertes dans le transformateur.

Système de refroidissement : Les transformateurs de puissance génèrent de la chaleur en fonctionnement, les systèmes de refroidissement peuvent inclure des radiateurs et des ventilateurs pour maintenir la température dans des limites acceptables.

I.5.1 Dispositifs de protection

- **Relais Buchholz** : il sert à détecter les défauts internes et les gaz produits par la décomposition de l'huile.
- **Parafoudres** : ils servent à protéger le transformateur contre les surtensions.
- **Disjoncteurs** : ils permettent la connexion ou la coupure du transformateur en cas de défaut.
- **Borne de connexion** : ils relient les enroulements primaires et secondaires au réseau électrique.
- **Indicateurs et instruments de mesure** : les transformateurs sont souvent équipés des indicateurs qui permettent de voir le niveau et la température de l'huile, et des capteurs pour surveiller les paramètres de fonctionnement.

I.6 Technologies de bobinages [17,20]

Deux principales technologies d'enroulement sont utilisées selon la structure du circuit magnétique : à colonne, où les enroulements entourent les colonnes du noyau, et à cuirassé, où les bobines sont complètement enveloppées par le circuit magnétique.

Chaque configuration offre des avantages spécifiques en matière de distribution du flux, de compacité et de refroidissement.

I.6.1 Cuirassé [17]

Dans la structure cuirassée, le circuit magnétique entoure complètement les enroulements haute et basse tensions d'une phase, comme le montre la figure ci-après.

Dans un transformateur à cuirassé, le flux magnétique de retour circule à l'extérieur des enroulements, à travers le circuit magnétique.

Grâce à sa conception offrant un excellent blindage magnétique, ce type de transformateur est particulièrement adapté à la fourniture de **basse tension à fort courant**, comme c'est le cas pour les transformateurs de **fours à arc**.




Figure I.2 Transformateur de Type cuirassé

Cette technologie présente une structure plus compacte que celle des transformateurs à colonne. Cependant, sa mise en œuvre requiert une expertise technique élevée ainsi qu'une main-d'œuvre importante, notamment pour la fabrication des enroulements et l'assemblage d'un circuit magnétique souvent très volumineux.

Historiquement, les transformateurs cuirassés ont été développés aux États-Unis par **Westinghouse**.

En France, la majorité des transformateurs de puissance produits par **Jeumont Schneider Transformateurs (JST)** adoptent ce type de configuration.

Des fabricants tels que **ABB** et **Mitsubishi** continuent également à produire ce genre de transformateurs à l'échelle internationale.

I.6.2 Colonne [17]

Dans les transformateurs à colonne, le flux magnétique de retour circule à travers les jambes latérales du circuit magnétique, lesquelles sont entourées concentriquement par les enroulements principaux, comme illustré dans la figure ci-dessous.

Dans un transformateur triphasé, chaque phase électrique est associée à une jambe du circuit magnétique. Ce type de transformateur est largement utilisé à travers le monde, dans une grande variété d'applications.

La technologie à colonne repose principalement sur deux techniques de bobinage :

- le bobinage en couches,
- le bobinage en galettes.




Figure I.3 Transformateur à colonnes

I.6.2.1 Colonne : en couches

L'un des avantages du bobinage en couches est sa bonne répartition, par capacité, des surtensions dues aux chocs de foudre le long des spires. Cependant, l'épaisseur de la bobine supporte la pleine tension de l'enroulement, ce qui nécessite une isolation soignée entre les couches.

Par leur construction, ces enroulements permettent une circulation verticale relativement aisée de l'huile, favorisant ainsi un refroidissement efficace. Ils sont particulièrement bien adaptés aux systèmes de refroidissement à huile naturelle tels que ONAN ou ONAF.

Les enroulements en couches sont généralement utilisés pour la haute tension, et l'usine Alstom Saint-Ouen a historiquement produit un grand nombre de transformateurs de ce type.




Figure I.4 Colonne en couches

I.6.2.2 Colonne : en galettes

Grâce à la structure des enroulements en galettes, la tension de l'enroulement est répartie uniformément sur toute la hauteur de la bobine. Contrairement au bobinage en couches, où la tension est concentrée sur l'épaisseur, les contraintes d'isolation dans le cas des galettes sont donc moins sévères, ce qui simplifie les exigences en matière d'isolation.

Un seul conducteur est généralement enroulé pour former l'ensemble de la bobine, ce qui reste relativement simple à mettre en œuvre.

Toutefois, afin d'améliorer la répartition des contraintes électriques — notamment celles liées aux surtensions dues aux chocs de foudre — différentes configurations d'enroulement et de connexion ont été développées.

Parmi les types d'enroulements en galettes les plus courants, on distingue :

- les galettes simples,
- les galettes à spires entrelacées,
- les galettes avec inter-écrans.




Figure I.5 Enroulement en galette.

I.7 Couplages d'un transformateur[21]

I.7.1 Mode de couplage

Au primaire les enroulements peuvent être connectés soit en étoile(Y) soit en triangle(D).




Figure I.6 Couplage de primaire .

Au secondaire les enroulements peuvent être couplés de 3 manières différentes : étoile(y), triangle(d) et zigzag(z).




Figure I.7 Couplage de secondaire .

On obtient ainsi 6 couplages possibles entre primaire et secondaire :

Y-y : étoile –étoile

Y-d : étoile-triangle

Y-z : étoile-zigzag

D-y : triangle- étoile

D-d : triangle –triangle

D-z : triangle-zigzag

On donne ci-dessous les représentations symboliques des couplages normalisés :




Figure I.8 Représentation symboliques

I.8 Pertes dans un transformateur

La conversion de l'énergie dans un transformateur s'accompagne de diverses pertes qui déterminent le niveau de l'échauffement et le rendement.

I.8.1 Courant de Foucault

Les courants de Foucault sont induits dans la masse du matériau ferromagnétique, lorsque ce matériau est soumis à un champ d'induction variable. Ces courants provoquent par effet joule une dissipation d'énergie. Pour les réduire, on feuillette et on empile les tôles isolées entre elles.

I.8.2 Pertes par effet joule

Les pertes par effet joule dans les enroulements sont appelées également pertes cuivre, elles dépendent de la résistance de ces enroulements et de l'intensité du courant qui les traverse, elles sont proportionnelles au carré de l'intensité du courant.

$$P_j = \sum R_i I_i^2$$

R_i : Résistance de l'enroulement i ($i = 1, 2$).

I_i : Intensité du courant qui le traverse.

I.9 Isolation

L'huile et les isolants celluloseux (papiers) possèdent des propriétés spécifiques qui se complètent pour offrir un isolement efficace entre les différentes parties du transformateur.

L'huile est souvent utilisé comme un milieu diélectrique liquide, tandis que les isolants celluloseux, tels que les papiers imprégnés d'huile, sont utilisés pour fournir une isolation solide entre les composants internes du transformateur.

Le transformateur doit être équipé d'une isolation diélectrique solide ou liquide qui lui permettra de résister à la fois à la tension alternative en régime permanent et aux surtensions transitoires sans subir de décharge électrique. Afin d'accomplir cela, elle doit rendre le champ électrique homogène dans le transformateur.

I.10 Défauts des systèmes d'isolation électrique

Le bon fonctionnement des équipements électriques repose notamment sur la qualité des structures isolantes qui y sont intégrées. Les systèmes d'isolation électrique ne sont jamais parfaitement homogènes en termes de matériaux isolants. Pendant leur fabrication, il est possible que des gaz se piègent au sein du matériau et forment des cavités d'air. De la même manière, lorsque l'isolant est mis en contact avec les pièces conductrices, il est possible que des décollements se produisent entre le diélectrique et le conducteur. Ces défauts de fabrication comprennent notamment la présence de particules étrangères dans l'isolant des enroulements [14] [15]. Ces défauts peuvent également être causés par des contraintes thermiques et mécaniques lors de la fabrication de ces enroulements, ainsi qu'une application incorrecte de la tension. Finalement, l'isolation vieillit inévitablement tout au long de la durée de vie du transformateur, et toutes les contraintes électriques, thermiques, mécaniques et environnementales que le matériau doit supporter entraînent des changements irréversibles dans sa structure. En ce qui concerne les contraintes électriques, c'est-à-dire lorsque le matériau est exposé à un champ électrique, les imperfections mentionnées précédemment sont des sites particulièrement favorables à l'émergence de décharges partielles [16]. Effectivement, compte tenu de la diversité du matériau et de la présence de défauts, la répartition du champ électrique au sein de celui-ci n'est pas homogène. Par exemple, lorsque les cavités gazeuses sont présentes dans l'isolant, le champ électrique local peut atteindre une valeur considérée comme disruptive. Dans cette situation, on observe un arc de décharge local qui s'oppose au champ appliqué. On qualifie ce phénomène de "charges partielles" car ces charges ne court-circuitent pas l'intégralité de l'isolation [15], [16].

I.11 Causes de défaillances des transformateurs de puissance

Les transformateurs de puissance sont souvent situés dans des endroits stratégiquement critiques. La perte d'un transformateur est évidemment très coûteuse. En générale, les défaillances sont de deux types à savoir : électrique et mécanique. Et pour chaque cas, elles peuvent être internes ou externes. Le tableau 1.1 présente des exemples de causes de défaillance

[8]. Ces causes peuvent survenir également dans la cuve du transformateur, dans le régleur en charge, ou dans l'enroulement.

Causes internes	Causes externes
- Détérioration de l'isolation - Perte de serrage d'enroulement - Contamination solide dans l'huile isolante - Décharge partielle - Défauts de conception et de fabrication	- Surtensions de manœuvres ou atmosphériques - Surcharge - séisme fort - déplacement de transformateur

Tableau I.1 Causes de défaillances des transformateurs[8]

I.12 Défauts fréquents dans les transformateurs

I.12.1 Défaut d'isolement de la partie active

Amorçage entre enroulements normalement isolés est caractérisé par un défaut d'isolement [11].

(La figure 1.7) illustre ce cas de défaut dans les bobinages de transformateur.



Figure I.9 Amorçage entre enroulements [10].

I.12.2 Amorçage diélectrique entre spires

C'est un amorçage entre spires d'un même enroulement, sans que les conducteurs soient mis en court-circuit entre eux (figure 1.8). L'isolant entre ces spires est donc dégradé, voire détruit, localement [11],[9].



Figure I.10 Amorçage entre spires, sans court-circuit [11].

I.12.3 Court-circuit entre spires

Le court-circuit entre spires est caractérisé par le contact électrique entre les spires d'un même enroulement qui devraient être normalement isolées entre elles (Figure 1.9). Cela arrive souvent suite à un amorçage diélectrique entre spires entretenu, ou le déchirement du papier isolant suite à une déformation mécanique violente des enroulements. Ce défaut peut aller jusqu'à la fusion du cuivre des conducteurs, et l'ouverture du circuit électrique dans certains cas [11].



Figure I.11 Court-circuit entre spires [11].

I.12.4 Décharges Partielles

Les décharges partielles, sont un phénomène local de micro décharges dues à une faiblesse de l'isolant. Un exemple entre des cales de bobinages est visible sur la Figure 1.10.

Les décharges en elles-mêmes sont rarement destructives. Mais avec le temps, elle se propager et diminue la tenue diélectrique entre certains éléments sous tension et ainsi aller jusqu'à provoquer un amorçage [10], [12].



Figure I.12 Décharges partielles sur des cales [12].

I.12.5 Coupure du circuit électrique

La plupart des cas de coupure d'un circuit électrique sont le résultat d'un défaut interne [11], [9] comme suit :

- Un amorçage entre spires entraînant une coupe le conducteur
- Mauvais alignement de l'enroulement.



Figure I.13 Coupure suite à la fusion d'un Conducteur[11]

I.12.6 Déformation géométrique des enroulements

Il est fréquemment possible qu'un enroulement de transformateur se déforme, généralement suite à des court-circuit extérieurs qui provoquent des courants extrêmement élevés, qui par voie de conséquence génèrent des forces de Laplace très importantes (Figure 1.12).

Un transformateur avec une telle déformation mécanique ne peut pas fonctionner normalement et dans ces cas nécessite une maintenance urgente [11],[13].



Figure I.13 Déformation mécanique d'un Enroulement [11]

I.14 Conclusion

Les transformateurs de puissance jouent un rôle fondamental dans la transmission et la distribution de l'énergie électrique. Pour garantir leur bon fonctionnement et prévenir les défaillances, des techniques de diagnostic avancées comme l'analyse de réponse en fréquence (FRA) sont utilisées. Cette méthode permet de détecter avec précision les défauts internes, notamment les déplacements d'enroulements ou les courts-circuits. Ainsi, le FRA s'impose comme un outil incontournable pour évaluer l'état de santé des transformateurs et assurer la fiabilité du réseau électrique.

Chapitre II : Analyse de la Réponse Fréquentielle (FRA)

II.1 Introduction

L'état de santé du transformateur est lié à celui de ses enroulements. Tout défaut ou défaillance affectant les enroulements a un impact négatif sur le bon fonctionnement du transformateur. L'une des techniques les plus efficaces pour évaluer l'état des enroulements d'un transformateur de puissance est l'analyse de la réponse en fréquence (FRA). Cette technique permet de détecter les défauts et les anomalies dans les enroulements dans le transformateur de puissance [22].

Ce chapitre est consacré à l'analyse de la réponse en fréquence, en abordant son principe, son objectif et la manière d'interpréter les résultats de cette technique.

II.2 L'Analyse de la Réponse en Fréquence (FRA)

L'analyse de la réponse en fréquence, aussi appelée FRA en anglais (The frequency response analysis) a été introduite dans l'industrie des transformateurs dans les années 1970, notamment grâce aux travaux des ingénieurs E.P. Dick et Clifford C. Erven [23].

FRA est une technique puissante et sensible qui peut donner une indication du mouvement de l'enroulement dans les transformateurs.

La FRA repose sur une mesure simple, tout en regardant à quel point un enroulement de transformateur peut transmettre un signal de faible tension avec une fréquence variable (pouvant aller jusqu'à 1 MHz). Tout cela est lié à son impédance, dont lequel les éléments capacitifs et inductifs sont distribués dans la construction physique du transformateur [24,25,26].

Toute variation ou changement dans la réponse en fréquence signifie qu'il y a un changement physique à l'intérieur de l'enroulement du transformateur. Il est donc nécessaire d'identifier et d'analyser les causes de ces changements [27].

En tenant compte de la construction physique du transformateur qui est basée sur un réseau complexe composé d'une cascade de circuits RLC magnétiquement couplés. Les éléments RLC sont utilisés pour représenter la résistance des enroulements de cuivre, l'inductance des bobines et la capacité pour les couches d'isolation entre les bobines, entre un enroulement et le noyau, entre le noyau et la cuve, etc. [28]

II.3 Principe de la FRA

Un transformateur se compose d'un grand nombre d'éléments passifs (RLC) comme indiqué dans la figure 2.1. Chaque transformateur génère une empreinte digitale ou signature unique lorsque des signaux sont injectés à des fréquences discrètes, et que des réponses sont représentées sous forme de courbe [21,30].




FIGURE II.1 Modèle d'un enroulement de transformateur [31].

Le circuit magnétique d'un transformateur de puissance dépend directement de la configuration géométrique des enroulements ainsi que de la distribution de ses composants, tels que les résistances, les inductances et les capacitances. Ce réseau RLC peut être identifié à l'aide de fonctions de transfert dépendant de la fréquence.

La FRA consiste à injecter un signal d'excitation électrique dans l'un des enroulements sur une large plage de fréquences (méthode de balayage en fréquence). [32]

Toutefois, toute modification de sa configuration entraîne une variation de son impédance ainsi la fonction de transfert. Les changements appliqués à la fonction de transfert permettront de détecter divers types de problèmes. L'utilisation de la mesure FRA permet ainsi de détecter les variations de la fonction de transfert d'un enroulement à l'intérieur du transformateur de puissance, ce qui facilite l'identification d'un déplacement ou d'une déformation dans sa structure[33,34].




FIGURE II.2 : Principe de la FRA [31].

II.4 Objectifs de la FRA

La technique FRA permet d'identifier divers états de défaillance des enroulements d'un transformateur, qu'ils soient d'origine mécanique ou électrique tels que[35]:

- Les déformations ou déplacements des enroulements(radial ou axial).
- Le court-circuit entre spires ou les enroulements ouverts.
- Les défauts dans les connexions
- Les affaissements partiels de l'enroulement.
- Le claquage des enroulements

La mesure par FRA est considérée comme l'une des méthodes les plus efficaces pour détecter les déplacements axiaux et radiaux des enroulements d'un transformateur [36].

II.5 Quand faut-il faire un test FRA [37,38]

Parmi les utilisations courantes de la technique FRA, on peut citer :

- Contrôle du transformateur après le test en court-circuit.
- Vérification de l'intégrité des transformateurs après un transport.
- Evaluation de l'état d'un transformateur ayant été soumise à des courants de défaut . transitoires élevés .
- Mesures de maintenance préventive courantes.

- Analyse consécutive à une alerte ou à l'activation du dispositif de protection du transformateur .
- Le test est effectué après des changements significatifs dans les paramètres surveillés en ligne, tels que la concentration de gaz dissous.
- Inspection approfondie consécutive l'observation de résultats de tests inhabituels.
- Le test est effectué après un séisme.
- Applications dans le cadre de recherches scientifiques.

II.6 Types de connexions FRA

La réponse en fréquence est obtenue en appliquant un signal sinusoïdal de faible tension à fréquence variable à une borne de l'enroulement, puis en mesurant le signal de réponse à l'autre borne du même enroulement. Le rapport de tension entre les signaux de sortie et d'entrée exprimé en décibels (dB) est tracé en fonction de la fréquence. Par ailleurs, la différence d'angle de phase entre les signaux de sortie et d'entrée est représentée par la réponse en angle de phase FRA. Cet essai est le plus couramment employé en raison de sa simplicité et de la possibilité qu'il offre d'analyser chaque enroulement de manière indépendante[39].

- Cependant, les normes internationales [40 ,41] et les brochures techniques du CIGRE [27,42] identifient quatre méthodes de connexion principales, comme le montre la figure2.3. V_s et V_r représentent respectivement la tension source et la tension de réponse. En plus de ces configurations principales, les schémas de mesure FRA peuvent être classés en fonction de différentes conditions de bornes telles que la mise à la terre du neutre. Il est crucial d'utiliser le même schéma de connexion pour obtenir les spectres de référence et de diagnostic. Il est fondamental d'adopter le même schéma de connexion lors de l'obtention des spectres de référence et de diagnostic pour chaque phase de l'enroulement du transformateur.




FIGURE II.3 Schémas de connexion pour les mesures FRA [42]

Facteurs	Commentaires
Câbles d'essai	Il est recommandé d'utiliser des câbles haute fréquence d'une impédance de 50 Ω . Le fil d'extension doit être bien serré le long de la traversée (Bushing en anglais).
Mesurée l'impédance	En pratique, il n'y a pas une valeur spécifique pour l'impédance spécifique soit bénéfique pour détecter la déformation des enroulements. Une impédance de 50 Ω est recommandée pour schéma de terminaison plus simple. Il est essentiel d'utiliser la même impédance de mesure pour les mesures de référence et de diagnostic.
Fréquence maximale Pour l'interprétation	La fréquence maximale peut être indiquée par le point où deux résultats mesurés s'écartent l'un de l'autre lorsque les mesures sont répétées.
Facteurs influençant les résultats de mesure	direction d'injection, conditions des autres bornes, impédance du câble

Exigences de l'équipement	Auto-étalonnage avant le test pour vérifier le système de mesure, une résolution en fréquence de plus de 200 points par décade devrait être fournie, une plage d'amplitude de -100 dB à 20 dB devrait être fournie pour couvrir tous les cas.	
Les caractéristiques des différents schémas de Connexion	Essais en circuit ouvert (End-to-end open circuit)	Simple et efficace pour détecter chaque enroulement Individuellement
	Essais en court-circuit (End-to end-short circuit)	similaire au test de circuit ouvert de bout en bout, mais l'influence de l'inductance magnétisante du noyau du transformateur sera éliminée, par exemple parfois le flux résiduel peut avoir un impact sur les résultats
	Essai capacitif entre enroulements (Capacitive interwinding)	le test donne un effet plus dominant à la capacité entre les enroulements, ne convient pas à l'autotransformateur
	Essai inductif entre enroulements (Inductive interwinding)	le test donne un effet plus dominant à l'inductance mutuelle entre les enroulements, Ainsi, le rapport de transformation devient un facteur clé dans la région des basses fréquences.

Tableau II.1 cas pratiques de mesure FRA [42]

II.7 Zones de fréquences d'analyse FRA

Le tableau 2.2 représente le champ d'interprétation en tenant compte des contraintes liées à la géométrie des installations d'essai. À basses fréquences, la courbe peut être modifiée par la présence de spires en court-circuit, par l'aimantation ou par des défauts dans le noyau magnétique. Les fréquences moyennes permettent généralement de détecter des déplacements axiaux ou radiaux des enroulements. Enfin, les hautes fréquences mettent en évidence des défauts au niveau des connexions, des traversées ou des changeurs de prise[31].

Plage de fréquence	Défauts
$F < 2000\text{Hz}$	• Magnétisme résiduel • Déformations du noyau
$2000\text{Hz} < F < 20\text{KHz}$	• Circuits ouverts • Court-circuit entre spires
$20\text{KHz} < F$	• Déplacement relatifs entre les enroulements
$200\text{KHz} < F < 2\text{MHz}$	• Déformations de l'enroulement
$2\text{MHz} < F < 10\text{MHz}$	• Disposition de couplages et câbles de mesure.

Tableau II.2 Domaines typiques d'interprétation de la méthode FRA [31]

II.8 Interprétation de la méthode

La FRA est une méthode comparative permettant d'évaluer l'état des enroulements des transformateurs de puissance. En se basant sur la comparaison de l'état actuel et ancien du transformateur[31], on distingue les différents type d'évaluation :

- **Evaluation par les empreintes digitales :** Une empreinte digitale est généralement obtenue lors du contrôle de réception en usine, ce qui peut être considéré comme la référence la plus fiable pour l'évaluation du test de FRA. Si les conditions techniques du test sont strictement respectées et qu'aucune modification n'est survenue sur le transformateur, il est probablement possible d'obtenir des résultats de test FRA identiques..
- **Comparaison entre des transformateurs jumeaux:** Il n'est pas toujours possible d'obtenir les résultats de l'empreinte digitale pour interpréter les tests FRA. Toutefois, les transformateurs conçus et assemblés de manière identique présentent généralement la même empreinte de référence. Les transformateurs jumeaux peuvent présenter de légères différences, qui sont dues aux tolérances et aux effets liés à la magnétisation du noyau lors de la fabrication.
- **Comparaison entre phases des enroulements du transformateur :** Si une empreinte digitale de référence n'est pas disponible, nous utilisons cette méthode pour l'obtenir. Cette

méthode consiste à comparer les différentes phases du transformateur afin d'obtenir une empreinte de référence.

II.9 Conclusion

Dans ce chapitre, nous avons introduit les concepts de base liés à la technique FRA, notamment son principe, ses objectifs, les différents types de connexion, ainsi que le domaine d'interprétation.

En effet, pour améliorer l'interprétation des résultats de FRA, il est souhaitable d'utiliser une technique avancée basée sur les indices mathématiques, cette dernière représente une contribution principale dans ce travail

Chapitre III: Interprétation des résultats FRA a l'aide des indicateurs mathématiques

III.1 Introduction


Le test FRA est l'une des techniques les plus fiables pour la détection précoce des défauts d'enroulement dans les transformateurs de puissance[41]. Cependant, l'interprétation des courbes de réponse produites par ce test nécessite un haut degré d'expérience et de précision, en raison de la complexité de la forme du signal et des multiples facteurs qui l'influencent[43]. Afin de surmonter la nature subjective de l'interprétation visuelle traditionnelle et d'obtenir une évaluation plus objective et plus précise, des indicateurs mathématiques ont été adoptés comme outils d'analyse quantitative qui aident à extraire des informations précises des signaux FRA mesurés.

