

Champ Magnétique Externe et Apprentissage Automatique pour le Diagnostic des Courts-Circuits Inter-Spires dans les Machines Synchrones

Mouad TALBAOUI^a, Younes AZZOU^a, Sébastien RAMEL^b, Remus PUSCA^a, Eric LEFEVRE^b, Raphaël ROMARY^a

^a Univ. Artois, UR 4025, Laboratoire Systèmes Électrotechniques et Environnement (LSEE), Béthune, F-62400, France

^b Univ. Artois, UR 3926, Laboratoire de Génie Informatique et d'Automatique de l'Artois (LGI2A), Béthune, F-62400, France
 mouad.talbaoui@univ-artois.fr

La détection précoce des courts-circuits inter-spires statoriques dans les machines synchrones constitue un enjeu majeur pour garantir la fiabilité des systèmes industriels. Cet article propose une méthode de classification fondée sur une forêt aléatoire, entraînée à partir de caractéristiques temporelles extraites des signaux de champ magnétique externe. Les signaux utilisés pour l'apprentissage sont générés par un modèle par éléments finis simplifié, permettant de réduire les coûts expérimentaux et le temps de traitement. Le modèle est d'abord évalué sur des données simulées, puis testé sur des signaux expérimentaux acquis en laboratoire. Les résultats montrent que, bien que performant sur données simulées, le modèle présente une capacité de généralisation limitée aux conditions réelles. Une stratégie d'ajustement, consistant à introduire des signaux expérimentaux dans l'apprentissage, permet d'améliorer significativement la précision de la classification. Cette approche hybride, simulation/expérimentation, offre ainsi une solution efficace, rapide et économiquement avantageuse pour le diagnostic de défauts dans les machines électriques.

Mots-clés— Diagnostic, courts-circuits, éléments finis, forêt aléatoire, champ magnétique externe, machine synchrone, apprentissage automatique, Catch22.

1. INTRODUCTION

Les machines synchrones sont largement utilisées dans plusieurs domaines tels que la production d'énergie, la propulsion électrique, la traction ferroviaire et les procédés industriels. Dans ces contextes, la fiabilité opérationnelle est primordiale, et toute défaillance non anticipée peut engendrer des interruptions de service et des pertes économiques substantielles. Parmi les différents types de défauts, ceux affectant les enroulements statoriques représentent une proportion importante des pannes recensées dans les machines électriques.

Selon une étude portant sur des moteurs électriques de puissance supérieure à 150 kW [1], 37 % des pannes sont liées au stator. Une autre étude [2], menée sur des moteurs asynchrones à cage de plus de 10 kW, principalement sous basse tension, estime cette proportion à environ 16 %. Cette différence peut s'expliquer par les variations de taille des machines et à la conception de leur système d'isolation.

Les Courts-Circuits Inter-Spires Statoriques (CCISS) figurent parmi les défauts statoriques les plus critiques.

Lorsqu'ils surviennent, ils entraînent des courants de défaut localisés, provoquant un échauffement rapide susceptible d'évoluer vers un court-circuit phase-masse ou phase-phase, menant à une défaillance complète de la machine [3].

Pour détecter ces défauts à un stade précoce, diverses techniques ont été proposées, notamment l'analyse des signatures de courant, des vibrations, ou encore du champ magnétique de fuite [4]. Ces dernières années, l'intégration de l'intelligence artificielle a permis d'améliorer la sensibilité et la précision des diagnostics. Par exemple, certains travaux ont obtenu une précision de 98 à 100 % en utilisant plus de 17 000 mesures expérimentales du champ magnétique externe pour entraîner des modèles d'apprentissage automatique comme les *k*-plus proches voisins, les perceptrons multicouches, les forêts aléatoires ou le gradient boosting extrême [5]. D'autres approches ont utilisé un capteur unique mesurant le champ dans l'entrefer, combiné à un réseau de neurones convolutif alimenté par une transformée en ondelettes, atteignant une précision de 98,6 % [6]. Enfin, certaines méthodes hybrides exploitant conjointement les signaux de courant et de champ magnétique, avec des techniques telles que la transformée en ondelettes discrète suivie d'un classifieur à vecteurs de support, sont désormais implémentables sur des composants logiques programmables (FPGA), rendant leur déploiement industriel envisageable [7].