Ce chapitre est consacré à la présentation des indices mathématiques exploités dans le cadre de cette étude. Il décrit les principes de calcul de chaque indicateur, leur utilisation dans l'analyse des réponses en fréquence (FRA), ainsi que leurs avantages et inconvénient.

III.2 Les indicateurs mathématiques

Dans le cadre du diagnostic des enroulements des transformateurs de puissance par analyse de réponse en fréquence (FRA), les indicateurs mathématiques sont utilisés pour quantifier les différences entre des courbes mesurées dans différents états (sain, défectueux). Leur rôle est d'améliorer la sensibilité et l'objectivité de la détection des défauts d'enroulement en remplaçant l'analyse visuelle traditionnelle par une analyse mathématique précise[43,44].

Les indicateurs numériques sont couramment utilisés pour évaluer l'état de santé des transformateurs [45]. Pour appliquer cette méthodologie, un indice mathématique est extrait de deux traces de test FRA : la première trace représente la mesure du courant, tandis que la deuxième trace est utilisée comme empreinte de référence précédemment enregistrée pour le même enroulement. La trace produite par une phase différente du même transformateur ou d'un transformateur similaire peut également être utilisée comme référence pour la comparaison [45]. En revanche, certains chercheurs proposent des modèles pour estimer les effets des tests FRA à l'aide de fonctions proportionnelles, puis dérivent des indicateurs numériques basés sur les changements de positions des pôles ou des coefficients du numérateur et du dénominateur, afin d'évaluer le niveau de distorsions dans les enroulements du transformateur [46,47].



FigureIII . 1Utilisation d'un indice numérique pour évaluer l'état des enroulements du transformateur. [44].

Après le calcul de la valeur de l'indicateur numérique à partir des courbes FRA, celle-ci est comparée à un seuil de référence prédéfini.

Si la valeur de l'indicateur dépasse ce seuil, cela traduit un écart significatif par rapport à l'état de référence, ce qui peut indiquer un défaut ou une déformation au niveau des enroulements.

En revanche, si la valeur reste en dessous du seuil, le comportement est considéré comme normal, suggérant que les enroulements sont en bon état.

III.2.1 Les indices extraits directement des vecteurs FRA

Les enregistrements de FRA sont représentés en termes de magnitude et de vecteur de phase, contenant des éléments distincts où chaque élément correspond à un échantillon de fréquence. Il est important de préciser que les échantillons de fréquence peuvent être distribués de manière linéaire ou logarithmique sur la gamme de fréquences définie dans une méthode standard pour uniformiser les indices. Tous les indices suivants sont calculés sur la base de leurs vecteurs de magnitude[44] .

Le tableau III.1 présente une liste des indicateurs extraits directement des vecteurs FRA utilisés dans cette étude :

Abrév.	Eq.num	Définition (français)	Définition (anglais)	Références
ED	(1)	Distance euclidienne	Euclidean Distance	[48,49]
SD	(2)	Écart-type	Standard Deviation	[50,51]
DABS	(3)	Différence absolue	Absolute difference	[52,53,54]
ASLE	(4)	Somme absolue de l'erreur logarithmique	Absolute Sum of Logarithmic Error	[51,55]
SDA	(5)	Zone de différence normalisée	Standardized Difference Area	[56]
RMSE	(6)	Erreur du carré moyen de la racine	Root Mean Square Error	[57]
σ	(7)	Déviaton du spectre	Spectrum deviation	[58,59]
ρ	(8)	Coefficient de corrélation normalisé	Normalized correlation coefficient	[56,60,61]
CC	(9)	Coefficient de corrélation	Correlation Coefficient	[48,62,63]
SSE	(10)	Erreur de somme au carré	Sum Squared Error	[49,55,64]
SSRE	(11)	Erreur de somme du rapport au carré	Sum Squared Ratio Error	[48 ,49,55]
SSMMRE	(12)	Erreur de rapport entre la somme au carré et le maximum	Sum Squared Max-Min Ratio Error	[55]

Tableau III.1 – Abréviations des indices extraits directement des vecteurs FRA[44]

Dans les équations qui suivent, Y et X désignent respectivement les vecteurs de magnitude de la nouvelle trace FRA et de son empreinte de référence. Les termes Y(i) et X(i) représentent les éléments individuels de ces vecteurs, et correspond au nombre total d'échantillons constituant chaque vecteur de trace FRA[44].

$$ED = \|X - Y\| = \sqrt{\sum_{i=1}^N (Y(i) - X(i))^2}, \quad (1)$$

$$SD = \sqrt{\frac{\sum_{i=1}^N (Y(i) - X(i))^2}{N - 1}} \quad (2)$$

$$DABS = \frac{\sum_{i=1}^n |y(i) - x(i)|}{N}, \quad (3)$$

$$ASLE = \frac{\sum_{i=1}^N |20 \log_{10} Y(i) - 20 \log_{10} X(i)|}{N}, \quad (4)$$

$$SDA = \frac{\int |y(f) - x(f)| df}{\int |x(f)| df}, \quad (5)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\frac{|Y(i)| - |X(i)|}{\frac{1}{N} \sum_{i=1}^N |X(i)|} \right)^2}, \quad (6)$$

$$\sigma = \frac{1}{N} \sum_{i=1}^N \times \sqrt{\left(\frac{X(i) - (X(i) + Y(i))/2}{(X(i) + Y(i))/2} \right)^2 + \left(\frac{Y(i) - (X(i) + Y(i))/2}{(X(i) + Y(i))/2} \right)^2} \quad (7)$$

$$\rho = \frac{\sum_{i=1}^N X^*(i)Y^*(i)}{\sqrt{\sum_{i=1}^N [X(i)]^2 \sum_{i=1}^N [Y(i)]^2}}, \quad (8)$$

$$cc = \frac{\sum_{i=1}^N X(i)Y(i)}{\sqrt{\sum_{i=1}^N [X(i)]^2 \sum_{i=1}^N [Y(i)]^2}}, \quad (9)$$

$$SSE = \frac{\sum_{i=1}^N (Y(i) - X(i))^2}{N}, \quad (10)$$

$$SSRE = \frac{\sum_{i=1}^N \left(\frac{Y(i)}{X(i)} - 1 \right)^2}{N}, \quad (11)$$

$$SSMMRE = \frac{\sum_{i=1}^N \left(\frac{\max(Y(i), X(i))}{\min(Y(i), X(i))} - 1 \right)^2}{N}, \quad (12)$$

Les indices présentés ici sont obtenus directement à partir des courbes FRA, sans nécessiter de traitement complexe, ce qui les rend particulièrement simples à utiliser. Les données de magnitude utilisées pour leur calcul peuvent être exprimées soit sous leur forme d'origine, soit converties en échelle décibels (dB). La plupart des études utilisent l'échelle dB, mais les valeurs brutes peuvent aussi être utilisées, bien que cela produise des résultats différents. C'est pourquoi il est important, dans toute méthode standardisée, d'indiquer clairement le type d'échelle utilisé. À ce jour, il n'existe pas d'étude montrant qu'une échelle est systématiquement meilleure que l'autre[44].

Un autre point à souligner est que dans le cas d'un transformateur intact, la plupart de ces indices prennent une valeur égale à zéro. Il y a toutefois une exception : les indices **CC** et **ρ** , qui prennent alors la valeur un.[56] Pour faciliter la comparaison entre tous les indices, on peut choisir d'utiliser **$1 - CC$** et **$1 - \rho$** , ce qui permet d'avoir une valeur nulle pour tous les indices lorsque la nouvelle courbe FRA correspond parfaitement à la courbe de référence.[67]

Il existe également deux autres indices appartenant à cette famille, basés cette fois sur des tests statistiques : le **test T**[67] et le **test F**[68] Ces tests servent à vérifier une hypothèse nulle, c'est-à-dire à évaluer si la nouvelle trace FRA est suffisamment proche de la référence. Le test T s'intéresse aux moyennes, tandis que le test F examine les écarts de variances entre les deux courbes. Le test T utilise une distribution dite "T de Student", alors que le test F repose sur une distribution "F de Fisher". Dans les deux cas, le nombre de degrés de liberté joue un rôle important pour juger si la différence observée est statistiquement significative. En clair, ces tests permettent de fixer un seuil à partir duquel on peut estimer qu'une différence entre les courbes est normale ou, au contraire, révélatrice d'un défaut. Les résultats de ces indices varient généralement entre 0 et 1, et La formule correspondante pour calculer la probabilité distribution, et les degrés de liberté sont donnés [54] et mise en œuvre dans des logiciels numériques comme MATLAB.

III.2.2 Les indices basés sur les points de résonance et d'anti-résonance

Lorsqu'on observe une courbe FRA, on remarque plusieurs sommets et creux : ce sont ce qu'on appelle les points de résonance et d'anti-résonance, selon les termes employés dans la littérature. Les indices présentés ici s'appuient précisément sur ces points, en tenant compte à la fois de leur amplitude et de leur fréquence. Pour pouvoir les calculer correctement, il est donc essentiel de commencer par repérer ces pics et creux sur la courbe. Une fois ces points identifiés, on peut appliquer les formules associées aux différents indices[44].

Abrév.	Eq.num	Définition (français)	Définition (anglais)	Références
MAD	(14)	Écart d'amplitude moyenne	Mean Amplitude Deviation	[61]
MFD	(15)	Écart de fréquence moyenne	MeanFrequencyDeviation	[61]
IAD	(16)	Indice de déviation d'amplitude	Index of Amplitude Deviation	[56,65]
IFD	(17)	Indice de déviation de fréquence	Index of FrequencyDeviation	[56,65]
F _a	(18)	Fonction d'amplitude	Amplitude Function	[66]
F _f	(19)	Fonction de fréquence	FrequencyFunction	[59]

Tableau III.2 Abréviations des indices basés sur les points de résonance et d'anti-résonance [44]

Dans ces formules, les lettres Y et X font référence, respectivement, à la nouvelle trace FRA à analyser et à la trace de référence (celle de l'état sain du transformateur). On utilise ensuite A(i) pour désigner l'amplitude et f(i) pour la fréquence du i^e point de résonance ou d'anti-résonance. Enfin, la variable AF représente l'aire située sous la courbe FRA entre deux points d'anti-résonance successifs, comme expliqué dans la référence [61]

$$\mathbf{MAD} = \frac{1}{k} \sum_{i=1}^k |A_y - A_x(i)|, \quad (13)$$

$$\mathbf{MFD} = \frac{1}{k} \sum_{i=1}^k |f_y(i) - f_x(i)|, \quad (14)$$

$$\mathbf{IAD} = \sum_{i=1}^k \left| \frac{A_y(i) - A_x(i)}{A_x(i)} \right|, \quad (15)$$

$$\mathbf{IFD} = \sum_{i=1}^k \left| \frac{f_y(i) - f_x(i)}{f_x(i)} \right|, \quad (16)$$

$$\mathbf{Fa} = \sum_{i=1}^k \frac{A_y(i)}{A_x(i)}, \quad (17)$$

$$\mathbf{Ff} = \sum_{i=1}^k \frac{fy(i)}{fx(i)}, \quad (18)$$

L'équation (12) peut être mise en œuvre uniquement pour la résonance points ou pour la résonance et l'anti-résonance points.




Figure III.2 Points de résonance et d'anti-résonance dans une trace FRA [69]

Par conséquent, une méthode normalisée devrait déclarer si les deux points de résonance et anti-résonance ou seulement les points de résonance sont utilisés dans le calcul des indices la Figure IV.2 illustre une trace de FRA mesurée à partir d'un échantillon 6 kV/400 V, DYn 600 kVA transformateur moyenne tension [69]. Les points de résonance et d'anti-résonance sont indiqués sur la trace. L'identification des maxima et minima locaux, respectivement appelés points de résonance et points d'anti-résonance, dans une trace FRA, constitue une opération particulièrement sensible du processus de diagnostic. En effet, la précision de cette détection a une influence directe sur la fiabilité des indices dérivés. Comme le montre la Figure III.1, une amplification de la courbe en fin de bande fréquentielle révèle une ambiguïté dans la localisation

exacte du minimum : il devient difficile de déterminer si le point 1 ou le point 2 correspond effectivement à un point d'anti-résonance [44].

Ce type d'incertitude est d'autant plus problématique que le bruit de mesure, inévitable dans les environnements industriels, peut altérer subtilement la morphologie du signal, entraînant un déplacement artificiel des extrema. Cette sensibilité est particulièrement critique dans les cas de déformations mineures des enroulements du transformateur, où les variations entre la trace FRA actuelle et la trace de référence sont minimales, voire marginales. Dans ces situations, un simple glissement d'un point caractéristique peut être interprété de manière erronée comme une altération structurelle, menant à une fausse détection de défaut [44].

Par conséquent, toute méthodologie de traitement des données FRA se doit d'intégrer une procédure normalisée et reproductible pour l'extraction des points de crête et de dépression, de manière à limiter les biais liés aux erreurs de détection. En complément, l'adjonction d'un algorithme de débruitage efficace, tel que suggéré dans [70], s'avère hautement recommandée. Une telle approche permettrait d'atténuer l'influence du bruit haute fréquence ou des artefacts de mesure, et de garantir une robustesse accrue des indices dérivés à partir des caractéristiques locales de la courbe FRA.

III.3 Avantages des indicateurs mathématiques[71,72]

Les indices de corrélation mathématique permettent de traduire les différences entre les réponses en fréquence en valeurs numériques comparables, ce qui aide à identifier facilement les défauts.

L'utilisation d'indicateurs numériques réduit les évaluations personnelles et l'expérience subjective nécessaires pour interpréter les courbes.

Le calcul des indicateurs est rapide et ne nécessite pas d'équipement complexe.

Les indicateurs fournissent des entrées idéales pour les modèles d'apprentissage automatique, améliorant la classification et la précision du diagnostic.

III.4 Inconvénients des indicateurs mathématiques[73,74]

Certains indicateurs sont affectés par un bruit élevé ou des erreurs d'enregistrement mineures, ce qui réduit la précision du diagnostic.

Généralement, les indicateurs nécessitent des seuils de référence précis, qui varient d'un transducteur à l'autre, ce qui ne permet pas de généraliser.

Le changement numérique de l'indicateur n'indique pas toujours la nature ou l'emplacement du défaut dans l'enroulement.

III.4 Conclusion

Dans ce chapitre, nous présentons un ensemble d'indicateurs mathématiques conçus pour diagnostiquer les enroulements de transformateur, en soulignant leurs utilisations, leurs propriétés et leurs inconvénients.

Dans le chapitre suivant, la machine à vecteurs de support (SVM) sera utilisée indépendamment pour classer et diagnostiquer les défauts des enroulements du transformateur.

ChapitreIV: Diagnostic par apprentissage

IV.1 Introduction

L'essor massif (big data) des données numériques et l'évolution rapide des capacités informatiques ont favorisé l'émergence des techniques d'apprentissage automatique, qui ont acquis une importance significative dans le domaine de l'ingénierie. Ces techniques ont permis aux ingénieurs et aux chercheurs d'analyser avec précision les systèmes complexes et de prendre des décisions plus stratégiques.

Aujourd'hui, l'apprentissage automatique se présente comme une solution novatrice pour le diagnostic des défauts, notamment dans les systèmes complexes tels que les données FRA pour les enroulements de transformateur [75].

Un algorithme d'apprentissage automatique est un outil capable d'analyser de grandes quantités de données et d'automatiser le développement des modèles. Cette approche permet d'améliorer la précision du diagnostic et les stratégies de maintenance [75].

Ce chapitre présente l'algorithme de la machine à vecteurs de support (SVM) et son application à l'interprétation des résultats de l'analyse de la réponse en fréquence (FRA) et classification des défauts dans les enroulements du transformateur de puissance.

IV.2 Machine Learning (Apprentissage Automatique)

La Machine Learning ou l'apprentissage Automatique est une branche de l'intelligence artificielle qui vise à faire des prédictions et des déductions à partir d'un ensemble de données. Il peut parfois être confondu avec la programmation classique, mais il ne nécessite pas d'algorithme explicite pour apprendre. Il détecte plutôt les similitudes et les motifs dans un ensemble de données donné et utilise ces connaissances pour interpréter les données futures [76,77,78].

L'apprentissage automatique se concentre sur les algorithmes et les modèles qui permettent aux ordinateurs d'apprendre à partir de données, de faire des prédictions et de prendre des décisions sans avoir besoin d'une programmation explicite pour des tâches spécifiques. L'objectif principal de l'apprentissage automatique est de reconnaître des modèles et d'extraire des informations significatives, ce qui permet d'améliorer les performances et la prise de décision sur la base des données analysées avec un minimum d'intervention humaine [77,79,80,81,82].

IV.3 Raison de l'utilisation de Machine Learning dans les interprétations

FRA

L'association des méthodes de FRA et de Machine Learning (ML) peut offrir une stratégie plus solide pour le diagnostic des défauts de transformateur, car elle répond aux contraintes significatives. L'interprétation des résultats de la méthode FRA exige une expertise poussée. La variabilité de la fonction de transfert selon divers types et conditions de défaut rend complexe l'harmonisation du processus d'interprétation, qui est fréquemment subjectif et incohérent. Diverses erreurs peuvent avoir divers impacts sur les signatures de la FRA, rendant leur interprétation encore plus complexe [83].

Les algorithmes de ML sont formés à partir de vastes ensembles de données provenant de différents scénarios de panne, qui sont issus d'expériences ou de modèles de simulation [80]. Avec un entraînement adéquate sur des données, les modèles de ML sont en mesure d'apprendre à déceler des motifs et des corrélations dans les signatures de FRA qui ne sont pas immédiatement apparentes pour les spécialistes humains. Cela facilite l'identification des anomalies et même la définition de leur nature et position avec une précision dépassant souvent 98 % [84].

IV.4 Support Vector Machine (SVM)

L'algorithme des machines à vecteurs support ou séparateurs à vastes marges (en anglais Support Vector Machines, SVM) a été proposé pour la première fois en 1992 par V. Vapnik [10,78] comme méthode d'apprentissage supervisé principalement pour les tâches de classification. Cette technique, qui est classée comme une méthode de classification binaire, vise à trouver un hyperplan qui sépare les classes de manière optimale. Cette méthode est basée sur la maximisation de la distance ou marge entre l'hyperplan et ses points les plus proches dans chaque classe, ces points étant appelés vecteurs de support. Cet hyperplan divise l'espace de données en deux régions distinctes, permettant de distinguer les classes. Cet algorithme peut désormais être utilisé dans des tâches de régression dont l'objectif principal est de déterminer un hyperplan qui offre la plus grande marge possible. Plus la marge est importante, plus la capacité de généralisation est grande et plus la probabilité d'erreur lors de la classification de nouvelles données est faible. La figure ci-jointe montre un exemple de cas linéairement séparable, avec trois points sur la limite de la marge, représentant les vecteurs de support [78, 79, 86, 87, 88, 89].




Figure IV.1: L'algorithme Support Vector Machine [89]

IV.5 SVM multi-classes

Dans les applications pratiques, la plupart des problèmes de classification concernent plus de deux classes. Pour résoudre ce problème, on utilise une machine à vecteurs de support multi-classes, qui repose sur trois stratégies : « tous avec tous » (en anglais : all-together), « un contre un » (one-vs-one) et « un contre tous » (one-vs-all). La stratégie « un contre un » permet d'obtenir une plus grande précision et nécessite moins de vecteurs de support, et par conséquent réduit le temps de calcul. Elle est donc préférable aux autres stratégies[90]. Dans cette étude, un modèle de machine à vecteurs supports (SVM) multi-classes a été entraîné avec une technique « un contre un ».

La stratégie un-contre-un a été initialement présentée par Knerr et al [91]. Elle a été associée à SVM pour la première fois par Mayoraz et Alpaydin [90]. Dans cette approche, on construit un premier ensemble de classifieurs binaires, puis un second, et ainsi de suite. Chaque classifieur est entraîné à partir des données de seulement deux classes à la fois. Le problème de classification multi-classes est décomposé en plusieurs sous-problèmes de classification binaire, chacun ayant sa propre fonction de décision. Cette méthode permet de simplifier le processus tout en assurant une bonne séparation entre les classes. En fait, la stratégie un-contre-un représente un cas spécial des méthodes de décomposition proposée par Dietterich et al [91] pour résoudre le problème de multi-classes.




Figure IV.2 La stratégie un-contre-un [92]

Dans La stratégie un-contre-un, nous cherchons à identifier l'hyperplan qui sépare chaque paire de classes, en ignorant les points de la troisième classe. Par exemple, dans la figure IV.2 la ligne rouge-bleu maximise la séparation uniquement entre les points bleus et rouges, sans prendre en compte les points verts[92].

IV.6 Noyaux dans la machine à vecteurs de support(Kernels in SVM)[93]

L'une des fonctionnalités les plus intéressantes de l'algorithme SVM est qu'il peut gérer des données non linéaires grâce à ce que l'on appelle l'astuce du noyaux(kernel trick), qui permet une classification plus facile des points. L'espace de faible dimension est transformé en un espace de dimension supérieure à l'aide de fonctions (souvent quadratiques) qui permettent de trouver des limites de décision plus claires. Ces fonctions sont appelées « noyauxKernels ».

IV.6.1 Types de noyau dans SVM[94]

Voici quelques types courants de noyaux dans les algorithmes de SVM:

- **Noyau linéaire (LinearKernel) :** Il est utilisé lorsque les données sont linéairement séparables. Il calcule le produit scalaire entre les vecteurs de caractéristiques d'entrée.
- **Noyau polynomiale(Polynomial Kernel) :** il est utilisé pour les données non linéaires. Ce noyau permet de mapper les vecteurs de caractéristiques d'entrée vers un espace de dimension supérieure à l'aide de fonctions polynomiales, ce qui permet au modèle d'apprendre les limites de décision non linéaires entre les classes.

- **Noyau de fonction de base radiale (Gaussian or RBF) :** Le noyau de fonction de base radiale est appelé Radial Basis Function Kernel (RBF) en anglais. Il est utilisé pour gérer des données non linéaires en mappant les vecteurs de caractéristiques d'entrée dans un espace de caractéristiques de dimension infinie. Ce noyau est efficace lorsque les limites de décision sont complexes ou mal définies.

IV.6.2 Choix de noyaux

Le choix du noyau est très important. La fonction la plus courante pour les données telles que les données FRA est la fonction de base radiale (RBF) [95].

La fonction RBF s'exprime comme suit [16]:

$$K(x, x') = \exp(-\gamma ||x - x'||^2) \quad (4.1)$$

Dont lequel il est spécifié par le paramètre gamma, doit être supérieur à 0.

x, x' : vecteurs d'entrée dans l'espace des caractéristiques

V.6.3 Hyper-paramètres de RBF [89]

Lors de l'utilisation du noyau RBF (Radial Basis Function) avec l'algorithme SVM, seuls deux hyperparamètres doivent être définis :

C : c'est un hyperparamètre commun à tous les noyaux des machines à vecteurs de support (SVM). Il est utilisé pour équilibrer les erreurs de classification lors de l'entraînement et simplifier la surface de décision. Si le **C** est élevé, on choisira un hyperplan à plus petite marge afin d'améliorer la précision de la classification. Inversement, une valeur faible de **C** permet d'obtenir une surface de décision lisse, mais peut augmenter les erreurs de classification.

γ : Ce paramètre n'est utilisé que lorsque le noyau choisi est un noyau RBF. Le paramètre gamma définit l'ampleur de l'influence d'un seul exemple d'entraînement. Une valeur élevée de gamma implique que seuls les points situés à proximité de l'hyperplan sont pris en compte, tandis qu'une valeur plus faible permet de considérer également les points à plus grande distance. Le choix des paramètres **C** et gamma est très important, en particulier dans les données non linéaires et complexes telles que les données FRA.

V.7 Avantages et inconvénients des machines à vecteurs de support [89,96]

Les avantages des machines à vecteurs de support sont les suivants :

- SVM est un algorithme qui offre une grande précision dans la prédiction.
- Efficaces dans les espaces à haute dimension.
- Plus efficace car ils utilisent un sous-ensemble de points d'entraînement.
- Utilisation de différents noyaux pour gérer les données non linéaires.
- Réduire le risque de sur apprentissage des données.

Les inconvénients des machines à vecteurs de support sont les suivants:

- Il est difficile d'interpréter les résultats de l'analyse du SVM.
- Cette solution n'est pas adaptée aux grands ensembles de données, car le temps d'entraînement avec les SVM peut s'avérer trop long.
- Lorsque du bruit et des valeurs aberrantes sont présents dans les ensembles de données, cet algorithme est moins efficace.
- Choisir la bonne fonction de noyau peut parfois être difficile.

IV.8Modèle SVM pour diagnostic les enroulements des transformateurs

IV.8.1 Préparation des données

Ce processus comprend la préparation des données FRA de l'enroulement du transformateur dans l'état sain et l'état défectueux. Ces données comprennent deux grandeurs de base, à savoir la fréquence, exprimée en Hertz(Hz), et l'impédance, exprimée en décibels(DB). Les données sont classifiées en attribuant, par exemple, la valeur zéro à un cas sain et la valeur un à un cas présentant un défaut. En présence de plusieurs types de défaut, chaque type se voit attribuer une classe spécifique permettant de distinguer les différentes catégories de défaut.

IV.8.2 Division des données

Cette étape est très importante pour entraîner un modèle SVM. Les données sont divisées en deux ensembles : un ensemble d'entraînement et un ensemble de test. Cette séparation est nécessaire pour que le modèle SVM puisse bien généraliser et donner des résultats fiables avec de nouvelles données. En absence de cette division, le modèle risque de surprendre les données d'entraînement (phénomène de sur apprentissage), ce qui pourrait entraîner une dégradation de ses performances lorsqu'il sera confronté à de nouvelles données.

Dans cette étude, nous avons divisé les données FRA en 80% pour l'entraînement et 20% pour le test. À partir de l'ensemble de l'entraînement, le modèle SVM apprend les motifs et les relations caractéristiques pour les différentes conditions des enroulements, qu'ils soient

sains ou défectueux pour pouvoir prédire ultérieurement l'état des nouvelles données. L'ensemble de test est utilisé pour évaluer les performances du modèle et sa capacité à généraliser et à gérer avec précision de nouvelles données.

IV.8.3 Extraction des caractéristiques statistiques de chaque échantillon

Dans cette étape, nous extrayons certaines caractéristiques statistiques de chaque échantillon des données FRA, ce qui aide le modèle SVM à distinguer plus efficacement les différents états du transformateur (sain et défectueux).

Les caractéristiques statistiques extraites sont : Moyenne arithmétique, écart type, valeur maximale, valeur minimale, Étendue (range) et Valeur quadratique moyenne

IV.8.4 Entraînement sur la base de SVM

Dans le cadre du diagnostic des défauts dans les enroulements du transformateur de puissance à l'aide des données FRA, le modèle SVM est entraîné à l'aide d'un ensemble de données contenant diverses données issues de différents états de l'enroulement (état sain ou défectueux).. Il est ainsi capable d'apprendre les motifs et les relations caractéristiques associés à chaque état. Un ensemble de test est effectué à la fin pour évaluer la capacité à classer correctement les états sains et défectueux, et à tracer avec précision les frontières de décision entre les différentes classes.

Le choix du noyau est très important, car il aide à trouver le meilleur hyperplan séparant les classes saines et défectueuses. Dans cette étude, le noyau RBF a été utilisé car il correspond à la nature des données FRA. Deux hyper paramètres (C et γ) de ce noyau ont été réglés afin d'optimiser les performances du modèle SVM.

Dans cette étape, l'algorithme SVM standardise automatiquement les données pour garantir qu'aucune fonctionnalité ne domine les autres lors de l'entraînement du modèle.

IV.8.5 Évaluation des performances du modèle

L'évaluation des performances du modèle est une étape essentielle dans tous les algorithmes d'apprentissage automatique. Il s'agit de déterminer la capacité du modèle à généraliser et à prédire l'état de l'enroulement du transformateur électrique sur la base de nouvelles données qu'il n'a pas encore vues. Dans ce travail, plusieurs métriques ont été utilisées pour évaluer les performances du modèle, notamment :

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

La matrice de confusion est un outil efficace pour évaluer la performance du modèle. Cette matrice nous permet de comprendre quels types d'erreurs le modèle commet et dans quelle mesure il est capable de distinguer les différentes classes.

Dans le cas d'une classification binaire, la matrice de confusion est la suivante :

Classe réelle	Classe prédite	
	Classe 0	Classe 1
	Classe 0	Classe 1
Classe 0	VN	FP
Classe 1	FN	VP

TableauIV.1 :Matrice de confusion

Avec :

-Classe 0 : enroulement sain

-Classe 1 : enroulement défectueux

-**Vrai positif (VP)** : le nombre de cas où l'enroulement était défectueux et le modèle a correctement prédit.

-**Vrai négatif (VN)**:le nombre de cas où l'enroulement était sain et le modèle a correctement prédit.

-**Faux positif (FP)** : Le nombre de cas où l'enroulement était sain, mais le modèle l'a prédit comme étant défectueux.

-**Faux négatif (FN)** : Le nombre de cas où l'enroulement était défectueux, mais le modèle a prédit comme sain.

Dans le cas d'une classification multi-classes, comme c'est le cas pour la classification des défauts d'enroulement des transformateurs électriques, la matrice de confusion est étendue pour inclure toutes les classes possibles, ce qui permet une analyse plus précise des performances du modèle.

La précision :elle exprime le pourcentage de prédictions positives correctes sur le total des prédictions positives faites par le modèle.

$$\text{Précision}(i) = \frac{VP(i)}{VP(i) + FP(i)} \quad (4.2)$$

Avec :

i : représentant l'indice d'une classe spécifique, il s'applique à chaque classe dans un problème de classification multi-classes.

Le rappel (sensitivity):elle exprime le pourcentage de prédictions positives correctes par rapport au nombre total de cas vraiment positifs.

$$\text{Rappel}(i) = \frac{VP(i)}{VP(i) + FN(i)} \quad (4.3)$$

avec :

i : représentant l'indice d'une classe spécifique, s'applique à chaque classe dans un problème de classification multi-classes.

F1-score :C'est une combinaison de précision et de rappel. Il est calculé pour refléter l'équilibre entre précision et rappel.

$$\text{F1-score}(i) = \frac{2 * \text{Précision}(i) * \text{Rappel}(i)}{\text{Précision}(i) + \text{Rappel}(i)} \quad (4.4)$$

Avec :

i : représentant l'indice d'une classe spécifique, s'applique à chaque classe dans un problème de classification multi-classes.

Accuracy: « Accuracy » est une mesure utilisée pour évaluer les performances globales de classification d'un modèle. Elle exprime le rapport entre les prédictions correctes (qu'elles soient positives ou négatives) et le nombre total de prédictions effectuées.

$$\text{Accuracy} = \frac{\sum_i^N (VP(i) + VN(i))}{\sum_i (VP(i) + VN(i) + FP(i) + FN(i))} \quad (4.5)$$

Avec:

i : représentant l'indice d'une classe spécifique, s'applique à chaque classe dans un problème de classification multi-classes.


N :est le nombre de classes classés dans le modèle.

IV.8.6 Outil utilisé

Le MATLAB (Matrix Laboratory) est un environnement de programmation très puissant largement utilisé dans les domaines de l'ingénierie et des sciences appliquées. MATLAB se caractérise par sa capacité à gérer facilement des matrices et des données complexes. Il est utilisé dans des domaines tels que l'analyse numérique, la visualisation graphique, le traitement du signal et l'apprentissage automatique. MATLAB est le Bon choix pour l'entraînement des modèles d'apprentissage automatique. En raison de la disponibilité de bibliothèques, telles que *Statistics and Machine Learning Toolbox*, qui prennent en charge directement diverses techniques d'apprentissage supervisé et non supervisé.

Dans cette étude, nous avons choisi d'utiliser MATLAB pour entraîner un modèle de Machine à Vecteurs de Support (SVM) en vue de diagnostiquer les défauts dans les enroulements des transformateurs de puissance.

IV.9 Organigramme de SVM



FigureIV.3 : Organigramme générale de l'algorithme SVM

IV.10 Conclusion

Ce chapitre a présenté l'algorithme des machines à vecteurs de support (SVM) et exploré son application à l'interprétation des résultats de l'analyse de la réponse en fréquence (FRA) des transformateurs de puissance. L'intégration des SVM dans ce contexte offre une approche prometteuse pour améliorer la détection et la classification des défauts internes des transformateurs.

Chapitre V : Résultats et discussion

V.1 Introduction

Ce chapitre présente les principaux résultats obtenus dans le cadre de cette étude. Dans un premier temps, les résultats des indicateurs mathématiques appliqués aux signaux FRA (Fréquence Response Analysis) seront exposés, en mettant en évidence leur capacité à différencier les états de l'enroulement. Ensuite, les performances du modèle SVM (Support Vector Machine) seront analysées à travers plusieurs scénarios de classification, permettant d'évaluer sa robustesse face aux différentes conditions de défaut.

V.2 Présentation du transformateur étudié [97]

L'étude a été réalisée sur un transformateur sec monophasé à deux enroulements (HV/LV), d'une puissance nominale de **111 kVA** et d'une tension de **7,33/1,22 kV**. Ce transformateur à noyau en fer est de type à enroulements croisés pour le côté haute tension (HV) et hélicoïdaux pour le côté basse tension (LV). L'enroulement HV comporte **7 couches**, chacune constituée de **5 spires**, avec des dimensions respectives de **545 mm** (hauteur), **255 mm** (diamètre intérieur) et **307 mm** (diamètre extérieur). L'enroulement LV se compose de **2 couches**, mesurant **595 mm** de hauteur, **183 mm** de diamètre intérieur et **217 mm** de diamètre extérieur.

Les tests FRA (Frequency Response Analysis) ont été réalisés sur l'enroulement HV, dans une plage fréquentielle allant de quelques Hz à 1 MHz, tandis que l'enroulement LV était mis à la terre pour éviter toute interférence. Le réservoir, le noyau, l'enroulement LV et la borne neutre du côté HV ont été reliés pour simuler un plan de masse commun.

V.3 Interprétation des résultats FRA à l'aide d'indicateurs mathématiques

Dans le cadre du diagnostic des transformateurs de puissance, l'utilisation d'indices mathématiques permet une mesure plus objective des différences entre les réponses en fréquence mesurées dans différentes conditions. Dans un premier temps, ces indicateurs seront calculés sur l'état de santé et comparés à des estimations obtenues à l'aide d'algorithmes d'optimisation ou d'intelligence artificielle. Ces mêmes indicateurs seront ensuite analysés dans plusieurs scénarios de défaut, notamment dans le cas d'un court-circuit partiel, pour identifier les signatures caractéristiques associées aux différents défauts. Cette approche fournit ainsi une base solide

pour le diagnostic automatique et fiable des défauts affectant les enroulements des transformateurs.

V.3.1 Étude comparative des indicateurs en état sain : à partir des données mesurées et estimées

Dans cette section, nous comparons les performances de trois algorithmes : K-means-FCCOA, l'algorithme d'évolution différentielle (DE) et l'algorithme génétique (AG). L'objectif est d'évaluer la précision et la stabilité de chaque méthode dans l'estimation de la courbe de référence afin d'identifier la plus fiable.

	référence	Algorithme K-means-FCCOA	algorithme d'évolution différentielle	algorithme génétique
ED	0	0.0771	0.1304	0.1272
CD	0	0.0771	0.1304	0.1272
SD	0	0.0028	0.0048	0.0047
DABS	0	1.0290e-04	1.7407e-04	1.6984e-04
ASLE	0	-5.8946e-06	-9.9739e-06	-9.7311e-06
RMSE	0	0.0139	0.0235	0.0230
σ	0	4.7987e-07	8.1196e-07	7.9220e-07
P	1	1	1.0000	1.0000
CC	1	1	1.0000	1
SSE	0	-1.0290e-04	-1.7407e-04	-1.6984e-04
SSRE	0	3.4478e-10	9.8676e-10	9.3932e-10
SSMMRE	0	3.4513e-10	9.8845e-10	9.4090e-10
IAD	0	0.0102	0.0235	0.0229
MAD	0	0.4250	0.9750	0.9500
IFD	0	0.0085	0.0189	0.0207
MFD	0	0.8250	1.8250	2
Fa	1	1.0102	1.0235	1.0229
FJ	1	1.0085	1.0189	0.9793

Tableau V.1 Étude comparative des indicateurs

ED, CD, SD, DABS, ASLE, RMSE, σ , ρ , CC, SSE, SSRE, SSMMRE, IAD, MAD, IFD, MFD, Fa et FJ
entre la référence et les résultats obtenus par les méthodes K-means-FCCOA, algorithme
d'évolution différentielle et algorithme génétique.




Figure V.1 Étude comparative des indicateurs ED, SD, DABS et ASLE entre la référence (et les résultats obtenus par les méthodes K-means-FCCOA, algorithme d'évolution différentielle et algorithme génétique.




Figure V.2 Étude comparative des indicateurs RMSE, σ_p et CC, entre la référence et les résultats obtenus par les méthodes K-means-FCCOA, algorithme d'évolution différentielle et algorithme génétique.




Figure V.3 Étude comparative des indicateurs SSE, SSRE et SSMRE entre la référence et les résultats obtenus par les méthodes K-means-FCCOA, algorithme d'évolution différentielle et algorithme génétique




Figure V.4 Étude comparative des indicateurs IAD, MAD et IFD, entre la référence et les résultats obtenus par les méthodes K-means-FCCOA, algorithme d'évolution différentielle et algorithme génétique




Figure V.5 Étude comparative des indicateurs MFD, Fa et Fj entre la référence et les résultats obtenus par les méthodes K-means-FCCOA, algorithme d'évolution différentielle et algorithme génétique.

Le tableau V.1 présente une évaluation comparative des performances de plusieurs indicateurs mathématiques appliqués à des données de réponse en fréquence (FRA), en utilisant des estimations de l'état sain obtenues par différentes méthodes d'approximation (K-means-FCCOA, **algorithme d'évolution différentielle et algorithme génétique**) comme référence.

Ces estimations sont utilisées pour calculer des indices permettant d'évaluer la capacité de chaque méthode à représenter avec précision la courbe de référence.

Les indicateurs ED, CD et RMSE, qui mesurent les écarts globaux entre les courbes de référence et estimées, affichent des valeurs nulles lorsque la courbe estimée correspond exactement à l'état sain. Les valeurs augmentent légèrement pour les trois méthodes, avec des variations notables d'une méthode à l'autre. Par exemple, l'algorithme d'évolution différentielle présente des écarts plus marqués pour l'indice ED, ce qui pourrait refléter une sensibilité plus grande aux fluctuations locales.

Les indices DABS, ASLE et σ , qui capturent les écarts subtils, confirment que toutes les méthodes fournissent une estimation proche de la référence, K-means-FCCOA se distinguant légèrement en termes de précision.

Les indicateurs SSE, SSRE et SSMMRE permettent d'évaluer la précision relative des approximations, des valeurs plus faibles indiquant une meilleure correspondance avec la référence. Une fois de plus, la méthode K-means-FCCOA présente les résultats les plus cohérents, traduisant une bonne précision.

Quant aux indices basés sur les écarts moyens (IAD, MAD, IFD et MFD), ils améliorent la qualité de l'analyse, car la méthode K-means-FCCOA montre des écarts plus faibles, ce qui indique une meilleure précision dans la représentation de la courbe de référence. En revanche, bien que l'algorithme génétique semble plus sensible, il a parfois tendance à surestimer certaines différences.

Enfin, les coefficients ρ , CC, Fa et FJ, proches de 1 dans tous les cas, indiquent une forte corrélation entre les profils estimés et la courbe de référence, ce qui confirme que les approximations conservent la tendance générale attendue.

Les résultats montrent que l'algorithme K-means-FCCOA offre une meilleure précision et stabilité, avec des estimations très proches de la référence. Les autres algorithmes sont un peu moins précis, mais restent proches de la référence.

V. 3.2 Analyse du comportement des indices mathématiques dans différents scénarios de défaut du transformateur

les indicateurs mathématiques interviennent comme des outils d'aide à la décision. En divers états dégradés, ces indices permettent de traduire visuellement les différences en valeurs numériques objectives. Ils facilitent ainsi l'évaluation de la sévérité des défauts et renforcent la fiabilité du diagnostic.

Cette section se propose d'examiner et de commenter les résultats des tests FRA à travers l'utilisation de différents indicateurs mathématiques, notamment le SSRE (Sum of Squared Relative Error), le CC (Correlation Coefficient) et le RHO (Ratio of High frequencies). Chacun de ces indices sera analysé en fonction de sa sensibilité, de sa pertinence et de sa capacité à discriminer les divers cas de défauts, dans l'optique d'identifier les outils les plus efficaces pour une évaluation précise de l'état de santé des transformateurs.

L'objectif de cette section est d'identifier les indices mathématiques les plus fiables pour évaluer l'état de santé des enroulements tout en comprenant l'influence de chaque type de défaut, qu'il soit partiel ou total, sur l'évolution des valeurs des indicateurs. Cette double approche permet

d'interpréter avec précision le comportement des indices face à différentes sévérités de dégradation. Voici l'interprétation des résultats de chaque indicateur :

- ED

	Référence (état sain)	court circuit entre 0 et 25 % de bobinage	court circuit entre 25 et 50 % de bobinage	court circuit entre 50% et 75% de bobinage	court circuit entre 75% et 100 % de bobinage	court circuit entre 0 et 50 % de bobinage	court circuit entre 0 et 75 % de bobinage
ED	0	8.5694	1.1878	0.7267	0.6583	13.3808	19.2818

Tableau V.2 valeurs de l'indice ED pour différents cas de test FRA




Figure V.6 Comparaison des valeurs ED pour différents niveaux de court-circuit

Le tableau V.2 présente l'évolution de l'indice ED dans différents scénarios de défauts simulés par test FRA sur un transformateur. Cet indice permet de mesurer dans quelle mesure la forme de la courbe de réponse en fréquence change lorsqu'un défaut apparaît. Plus la valeur est élevée, plus le changement est significatif.

Sans surprise, l'état sain du transformateur (référence) affiche une valeur de **0**, ce qui est logique puisqu'il n'y a aucune déviation entre la courbe mesurée et sa référence.

Dès l'apparition d'un court-circuit, même limité, on constate une augmentation de l'indice ED. Par exemple, un court-circuit touchant seulement les 25 % premiers du bobinage provoque déjà une hausse importante (**8.5694**), ce qui montre que cette zone est particulièrement sensible.

Lorsque le court-circuit couvre des zones plus étendues, comme entre 0 % et 50 % ou entre 0 % et 75 %, l'indice grimpe encore plus, atteignant respectivement **13.3808** et **19.2818**. Cela montre que plus la zone affectée est grande, plus la signature fréquentielle du transformateur est perturbée.

En revanche, les court-circuits situés vers la fin du bobinage, comme entre 50 % et 100 %, ont un effet beaucoup plus modéré sur l'indice ED (entre **0.6583** et **0.7267**). Cela suggère que ces zones sont moins critiques en termes d'impact sur la réponse fréquentielle.

Globalement, ce tableau montre bien que l'indice ED est un indicateur fiable et sensible aux modifications provoquées par les défauts internes, et qu'il permet non seulement de détecter un problème, mais aussi d'estimer sa gravité selon sa localisation.

- SD

	Référence (état sain)	court circuit entre 0 et 25 % de bobinage	court circuit entre 25 et 50 % de bobinage	court circuit entre 50% et 75% de bobinage	court circuit entre 75% et 100 % de bobinage	court circuit entre 0 et 50 % de bobinage	court circuit entre 0 et 75 % de bobinage
SD	0	0.3133	0.0434	0.0266	0.0241	0.4892	0.7050

Tableau V.3 valeurs de l'indice SD pour différents cas de test FRA




Figure V.7 Comparaison des valeurs SD pour différents niveaux de court-circuit

Le tableau **V.3** représente les valeurs de l'indice SD (écart-type des différences) pour différents scénarios de court-circuit dans les enroulements du transformateur, obtenues par le test FRA. Comme attendu, la valeur de référence (correspondant à un état sain) est nulle, puisque la signature fréquentielle est parfaitement conforme au modèle initial.

Dès l'apparition d'un court-circuit, même limité, on constate une augmentation de l'indice SD. Par exemple, un court-circuit touchant seulement les **25 % premiers** du bobinage provoque déjà une hausse importante (**0.3133**), ce qui montre que cette zone est particulièrement sensible.

Lorsque le court-circuit couvre des zones plus étendues, comme **de 0 à 50 %** ou **de 0 à 75 %**, l'indice grimpe encore plus, atteignant respectivement (0.4892 et 0.7050). Cela montre que plus la zone affectée est grande, plus la signature fréquentielle du transformateur est perturbée.

En revanche, les court-circuits situés vers la fin du bobinage, comme **entre 50 % et 100 %**, ont un effet beaucoup plus modéré sur l'indice SD (entre **0.0266** et **0.0241**). Cela suggère que ces zones sont moins critiques en termes d'impact sur la réponse fréquentielle.

Globalement, cet indice SD permet de détecter efficacement la présence de défauts et de quantifier leur étendue, en mettant en lumière la variation globale de la réponse en fréquence du transformateur.

- DABS

	Référence (état sain)	court circuit entre 0 et 25 % de bobinage	court circuit entre 25 et 50 % de bobinage	court circuit entre 50% et 75% de bobinage	court circuit entre 75% et 100 % de bobinage	court circuit entre 0 et 50 % de bobinage	court circuit entre 0 et 75 % de bobinage
DABS	0	0.0114	0.0016	9.7027e-04	8.7892e-04	0.0179	0.0257

Tableau V.4 valeurs de l'indice DABS pour différents cas de test FRA




Figure V.8 Comparaison des valeurs DABS pour différents niveaux de court-circuit

Le tableau V.5 présente les valeurs de l'indice DABS (Difference Area Between Signatures) obtenues pour différents cas de court-circuit simulés dans le bobinage d'un transformateur, dans le cadre d'un test de réponse en fréquence (FRA). Cet indice permet de quantifier l'écart entre la signature fréquentielle d'un état sain (référence) et celle d'un état présentant une dégradation.

En situation de référence, c'est-à-dire en l'absence de défaut, l'indice DABS est naturellement nul, ce qui confirme l'absence de variation entre les courbes comparées. Lorsqu'un défaut de type court-circuit est introduit, même partiellement, l'indice devient non nul, traduisant une modification du comportement fréquentiel du bobinage.

Dès l'apparition d'un court-circuit, même limité, on constate une augmentation de l'indice DABS. Par exemple, un court-circuit touchant seulement les **25 % premiers** du bobinage provoque déjà une hausse importante (**0.0114**), ce qui montre que cette zone est particulièrement sensible.

Lorsque le court-circuit couvre des zones plus étendues, comme **de 0 à 50 %** ou **de 0 à 75 %**, l'indice grimpe encore plus, atteignant respectivement (**0.0179** et **0.0257**). Cela montre que plus la zone affectée est grande, plus la signature fréquentielle du transformateur est perturbée.

En revanche, les court-circuits situés vers la fin du bobinage, comme **entre 50 % et 100 %**, ont un effet beaucoup plus modéré sur l'indice DABS (entre **9.7027e-04** et **8.7892e-04**). Cela suggère que ces zones sont moins critiques en termes d'impact sur la réponse fréquentielle.

En conclusion, l'indice DABS se révèle adapté à la détection des défauts étendus dans les bobinages, mais peut montrer une sensibilité limitée face aux anomalies localisées. Il est donc recommandé de l'utiliser en complément d'autres indicateurs pour une évaluation complète de l'intégrité structurelle du transformateur.