Malgré leurs performances, ces méthodes présentent plusieurs limitations. D'une part, la plupart nécessitent un grand volume de données expérimentales pour l'apprentissage, dont l'acquisition est souvent longue, coûteuse, voire risquée. D'autre part, certaines approches s'appuient sur des configurations invasives, ce qui augmente la complexité du système. Enfin, plusieurs méthodes reposent sur une analyse fréquentielle, généralement plus lourde en calcul et moins adaptée aux contraintes de diagnostic rapide que l'analyse dans le domaine temporel.

Face à ces limites, nous proposons une approche hybride pour la détection des CCISS, reposant sur un modèle de forêt aléatoire entraîné à partir de caractéristiques statistiques extraites dans le domaine temporel de signaux de champ magnétique externe. Ces signaux sont obtenus via des simulations 2D par éléments finis, représentant différents scénarios de fonctionnement, sains et défectueux. Cette stratégie

permet d'éviter l'introduction de défauts réels sur la machine et réduit considérablement le coût et la durée de la phase d'apprentissage. De plus, l'utilisation de caractéristiques temporelles, rapides à extraire, rend l'approche compatible avec des contraintes de calcul réduites. L'originalité de ce travail réside donc dans l'exploitation exclusive de données simulées pour l'apprentissage initial, combinée à une phase d'ajustement minimal via des mesures réelles, tout en s'appuyant sur des descripteurs temporels légers mais discriminants.

La suite de cet article est structurée comme suit : la section 2 décrit la méthodologie proposée ; la section 3 présente les données simulées et expérimentales ; la section 4 détaille le traitement des signaux et l'extraction des caractéristiques ; la section 5 expose les résultats de l'entraînement et de l'évaluation du modèle ; enfin, la section 6 conclue ce travail.

2. METHODOLOGIE

La méthodologie de l'approche proposée (Fig.1) repose sur l'extraction de caractéristiques temporelles à partir de signaux du champ magnétique externe d'une machine synchrone, afin de détecter la présence de CCISS. Ces signaux proviennent de deux sources complémentaires :

- des données simulées, obtenues par modélisation 2D par éléments finis de la machine,
- des mesures expérimentales, collectées via un capteur bobiné placé autour de la machine.

Pour représenter efficacement les signaux tout en réduisant le coût de calcul, l'algorithme Catch22 est utilisé pour extraire 22 caractéristiques statistiques dans le domaine temporel. Ces caractéristiques servent d'entrée à un modèle de forêt aléatoire, entraîné pour classifier les états sain/défectueux.

L'évaluation du modèle repose sur une validation croisée stratifiée à 5 plis, avec les indicateurs F1-score et AUC (Area Under the Curve ROC) comme mesures de performance. Le modèle est, dans un premier temps, entraîné uniquement à partir de données simulées, puis testé sur des signaux expérimentaux. Dans un second temps, ses performances ont été améliorées par l'intégration d'un faible volume de données réelles au jeu d'apprentissage.




Fig. 1 Diagramme de la méthodologie proposée pour la détection des défauts CCISS.

3. ACQUISITION ET GENERATION DE DONNEES

Pour entraîner un modèle de classification supervisé capable de distinguer les signaux de champ magnétique externe d'une machine saine de ceux d'une machine présentant un CCISS, il est indispensable de disposer de données représentatives dans les deux états, et ce, sur une diversité de points de fonctionnement. Toutefois, l'acquisition expérimentale de ces signaux est souvent coûteuse, longue à mettre en œuvre et techniquement contraignante. Pour pallier ces limitations, un modèle simplifié de la machine a été développé par la méthode des éléments finis, permettant de générer un ensemble de signaux simulés couvrant plusieurs conditions de fonctionnement, en situation saine comme défectueuse. En complément, la machine réelle a été modifiée de manière à introduire volontairement un CCISS, rendant possible l'enregistrement de signaux expérimentaux destinés à valider les performances du modèle sur des données réelles.