- ASLE

	Référence (état sain)	court circuit entre 0 et 25 % de bobinage	court circuit entre 25 et 50 % de bobinage	court circuit entre 50% et 75% de bobinage	court circuit entre 75% et 100 % de bobinage	court circuit entre 0 et 50 % de bobinage	court circuit entre 0 et 75 % de bobinage
ASLE	0	-6.7450e-04	-9.1181e-05	-5.0447e-05	-0.0011	-0.0016	-5.0447e-05

Tableau V.5 valeurs de l'indice ASLE pour différents cas de test FRA




Figure V.9 Comparaison des valeurs | ASLE | pour différents niveaux de court-circuit

Le tableau V.5 présente les valeurs de l'indice ASLE (probablement un indicateur lié à l'analyse des bobinages) pour différents cas de test FRA (Frequency Response Analysis). Les résultats montrent les variations de l'ASLE en fonction de la localisation des courts-circuits dans le bobinage, comparées à un état sain (référence).

Comme attendu, la valeur de référence (correspondant à un état sain) est nulle, puisque la signature fréquentielle est parfaitement conforme au modèle initial.

Dès l'apparition d'un court-circuit, même limité, on constate une augmentation de l'indice ALSE. Par exemple, un court-circuit touchant seulement les **25 % premiers** du bobinage provoque déjà une hausse importante (**-6.7450e-04**), ce qui montre que cette zone est particulièrement sensible.

Lorsque Un court-circuit est localisé au début du bobinage (entre 0 et 25 %) provoque une baisse importante de l'indice (**-6.7450e-04**), ce qui montre que cette zone est particulièrement sensible.

Lorsque le défaut se déplace plus loin (25 à 50 %), l'impact est moins marqué (**-9.1181e-05**), et il devient encore plus faible entre 50 et 75 % (**-5.0447e-05**).

En revanche, un court-circuit situé à l'extrémité du bobinage (75 à 100 %) fait chuter l'indice à **-0.0011**, une valeur assez importante qui suggère que cette zone est elle aussi critique.

Le cas le plus notable est celui où le court-circuit s'étend de 0 à 50 % du bobinage : l'indice atteint **-0.0016**, soit la plus forte déviation du tableau. Cela montre qu'un défaut affectant une grande portion du bobinage entraîne un déséquilibre plus important.

À l'inverse, lorsque la zone endommagée couvre 75 % du bobinage (de 0 à 75 %), l'indice retombe à une valeur très faible (**-5.0447e-05**), ce qui pourrait paraître contre-intuitif. Cela peut s'expliquer par une compensation des effets sur une zone plus étendue, rendant le défaut plus difficile à détecter par cette méthode.

En conclusion, l'indice ASLE réagit de manière non linéaire à l'emplacement et à l'étendue du défaut. Les perturbations situées aux extrémités du bobinage (début ou fin) semblent avoir un impact plus fort que celles au centre. Cela pourrait s'expliquer par la sensibilité de certaines zones aux variations de fréquence mesurées lors du test FRA.

- RMSE

	Référence (état sain)	court circuit entre 0 et 25 % de bobinage	court circuit entre 25 et 50 % de bobinage	court circuit entre 50% et 75% de bobinage	court circuit entre 75% et 100 % de bobinage	court circuit entre 0 et 50 % de bobinage	court circuit entre 0 et 75 % de bobinage
RMSE	0	1.5464	0.2143	0.1311	0.1188	2.4146	3.4795

Tableau V.6 valeurs de l'indice RMSE pour différents cas de test FRA




Figure V.10 Comparaison des valeurs RMSE pour différents niveaux de court-circuit

Le tableau V.6 présente les valeurs de l'indice RMSE (Root Mean Square Error) obtenues pour différents cas de court-circuit simulés dans le bobinage d'un transformateur, dans le cadre d'un test de réponse en fréquence (FRA). Cet indice permet de quantifier l'écart entre la signature fréquentielle d'un état sain (référence) et celle d'un état présentant une dégradation.

En situation de référence, c'est-à-dire en l'absence de défaut, l'indice RMSE est naturellement nul, ce qui confirme l'absence de variation entre les courbes comparées. Lorsqu'un défaut de type court-circuit est introduit, même partiellement, l'indice devient non nul, traduisant une modification du comportement fréquentiel du bobinage.

Dès l'apparition d'un court-circuit, même limité, on constate une augmentation de l'indice RMSE. Par exemple, un court-circuit touchant seulement les 25 % premiers du bobinage provoque déjà une hausse importante (1.5464), ce qui montre que cette zone est particulièrement sensible.

Lorsque le court-circuit couvre des zones plus étendues, comme de 0 à 50 % ou de 0 à 75 %, l'indice grimpe encore plus, atteignant respectivement (2.4146 et 3.4795). Cela montre que plus la zone affectée est grande, plus la signature fréquentielle du transformateur est perturbée.

En revanche, les court-circuits situés vers la fin du bobinage, comme entre 50 % et 100 %, ont un effet beaucoup plus modéré sur l'indice RMSE (entre 0.1311 et 0.1188). Cela suggère que ces zones sont moins critiques en termes d'impact sur la réponse fréquentielle.

En résumé, le RMSE est un bon indicateur pour repérer et mesurer les courts-circuits internes. Il donne une vision claire de l'écart entre un fonctionnement normal et un fonctionnement perturbé, ce qui en fait un outil précieux pour le diagnostic des transformateurs.

- σ

	Référence (état sain)	court circuit entre 0 et 25 % de bobinage	court circuit entre 25 et 50 % de bobinage	court circuit entre 50% et 75% de bobinage	court circuit entre 75% et 100 % de bobinage	court circuit entre 0 et 50 % de bobinage	court circuit entre 0 et 75 % de bobinage
σ	0	5.4895e-05	7.4229e-06	4.5347e-06	4.1069e-06	8.7138e-05	1.2818e-04

Tableau V.7 valeurs de l'indice σ pour différents cas de test FRA




Figure V.11 Comparaison des valeurs σ pour différents niveaux de court-circuit

Le tableau V.7 met en lumière les variations de l'indice σ (sigma) dans différents scénarios de défauts détectés par analyse FRA. Cet indice mesure à quel point la courbe de réponse fréquentielle d'un transformateur défectueux s'éloigne de celle d'un transformateur en bon état.

Sans surprise, dans le cas de référence (état sain), l'indice est nul, ce qui confirme qu'il n'y a aucune différence entre les courbes. En revanche, dès qu'un court-circuit est introduit, même sur une petite portion du bobinage (entre 0 et 25 %), σ augmente nettement (5.4895×10^{-5}), ce qui indique que l'outil détecte déjà des changements dans le comportement électrique du transformateur.

Fait intéressant : lorsque le court-circuit est localisé plus profondément (entre 25 % et 100 % du bobinage), les valeurs de σ chutent, devenant très faibles (de l'ordre de 10^{-6}). Cela suggère que ces défauts sont moins perceptibles avec cet indice, peut-être parce qu'ils affectent moins la forme globale de la courbe.

En revanche, lorsque le court-circuit s'étend sur une plus grande portion du bobinage (entre 0 et 50 %, ou entre 0 et 75 %), σ grimpe fortement (jusqu'à 1.2818×10^{-4}), traduisant une perturbation plus importante et plus facile à capter.

En résumé, σ est un bon indicateur pour repérer les défauts larges ou étendus. Il semble toutefois un peu moins sensible aux défauts plus localisés. Cela montre qu'il peut être utile en complément d'autres indices pour bien diagnostiquer l'état du transformateur.

- CC

	Référence (état sain)	court circuit entre 0 et 25 % de bobinage	court circuit entre 25 et 50 % de bobinage	court circuit entre 50% et 75% de bobinage	court circuit entre 75% et 100 % de bobinage	court circuit entre 0 et 50 % de bobinage	court circuit entre 0 et 75 % de bobinage
Cc	1	1	1	1	1	1	1

Tableau V.8 valeurs de l'indice CC pour différents cas de test FRA




Figure V.12 Comparaison des valeurs CC pour différents niveaux de court-circuit

Le tableau V.8 présente l'évolution de l'indice CC (pour "court-circuit") appliqué à différents scénarios de défaut dans le bobinage d'un transformateur, dans le cadre de tests par analyse de réponse fréquentielle (FRA).

Ce qui ressort immédiatement de ce tableau, c'est la constance absolue de la valeur de l'indice, qui est fixée à 1 dans tous les cas, y compris pour l'état de référence dit « sain ». Cela signifie que, d'après cet indice, aucune distinction n'est faite entre un transformateur sans défaut et ceux présentant divers niveaux de court-circuit (qu'ils soient partiels ou étendus).

Un tel résultat soulève des questions sur la sensibilité et la pertinence de l'indice CC dans ce contexte précis. Il semble en effet incapable de détecter ou de refléter les variations induites par

les défauts dans le bobinage. Cela suggère que, pris seul, l'indice CC n'est pas un indicateur fiable pour diagnostiquer l'état d'un transformateur via la méthode FRA.

En somme, ce tableau met en évidence une limite importante de l'indice CC : il ne réagit pas aux défauts progressifs ou localisés, ce qui en réduit considérablement l'intérêt pratique dans une démarche de maintenance conditionnelle. D'autres indices plus sensibles (comme SSE ou SSRE) doivent donc être privilégiés pour une évaluation précise de l'état de santé du transformateur.

- ρ

	Référence (état sain)	court circuit entre 0 et 25 % de bobinage	court circuit entre 25 et 50 % de bobinage	court circuit entre 50% et 75% de bobinage	court circuit entre 75% et 100 % de bobinage	court circuit entre 0 et 50 % de bobinage	court circuit entre 0 et 75 % de bobinage
ρ	1	1	1	1	1	1	1

Tableau V.9 valeurs de l'indice ρ pour différents cas de test FRA




Figure V.13 Comparaison des valeurs ρ pour différents niveaux de court-circuit

Le tableau V.9 présente les valeurs de l'indice ρ appliqué à plusieurs scénarios de court-circuit dans le bobinage d'un transformateur, toujours dans le cadre de tests par réponse fréquentielle (FRA).

L'observation la plus marquante ici est l'uniformité parfaite des valeurs de l'indice : elles sont toutes égales à 1, quel que soit le niveau ou la gravité du court-circuit simulé, y compris pour l'état de référence considéré comme sain. Autrement dit, l'indice ρ ne permet aucune différenciation entre un transformateur en bon état et un transformateur présentant des défauts internes de divers degrés.

D'un point de vue technique, ce constat met en lumière une faible sensibilité de l'indice ρ aux modifications de l'état du bobinage. Il apparaît donc inapte à jouer un rôle discriminant dans le diagnostic des dégradations internes par la méthode FRA. Pour un outil censé accompagner la maintenance préventive et garantir la fiabilité des équipements, cela constitue une limite importante.

En résumé, bien que simple à calculer, l'indice rho ne reflète pas l'évolution de l'état du transformateur face à des défauts progressifs, ce qui réduit fortement sa pertinence dans une analyse conditionnelle. Il serait plus judicieux de se tourner vers des indices plus sensibles et dynamiques, tels que le SSRE, capables de traduire fidèlement les altérations du comportement fréquentiel de l'équipement.

- SSE

	Référence (état sain)	court circuit entre 0 et 25 % de bobinage	court circuit entre 25 et 50 % de bobinage	court circuit entre 50% et 75% de bobinage	court circuit entre 75% et 100 % de bobinage	court circuit entre 0 et 50 % de bobinage	court circuit entre 0 et 75 % de bobinage
SSE	0	-0.0114	-0.0016	-9.7027e-04	-8.7892e-04	-0.0179	-0.0257

Tableau V.10 valeurs de l'indice SSE pour différents cas de test FRA




Figure V.14 Comparaison des valeurs |SSE| pour différents niveaux de court-circuit

Le tableau **V.10** présente l'évolution de l'indice SSE (Sum of Squared Errors) dans plusieurs scénarios de court-circuit détectés à travers la méthode FRA. Cet indice mesure l'écart quadratique total entre la courbe de référence (transformateur sain) et celles obtenues dans les cas de défauts. En d'autres termes, plus la valeur absolue de SSE est élevée, plus la courbe est altérée par le défaut.

Comme attendu, la valeur de SSE est nulle dans le cas de référence (aucun défaut), ce qui confirme l'absence de différence entre les réponses fréquentielles. Dès l'apparition d'un court-circuit, même limité (entre 0 et 25 % du bobinage), une valeur négative apparaît (-0.0114), traduisant un écart significatif avec la courbe de base.

Ce que l'on observe ensuite est très révélateur : plus la portion de bobinage affectée est grande, plus la valeur absolue de SSE augmente. Cela se vérifie notamment dans les cas de court-circuit étendu entre 0 et 50 % (-0.0179) ou entre 0 et 75 % du bobinage (-0.0257), qui présentent les écarts les plus importants.

Inversement, pour des défauts localisés à des intervalles plus élevés du bobinage (au-delà de 50 %), les variations sont plus faibles (de l'ordre de 10^{-4}), ce qui pourrait indiquer que ces zones ont un impact moindre sur la signature fréquentielle globale.

Enfin, il est intéressant de noter que toutes les valeurs sont négatives. Cela peut s'expliquer par une configuration particulière du calcul SSE où les erreurs sont orientées vers une sous-estimation de la courbe de défaut par rapport à celle de référence.

En résumé, l'indice SSE apparaît sensible et pertinent pour détecter et quantifier les écarts dans les cas de défauts étendus. Il complète bien les autres indicateurs comme σ et DABS, en apportant une vision globale de la distorsion introduite par les défauts sur la réponse fréquentielle du transformateur.

- SSRE

	Référence (état sain)	court circuit entre 0 et 25 % de bobinage	court circuit entre 25 et 50 % de bobinage	court circuit entre 50% et 75% de bobinage	court circuit entre 75% et 100 % de bobinage	court circuit entre 0 et 50 % de bobinage	court circuit entre 0 et 75 % de bobinage
SSRE	0	4.2627e-06	8.1893e-08	3.0657e-08	2.5156e-08	1.0393e-05	2.1581e-05

Tableau V.11 valeurs de l'indice SSRE pour différents cas de test FRA




Figure V.15 Comparaison des valeurs SSRE pour différents niveaux de court-circuit

Le tableau V.11 illustre comment l'indice **SSRE** évolue selon différents scénarios de court-circuit dans le bobinage d'un transformateur, en s'appuyant sur les résultats du test FRA. Cet indice

permet de mesurer, en quelque sorte, l'écart global entre la réponse fréquentielle d'un transformateur sain et celle d'un transformateur endommagé.

Sans surprise, dans le cas de référence où aucun défaut n'est présent, la valeur de SSRE est nulle. C'est la base sur laquelle on peut ensuite comparer les autres cas. Lorsqu'un court-circuit affecte une petite portion du bobinage (entre 0 et 25 %), l'indice grimpe rapidement à **4.2627e-06**, indiquant un début de dégradation perceptible dans la signature fréquentielle.


Ce qui attire l'attention, cependant, c'est que lorsque le court-circuit se situe uniquement dans des portions plus centrales ou plus éloignées du bobinage (entre 25 % et 100 %), les valeurs du SSRE sont étonnamment faibles. On observe des valeurs comme **8.1893e-08**, **3.0657e-08** et **2.5156e-08**, ce qui suggère que ces défauts ponctuels, bien qu'existants, perturbent moins la réponse globale du transformateur.

En revanche, dès que le court-circuit couvre une zone plus large – comme entre 0 % et 50 % ou entre 0 % et 75 % du bobinage – les valeurs du SSRE augmentent sensiblement, atteignant respectivement **1.0393e-05** et **2.1581e-05**. Cela signifie que plus le défaut s'étend, plus il devient visible à travers l'analyse fréquentielle.

En résumé, ce tableau met en évidence que l'indice SSRE est particulièrement sensible aux défauts étendus, ce qui en fait un outil utile pour détecter des anomalies généralisées dans le bobinage. Cependant, pour des défauts plus localisés, son efficacité semble limitée. Cela montre l'intérêt de combiner plusieurs indices pour obtenir un diagnostic plus fiable et complet de l'état du transformateur.

- SSMMRE

	Référence (état sain)	court circuit entre 0 et 25 % de bobinage	court circuit entre 25 et 50 % de bobinage	court circuit entre 50% et 75% de bobinage	court circuit entre 75% et 100 % de bobinage	court circuit entre 0 et 50 % de bobinage	court circuit entre 0 et 75 % de bobinage
SSMMRE	0	4.7885e-06	8.3191e-08	3.0953e-08	2.5376e-08	1.2502e-05	2.8326e-05

Tableau V.12 valeurs de l'indice SSMMRE pour différents cas de test FRA**Figure V.16** Comparaison des valeurs SSMMRE pour différents niveaux de court-circuit

Le tableau V.12 illustre comment l'indice SSMMRE présente les valeurs de l'indice SSMMRE pour différents cas de court-circuit dans les enroulements, toujours dans le cadre du test FRA.

On remarque immédiatement que la valeur de référence, correspondant à un transformateur en bon état (sans défaut), est nulle (0). Cela est logique : l'indice SSMMRE est conçu pour quantifier l'écart par rapport à une situation de référence saine. Plus cette valeur est élevée, plus l'écart est important.

Dès l'apparition d'un court-circuit, même partiel, on observe une augmentation de l'indice. Par exemple, un défaut localisé entre 0 et 25 % du bobinage donne une valeur de 4.7885e-06, ce qui montre déjà une sensibilité appréciable de l'indice à de faibles défauts. Ensuite, pour les défauts entre 25 % et 100 %, les valeurs restent relativement faibles (de l'ordre de 10^{-8}), ce qui peut indiquer une détection moins prononcée dans ces cas intermédiaires.

Cependant, dès que la portion endommagée s'élargit davantage (comme entre 0 et 50 % ou 0 et 75 %), l'indice grimpe nettement pour atteindre respectivement 1.2502e-05 et 2.8326e-05. Cela

confirme que SSMMRE réagit de manière plus marquée aux défauts étendus qu'aux défauts localisés.

En résumé, l'indice SSMMRE se montre particulièrement efficace pour signaler l'apparition et l'évolution de défauts dans les bobinages, surtout lorsque la zone de court-circuit s'élargit. Il constitue donc un bon indicateur de gravité dans l'analyse FRA.

- IAD

	Référence (état sain)	court circuit entre 0 et 25 % de bobinage	court circuit entre 25 et 50 % de bobinage	court circuit entre 50% et 75% de bobinage	court circuit entre 75% et 100 % de bobinage	court circuit entre 0 et 50 % de bobinage	court circuit entre 0 et 75 % de bobinage
IAD	0	0.0449	0.0321	0.0992	0.0090	0.1072	0.1837

Tableau V.13 valeurs de l'indice IAD pour différents cas de test FRA




Figure V.17 Comparaison des valeurs IAD pour différents niveaux de court-circuit

Le tableau V.13 présente l'évolution de l'indice IAD dans différents cas de court-circuit sur le bobinage, détectés par la méthode de test FRA. À titre de rappel, l'indice IAD mesure l'écart global entre une courbe de référence (état sain) et celle obtenue en cas de défaut.

Sans surprise, on observe que l'indice est nul lorsque le transformateur est sain. Dès l'apparition d'un court-circuit, même sur une petite portion du bobinage, la valeur de l'indice augmente, indiquant une dégradation détectée. Par exemple, pour un court-circuit entre 0 et 25 % du bobinage, l'IAD monte à **0.0449**, montrant une première détection.

Cependant, ce qui frappe ici, c'est que l'indice ne suit pas une progression linéaire selon la localisation du défaut. Il est par exemple plus faible (**0.0090**) pour un court-circuit en fin de bobinage (75–100 %) que pour une zone plus centrale (50–75 %, avec **0.0992**). Cela peut laisser penser que certaines zones du bobinage sont « moins visibles » pour l'indice IAD que d'autres, peut-être en raison de leur impact moindre sur la réponse fréquentielle.

L'indice semble en revanche bien réagir lorsque le court-circuit touche une portion étendue du bobinage. Ainsi, lorsqu'on affecte entre 0 et 75 % du bobinage, la valeur atteint **0.1837**, ce qui est la plus haute du tableau. Cela montre que **IAD** est particulièrement sensible aux défauts de grande étendue, même s'il l'est un peu moins à leur position exacte.

En somme, l'indice IAD est un bon indicateur global de la présence d'un défaut, mais il ne suffit pas à lui seul pour déterminer précisément où se situe ce défaut. Il gagne à être utilisé en combinaison avec d'autres indices pour une analyse plus complète et localisée.

- MAD

	Référence (état sain)	court circuit entre 0 et 25 % de bobinage	court circuit entre 25 et 50 % de bobinage	court circuit entre 50% et 75% de bobinage	court circuit entre 75% et 100 % de bobinage	court circuit entre 0 et 50 % de bobinage	court circuit entre 0 et 75 % de bobinage
MAD	0	3.1667	2.2667	7	0.6333	7.5667	12.9667

Tableau V.14 valeurs de l'indice MAD pour différents cas de test FRA




Figure V.18 Comparaison des valeurs MAD pour différents niveaux de court-circuit

Le tableau **V.14** nous donne un aperçu concret de la manière dont l'indice MAD (Mean Absolute Deviation) réagit face à différents niveaux de défauts dans le bobinage d'un transformateur. En clair, cet indice mesure à quel point la « signature » électrique d'un transformateur change lorsqu'il est endommagé.

Sans surprise, pour un transformateur en bon état (référence saine), l'indice est nul ce qui est parfaitement normal : il n'y a aucune différence entre la courbe de référence et celle mesurée.

Dès qu'un court-circuit apparaît, même s'il ne concerne qu'une petite portion du bobinage (entre 0 et 25 %), la valeur de l'indice grimpe déjà à **3.1667**. Cela montre que même un défaut mineur laisse une trace visible dans la réponse électrique de l'équipement.

Mais ce qui est intéressant, c'est que l'évolution de l'indice n'est pas toujours logique ou linéaire. Par exemple, un défaut situé entre 25 % et 50 % du bobinage donne une valeur plus basse (**2.2667**) que le cas précédent, ce qui peut paraître surprenant. Cela signifie que l'emplacement du défaut joue un rôle important dans la perturbation du signal, et que certains endroits sont plus critiques que d'autres.

Plus le défaut s'étend, notamment entre 50 % et 75 %, l'indice bondit à **7.0** un signe clair qu'un problème sérieux affecte le fonctionnement du transformateur. Étonnamment, lorsqu'on atteint la zone entre 75 % et 100 %, l'indice chute fortement à **0.6333**, ce qui suggère que cette partie du bobinage est peut-être moins sensible, ou que les effets du défaut y sont moins détectables.

Enfin, lorsqu'on simule des défauts plus larges (entre 0 et 50 %, ou même entre 0 et 75 % du bobinage), les valeurs deviennent très élevées (**7.5667** et **12.9667**), ce qui confirme que plus le défaut est étendu, plus l'indice **MAD** augmente, traduisant une détérioration marquée du signal.

En résumé, ce tableau nous montre que l'indice MAD est un bon indicateur pour repérer les défauts, mais qu'il peut réagir de façon différente selon où se situe le problème. Cela souligne l'intérêt de croiser les résultats avec d'autres indicateurs pour poser un diagnostic plus fiable.

- IFD

	Référence (état sain)	court circuit entre 0 et 25 % de bobinage	court circuit entre 25 et 50 % de bobinage	court circuit entre 50% et 75% de bobinage	court circuit entre 75% et 100 % de bobinage	court circuit entre 0 et 50 % de bobinage	court circuit entre 0 et 75 % de bobinage
IFD	0	0.2304	0.0999	0.0976	0.2262	0.2369	0.2392

Tableau V.15 valeurs de l'indice IFD pour différents cas de test FRA




Figure V.19 Comparaison des valeurs IFD pour différents niveaux de court-circuit

Le tableau V.15 illustre l'évolution de l'indice IFD face à différents niveaux de court-circuit dans les enroulements d'un transformateur. Comme attendu, la valeur de référence pour un transformateur en bon état est nulle, ce qui est cohérent : il n'y a aucune anomalie détectée.

Dès qu'un défaut apparaît, même léger (entre 0 et 25 % du bobinage), l'indice grimpe à 0.2304, ce qui indique que l'IFD est sensible aux premières altérations du signal. Cela signifie qu'il peut détecter les défauts dès leur apparition.

Cependant, lorsque le court-circuit se situe entre 25 % et 75 % du bobinage, les valeurs chutent à **0.0999** et **0.0976**, respectivement. Cela peut paraître étonnant, mais cela montre que l'IFD ne réagit pas de manière strictement proportionnelle à l'ampleur du défaut. Il semble donc que certains segments du bobinage soient moins influents dans la réponse fréquentielle globale du transformateur.

Puis, pour des défauts situés entre 75 % et 100 % du bobinage, la valeur remonte à **0.2262**, ce qui suggère que cette portion du bobinage a, elle aussi, un impact marqué sur la courbe de réponse.


Enfin, lorsque le défaut devient plus global (entre 0 et 50 % puis entre 0 et 75 %), l'indice atteint **0.2369** et **0.2392**, des niveaux proches du maximum observé. Cela confirme que plus la zone affectée est large, plus le signal se dégrade, ce que l'indice IFD traduit fidèlement.

En résumé, l'indice IFD montre une bonne capacité de détection, en particulier pour des défauts localisés en début ou en fin de bobinage, ainsi que pour les défauts étendus. Il constitue donc un outil pertinent pour identifier les défauts de type court-circuit, même si sa réponse peut parfois être moins marquée pour certaines zones du bobinage.

- MFD

	Référence (état sain)	court circuit entre 0 et 25 % de bobinage	court circuit entre 25 et 50 % de bobinage	court circuit entre 50% et 75% de bobinage	court circuit entre 75% et 100 % de bobinage	court circuit entre 0 et 50 % de bobinage	court circuit entre 0 et 75 % de bobinage
MFD	0	23.6000	10.2333	10	23.1667	24.2667	24.5000

Tableau V.16 valeurs de l'indice MFD pour différents cas de test FRA



Figure

V.20 Comparaison des valeurs MFD pour différents niveaux de court-circuit

Le tableau **V.16** met en évidence l'évolution de l'indice MFD en fonction de divers scénarios de court-circuit affectant les enroulements du transformateur. Comme pour les autres indices, la valeur de référence en absence de défaut est nulle, ce qui confirme que l'indice ne détecte aucune anomalie en situation normale.

Dès l'apparition d'un défaut, même limité (entre 0 et 25 % de bobinage), la valeur de l'indice grimpe brusquement à **23.6000**, ce qui démontre une forte sensibilité de l'indice MFD aux premiers signes de défaut. Cette tendance reste cohérente pour d'autres cas avec de larges zones

affectées : on observe des valeurs tout aussi élevées pour les courts-circuits entre 75 % et 100 % **(23.1667)**, entre 0 % et 50 % **(24.2667)** et entre 0 % et 75 % **(24.5000)**.

En revanche, pour des défauts situés entre 25 % et 75 %, les valeurs sont plus faibles **(10.2333 et 10.0000)**. Cela peut indiquer que, dans ces plages spécifiques, la réponse fréquentielle est modérément affectée, ou bien que ces zones sont moins critiques d'un point de vue électrique.

Dans l'ensemble, l'indice MFD montre une réactivité marquée et cohérente pour les défauts couvrant les extrémités ou une large portion du bobinage. Il se distingue donc par sa capacité à détecter efficacement les anomalies majeures, mais semble aussi moins discriminant pour les défauts localisés au centre de l'enroulement.

- F_a

	Référence (état sain)	court circuit entre 0 et 25 % de bobinage	court circuit entre 25 et 50 % de bobinage	court circuit entre 50% et 75% de bobinage	court circuit entre 75% et 100 % de bobinage	court circuit entre 0 et 50 % de bobinage	court circuit entre 0 et 75 % de bobinage
F_a	1	0.9551	0.9679	0.9008	0.9910	1.1072	1.1837

Tableau V.17 valeurs de l'indice F_a pour différents cas de test FRA




Figure V.21 Comparaison des valeurs F_a pour différents niveaux de court-circuit

Le tableau **V.17** montre l'évolution de l'indice **F_a** (indice de similarité fréquentielle) en fonction de plusieurs scénarios de court-circuit dans le bobinage. Cet indice est conçu pour détecter les écarts de réponse fréquentielle entre un état sain et un état défectueux du transformateur.

La valeur de référence pour un transformateur en bon état est logiquement égale à **1**, ce qui signifie une parfaite concordance de la réponse fréquentielle avec le modèle de référence.

Lorsque l'on introduit un court-circuit dans différentes portions du bobinage, l'indice **F_a** varie légèrement, oscillant autour de cette valeur de référence. Pour des défauts localisés, comme entre **0 et 25 % (0.9551)** ou **25 % et 50 % (0.9679)**, la variation reste relativement faible. Cela indique une faible sensibilité de l'indice **F_a** à des défauts partiels ou limités dans l'enroulement.

La valeur la plus basse observée est **0.9008** pour un court-circuit situé entre 50 % et 75 %, ce qui marque une déviation plus notable, mais reste dans une plage proche de la normale. En revanche, pour des défauts plus étendus, notamment entre 0 % et 50 % (**1.1072**) et entre 0 % et 75 % (**1.1837**), l'indice dépasse la valeur de référence. Cette augmentation suggère une perturbation significative de la signature fréquentielle, détectée avec une plus grande efficacité.

Cela reflète un comportement stable de l'indice **F_a**, bien que moins discriminant pour des défauts localisés par rapport à d'autres indices comme le MFD.

- F_j

	Référence (état sain)	court circuit entre 0 et 25 % de bobinage	court circuit entre 25 et 50 % de bobinage	court circuit entre 50% et 75% de bobinage	court circuit entre 75% et 100 % de bobinage	court circuit entre 0 et 50 % de bobinage	court circuit entre 0 et 75 % de bobinage
F _j	1	1.2304	1.0999	1.0976	1.2262	1.2369	1.2392

Tableau V.18 valeurs de l'indice **F_j** pour différents cas de test FRA




Figure V.22 Comparaison des valeurs F_j pour différents niveaux de court-circuit

Le tableau V.18 illustre la variation de l'indice F_j , utilisé pour évaluer la distorsion fréquentielle du signal mesuré par rapport à un état de référence (transformateur sain), en cas de court-circuit dans diverses portions du bobinage.

La valeur de référence de 1 correspond à un état sain, sans défaut dans l'enroulement. Dès l'apparition d'un court-circuit, même partiel, une augmentation de l'indice F_j est observée. Cette sensibilité est particulièrement remarquable.

Pour un court-circuit affectant entre 0 et 25 % du bobinage, la valeur monte à 1.2304, traduisant une perturbation notable.

De manière intéressante, pour des courts-circuits situés plus loin dans l'enroulement entre 25 et 50 % (1.0999) et entre 50 et 75 % (1.0976), l'indice diminue légèrement mais reste supérieur à 1, signalant un effet mesurable mais un peu moins prononcé.

Lorsqu'on avance vers un défaut couvrant une plus grande portion, comme entre 0 et 50 % (1.2369) ou 0 et 75 % (1.2392), l'indice augmente sensiblement. Cela confirme que F_j est particulièrement sensible à l'ampleur du défaut, en plus de sa localisation.

Cette évolution progressive rend l'indice F_j très pertinent pour détecter des défauts étendus, bien qu'il semble également bien réagir à des courts-circuits localisés. Comparé aux autres indices, il présente une réponse plus marquée et plus cohérente en fonction de la gravité du défaut.

V.4 Interprétation des résultats FRA par la méthode SVM

V.4.1 Raison du choix de SVM

L'algorithme Support Vecteur Machine (SVM) est choisi pour classer les données de la FRA raison de sa grande efficacité dans la séparation des classes complexes. L'une de ses caractéristiques les plus remarquables est sa capacité à gérer des données de grande dimension, ce qui le rend adapté à la résolution de problèmes de classification multi-classes, tels que l'analyse des signaux de réponse en fréquence des transformateurs électrique

V.4.2 Choix de C et gamma

Après avoir mis en œuvre les algorithmes de recherche aléatoire (randomsearch) et de recherche par grille (gridsearch), un ensemble de valeurs dans les plages étudiées a été testé. Grâce à l'expérimentation et à la comparaison, il a été constaté que les valeurs $C = 100$ et $\text{Gamma} = 0,1$ permettent d'obtenir de bonnes performances de classification. Par conséquent, ces valeurs ont été adoptées dans le modèle final en raison de leur équilibre entre précision et complexité.

V.4.3 Définition des classes utilisées

Dans ce chapitre, toutes les expériences de classification sont basées sur plusieurs classes représentant différents états des enroulements du transformateur. Le tableau suivant montre les classes utilisées dans cette étude et leurs conditions d'enroulement de transformateur réelles correspondantes.

Classe	État correspondant des enroulements
0	État sain (absence de défaut)
1	Court-circuit entre 0 % et 25 % du bobinage
2	Court-circuit entre 0 % et 50 % du bobinage
3	Court-circuit entre 0 % et 75 % du bobinage
4	Court-circuit entre 25 % et 50 % du bobinage
5	Court-circuit entre 50 % et 75 % du bobinage
6	Court-circuit entre 75 % et 100 % du bobinage

Tableau V.19 Définition des classes utilisées dans la classification

V.4.4 Stratégie de classification adoptée

Afin d'évaluer la capacité du modèle SVM à distinguer les différentes conditions des enroulements du transformateur, le travail a été structuré en deux phases. Dans la première phase, une classification binaire a été utilisée pour distinguer l'état sain d'un seul type de défaut à la fois. Cela permet d'évaluer la capacité du modèle à détecter avec précision la présence d'un défaut. Dans la deuxième phase, une classification multi-classes a été mise en œuvre afin de discriminer entre plusieurs niveaux de court-circuit. Cette étape permet d'analyser la performance du modèle face à une diversité croissante de scénarios défectueux.

V.4.5 Détection individuelle des défauts (classification binaire)

Dans cette partie de l'étude, une machine à vecteurs de support (SVM) sera utilisée pour entraîner un modèle capable de distinguer entre un état sain du transformateur et un cas spécifique de défauts de court-circuit dans les enroulements du transformateur (court-circuit) représentant différents pourcentages de dommages tels que court-circuit entre 0% et 25%, 0% et 50%, 25% et 50%, et d'autres pourcentages progressifs. Cette approche vise à évaluer la capacité du modèle à détecter et à différencier avec précision chacun de ces types de défauts par rapport à l'état sain, contribuant ainsi à améliorer le diagnostic précoce des défauts et à fournir une analyse précise et fiable de l'état du transformateur. De cette manière, l'impact de chaque degré de défaillance sur les performances du modèle peut être étudié séparément, soutenant ainsi le développement de systèmes de maintenance intelligents et efficaces pour les transformateurs électriques.

- court circuit entre 0% et 25 % de bobinage

Un modèle de machine à vecteurs de support (SVM) a été entraîné pour le classement et la distinction des données de la FRA entre l'état sain et l'état en court-circuit entre 0% et 25 % de bobinage du transformateur.




Figure V.23 Classification SVM avec frontière de décision entre l'état sain (classe 0) et court-circuit entre 0% et 25 % de bobinage (classe 1)

Dans la figure V.23, la zone verte représente l'état sain de l'enroulement du transformateur (classe 0), tandis que la zone grise indique l'état de court-circuit entre 0 % et 25 % de bobinage (classe 1).

Matrice de confusion entre : Classe 0 vs Classe 1




Figure V.24 Matrice de confusion : Classe 0 vs Classe 1

La figure V.24 représente la matrice de confusion illustrant les performances du modèle SVM entre la classe 0 et la classe 1. Voici l'interprétation des résultats:

- Vrais Négatifs (VN) : Le modèle a correctement identifié 153 échantillons comme appartenant à la classe 0, représentant des instances sans défaut (état sain).
- Faux Positifs (FP) : Le modèle a prédit à tort un défaut de court circuit entre 0% et 25 % (classe 1) pour 5 échantillons qui étaient en réalité sans défaut (classe 0).
- Faux Négatifs (FN) : Le modèle a classé à tort 3 échantillons présentant un court-circuit entre 0% et 25 % (classe 1) comme étant en état sain (classe 0).
- Vrais Positifs (VP) : Le modèle a correctement identifié 139 échantillons présentant un court-circuit entre 0 % et 25 % de bobinage (classe 1).

Sur la base de résultats cette matrice, le modèle SVM a montré une bonne capacité à identifier le défaut de court-circuit entre 0 % et 25 %. Cependant, il y a des erreurs de classification avec des faux positifs (FP) et des faux négatifs (FN), leur nombre reste relativement faible et peut être considéré comme acceptable au vu des performances globales du modèle.

Évaluation et interprétation des résultats

Classe	Précision (%)	Rappel (%)	F1-score (%)
Classe 0	98.08%	96.84%	97.45%
Classe 1	96.53%	97.89%	97.20%
Moyenne macro (%)	Macro Précision: 97.30%	Macro rappel: 97.36%	Macro F1-score: 97.33%
Training Accuracy (%)	98.58%		
Accuracy globale(%)	97.33%		

Tableau V.20 Rapport de classification de l'algorithme SVM entre classe 0 et classe 1

Le rapport de classification montre les performances du modèle SVM entre classe 0 et classe 1. Voici l'interprétation des résultats :

Précision d'entraînement (Training Accuracy): Le modèle a démontré une excellente précision sur les données d'entraînement, atteignant 98,58 %, indiquant d'excellentes performances pendant l'apprentissage .

précision de test (test accuracy) : Le modèle atteint une précision de 97,33 % sur les données de test, ce qui indique qu'il se généralise bien à de nouvelles données qu'il n'a pas vues pendant l'entraînement.

Rapport de classification pour SVM

- Pour la classe 0 (absence de défaut)

Précision: 98,08 % , ce qui signifie que parmi toutes les prédictions indiquant une absence de défaut, 98,08 %%% étaient correctes

Rappel : 96,84 %, ce qui signifie que la plupart des échantillons réellement sans défaut ont été correctement détectés par le modèle.

Score F1 : 97,45 %, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas sans défaut.

- Pour la classe 1 (défaut de court-circuit entre 0 % et 25 % de bobinage)

Précision: 96,53 % ,ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 0 % et 25%, 96,53 % étaient correctes.

Rappel : 97,89 %, ce qui signifie que la plupart des échantillons présentant réellement un défaut de court-circuit entre 0 % et 25 % de bobinage ont été correctement détectés par le modèle..

Score F1 : 97,20 %, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 0 % et 25 % de bobinage.

Moyenne macro : Les moyennes des scores pour la précision, le rappel et le score F1 sont respectivement de 97.30%, 97.36% et 97.33%. Cela indique un bon équilibre de performance entre la détection de la classe 0 (état sain) et la classe 1 (défaut de court-circuit entre 0 % et 25 % de bobinage), Sans parti pris envers une classification particulière.

Ces résultats suggèrent que le modèle SVM est performant pour prédire le défaut de court-circuit entre 0 % et 25 % de bobinage, avec une capacité à identifier correctement les échantillons présentant ce type de défaut .

- court circuit entre 0% et 50 % de bobinage

un modèle de machine à vecteurs de support (SVM) a été entraîné pour le classement et la distinction des données de la FRA entre l'état sain et court-circuit entre 0% et 50% de bobinage du transformateur.




Figure V.25 Classification SVM avec frontière de décision entre l'état sain (classe 0) et court-circuit entre 0% et 50 % de bobinage (classe 2).

Dans la figure V.25, la zone verte représente l'état sain de l'enroulement du transformateur (classe 0), tandis que la zone rose clair indique l'état de court-circuit entre 0 % et 50% de bobinage (classe 2).

Matrice de confusion : Classe 0 vs Classe 2




Figure V.26 Matrice de confusion : Classe 0 vs Classe 2

La figure V.26 représente la matrice de confusion illustrant les performances du modèle SVM entre la classe 0 et la classe 2. Voici l'interprétation des résultats:

- Vrais Négatifs (VN) : Le modèle a correctement identifié 138 échantillons comme appartenant à la classe 0, représentant des instances sans défaut (état sain).
- Faux Positifs (FP) : Le modèle a prédit à tort un défaut de court-circuit entre 0% et 50 % (classe 1) pour 4 échantillons qui étaient en réalité sans défaut (classe 0).
- Faux Négatifs (FN) : Le modèle a classé à tort 3 échantillons présentant un court-circuit entre 0% et 50 % (classe 2) comme étant en état sain (classe 0).
- Vrais Positifs (VP) : Le modèle a correctement identifié 155 échantillons présentant un court-circuit entre 0 % et 50 % de bobinage (classe 2).

Sur la base de résultats cette matrice, le modèle SVM a montré une bonne capacité à identifier le défaut de court-circuit entre 0 % et 50 %. Cependant des erreurs de classification soient toujours présentes, avec des faux positifs (FP) et des faux négatifs (FN), leur nombre reste relativement faible et peut être considéré comme acceptable au vu des performances globales du modèle.

Évaluation et interprétation des résultats

Classe	Précision (%)	Rappel (%)	F1-score (%)
Classe 0	97.87%	97.18%	97.53%
Classe 2	97.48%	98.10%	97.79%
Moyenne macro (%)	Macro Précision: 97.68%	Macro rappel: 97.64%	Macro F1-score: 97.66%
Training Accuracy (%)	98.91%		
Accuracy globale (%)	97.67%		

Tableau V.21 Rapport de classification du l'algorithme SVM entre classe 0 et classe 2

Le rapport de classification montre les performances du modèle SVM entre classe 0 et classe 2. Voici l'interprétation des résultats :

Précision d'entraînement (Training Accuracy): Le modèle a démontré une excellente précision sur les données d'entraînement, atteignant 98.91%. Indiquer d'excellentes performances pendant l'apprentissage .

précision de test (test accuracy) : Le modèle atteint une précision de 97.67%% sur les données de test, ce qui indique qu'il se généralise bien à de nouvelles données qu'il n'a pas vues pendant l'entraînement.

Rapport de classification pour SVM

- Pour la classe 0 (absence de défaut)

Précision: 97.87%, ce qui signifie que parmi toutes les prédictions indiquant une absence de défaut, 97.87% étaient correctes

Rappel : 97.18%, ce qui signifie que la plupart des échantillons réellement sans défaut ont été correctement détectés par le modèle.

Score F1 : 97.53%%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas sans défaut.

- Pour la classe 2 (défaut de court-circuit entre 0 % et 50 % de bobinage)

Précision: 97.48%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 0 % et 50%, 97.48% étaient correctes.

Rappel : 98.10%, ce qui signifie que la plupart des échantillons présentant réellement un défaut de court-circuit entre 0 % et 50 % de bobinage ont été correctement détectés par le modèle..

Score F1 : 97.79%%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 0 % et 50 % de bobinage.

Moyenne macro : Les moyennes des scores pour la précision, le rappel et le score F1 sont respectivement de 97.68%, 97.64% et 97.66%. Cela indique un bon équilibre de performance entre la détection de la classe 0 (état sain) et la classe 2 (défaut de court-circuit entre 0 % et 50 % de bobinage), Sans parti pris envers une classification particulière.

Ces résultats suggèrent que le modèle SVM est performant pour prédire le défaut de court-circuit entre 0 % et 50% de bobinage, avec une capacité à identifier correctement les échantillons présentant ce type de défaut.

- court circuit entre 0% et 75 % de bobinage

un modèle de machine à vecteurs de support (SVM) a été entraîné pour le classement et la distinction des données de la FRA entre l'état sain et court-circuit entre 0% et 75% de bobinage du transformateur.




Figure V.27 Classification SVM avec frontière de décision entre l'état sain (classe 0) et court-circuit entre 0% et 75% de bobinage (classe 3).

Dans la figure V.27, la zone verte représente l'état sain de l'enroulement du transformateur (classe 0), tandis que la zone mauve clair indique l'état de court-circuit entre 0 % et 75% de bobinage (classe 3).

Matrice de confusion : Classe 0 vs Classe 3




Figure V.28 Matrice de confusion : Classe 0 vs Classe 3

La figure V.28 représente la matrice de confusion illustrant les performances du modèle SVM entre la classe 0 et la classe 3. Voici l'interprétation des résultats:

- Vrais Négatifs (VN) : Le modèle a correctement identifié 145 échantillons comme appartenant à la classe 0, représentant des instances sans défaut (état sain).
- Faux Positifs (FP) : Le modèle a prédit à tort un défaut de court circuit entre 0% et 75 % (classe 3) pour 7 échantillons qui étaient en réalité sans défaut (classe 0).
- Faux Négatifs (FN) : Le modèle a classé à tort 4 échantillons présentant un court-circuit entre 0% et 75 % (classe 3) comme étant en état sain (classe 0).
- Vrais Positifs (VP) : Le modèle a correctement identifié 144 échantillons présentant un court-circuit entre 0 % et 75 % de bobinage (classe 3).

Sur la base de résultats cette matrice, le modèle SVM a montré une bonne capacité à identifier le défaut de court-circuit entre 0 % et 75 %. Cependant des erreurs de classification soient toujours présentes, avec des faux positifs (FP) et des faux négatifs (FN), leur nombre reste relativement faible et peut être considéré comme acceptable au vu des performances globales du modèle.

Évaluation et interprétation des résultats

Classe	Précision (%)	Rappel (%)	F1-score (%)
Classe 0	97.32%	95.39%	96.35%
Classe 3	95.36%	97.30%	96.32%
Moyenne macro (%)	Macro Précision: 96.34%	Macro rappel: 96.35%	Macro F1-score: 96.33%
Training Accuracy (%)	99.33%		
Accuracy globale(%)	96.33%		

-

Tableau V.22 Rapport de classification du l'algorithme SVM entre classe 0 et classe 3

Le rapport de classification montre les performances du modèle SVM entre classe 0 et classe 3. Voici l'interprétation des résultats :

Précision d'entraînement (Training Accuracy): Le modèle a démontré une excellente précision sur les données d'entraînement, atteignant 96.33% Indiquer d'excellentes performances pendant l'apprentissage .

précision de test (test accuracy) : Le modèle atteint une précision de 97.67%% sur les données de test, ce qui indique qu'il se généralise bien à de nouvelles données qu'il n'a pas vues pendant l'entraînement.

Rapport de classification pour SVM

- Pour la classe 0 (absence de défaut) .

Précision: 97.32%, ce qui signifie que parmi toutes les prédictions indiquant une absence de défaut, 97.32% étaient correctes.

Rappel : 95.39%, ce qui signifie que la plupart des échantillons réellement sans défaut ont été correctement détectés par le modèle.

Score F1 : 96.35%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas sans défaut.

- Pour la classe 3 (défaut de court-circuit entre 0 % et 75 % de bobinage)

Précision: 95.36%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 0 % et 75%, 95.36% étaient correctes.

Rappel : 97.30% , ce qui signifie que la plupart des échantillons présentant réellement un défaut de court-circuit entre 0 % et 75 % de bobinage ont été correctement détectés par le modèle.

Score F1 : 96.32%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 0 % et 75 % de bobinage.

Moyenne macro : Les moyennes des scores pour la précision, le rappel et le score F1 sont respectivement de 96.34% , 96.35% et 96.33%. Cela indique un bon équilibre de performance entre la détection de la classe 0 (état sain) et la classe 3 (défaut de court-circuit entre 0 % et 75% de bobinage), Sans parti pris envers une classification particulière.

Ces résultats suggèrent que le modèle SVM est performant pour prédire le défaut de court-circuit entre 0 % et 75% de bobinage, avec une capacité à identifier correctement les échantillons présentant ce type de défaut.

- court-circuit entre 25 % et 50% de bobinage

un modèle de machine à vecteurs de support (SVM) a été entraîné pour le classement et la distinction des données de la FRA entre l'état sain et court-circuit entre 25% et 50% de bobinage du transformateur.




Figure V.29 Classification SVM avec frontière de décision entre l'état sain (classe 0) et court-circuit entre 25% et 50% de bobinage (classe 4).

Dans la figure V.29, la zone verte représente l'état sain de l'enroulement du transformateur (classe 0), tandis que la zone jaune indique l'état de court-circuit entre 25% et 50% de bobinage (classe 4).