3.1. Machine étudiée

L'étude a été menée sur une machine synchrone triphasée à rotor bobiné d'une puissance nominale de 10 kVA, conçue pour un fonctionnement de 230V/400V et une fréquence de 50 Hz. La machine est dotée de 4 pôles et atteint une vitesse nominale de 1500 tr/min. Le bobinage rotorique est alimenté en courant continu via des bagues collectrices.

Pour les besoins de l'étude, la machine a été modifiée afin de permettre l'introduction contrôlée de défauts de type CCISS sur les trois phases statoriques, avec différents niveaux de sévérité. Cette modification rend possible la réalisation d'essais expérimentaux dans des conditions reproductibles.

3.2. Modélisation par éléments finis

Comme décrit dans [8], la méthode des éléments finis offre une compréhension plus fine des phénomènes physiques dans les machines électriques que les modèles analytiques classiques. Elle a donc été retenue pour modéliser à la fois la machine et les capteurs. Cependant, un modèle 3D complet serait trop complexe et coûteux en temps de calcul. Pour équilibrer précision et efficacité, un modèle 2D simplifié avec couplage circuit a été adopté.

Un modèle géométrique de la machine ainsi qu'un modèle du capteur bobiné ont été réalisés (Fig.2). La géométrie de la machine comprend l'arbre, le rotor, le noyau du stator et l'entrefer. Les encoches du stator ont été simplifiées sous forme rectangulaire. Les enroulements statorique et rotorique sont modélisés électriquement à l'aide de bobines, dont le nombre de spires est défini par la géométrie.

Le CCISS est représenté de manière explicite, à la fois dans le modèle géométrique et dans le modèle de circuit (Fig.3). Les enroulements de la phase A ont été modélisés de façon détaillée, chaque spire étant représentée individuellement. Une résistance de faible valeur est insérée entre certaines spires pour simuler la condition de défaut. Le modèle a été finement maillé, en particulier au niveau de l'entrefer, afin de garantir une précision adéquate dans les zones critiques du champ magnétique.

Le capteur bobiné, composé de 1200 spires, est intégré au circuit avec une résistance de charge élevée, permettant de mesurer la tension induite. Différentes conditions de fonctionnement ont été simulées, en faisant varier la vitesse de rotation, le courant d'excitation, le niveau de charge, la sévérité du défaut (de 1 à 6 spires court-circuitées), ainsi que la position du capteur par rapport à celle du défaut (Fig.2). Les signaux de

force électromotrice ont été enregistrés pour chaque configuration avec une fréquence d'échantillonnage de 10 kHz.

Au total, 1464 signaux ont été générés, dont 600 correspondent à des états défectueux et 864 à des états sains (Fig.5).




Fig. 2 Modèle par éléments finis de la machine synchrone et du capteur dans différentes positions, et la distribution du champ magnétique simulé (vue en coupe radiale).




Fig. 3 Schéma de circuit du modèle par éléments finis illustrant l'introduction d'un court-circuit entre deux spires de la phase A du stator.

3.3. Mesures expérimentales

Un banc d'essai a été mis en place en laboratoire (Fig.4), comprenant la machine synchrone modifiée couplée à une machine à courant continu et à une charge résistive. La machine à courant continu entraîne mécaniquement la machine synchrone, dont le rotor est excité par un courant continu, simulant ainsi un fonctionnement en mode génératrice, identique à celui utilisé dans les simulations.




Fig. 4 Banc d'essai expérimental.

Comme pour la simulation, un capteur bobiné de 1200 spires est placé autour de la machine, perpendiculairement à l'axe statorique, au centre de celle-ci. La position du capteur peut également être modifiée afin d'évaluer l'influence de son emplacement par rapport à la zone du défaut. Le capteur est connecté à une carte d'acquisition de données, intégrée à un système LabVIEW pour une acquisition en temps réel. Des essais ont été réalisés en faisant varier les conditions d'excitation

rotorique, le niveau de charge, la sévérité du défaut ainsi que la position du capteur. Les signaux ont été enregistrés à une fréquence d'échantillonnage de 100 kHz.

Au total, 184 signaux expérimentaux ont été collectés, dont 146 en état défectueux et 38 en état sain (Fig.5).

4. TRAITEMENT DES DONNEES

Afin de garantir la cohérence et la reproductibilité entre les données simulées et expérimentales, un ensemble d'étapes de traitement a été appliqué avant l'entraînement du modèle de classification. Dans les essais expérimentaux, la vitesse de rotation de la machine n'a pas dépassé 1500 tr/min, correspondant à une fréquence fondamentale $f = 50$ Hz. Il est bien établi dans [9], [10] et [11] que les CCISS génèrent des composantes harmoniques dans les basses fréquences, notamment à des fréquences définies par la relation $n \times k \times f$ avec $k = 1$ ou 3 et $n = 1, 2, \dots, (p - 1)$. Pour préserver ces composantes caractéristiques tout en éliminant les bruits parasites liés à l'environnement, un filtrage passe-bas numérique a été appliqué aux signaux expérimentaux afin de supprimer les fréquences supérieures à 1500 Hz. Une fois filtrés, ces signaux sont traités selon la même procédure que les signaux issus des simulations, assurant une homogénéité dans le traitement des données. Les signaux ainsi obtenus ont été caractérisés à l'aide de l'algorithme Catch22 [12], qui extrait automatiquement 22 caractéristiques statistiques représentatives des séries temporelles. Cet algorithme, dérivé d'un ensemble initial de 4791 caractéristiques (bibliothèque HCTSA), permet de résumer les propriétés dynamiques essentielles d'un signal, telles que l'autocorrélation, l'entropie, la non-linéarité, la périodicité et la tendance. Il permet une extraction rapide (environ 0,5 seconde pour 10000 échantillons), facilitant ainsi la classification de signaux issus de systèmes dynamiques complexes.

Les 22 caractéristiques extraites présentent des unités et des échelles différentes. Par conséquent, une étape de normalisation a été appliquée à l'ensemble des données afin de garantir une comparaison équitable lors de l'apprentissage du modèle.

En appliquant cette procédure aux signaux simulés ainsi qu'aux signaux expérimentaux, deux bases de données ont été constituées BDSim et BDExp. Chaque base regroupe, pour chaque signal, les 22 caractéristiques extraites ainsi que l'étiquette correspondante indiquant l'état de la machine (sain ou défectueux).

5. ENTRAÎNEMENT DU MODELE ET EVALUATION DE CES PERFORMANCES

Le modèle d'apprentissage automatique utilisé dans cette étude est la forêt aléatoire, fondée sur un ensemble d'arbres de décision. Ce type de modèle est particulièrement adapté pour modéliser des relations non linéaires et des interactions complexes entre les caractéristiques extraites des signaux.

Pour garantir une évaluation rigoureuse et représentative, une validation croisée stratifiée à 5 plis (Stratified K-Fold, avec $K = 5$) a été mise en œuvre. Cette méthode préserve la proportion des classes (sain/défectueux) dans chaque sous-ensemble, assurant une répartition équilibrée des échantillons tout au long du processus. Le modèle est entraîné sur quatre plis et testé sur le cinquième, l'opération étant répétée cinq fois de sorte que chaque échantillon soit utilisé pour l'apprentissage et l'évaluation. Les performances finales sont obtenues en moyennant les résultats des cinq itérations, et l'écart type est calculé pour évaluer la stabilité et la robustesse du modèle.




Fig. 5 Signaux de champ magnétique externe; (a): simulation par éléments finis 2D, (b): mesures expérimentales pour des états sains et défectueux avec différentes sévérités du défaut.