Matrice de confusion : Classe 0 vs Classe 4




Figure V.30 Matrice de confusion : Classe 0 vs Classe 4

La figure V.30 représente la matrice de confusion illustrant les performances du modèle SVM entre la classe 0 et la classe 4. Voici l'interprétation des résultats:

- Vrais Négatifs (VN) : Le modèle a correctement identifié 144 échantillons comme appartenant à la classe 0, représentant des instances sans défaut (état sain).
- Faux Positifs (FP) : Le modèle a prédit à tort un défaut de court-circuit entre 25% et 50 % (classe 4) pour 11 échantillons qui étaient en réalité sans défaut (classe 0).
- Faux Négatifs (FN) : Le modèle a classé à tort 4 échantillons présentant un court-circuit entre 25% et 50 % (classe 4) comme étant en état sain (classe 0).
- Vrais Positifs (VP) : Le modèle a correctement identifié 141 échantillons présentant un court-circuit entre 25 % et 50 % de bobinage (classe 4).

Sur la base de résultats cette matrice, le modèle SVM a montré une bonne capacité à identifier le défaut de court-circuit entre 25 % et 50 %. Cependant des erreurs de classification soient toujours présentes, avec des faux positifs (FP) et des faux négatifs (FN), leur nombre reste relativement faible et peut être considéré comme acceptable au vu des performances globales du modèle.

Évaluation et interprétation des résultats

Classe	Précision (%)	Rappel (%)	F1-score (%)
Classe 0	97.30%	92.90%	95.05%
Classe 4	92.76%	97.24%	94.95%
Moyenne macro (%)	Macro Précision: 95.03%	Macro rappel: 95.07%	Macro F1-score: 95.00%
Training Accuracy (%)	97.41%		
Accuracy globale(%)	95.00%		

Tableau V.23 Rapport de classification du l'algorithme SVM entre classe 0 et classe 4

Le rapport de classification montre les performances du modèle SVM entre classe 0 et classe 4. Voici l'interprétation des résultats : **Précision d'entraînement (Training Accuracy)**: Le modèle a démontré une excellente précision sur les données d'entraînement, atteignant 97.41%. Indiquer d'excellentes performances pendant l'apprentissage .

précision de test (test accuracy) : Le modèle atteint une précision de 95.00% sur les données de test, ce qui indique qu'il se généralise bien à de nouvelles données qu'il n'a pas vues pendant l'entraînement.

Rapport de classification pour SVM

- Pour la classe 0 (absence de défaut)

Précision: 97.30%, ce qui signifie que parmi toutes les prédictions indiquant une absence de défaut, 97.30% étaient correctes

Rappel : 92.90% ,ce qui signifie que la plupart des échantillons réellement sans défaut ont été correctement détectés par le modèle.

Score F1 : 95.05%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas sans défaut.

- Pour la classe 4(défaut de court-circuit entre 25 % et 50 % de bobinage)

Précision: 92.76%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 25 % et 50%, 92.76% étaient correctes

Rappel : 97.24% , ce qui signifie que la plupart des échantillons présentant réellement un défaut de court-circuit entre 25 % et 50 % de bobinage ont été correctement détectés par le modèle.

Score F1 : 94.95%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 25 % et 50 % de bobinage.

Moyenne macro : Les moyennes des scores pour la précision, le rappel et le score F1 sont respectivement de 95.03%, 95.07% et 95.00%. Cela indique un bon équilibre de performance entre la détection de la classe 0 (état sain) et la classe 4 (défaut de court-circuit entre 25 % et 50% de bobinage), Sans parti pris envers une classification particulière.

Ces résultats suggèrent que le modèle SVM est performant pour prédire le défaut de court-circuit entre 25 % et 50% de bobinage, avec une capacité à identifier correctement les échantillons présentant ce type de défaut.

- court-circuit entre 50% et 75% de bobinage

un modèle de machine à vecteurs de support (SVM) a été entraîné pour le classement et la distinction des données de la FRA entre l'état sain et court-circuit entre 50% et 75% de bobinage du transformateur.




Figure V.31 Classification SVM avec frontière de décision entre l'état sain (classe 0) et court-circuit entre 50% et 75% de bobinage (classe 5).

Dans la figure V.31, la zone verte représente l'état sain de l'enroulement du transformateur (classe 0), tandis que la zone bleu ciel indique l'état de court-circuit entre 50% et 75% de bobinage (classe 5).

Matrice de confusion : Classe 0 vs Classe 5




Figure V.32 Matrice de confusion : Classe 0 vs Classe 5

La figure V.32 représente la matrice de confusion illustrant les performances du modèle SVM entre la classe 0 et la classe 5. Voici l'interprétation des résultats:

- Vrais Négatifs (VN) : Le modèle a correctement identifié 145 échantillons comme appartenant à la classe 0, représentant des instances sans défaut (état sain).
- Faux Positifs (FP) : Le modèle a prédit à tort un défaut de court-circuit entre 50% et 75 % (classe 5) pour un seul échantillon qu'étaient en réalité sans défaut (classe 0).
- Faux Négatifs (FN) : Le modèle a classé à tort 5 échantillons présentant un court-circuit entre 50% et 75% (classe 5) comme étant en état sain (classe 0).
- Vrais Positifs (VP) : Le modèle a correctement identifié 149 échantillons présentant un court-circuit entre 50 % et 75 % de bobinage (classe 5).

Sur la base de résultats cette matrice, le modèle SVM a montré une bonne capacité à identifier le défaut de court-circuit entre 50% et 75 %. Cependant des erreurs de classification soient toujours présentes, avec des faux positifs (FP) et des faux négatifs (FN), leur nombre reste relativement faible et peut être considéré comme acceptable au vu des performances globales du modèle.

Évaluation et interprétation des résultats

Classe	Précision (%)	Rappel (%)	F1-score (%)
Classe 0	96.67%	99.32%	97.97%
Classe 5	99.33%	96.75%	98.03%
Moyenne macro (%)	Macro Précision: 98.00%	Macro rappel: 98.03%	Macro F1-score: 98.00%
Training Accuracy (%)	99.75%		
Accuracy globale(%)	98.00		

-

Tableau V.24 Rapport de classification du l'algorithme SVM entre classe 0 et classe 5

Le rapport de classification montre les performances du modèle SVM entre classe 0 et classe 5. Voici l'interprétation des résultats :

Précision d'entraînement (Training Accuracy): Le modèle a démontré une excellente précision sur les données d'entraînement, atteignant 99.75%. Indiquer d'excellentes performances pendant l'apprentissage .

précision de test (test accuracy) : Le modèle atteint une précision de 98.00% sur les données de test, ce qui indique qu'il se généralise bien à de nouvelles données qu'il n'a pas vues pendant l'entraînement.

Rapport de classification pour SVM

- Pour la classe 0 (absence de défaut)

Précision: 96.67%, ce qui signifie que parmi toutes les prédictions indiquant une absence de défaut, 96.67% étaient correctes

Rappel : 99.32%, ce qui signifie que la plupart des échantillons réellement sans défaut ont été correctement détectés par le modèle.

Score F1 : 97.97%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas sans défaut.

- Pour la classe 5 (défaut de court-circuit entre 50% et 75% de bobinage)

Précision: 99.33%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 50 % et 75%, 99.33% étaient correctes.

Rappel : 96.75% , ce qui signifie que la plupart des échantillons présentant réellement un défaut de court-circuit entre 50% et 75% de bobinage ont été correctement détectés par le modèle.

Score F1 : 98.03%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 50% et 75% % de bobinage.

Moyenne macro : Les moyennes des scores pour la précision, le rappel et le score F1 sont respectivement de 98.00%, 98.03% et 98.00%. Cela indique un bon équilibre de performance entre la détection de la classe 0 (état sain) et la classe 5 (défaut de court-circuit entre 50% et 75% de bobinage), sans parti pris envers une classification particulière.

Ces résultats suggèrent que le modèle SVM est performant pour prédire le défaut de court-circuit entre 50% et 75% de bobinage, avec une capacité à identifier correctement les échantillons présentant ce type de défaut.

- court circuit entre 75% et 100% de bobinage

un modèle de machine à vecteurs de support (SVM) a été entraîné pour le classement et la distinction des données de la FRA entre l'état sain et court-circuit entre 75% et 100% de bobinage du transformateur .




Figure V.33 Classification SVM avec frontière de décision entre l'état sain (classe 0) et court-circuit entre 75% et 100% de bobinage (classe 6).

Dans la figure V.33, la zone verte représente l'état sain de l'enroulement du transformateur (classe 0), tandis que la zone bleu clair indique l'état de court-circuit entre 75% et 100% de bobinage (classe 6).

Matrice de confusion entre : Classe 0 vs Classe 6




Figure V.34 Matrice de confusion : Classe 0 vs Classe 6

La figure V.34 représente la matrice de confusion illustrant les performances du modèle SVM entre la classe 0 et la classe 6. Voici l'interprétation des résultats:

- Vrais Négatifs (VN) : Le modèle a correctement identifié 147 échantillons comme appartenant à la classe 0, représentant des instances sans défaut (état sain).
- Faux Positifs (FP) : Le modèle a prédit à tort un défaut de court-circuit entre 75% et 100 % (classe 6) pour 4 échantillons qui étaient en réalité sans défaut (classe 0).
- Faux Négatifs (FN) : Le modèle a classé à tort 5 échantillons présentant un court-circuit entre 75% et 100 % (classe 6) comme étant en état sain (classe 0).
- Vrais Positifs (VP) : Le modèle a correctement identifié 144 échantillons présentant un court-circuit entre 75 % et 100 % de bobinage (classe 6).

Sur la base de résultats cette matrice, le modèle SVM a montré une bonne capacité à identifier le défaut de court-circuit entre 75% et 100%. Cependant des erreurs de classification soient toujours présentes, avec des faux positifs (FP) et des faux négatifs (FN), leur nombre reste relativement faible et peut être considéré comme acceptable au vu des performances globales du modèle.

Évaluation et interprétation des résultats

Classe	Précision (%)	Rappel (%)	F1-score (%)
Classe 0	96.71%	97.35%	97.03%
Classe 6	97.30%	96.64%	96.97%
Moyenne macro (%)	Macro Précision: 97.00%	Macro rappel: 97.00%	Macro F1-score: 97.00%
Training Accuracy (%)	99.17%		
Accuracy globale(%)	97.00%		

Tableau V.25 Rapport de classification du l'algorithme SVM entre classe 0 et classe 6

Le rapport de classification montre les performances du modèle SVM entre classe 0 et classe 6. Voici l'interprétation des résultats : **Précision d'entraînement (Training Accuracy)**: Le modèle a démontré une excellente précision sur les données d'entraînement, atteignant 99.17% Indiquer d'excellentes performances pendant l'apprentissage .

précision de test (test accuracy) : Le modèle atteint une précision de 97.00% sur les données de test, ce qui indique qu'il se généralise bien à de nouvelles données qu'il n'a pas vues pendant l'entraînement.

Rapport de classification pour SVM

- Pour la classe 0 (absence de défaut)

Précision: 96.71%, ce qui signifie que parmi toutes les prédictions indiquant une absence de défaut, 96.71% étaient correctes

Rappel : 97.35%, ce qui signifie que la plupart des échantillons réellement sans défaut ont été correctement détectés par le modèle.

Score F1 : 97.03%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas sans défaut.

- Pour la classe 6 (défaut de court-circuit entre 75% et 100% de bobinage)

Précision: 97.30%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 75 % et 100%, 97.30% étaient correctes.

Rappel : 96.64%, ce qui signifie que la plupart des échantillons présentant réellement un défaut de court-circuit entre 75% et 100% de bobinage ont été correctement détectés par le modèle.

Score F1 : 96.97%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 75% et 100% de bobinage.

Moyenne macro : Les moyennes des scores pour la précision, le rappel et le score F1 sont respectivement de 97.00%, 97.00% et 97.00%. Cela indique un bon équilibre de performance entre la détection de la classe 0 (état sain) et la classe 6 (défaut de court-circuit entre 75% et 100% de bobinage), sans parti pris envers une classification particulière.

Ces résultats suggèrent que le modèle SVM est performant pour prédire le défaut de court-circuit entre 75% et 100% de bobinage, avec une capacité à identifier correctement les échantillons présentant ce type de défaut.

V.4.6 Discrimination entre défauts multiples (classification multi classes)

L'objectif de cette section est d'évaluer la capacité du modèle SVM à discriminer entre plusieurs scénarios de défauts des enroulements du transformateur, en augmentant progressivement le nombre de classes.

Pour cela, un modèle SVM multi classe est entraîné sur des données issues de différents cas identifiés par des tests de réponse en fréquence (FRA). Ces cas incluent l'état sain ainsi que plusieurs niveaux de court-circuit affectant les enroulements. L'analyse vise à mesurer les performances du modèle dans la reconnaissance de l'état normal et la détection précise du type de défaut présent.

- Classe 0 vs Classe 1 vs Classe 2

Le modèle SVM a été entraîné pour distinguer et prédire l'état sain des enroulements du transformateur ainsi que deux scénarios de courts-circuits : un entre 0 % et 25 % du bobinage, et un autre entre 0 % et 50%. Voici les résultats de la classification :




Figure V.35 Classification SVM avec frontière de décision : classe 0 vs classe 1 vs classe 2

Dans la figure V.35, les zones vertes, grises et rouge clair représentent respectivement les états suivants : « sain », « court-circuit entre 0 % et 25 % » et « court-circuit entre 0 % et 50 % ».




Figure V.36 Matrice de confusion : classe 0 vs classe 1 vs classe 2 .

Classe	Précision (%)	Rappel (%)	F1-score (%)
Classe 0	95.21%	94.56%	94.88%
Classe 1	93.71%	93.13%	93.42%
Classe 2	91.03%	92.31%	91.67%
Moyenne macro (%)	Macro Précision: 93.32%	Macro rappel: 93.33%	Macro F1-score: 93.32%
Training Accuracy (%)	98.00%		
Accuracy globale(%)	93.33%		

Tableau V.26 Rapport de classification du l'algorithme SVM : classe 0 vs classe 1 vs classe 2

Interprétation des résultats

Précision d'entraînement (Training Accuracy): Le modèle a démontré une excellente précision sur les données d'entraînement, atteignant 98.00 %, ce qui indique d'excellentes performances pendant la phase d'apprentissage. **précision de test (test accuracy) :** Le modèle atteint une précision de 93.33% sur les données de test, ce qui indique qu'il se généralise bien à de nouvelles données qu'il n'a pas vues pendant l'entraînement.

- Pour la classe 0 (absence de défaut)

Le modèle a correctement classé 139 échantillons comme appartenant à la classe 0, mais il

a mal classé 8 échantillons, 3 dans la classe 1 et 5 dans la classe 2. Voici l'interprétation des résultats :

Précision: 95,21 %, ce qui signifie que parmi toutes les prédictions indiquant une absence de défaut, 95,21 % étaient correctes.

Rappel: 94,56 %, ce qui signifie que 94,56 % des échantillons réellement sans défaut ont été correctement détectés par le modèle.

Score F1 : 94.88%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas sans défaut.

- Pour la classe 1(défaut de court-circuit entre 0% et 25% de bobinage)

Le modèle a correctement classé 149 échantillons comme appartenant à la classe 1, mais il a mal classé 11 échantillons, 3 dans la classe 0 et 8 dans la classe 2. Voici l'interprétation des résultats :

Précision: 93.71%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 0 % et 25 %, 93.71% étaient correctes.

Rappel : 93.13% ,ce qui signifie que 93.13% des échantillons présentant réellement un défaut de court-circuit entre 0% et 25% de bobinage ont été correctement détectés par le modèle.

Score F1 : 93.42% ,ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 0% et 25% de bobinage.

- Pour la classe 2(défaut de court-circuit entre 0% et 50% de bobinage)

Le modèle a correctement classé 132 échantillons comme appartenant à la classe 2, mais il a mal classé 11 échantillons, 4 dans la classe 0 et 7 dans la classe 1. Voici l'interprétation des résultats :

Précision: 91.03%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 0 % et 50 %, 91.03% étaient correctes.

Rappel : 92.31%, ce qui signifie que 92.31% des échantillons présentant réellement un défaut de court-circuit entre 0% et 50% de bobinage ont été correctement détectés par le modèle.

Score F1 : 91.67%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 0% et 50% de bobinage.

Moyenne macro : Les moyennes des scores pour la précision, le rappel et le score F1 sont respectivement de 93.32%, 93.33 % et 93.32 % ce qui indique un bon équilibre de performance du modèle dans la détection des classes 0, 1 et 2, Sans parti pris envers une classification particulière.

Ces résultats suggèrent que le modèle SVM atteint d'excellentes performances globales, en distinguant avec précision l'état sain des enroulements du transformateur ainsi que les différents types de défauts. Plus précisément, le modèle identifie efficacement le type de défaut, en différenciant un court-circuit affectant entre 0 % et 25 % du bobinage d'un court-circuit s'étendant entre 0 % et 50 % du bobinage.

- Classe 0 vs Classe 1 vs Classe 2 vs Classe 3

Le modèle SVM a été entraîné pour distinguer et prédire l'état sain des enroulements du transformateur ainsi que trois scénarios de court-circuit : entre 0 % et 25 %, entre 0 % et 50 %, et entre 0 % et 75 % du bobinage. Voici les résultats de la classification :




Figure V.37 Classification SVM avec frontière de décision : classe 0 vs classe 1 vs classe 2 vs classe 3

Dans la figure V.37, les zones vertes, grises, rouge clair et mauve clair représentent respectivement les états suivants : « sain », « court-circuit entre 0 %, 25 % » et « court-circuit entre 0 % et 50 % » et « court-circuit entre 0 % et 75 % » .




Figure V.38 Matrice de confusion : classe 0 vs classe 1 vs classe 2 vs classe 3

Classe	Précision (%)	Rappel (%)	F1-score (%)
Classe 0	91.61%	89.12%	90.34%
Classe 1	90.97%	91.56%	91.26%
Classe 2	93.48%	91.49%	92.47%
Classe 3	92.07%	95.57%	93.79%
Moyenne macro (%)	Macro Précision: 92.03%	Macro Rappel : 91.93%	Macro F1-Score :91.97%
Training Accuracy (%)	97.70%		
Accuracy globale(%)	92.00%		

Tableau V.27 Rapport de classification du l'algorithme SVM : classe 0 vs classe 1 vs classe 2 vs classe 3

Interprétation des résultats
Précision d'entraînement (Training Accuracy): Le modèle a démontré une excellente précision sur les données d'entraînement, atteignant 97.70%, ce qui indique d'excellentes performances pendant la phase d'apprentissage.

précision de test (test accuracy) : Le modèle atteint une précision de 92.00% sur les données de test, ce qui indique qu'il se généralise bien à de nouvelles données qu'il n'a pas vues pendant l'entraînement.

- Pour la classe 0 (absence de défaut)

Le modèle a correctement classé 131 échantillons comme appartenant à la classe 0, mais il a mal classé 16 échantillons, 7 dans la classe 1, 4 dans la classe 2 et 5 dans la classe 3. Voici l'interprétation des résultats :

Précision: 91.61%, ce qui signifie que parmi toutes les prédictions indiquant une absence de défaut, 91.61% étaient correctes.

Rappel: 89.12%, ce qui signifie que 89.12% des échantillons réellement sans défaut ont été correctement détectés par le modèle.

Score F1 : 90.34%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas sans défaut.

- Pour la classe 1 (défaut de court-circuit entre 0% et 25% de bobinage)

Le modèle a correctement classé 141 échantillons comme appartenant à la classe 1, mais il a mal classé 13 échantillons, 4 dans la classe 0, 5 dans la classe 2 et 4 dans la classe 3. Voici l'interprétation des résultats :

Précision: 90.97%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 0 % et 25 %, 90.97% étaient correctes.

Rappel : 91.56%, ce qui signifie que 91.56% des échantillons présentant réellement un défaut de court-circuit entre 0% et 25% de bobinage ont été correctement détectés par le modèle.

Score F1 : 91.26%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 0% et 25% de bobinage.

- Pour la classe 2 (défaut de court-circuit entre 0% et 50% de bobinage)

Le modèle a correctement classé 129 échantillons comme appartenant à la classe 2, mais il a mal classé 12 échantillons, 5 dans la classe 0, 3 dans la classe 1 et 4 dans la classe 3. Voici l'interprétation des résultats :

Précision:93.48%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 0 % et 50 %, 93.48% étaient correctes.

Rappel : 91.49%, ce qui signifie que 91.49% des échantillons présentant réellement un défaut de court-circuit entre 0% et 50% de bobinage ont été correctement détectés par le modèle.

Score F1 :92.47%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 0% et 50% de bobinage.

- Pour la classe 3(défaut de court-circuit entre 0% et 75% de bobinage)

Le modèle a correctement classé 151 échantillons comme appartenant à la classe 2, mais il a mal classé 7 échantillons, 3 dans la classe 0 et 4 dans la classe 1. Voici l'interprétation des résultats :

Précision:92.07%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 0 % et 75 %, 92.07% étaient correctes.

Rappel : 95.57%, ce qui signifie que 95.57% des échantillons présentant réellement un défaut de court-circuit entre 0% et 75% de bobinage ont été correctement détectés par le modèle.

Score F1 :93.79%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 0% et 75% de bobinage.

Moyenne macro : Les moyennes des scores pour la précision, le rappel et le score F1 sont respectivement de 92.03%, 91.93% et 91.97% ce qui indique un bon équilibre de performance du modèle dans la détection des classes 0, 1, 2 et 3, Sans parti pris envers une classification particulière.

Le modèle SVM présente d'excellentes performances globales, en distinguant clairement l'état sain ainsi que chaque niveau de court-circuit : entre 0 % et 25 %, entre 0 % et 50 %, et entre 0 % et 75 % du bobinage.

- Classe 0 vs Classe 1 vs Classe 2 vs Classe 3 vs Classe 4

Le modèle SVM a été entraîné pour distinguer et prédire l'état sain des enroulements du transformateur ainsi que quatre scénarios de court-circuit : entre 0 % et 25 %, entre 0 % et 50 %, entre 0 % et 75 %, et entre 25 % et 50 % du bobinage. Voici les résultats de la classification :




Figure V.39 Classification SVM avec frontière de décision : classe 0 vs classe 1 vs classe 2 vs classe 3 vs classe 4

Dans la figure V.39, les zones vertes, grises, rouge clair, mauve clair et jaune représentent respectivement les états suivants : « sain », « court-circuit entre 0 %, 25 % », « court-circuit entre 0 % et 50 % » et « court-circuit entre 0 % et 75 % » et « court-circuit entre 25 % et 50 % »

Matrice de confusion

Classe réelle \ Classe prédite	Classe 0	Classe 1	Classe 2	Classe 3	Classe 4
Classe 0	137	6	4	8	4
Classe 1	0	135	3	4	2
Classe 2	7	3	138	4	4
Classe 3	2	2	3	130	1
Classe 4	8	3	4	1	136

Figure V.40 Matrice de confusion : classe 0 vs classe 1 vs classe 2 vs classe 3 vs classe 4

Classe	Précision (%)	Rappel (%)	F1-score (%)
Classe 0	88.96%	86.16%	87.54%
Classe 1	90.60%	93.75%	92.15%
Classe 2	90.79%	88.46%	89.61%
Classe 3	88.44%	94.20%	91.23%
Classe 4	92.52%	89.47%	90.97%
Moyenne macro (%)	Macro Précision:90.26%	Macro rappel: 90.26%	Macro F1-score: 90.30%
Training Accuracy (%)	97.00%		
Accuracy globale(%)	90.25%		

Tableau V.28Rapport de classification du l’algorithme SVM : classe 0 vs classe 1 vs classe 2 vs classe 3 classe 4

Interprétation des résultats

Précision d'entraînement (Training Accuracy):Le modèle a démontré une excellente précision sur les données d'entraînement, atteignant 97.00% , ce qui indique d'excellentes performances pendant la phase d'apprentissage.

précision de test (test accuracy) : Le modèle atteint une précision de 90.25% sur les données de test, ce qui indique qu’il se généralise bien à de nouvelles données qu’il n’a pas vues pendant l’entraînement.

- Pour la classe 0 (absence de défaut)

Le modèle a correctement classé 137 échantillons comme appartenant à la classe 0, mais il a mal classé 22 échantillons, 6 dans la classe 1 , 4 dans la classe 2 , 8 dans la classe 3 et 4 dans la classe 4 . Voici l’interprétation des résultats :

Précision: 88.96%, ce qui signifie que parmi toutes les prédictions indiquant une absence de défaut, 88.96% étaient correctes.

Rappel: 86.16% , ce qui signifie que 86.16% des échantillons réellement sans défaut ont été correctement détectés par le modèle.

Score F1 : 87.54%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas sans défaut.

- Pour la classe 1(défaut de court-circuit entre 0% et 25% de bobinage)

Le modèle a correctement classé 135 échantillons comme appartenant à la classe 1, mais il a mal classé 9 échantillons, 3 dans la classe 2, 4 dans la classe 3 et 2 dans la classe 4. Voici l'interprétation des résultats :

Précision: 90.60%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 0 % et 25 %, 90.60% étaient correctes.

Rappel : 93.75%, ce qui signifie que 93.75% des échantillons présentant réellement un défaut de court-circuit entre 0% et 25% de bobinage ont été correctement détectés par le modèle.

Score F1 : 92.15%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 0% et 25% de bobinage.

- Pour la classe 2(défaut de court-circuit entre 0% et 50% de bobinage)

Le modèle a correctement classé 138 échantillons comme appartenant à la classe 2, mais il a mal classé 18 échantillons, 7 dans la classe 0 , 3 dans la classe 1 , 4 dans la classe 3 et 4 dans la classe 4. Voici l'interprétation des résultats :

Précision: 90.79% , ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 0 % et 50 %, 90.79% étaient correctes.

Rappel : 88.46%, ce qui signifie que 88.46% des échantillons présentant réellement un défaut de court-circuit entre 0% et 50% de bobinage ont été correctement détectés par le modèle.

Score F1 : 89.61%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 0% et 50% de bobinage.

- Pour la classe 3(défaut de court-circuit entre 0% et 75% de bobinage)

Le modèle a correctement classé 130 échantillons comme appartenant à la classe 2, mais il a mal classé 8 échantillons, 2 dans la classe 0 , 2 dans la classe 1, 3 dans la classe 2 et 1 dans la classe 4 . Voici l'interprétation des résultats :

Précision:88.44%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 0 % et 75 %, 88.44% étaient correctes.

Rappel : 94.20%,ce qui signifie que 94.20% des échantillons présentant réellement un défaut de court-circuit entre 0% et 75% de bobinage ont été correctement détectés par le modèle.

Score F1 :91.23% ,ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 0% et 75% de bobinage.

- Pour la classe 4(défaut de court-circuit entre 25% et 50% de bobinage)

Le modèle a correctement classé 136 échantillons comme appartenant à la classe 2, mais il a mal classé 16 échantillons, 8 dans la classe 0 , 3 dans la classe 1, 4 dans la classe 2 et 1 dans la classe 3 . Voici l'interprétation des résultats :

Précision:92.52%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 25 % et 50 %, 92.52% étaient correctes.

Rappel : 89.47%,ce qui signifie que 89.47% des échantillons présentant réellement un défaut de court-circuit entre 25% et 50% de bobinage ont été correctement détectés par le modèle.

Score F1 :90.97%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 25% et 50% de bobinage.

Moyenne macro : Les moyennes des scores pour la précision, le rappel et le score F1 sont respectivement de 90.26%,90.41% et 90.30% ce qui indique un bon équilibre de performance du modèle dans la détection des classes 0, 1, 2, 3 et 4 ,Sans parti pris envers une classification particulière.

Les résultats obtenus indiquent que le modèle SVM atteint d'excellentes performances dans la classification des différents états des enroulements du transformateur. Le modèle a démontré

une grande capacité à distinguer l'état sain et les conditions de court-circuit à différents niveaux. Il a également été possible d'identifier avec précision le type de défaut.

Le modèle SVM présente d'excellentes performances globales, en distinguant clairement l'état sain ainsi que chaque niveau de court-circuit : entre 0 % et 25 %, entre 0 % et 50 %, entre 0 % et 75 %, et entre 25 % et 50 % du bobinage.

- Classe 0 vs Classe 1 vs Classe 2 vs Classe 3 vs Classe 4 vs Classe 5

Le modèle SVM a été entraîné pour distinguer et prédire l'état sain des enroulements du transformateur ainsi que cinq scénarios de court-circuit : entre 0 % et 25 %, entre 0 % et 50 %, entre 0 % et 75 %, entre 25 % et 50 %, et entre 50 % et 75 % du bobinage. Voici les résultats de la classification :




Figure V.41 Classification SVM avec frontière de décision : classe 0 vs classe 1 vs classe 2 vs classe 3 vs classe 4 vs classe 5

Dans la figure V.41, les zones vertes, grises, rouge clair, mauve clair, jaune et bleu ciel représentent respectivement les états suivants : « sain », « court-circuit entre 0 %, 25 % », « court-circuit entre 0 % et 50 % » et « court-circuit entre 0 % et 75 % », « court-circuit entre 25 % et 50 % » et « court-circuit entre 50 % et 75 % ».



Figure V.42 Matrice de confusion : classe 0 vs classe 1 vs classe 2 vs classe 3 vs classe 4 vs classe 5

Classe	Précision (%)	Rappel (%)	F1-score (%)
Classe 0	87.84%	83.87%	85.81%
Classe 1	90.06%	91.19%	90.62%
Classe 2	85.53%	89.47%	87.46%
Classe 3	87.67%	87.07%	87.37%
Classe 4	81.56%	82.73%	82.14%
Classe 5	90.28%	88.44%	89.35%
Moyenne macro (%)	Macro Précision: 87.16%	Macro rappel: 87.13%	Macro F1-score: 87.13%
Training Accuracy (%)	96.33%		
Accuracy globale(%)	87.21%		

Tableau V.29 Rapport de classification du l'algorithme SVM : classe 0 vs classe 1 vs classe 2 vs classe 3 classe 4 vs classe 5

Interprétation des résultats

Précision d'entraînement (Training Accuracy): Le modèle a démontré une excellente précision sur les données d'entraînement, atteignant 96.33%, ce qui indique d'excellentes performances pendant la phase d'apprentissage.

précision de test (test accuracy) : Le modèle atteint une précision de 87.21% sur les données de test, ce qui indique qu'il se généralise bien à de nouvelles données qu'il n'a pas vues pendant l'entraînement.

- Pour la classe 0 (absence de défaut)

Le modèle a correctement classé 130 échantillons comme appartenant à la classe 0, mais il a mal classé 25 échantillons, 3 dans la classe 1, 9 dans la classe 2, 5 dans la classe 3, 7 dans la classe 4 et 1 dans la classe 5. Voici l'interprétation des résultats :

Précision: 87.84%, ce qui signifie que parmi toutes les prédictions indiquant une absence de défaut, 87.84% étaient correctes.

Rappel: 83.87%, ce qui signifie que 83.87% des échantillons réellement sans défaut ont été correctement détectés par le modèle.

Score F1 : 85.81%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas sans défaut.

- Pour la classe 1 (défaut de court-circuit entre 0% et 25% de bobinage)

Le modèle a correctement classé 145 échantillons comme appartenant à la classe 1, mais il a mal classé 14 échantillons, 5 dans la classe 0, 2 dans la classe 2, 5 dans la classe 4 et 2 dans la classe 5. Voici l'interprétation des résultats :

Précision: 90.06%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 0 % et 25 %, 90.06% étaient correctes.

Rappel : 91.19%, ce qui signifie que 91.19% des échantillons présentant réellement un défaut de court-circuit entre 0% et 25% de bobinage ont été correctement détectés par le modèle.

Score F1 : 90.62%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 0% et 25% de bobinage.

- Pour la classe 2 (défaut de court-circuit entre 0% et 50% de bobinage)

Le modèle a correctement classé 136 échantillons comme appartenant à la classe 2, mais il a mal classé 16 échantillons, 4 dans la classe 0, 6 dans la classe 1, 4 dans la classe 3 et 2 dans la classe 4. Voici l'interprétation des résultats :

Précision:85.53%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 0 % et 50 %, 85.53% étaient correctes.

Rappel : 89.47%, ce qui signifie que 89.47% des échantillons présentant réellement un défaut de court-circuit entre 0% et 50% de bobinage ont été correctement détectés par le modèle.

Score F1 :87.46%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 0% et 50% de bobinage.

- Pour la classe 3(défaut de court-circuit entre 0% et 75% de bobinage)

Le modèle a correctement classé 128 échantillons comme appartenant à la classe 3, mais il a mal classé 19 échantillons, 5 dans la classe 1, 4 dans la classe 2, 6 dans la classe 4 et 4 dans la classe 5. Voici l'interprétation des résultats :

Précision:87.67%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 0 % et 75 %, 87.67% étaient correctes.

Rappel :87.07%, ce qui signifie que 87.07% des échantillons présentant réellement un défaut de court-circuit entre 0% et 75% de bobinage ont été correctement détectés par le modèle.

Score F1 : 87.37%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 0% et 75% de bobinage.

- Pour la classe 4(défaut de court-circuit entre 25% et 50% de bobinage)

Le modèle a correctement classé 115 échantillons comme appartenant à la classe 4, mais il a mal classé 24 échantillons, 6 dans la classe 0, 2 dans la classe 1, 4 dans la classe 2, 5 dans la classe 3 et 7 dans la classe 5. Voici l'interprétation des résultats :

Précision:81.56%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 25 % et 50 %, 81.56% étaient correctes. **Rappel :**82.73%, ce qui signifie que 82.73% des échantillons présentant réellement un défaut de court-circuit entre 25% et 50% de bobinage ont été correctement détectés par le modèle.

Score F1 : 82.14% ,ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 25% et 50% de bobinage.

- Pour la classe 5 (défaut de court-circuit entre 50% et 75% de bobinage)

Le modèle a correctement classé 130 échantillons comme appartenant à la classe 5, mais il a mal classé 17 échantillons, 3 dans la classe 0 , 4 dans la classe 2, 4 dans la classe 3 et 6 dans la classe 4. Voici l'interprétation des résultats :

Précision:90.28%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 50% et 75% %, 90.28% étaient correctes.

Rappel :88.44% ,ce qui signifie que 88.44% des échantillons présentant réellement un défaut de court-circuit entre 50% et 75% de bobinage ont été correctement détectés par le modèle.

Score F1 : 89.35% ,ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 50% et 75% de bobinage.

Moyenne macro : Les moyennes des scores pour la précision, le rappel et le score F1 sont respectivement de 87.16%, 87.13% et 87.13% ce qui indique un bon équilibre de performance du modèle dans la détection des classes 0, 1, 2, 3 , 4 et 5 ,Sans parti pris envers une classification particulière.

Le modèle SVM présente de bonnes performances globales en distinguant l'état sain ainsi que les différents niveaux de court-circuit : entre 0 % et 25 %, entre 25 % et 50 %, entre 50 % et 75 %, entre 0 % et 50 % et entre 0 % et 75 % du bobinage. Bien que ces performances soient légèrement inférieures à celles obtenues avec des classifications moins complexes (en deux, trois ou quatre classes), elles restent satisfaisantes et montrent la capacité du modèle à gérer une complexité croissante des scénarios.

- Classe 0 vs Classe 1 vs Classe 2 vs Classe 3 vs Classe 4 vs Classe 5 vs Classe 6

Le modèle SVM a été entraîné pour distinguer et prédire l'état sain des enroulements du transformateur ainsi que six scénarios de court-circuit : entre 0 % et 25 %, entre 0 % et 50 %, entre 0 % et 75 %, entre 25 % et 50 %, entre 50 % et 75 % , et entre 75 % et 100 % du bobinage. Voici les résultats de la classification :




Figure V.43 Classification SVM avec frontière de décision : classe 0 vs classe 1 vs classe 2 vs classe 3 vs classe 4 vs classe 5 vs classe 6.

Dans la figure V.43, les zones vertes, grises, rouge clair, mauve clair, jaune, bleu ciel et bleu clair représentent respectivement les états suivants : « sain », « court-circuit entre 0 %, 25 % », « court-circuit entre 0 % et 50 % » et « court-circuit entre 0 % et 75 % », « court-circuit entre 25 % et 50 % », « court-circuit entre 50 % et 75 % », « court-circuit entre 75 % et 100 % ».

		Matrice de confusion						
Classe réelle	Classe 0	109	5	6	8	6	0	2
	Classe 1	1	136	1	3	2	3	2
	Classe 2	1	6	120	3	2	3	3
	Classe 3	2	6	6	133	2	3	2
	Classe 4	8	3	3	7	118	9	2
	Classe 5	2	0	1	2	10	140	3
	Classe 6	1	10	1	1	4	0	148
		Classe 0	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6
		Classe prédite						

Figure V.44 Matrice de confusion : classe 0 vs classe 1 vs classe 2 vs classe 3 vs classe 4 vs classe 5 vs classe 6

Classe	Précision (%)	Rappel (%)	F1-score (%)
Classe 0	87.90%	80.15%	83.85%
Classe 1	81.93%	91.89%	86.62%
Classe 2	86.96%	86.96%	86.96%
Classe 3	84.71%	86.36%	85.53%
Classe 4	81.94%	78.67%	80.27%
Classe 5	88.61%	88.61%	88.61%
Classe 6	91.36%	89.70%	90.52%
Moyenne macro (%)	Macro Précision :86.20%	Macro rappel:86.05%	Macro F1-score:86.05%
Training Accuracy (%)	95.57%		
Accuracy globale(%)	86.18%		

Tableau V.30 Rapport de classification du l'algorithme SVM : classe 0 vs classe 1 vs classe 2 vs classe 3 classe 4 vs classe 5 vs classe 6

Interprétation des résultats

Précision d'entraînement (Training Accuracy): Le modèle a démontré une excellente précision sur les données d'entraînement, atteignant 95.57%, ce qui indique d'excellentes performances pendant la phase d'apprentissage.

précision de test (test accuracy) : Le modèle atteint une précision de 86.18% sur les données de test, ce qui indique qu'il se généralise bien à de nouvelles données qu'il n'a pas vues pendant l'entraînement.

- Pour la classe 0 (absence de défaut)

Le modèle a correctement classé 109 échantillons comme appartenant à la classe 0, mais il a mal classé 27 échantillons, 5 dans la classe 1, 6 dans la classe 2, 8 dans la classe 3, 6 dans la classe 4 et 2 dans la classe 6. Voici l'interprétation des résultats :

Précision: 87.90%, ce qui signifie que parmi toutes les prédictions indiquant une absence de défaut, 87.90%%étaient correctes.

Rappel:80.15%, ce qui signifie que 80.15% des échantillons réellement sans défaut ont été correctement détectés par le modèle.

Score F1 :83.85%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas sans défaut.

- Pour la classe 1(défaut de court-circuit entre 0% et 25% de bobinage)

Le modèle a correctement classé 136 échantillons comme appartenant à la classe 1, mais il a mal classé 12 échantillons, 1 dans la classe 0 , 1 dans la classe 2 , 3 dans la classe 3 , 2 dans la classe 4 , 3 dans la classe 5 ,2 dans la classe 6 . Voici l'interprétation des résultats :

Précision: 81.93%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 0 % et 25 %, 81.93% étaient correctes.

Rappel :91.89%,ce qui signifie que 91.89% des échantillons présentant réellement un défaut de court-circuit entre 0% et 25% de bobinage ont été correctement détectés par le modèle.

Score F1 :86.62% ,ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 0% et 25% de bobinage.

- Pour la classe 2(défaut de court-circuit entre 0% et 50% de bobinage)

Le modèle a correctement classé 120 échantillons comme appartenant à la classe 2, mais il a mal classé 18 échantillons, 1 dans la classe 0 , 6 dans la classe 1 , 3 dans la classe 3 , 2 dans la classe 4 , 3 dans la classe 5 et 3 dans la classe 6. Voici l'interprétation des résultats :

Précision:86.96%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 0 % et 50 %, 86.96% étaient correctes.

Rappel :86.96%,ce qui signifie que 86.96% des échantillons présentant réellement un défaut de court-circuit entre 0% et 50% de bobinage ont été correctement détectés par le modèle.

Score F1 : 86.96%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 0% et 50% de bobinage.

- Pour la classe 3(défaut de court-circuit entre 0% et 75% de bobinage)

Le modèle a correctement classé 133 échantillons comme appartenant à la classe 3, mais il a mal classé 21 échantillons, 2 dans la classe 0, 6 dans la classe 1, 6 dans la classe 2, 2 dans la classe 4, 3 dans la classe 5 et 2 dans la classe 6. Voici l'interprétation des résultats :

Précision: 84.71%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 0 % et 75 %, 84.71% étaient correctes.

Rappel : 86.36%, ce qui signifie que 86.36% des échantillons présentant réellement un défaut de court-circuit entre 0% et 75% de bobinage ont été correctement détectés par le modèle.

Score F1 : 85.53%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 0% et 75% de bobinage.

- Pour la classe 4 (défaut de court-circuit entre 25% et 50% de bobinage)

Le modèle a correctement classé 118 échantillons comme appartenant à la classe 4, mais il a mal classé 32 échantillons, 8 dans la classe 0, 3 dans la classe 1, 3 dans la classe 2, 7 dans la classe 3, 9 dans la classe 5 et 2 dans la classe 6. Voici l'interprétation des résultats :

Précision: 81.94%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 25 % et 50 %, 81.94% étaient correctes.

Rappel : 78.67%, ce qui signifie que 78.67% des échantillons présentant réellement un défaut de court-circuit entre 25% et 50% de bobinage ont été correctement détectés par le modèle.

Score F1 : 80.27%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 25% et 50% de bobinage.

- Pour la classe 5 (défaut de court-circuit entre 50% et 75% de bobinage)

Le modèle a correctement classé 140 échantillons comme appartenant à la classe 5, mais il a mal classé 18 échantillons, 2 dans la classe 0, 1 dans la classe 2, 2 dans la classe 3, 10 dans la classe 4 et 3 dans la classe 6. Voici l'interprétation des résultats :

Précision: 88.61%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 50% et 75% %, 88.61% étaient correctes.

Rappel : 88.61% ,ce qui signifie que 88.61% des échantillons présentant réellement un défaut de court-circuit entre 50% et 75% de bobinage ont été correctement détectés par le modèle.

Score F1 : 88.61%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 50% et 75% de bobinage.

- Pour la classe 6(défaut de court-circuit entre 75% et 100% de bobinage)

Le modèle a correctement classé 148 échantillons comme appartenant à la classe 6, mais il a mal classé 17 échantillons, 1 dans la classe 0 , 10 dans la classe 1, 1 dans la classe 2 , 1 dans la classe 3 et 4 dans la classe 4. Voici l'interprétation des résultats :

Précision: 91.36%, ce qui signifie que parmi toutes les prédictions indiquant un défaut de court-circuit entre 75% et 100% , 91.36% étaient correctes.

Rappel : 89.70%, ce qui signifie que 89.70% des échantillons présentant réellement un défaut de court-circuit entre 75% et 100% de bobinage ont été correctement détectés par le modèle.

Score F1 : 90.52%, ce qui signifie un bon équilibre entre la précision et le rappel dans la détection des cas de défaut de court-circuit entre 75% et 100% de bobinage

Moyenne macro : Les moyennes des scores pour la précision, le rappel et le score F1 sont respectivement de 86.20%, 86.05% et 86.05% ce qui indique un bon équilibre de performance du modèle dans la détection des classes 0, 1, 2, 3 , 4 ,5 et 6 ,Sans parti pris envers une classification particulière.

Les résultats obtenus indiquent que le modèle SVM atteint d'excellentes performances dans la classification des différents états des enroulements du transformateur. Le modèle a démontré une grande capacité à distinguer l'état sain et les conditions de court-circuit à différents niveaux. Il a également été possible d'identifier avec précision le type de défaut.

Le modèle SVM présente de bonnes performances globales en distinguant l'état sain ainsi que les différents niveaux de court-circuit : entre 0 % et 25 %, entre 25 % et 50 %, entre 50 % et 75 %, entre 75 % et 100 % ,entre 0 % et 50 % et entre 0 % et 75 % du bobinage. Bien que ces performances soient légèrement inférieures à celles obtenues avec des classifications moins complexes (en deux, trois ou quatre classes), elles restent satisfaisantes et montrent la capacité du modèle à gérer une complexité croissante des scénarios.

V.5 Conclusion

Dans ce chapitre, les résultats montrent que l'utilisation d'indices mathématiques pour l'analyse de la réponse en fréquence (FRA) est une approche précise et efficace pour évaluer l'état des enroulements des transformateurs électriques. Certains indices, comme le SSRE, ont montré une grande sensibilité, même aux défauts mineurs, ce qui permet de suivre l'évolution de la détérioration. En revanche, les indices CC et q se sont avérés incapables d'identifier le défaut et de distinguer l'état sain de l'état défectueux, ce qui limite leur efficacité pour établir un diagnostic précis. Il a également été noté que d'autres indicateurs contribuent à détecter certains types de défauts, mais ne permettent pas de distinguer ou de détecter d'autres défauts. Il apparaît donc évident qu'il est important de combiner plusieurs indicateurs pour tirer parti de leurs différents atouts. Cette approche fournit une vue d'ensemble équilibrée de l'état de l'enroulement, améliorant ainsi la précision du diagnostic et contribuant à une maintenance optimale du transformateur.

Concernant la machine à vecteurs de support (SVM), les résultats ont mis en évidence de très bonnes performances dans le cas de la classification binaire, permettant de distinguer avec précision l'état sain des enroulements du transformateur ainsi que plusieurs niveaux de court-circuit. Malgré une légère baisse des performances due à la complexité des tâches et à l'augmentation du nombre de classes lors du passage à la classification multi-classes, le modèle a conservé de bonnes propriétés et des résultats satisfaisants, soulignant ainsi sa capacité à gérer plusieurs scénarios de défaillance.

CONCLUSION GENERALE

Les transformateurs de puissance sont des composants essentiels dans réseaux électriques, jouant un rôle principal dans la transmission et la distribution efficaces de l'énergie. Malgré leur fiabilité généralement élevée, ils peuvent présenter certaines défaillances, notamment celles liées aux déformations des enroulements. Ce type de défaut est l'un des plus complexes et il est difficile de le détecter visuellement à ses débuts, ce qui souligne l'importance des techniques de diagnostic avancées, telles que l'analyse de la réponse en fréquence (FRA), pour une détection précoce.

Cette étude utilise deux approches indépendantes pour diagnostiquer les défauts des enroulements des transformateurs de puissance : les indices mathématiques et la machine à vecteurs de support (SVM), basées sur les données de la réponse en fréquence (FRA). Ces méthodes visent à améliorer la détection précoce et la distinction entre états sains et défectueux, en dépassant l'interprétation visuelle traditionnelle.

Les résultats ont montré que les indicateurs mathématiques fournissent une compréhension complète et précise de l'état des enroulements. Certains indicateurs se sont révélés sensibles et efficaces pour détecter précocement certains types de défauts, tandis que d'autres ont montré une capacité limitée à distinguer les cas sains des cas défectueux. Il a également été démontré que la combinaison de plusieurs indicateurs permet d'affiner le diagnostic en offrant une vue d'ensemble plus précise.

Le modèle SVM a démontré sa grande capacité en matière de classification des défauts, en particulier dans le cas de la classification binaire, avec de bonnes performances dans les scénarios de classification multi-classes malgré la complexité accrue des tâches. Cela reflète l'adaptabilité du modèle à différents défis diagnostiques et permet d'obtenir des résultats fiables.

Cette étude souligne l'importance de combiner des méthodes quantitatives basées sur des indices mathématiques et des techniques intelligentes, telles que la machine à vecteurs de support (SVM), pour obtenir un diagnostic plus précis et plus rapide des défauts d'enroulement des transformateurs. Cette approche permet d'optimiser la maintenance des transformateurs, d'assurer la fiabilité des réseaux électriques et de diminuer les risques liés aux pannes.

Pour améliorer la précision d'un modèle SVM, notamment dans les scénarios de classification multi-classes, plusieurs axes peuvent être explorés. L'utilisation de données d'entrée basées sur

Conclusion générale

des indicateurs mathématiques à la place de signaux bruts permet par exemple de mieux saisir les différences entre les cas. Les modèles hybrides combinant SVM avec des algorithmes d'ensemble, tels que les forêts aléatoires ou les méthodes de boosting, peuvent également être étudiés afin de réduire les erreurs de classification et d'améliorer la robustesse du modèle face à la complexité croissante des scénarios de défaillance.

En conclusion, cette étude met en évidence l'importance du diagnostic des transformateurs électriques pour l'amélioration de leurs performances et la continuité de service des réseaux. Les résultats obtenus démontrent que l'utilisation d'indicateurs mathématiques combinée à des techniques modernes telles que les machines à vecteurs de support (SVM) constitue une voie prometteuse pour le développement de méthodes de diagnostic précoce. Ce travail ouvre ainsi des perspectives pour des recherches futures visant à optimiser la maintenance préventive des transformateurs et à renforcer l'efficacité des systèmes électriques.

BIBLIOGRAPHIE

- [1] M. Bagheri, M. S. Naderi, T. Blackburn, and T. Phung, Frequency response analysis and short-circuit impedance measurement in detection of winding deformation within power transformers, IEEE Elect. Insul. Mag., vol. 29, no. 3, pp. 3340, May 2013.
- [2] H.-M. Ahn, Y. H. Oh, J.-K. Kim, J.-S. Song, and S.-C. Hahn, Experimental verification and finite element analysis of short-circuit electromagnetic force for dry-type transformer, IEEE Trans. Magn., vol. 48, no. 2, pp. 819822, Feb. 2012.
- [3] M. Wang, Winding movement and condition monitoring of power transformers in service, Ph.D. dissertation, Dept. Elect. Comput. Eng., Univ. British Columbia, Vancouver, BC, Canada, 2003.
- [4] M. Bagheri, A. Zollanvari, and S. Nezhivenko, Transformer fault condition prognosis using vibration signals over cloud environment, IEEE Access, vol. 6, pp. 98629874, 2018.
- [5] A. Abu-Siada, N. Hashemnia, S. Islam, and M. A. S. Masoum, Understanding power transformer frequency response analysis signatures, IEEE Elect. Insul. Mag., vol. 29, no. 3, pp. 4856, May 2013.
- [6] H. Rahbarimagham, H. K. Porzani, M. S. A. Hejazi, M. S. Naderi, and G. B. Gharehpetian, Determination of transformer winding radial deformation using UWB system and hyperboloid method, IEEE Sensors J., vol. 15, no. 8, pp. 41944202, Aug. 2015.
- [7] U. A. Bakshi and M. V. Bakshi, Electrical Machines-I. Technical Publications, 2020.
- [8] M. Wang, A. J. Vandermaar, and K. D. Srivastava, "Review of condition assessment of power transformers in service," IEEE Electrical Insulation Magazine, vol. 18, no. 6, pp. 12-25, 2002.
- [9] : Formation Transformateur GRTE avril 2005.
- [10] : JEAN SANCHEZ « Aide au diagnostic de défauts des transformateurs de puissance » Thèse de doctorat, Université de Grenoble, 2006.
- [11] : BOUCHOU HAMZA et DJEDILI MOHAMED « Modélisation des transformateurs triphasés basée sur l'analyse de la réponse en fréquence en HF et son diagnostic » Mémoire de Master, 2021.
- [12] : ANKITA NAMEDO AND DR. SHAILJA SHUKLA FAULT « Identification of 45MVA Transformer winding by changing Capacitance Value Using Frequency Response Analysis with Artificial Bee Colony », Method International Journal of Novel Research and Mechanical Engineering Vol 2.

- [13] : MR.KHALDI M ET MR.BOUAICHA OUI I« Modélisation et analyse fréquentielle dans les enroulements d'un transformateur triphasé en régime MF :application d'ABC» Université de Médéa ,2021.
- [14] AZZOUZ, Zin-Eddine. Modélisation 3D d'un transformateur de puissance. Etude de son comportement à haute fréquence. 1992. Thèse de doctorat. Institut National Polytechnique Grenoble (INPG).DidierNilly.Lediagnosticd'e ´tatdestransformateursdepuissance.2017.
- [15] PARK, Chanyeop. Electret: An entirely new approach of solving partial discharge caused by triple points, sharp edges, bubbles, and airgaps. IEEE Access, 2020, vol. 8, p. 78354-78366.
- [16] HUSSAIN, Md Rashid, REFAAT, Shady S., et ABU-RUB, Haitham. Overview and partial discharge analysis of power transformers: A literature review. IEEE Access, 2021, vol. 9, p. 64587-64605.
- [17] Site maintenance des transformateurs TSV TRANSFORMATEURS SULUTION VENISIEUX <http://www.tsv-transfo.com/fr/>
- [18] *Les transformateurs électriques : Théorie, technologie, applications*,Dunod, 2^e édition, 2018. ISBN: 978-2100788987.
- [19]*Les transformateurs : Théorie et technologie des transformateurs de puissance*,Éditions Tec & Doc (Lavoisier), 2006.
- [20] S.V. Kulkarni, S.A. Khaparde,*Transformer Engineering: Design, Technology, and Diagnostics*,CRC Press, 2nd edition, 2012.
- [21]Pierre Delaroche, *Transformateurs et équipements électriques : cours et exercices corrigés*, Éditions Cépaduès, 2011.
- [22] M. Azizi Abdul Rahman, H. Hashim, and P. S., “Frequency Response Analysis of a Power Transformer,” *Electrical Engineering Department, College of Engineering, UniversitiTenaga Nasional*,
- [23] S. Tenbohlen, «Assessment Of Power Transformer Reliability Xvii,» International Symposium on High Voltage Engineering, Hannover, Germany, 2011.
- [24]SATISH, L. et SAHOO, Subrat K. Locating faults in a transformer winding: An experimental study. Electric Power Systems Research, 2009, vol. 79, no 1, p. 89-97

- [25] RAGAVAN, K. et SATISH, L. Localization of changes in a model winding based on terminal measurements: Experimental study. *IEEE transactions on power delivery*, 2007, vol. 22, no 3, p. 1557-1565.
- [26] Charles Sweetser, B.Sc., M.Sc. Dr. Tony McGrail, 'Sweep Frequency Response Analysis Transformer Applications A Technical Paper from Doble Engineering' Version 1.0, 01/2003
- [27] CIGRE Working Group A2.53, *Interprétation des mesures FRA des transformateurs*, CIGRE Technical Brochure No. 812, October 2020. Disponible en ligne : <https://electra.cigre.org/fr/312-october-2020/technical-brochures/interpretation-des-mesures-fra-des-transformateurs.html>
- [28] S. Banaszak, K. M. Gawrylczyk, and K. Trela, "Frequency Response Modelling of Transformer Windings Connected in Parallel," *Energies*, vol. 13, no. 6, p. 1395, 2020. [Online]. Available: <https://www.mdpi.com/1996-1073/13/6/1395>
- [29] Rahimpour, Hossein. The Practical Field Measurement Challenges of Transformer FRA and Developing the Fundamentals for an On-line Approach. 2018. Thèse de doctorat. Master Thesis. Master of Philosophy in Electrical Engineering. The University of Newcastle.
- [30] Modélisation électronique et électromagnétique d'un transformateur haute fréquence à circuit magnétique en fonte François Blache.
- [31] MOUSAVI, Seyedali. Electromagnetic modelling of power transformers for study and mitigation of effects of GICs. 2015. Thèse de doctorat. KTH Royal Institute of Technology.
- [32] Zhao, X.; Wu, G.; Yang, D.; Xu, G.; Xing, Y.; Yao, C.; Abu-Siada, A. Enhanced detection of power transformer winding faults through 3D FRA signatures and image processing techniques. *Electr. Power Syst. Res.* 2025, 242, 111433. [[Google Scholar](#)] [[CrossRef](#)]
- [33] Zhang, Z. Derivation of transformer winding equivalent circuit by employing the transfer function obtained from frequency response analysis data. *IET Electr. Power Appl.* 2024, 18, 826–840. [[Google Scholar](#)] [[CrossRef](#)]
- [34] Reddy, R.; Shah, K.; Kallamadi, M. Performance Evaluation of Laboratory and Industrial Equipment in FRA Measurement. *Iran. J. Sci. Technol. Trans. Electr. Eng.* 2024, 48, 187–199. [[Google Scholar](#)] [[CrossRef](#)]

- [35] L. Bouchaoui, K. E. Hemsas, and S. Belahneche, "Diagnostic des transformateurs de puissance par l'analyse de la réponse fréquentielle (FRA)," LAS, Université Ferhat Abbas, Sétif; Laboratoire d'Analyse Régionale,
- [36] Bergman, C. 'SFRA-an application that creates customer value?' Thesis Department Electrical Engineering Sweden, 2006.
- [37] OMICRON electronics « FR Analyzer Manuel d'utilisation » Référence -VESD0662 Version du manuel : FRA.FR.1, 2006.
- [38] Megger 'FRAX 101 Analyseur de réponse de la fréquence de balayage 'FRAX101_DS_Fr_V01.
- [39] Kumara, S; Matharage, S; Bandara, K; et al 'Frequency Domain Measurements for Diagnosis of Power Transformers: Experiences from Australia, Malaysia, Sri Lanka and UK', CIGRE Science and Engineering, 24 August 2022
- [40] IEC 60076-18, "Power Transformers-part 18: Measurement of Frequency Response," 2012.
- [41] IEEE Std C57.149-2012, "IEEE Guide for the Application and Interpretation of Frequency Response Analysis for Oil-Immersed Transformers," pp. 1-72, 2013.
- [42] Cigre technical brochure 342, "Mechanical Condition Assessment of Transformer Windings using Frequency Response Analysis (FRA)," Cigre working group WG A2.26
- [43] C. Parkash and A. R. Abbasi, "Transformer's frequency response analysis results interpretation using a novel cross entropy based methodology," *Scientific Reports*, vol. 13, no. 1, pp. 1–12, Apr. 2023,
- [44] M. H. Samimi and S. Tenbohlen, "FRA interpretation using numerical indices: State-of-the-art," *Electric Power Systems Research*, vol. 89, pp. 115-125, 2017.
- [45] J. Gonzales Arispe and E. Mombello, "Detection of failures within transformers by FRA using multiresolution decomposition," *IEEE Transactions on Power Delivery*, vol. 29, no. 3, pp. 1127–1137, Jun. 2014,.
- [46] A. J. Ghanizadeh and G. B. Gharehpetian, "ANN and cross-correlation based features for discrimination between electrical and mechanical defects and their localization in transformer winding," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 21, no. 5, pp. 2374–2382, Oct. 2014

[47] M. Bigdeli, M. Vakilian, and E. Rahimpour, "A new method for detection and evaluation of winding mechanical faults in transformer through transfer function measurements," *Advances in Electrical and Computer Engineering*, vol. 11, no. 2, pp. 23–30, 2011.

[48] Ghanizadeh AJ, Gharehpetian GB. ANN and cross-correlation based features for discrimination between electrical and mechanical defects and their localization in transformer winding. *IEEE Trans Dielectr Electr Insul* 2014;21 (5):2374–82. <http://dx.doi.org/10.1109/TDEI.2014.004364>.

[49] Pourhossein K, Gharehpetian G, Rahimpour E, Araabi B. A probabilistic feature to determine type and extent of winding mechanical defects in power transformers. *Electr Power Syst Res* 2012;82(1):1–10.

[50] Bagheri M, Phung B, Blackburn T. Influence of temperature and moisture content on frequency response analysis of transformer winding. *IEEE Trans Dielectr Electr Insul* 2014;21(3):1393–404. <http://dx.doi.org/10.1109/TDEI.2014.6832288>.

[23 51] Nirgude P, Ashokraj D, Rajkumar A, Singh B. Application of numerical evaluation techniques for interpreting frequency response measurements in power transformers. *IET Sci Meas Technol* 2008;2(5):275–85. <http://dx.doi.org/10.1049/iet-smt:20070072>.

[52] SantAna WC, Salomon CP, Lambert-Torres G, da Silva LEB, Bonaldi EL, de Lacerda de Oliveira LE, et al. A survey on statistical indexes applied on frequency response analysis of electric machinery and a trend based approach for more reliable results. *Electr Power Syst Res* 2016;137:26–33.

<http://dx.doi.org/10.1016/j.epsr.2016.03.044>.

[53] Secue J, Mombello E. Sweep frequency response analysis (SFRA) for the assessment of winding displacements and deformation in power transformers. *Electr Power Syst Res* 2008;78(6):1119–28. <http://dx.doi.org/10.1016/j.epsr.2007.08.005>

[54] Ryder SA. Transformer diagnosis using frequency response analysis: results from fault simulations. In: *Power engineering society summer meeting, 2002*, vol. 1. IEEE; 2002. p. 399–404. <http://dx.doi.org/10.1109/PESS.2002.1043265>.

[55] Kim J-W, Park B, Jeong SC, Kim SW, Park P. Fault diagnosis of a power transformer using an improved frequency-response analysis. *IEEE Trans Power Deliv* 2005;20(1):169–78. <http://dx.doi.org/10.1109/TPWRD.2004.835428>.

- [56] Rahimpour E, Jabbari M, Tenbohlen S. Mathematical comparison methods to assess transfer functions of transformers to detect different types of mechanical faults. *IEEE Trans Power Deliv* 2010;25(4):2544–55. <http://dx.doi.org/10.1109/TPWRD.2010.2054840>
- [57] Heindl M, Tenbohlen S, Kraetge A, Krüger M, Velásquez J. Algorithmic determination of pole-zero representations of power transformers transfer functions for interpretation of FRA data. In: Paper D-26, 16th int. symp. on high voltage engineering, Johannesburg; 2009.
- [58] Tang WH, Shintemirov A, Wu QH. Detection of minor winding deformation fault in high frequency range for power transformer. In: IEEE PES general meeting; 2010. p. 1–6. <http://dx.doi.org/10.1109/PES.2010.5589573>.
- [59] Ji T, Tang W, Wu Q. Detection of power transformer winding deformation and variation of measurement connections using a hybrid winding model. *Electr Power Syst Res* 2012;87:39–46. <http://dx.doi.org/10.1016/j.epsr.2012.01.007>
- [60] IEEE guide for the application and interpretation of frequency response analysis for oil-immersed transformers. *IEEE Std C57.149-2012*; 2013. p. 1–72. <http://dx.doi.org/10.1109/IEEESTD.2013.6475950>.
- [61] Wimmer R, Tenbohlen S, Heindl M, Kraetge A, Krüger M, Christian J. Development of algorithms to assess the FRA. In: Proc. of 15th international symposium on high voltage engineering, T7-523; 2007.
- [62] Gonzales Arispe J, Mombello E. Detection of failures within transformers by FRA using multiresolution decomposition. *IEEE Trans Power Deliv* 2014;29 (3):1127–37. <http://dx.doi.org/10.1109/TPWRD.2014.2306674>.
- [63] Nirgude P, Ashokraju D, Rajkumar A, Singh B. Application of numerical evaluation techniques for interpreting frequency response measurements in power transformers. *IET Sci Meas Technol* 2008;2(5):275–85. <http://dx.doi.org/10.1049/iet-smt:20070072>.
- [64] Badgujar KP, Maoyafikuddin M, Kulkarni SV. Alternative statistical techniques for aiding SFRA diagnostics in transformers. *IET Gener Transm Distrib* 2012;6 (3):189–98. <http://dx.doi.org/10.1049/iet-gtd.2011.0268>.
- [65] Karimifard P, Gharehpetian G, Tenbohlen S. Determination of axial displacement extent based on transformer winding transfer function estimation using vector-fitting method. *Eur Trans Electr Power* 2008;18 (4):423–36.

- [66] Bigdeli M, Vakilian M, Rahimpour E. Transformer winding faults classification based on transfer function analysis by support vector machine. *IET Electr Power Appl* 2012;6(5):268–76. <http://dx.doi.org/10.1049/iet-epa.2011.0232>.
- [67] Samimi MH, Tenbohlen S, Akmal AAS, Mohseni H. Using the complex values of the frequency response to improve power transformer diagnostics. In: 2016 24th Iranian conference on electrical engineering (ICEE); 2016. p. 1689–93.
- [68] Behjat V, Mahvi M. Statistical approach for interpretation of power transformers frequency response analysis results. *IET Sci Meas Technol* 2015;9(3):367–75. <http://dx.doi.org/10.1049/iet-smt.2014.0097>.
- [69] Samimi M, Tenbohlen S, Shayegani Akmal A, Mohseni H. Effect of terminating and shunt resistors on the FRA method sensitivity. In: Proceedings of the international power system conference, Tehran, Iran; 2015. p. 23–5.
- [70] Pham D, Velsquez JL, Pham TMT, Gockenbach E. Noise and denoising methods for measured frequency response signals of power transformers.
- [71] Ryder SA. Transformer diagnosis using frequency response analysis: results from fault simulations. In: Power engineering society summer meeting, 2002, vol. 1. IEEE; 2002. p. 399–404. <http://dx.doi.org/10.1109/PESS.2002.1043265>.
- [72] A. Khalil and A. Ibrahim, "Statistical approach for interpretation of power transformers frequency response analysis results," *IET Science, Measurement & Technology*, vol. 8, no. 5, pp. 255–261, 2014. [Online]. Available: <https://doi.org/10.1049/iet-smt.2014.0097>
- [73] B. Gavrilovic, M. Lukic, and A. Djordjevic, "A Comprehensive Review of Transformer Winding Diagnostics," *Energies*, vol. 18, no. 5, p. 1209, Mar. 2023. Available: <https://doi.org/10.3390/en18051209>
- [74] S. Shahriari and A. Jalilian, "Performance of Mathematical Indices in Transformer Condition Assessment," *Electrical Engineering (EEJ) – Amirkabir University of Technology*, vol. 72, no. 1, pp. 27–34, 2020. Available: https://eej.aut.ac.ir/article_4237_806e43dc3378583b0857559b4ec61
- [75] Wang, J., Ma, Y., Zhang, L., Gao, R. X., & Wu, D. (2018). Deep learning for smart manufacturing: Methods and applications. *Journal of Manufacturing Systems*, 48, 144.

- [76].N. Yüksel, H. R. Börklü, H. K. Sezer, and O. E. Canyurt, "Review of artificial intelligence applications in engineering design perspective," *Engineering Applications of Artificial Intelligence*, vol. 118, p. 105697, 2023/02/01/ 2023,
- [77].M. Bertolini, D. Mezzogori, M. Neroni, and F. Zammori, "Machine Learning for industrial applications: A comprehensive literature review," *Expert Systems with Applications*, vol. 175, p. 114820, 2021/08/01/ 2021
- [78].C.-H. Chien, A. J. C. Trappey, and C.-C. Wang, "ARIMA-AdaBoost hybrid approach for product quality prediction in advanced transformer manufacturing," *Advanced Engineering Informatics*, vol. 57, p. 102055, 2023/08/01/ 2023
- [79].M. de Castro-Cros, M. Velasco, and C. Angulo, "Machine-Learning-Based Condition Assessment of Gas Turbines—A Review," *Energies*, vol. 14, no. 24, p. 8468, 2021.
- [80].A. Kumbhar, P. G. Dhawale, S. Kumbhar, U. Patil, and P. Magdum, "A comprehensive review: Machine learning and its application in integrated power system," *Energy Reports*, vol. 7, pp. 5467-5474, 2021/11/01/ 2021
- [81] M. A. Hariri-Ardebili, G. Mahdavi, L. K. Nuss, and U. Lall, "The role of artificial intelligence and digital technologies in dam engineering: Narrative review and outlook," *Engineering Applications of Artificial Intelligence*, vol. 126, p. 106813, 2023/11/01/ 2023
- [82] S. R. Vadyala, S. N. Betgeri, J. C. Matthews, and E. Matthews, "A review of physics-based machine learning in civil engineering," *Results in Engineering*, vol. 13, p. 100316, 2022/03/01/ 2022
- [83] EsmailiNezhad, A.; Samimi, M.H. A review of the applications of machine learning in the condition monitoring of transformers. *Energy Syst* 2024, 15, 463–493. [CrossRef]
- [84] Barkas, D.A.; Kaminaris, S.D.; Kalkanis, K.K.; Ioannidis, G.C.; Psomopoulos, C.S. Condition Assessment of Power Transformers through DGA Measurements Evaluation Using Adaptive Algorithms and Deep Learning. *Energies* 2023, 16, 54. [CrossRef]
- [85] Picher, P.; Lachman, M.; Patel, P. Advances in the interpretation of transformer Frequency Response Analysis (FRA). In *Cigre Technical Brochure*; Cigre: Paris, France, 2020; Volume 812.
- [86] P. Santos, L. F. Villa, A. Reñones, A. Bustillo, and J. Maudes, "An SVM Based Solution for Fault Detection in Wind Turbines," *Sensors*, vol. 15, no. 3, pp. 5627-5648, 2015.

- [87] S. Jain and A. Saha, "Improving performance with hybrid feature selection and ensemble machine learning techniques for code smell detection," *Science of Computer Programming*, vol. 212, p. 102713, 2021/12/01/ 2021,
- [88] X. Dong, Y. Liang, S. Miyamoto, and S. Yamaguchi, "Ensemble learning based software defect hjchchkshdz," *Journal of Engineering Research*, vol. 11, no. 4, pp. 377-391, 2023/12/01/ 2023,
- [89] "classification." <https://scikit-learn.org/stable/modules/svm.html#classification> (accessed.
- [90] E. Mayoraz and E. Alpaydin. Support vector machines for multi-class classification. Technical Report 98-06, IDIAP, 1998.
- [91] T.G. Dietterich and G. Bakiri. Solving multiclass learning problems via error-correcting output codes. *Journal of Artificial Intelligence Research*, 2 :263-286, 1995.
- [92] Analytics Vidhya, "Multiclass Classification Using SVM," *Analytics Vidhya*, May 6, 2021. [Online]. Available: <https://www.analyticsvidhya.com/blog/2021/05/multiclass-classification-using-svm/>. [Accessed: Apr. 15, 2025]
- [93] Analytics Vidhya, "Support Vector Machine (SVM) Algorithm: A Complete Guide for Beginners," *Analytics Vidhya*, Oct. 14, 2021. [Online]. Available: <https://www.analyticsvidhya.com/blog/2021/10/support-vector-machinessvm-a-complete-guide-for-beginners/>. [Accessed: Apr. 15, 2025]
- [94] G. Ciaburro, *MATLAB for Machine Learning*, 2nd ed. Birmingham, UK: Packt Publishing, 2024
- [95] ZhaoZhongyong, Chao Tang, Qu Zhou, Lingna Xu, YingangGui, and Chenguo Yao, Identification of power transformer winding mechanical fault types based on online IFRA by support vector machine, *Energies*, 2022, vol. 10, no. 12.
- [96] L. Oneto, D. Anguita, and A. Ghio, "Model selection for support vector machines: Advantages and disadvantages of the Machine Learning Theory," 2011. [Online]. Available: <https://www.researchgate.net/publication/224181170>
- [97] Rajesh Reddy ,Krupa Shah , ManjunathKallamadi,' Towards Unique Circuit Synthesis of Power Transformer Winding using Gradient and Population based Methods', *IEEE LATIN*

AMERICA TRANSACTIONS, VOL. 21, NO. 3, MARCH 2023Population based Methods’,
IEEE LATIN AMERICA TRANSACTIONS, VOL. 21, NO. 3, MARCH 2023

ANNEXE

EXPLOITATION DE LA BASE DES DONNÉES

La capture d'écran ci-dessous présente une section de la base de données utilisée dans le chapitre v.

	A	B	C	D	E	F	G	H
1	Fréquence(Hz)	Impédance(DB	Étiquette					
2	2024	126.7798	0					
3	2692	132.5055	0					
4	3360	136.9664	0					
5	281896	162.1815	1					
6	282564	161.9138	1					
7	345356	126.8321	2					
8	346024	126.2530	2					
9	233132	115.7234	3					
10	233800	114.8306	3					
11	498328	150.5448	4					
12	499664	150.4721	4					
13	668	69.8481	5					
14	1336	83.1472	5					
15								
16								
17								
18								
19								
20								
21								