L'évaluation repose sur deux indicateurs : le F1-score, qui mesure l'équilibre entre la précision (proportion de prédictions positives correctes) et le rappel (capacité du modèle à détecter les cas positifs), et l'aire sous la courbe ROC (AUC), qui reflète la capacité du modèle à discriminer entre les deux classes. Le F1-score est défini par la relation :

$$F1_Score = 2 * \frac{Precision * Rappel}{Precision + Rappel}$$

Avec : $Precision = \frac{VP}{VP+FP}$, $Rappel = \frac{VP}{VP+FN}$

Où :

- VP (vrais positifs) : défauts correctement identifiés
- FP (faux positifs) : machines saines incorrectement classées comme défectueuses
- FN (faux négatifs) : défauts non détectés par le modèle.

La courbe ROC trace le taux de faux positifs (axe des abscisses) en fonction du taux de vrais positifs (axe des

ordonnées), et l'AUC correspond à la surface sous cette courbe. Une AUC proche de 1 indique une excellente capacité de discrimination, tandis qu'une valeur proche de 0,5 correspond à une classification aléatoire.

Dans un premier temps, le modèle a été entraîné et validé sur la base BDSim (signaux simulés), à l'aide de la validation croisée à 5 plis. Les résultats obtenus sont très satisfaisants, comme le montrent les figures Fig.6 et Fig.7 : un F1-score moyen de $98,81\% \pm 0,96\%$ et une AUC de $99,9\% \pm 0,2\%$, démontrant une capacité élevée du modèle à distinguer les états sains et défectueux à partir des 22 caractéristiques extraites.

Ensuite, le modèle entraîné uniquement sur BDSim a été testé sur la base BDExp (signaux expérimentaux). Les performances se dégradent sensiblement comme présenté dans Fig.6 et Fig.8, avec un F1-score de $90,41\% \pm 1,75\%$ et une AUC de $66,3\% \pm 12,5\%$. Ces résultats indiquent que le modèle, bien qu'efficace sur les données simulées, ne parvient pas à généraliser correctement sur les données expérimentales.

Afin de comprendre pourquoi le modèle ne parvient pas à appliquer efficacement ce qu'il a appris à partir des données simulées pour classer les signaux expérimentaux, une analyse approfondie de son fonctionnement a été réalisée. L'objectif est d'identifier les caractéristiques sur lesquelles il s'appuie le plus, de sorte que l'on puisse expliquer la baisse de performance observée. Pour cela, les poids associés aux 22 caractéristiques utilisées lors de l'entraînement ont été extraits, afin que l'on détermine celles qui influencent le plus les décisions du modèle.




Fig. 6 Diagramme moustache présentant les F1-scores du modèle entraîné sur données simulées : comparaison entre test sur les données simulées et sur les données expérimentales.




Fig. 7 Courbes ROC et AUC par pli de validation croisée sur les données simulées.




Fig. 8 Courbes ROC et AUC par pli de validation croisée sur les données expérimentales.

Le diagramme d'importance (Fig. 9) met en évidence que les caractéristiques portant les numéros 13, 17, 16 et 11 de l'algorithme Catch22 sont les plus influentes dans le processus de classification. Une comparaison, présentée dans le Tableau 1, des valeurs de ces quatre caractéristiques a été effectuée entre signaux simulés et expérimentaux, dans les deux états de la machine (sain et défectueux). Cette comparaison vise à ce que l'on identifie les divergences entre les deux types de données et que l'on comprenne pourquoi le modèle éprouve des difficultés lorsqu'il est appliqué à des mesures réelles.

On observe que l'évolution des caractéristiques entre les états sain et défectueux suit la même tendance pour les données simulées et expérimentales (par exemple, *Stretch_decreasing* et *Embedding_Dist* diminuent dans les deux cas). Toutefois, les valeurs diffèrent fortement entre les deux sources. Cette disparité est la cause principale du manque de généralisation du modèle.




Fig. 9 Diagramme d'importance des caractéristiques Catch22 dans la classification des états sain/défectueux.

Tableau 1 Valeurs comparées des quatre caractéristiques clés (Catch22) pour des signaux simulés et expérimentaux, en états sain et défectueux.

Caractéristiques	Signal sim. sain	Signal sim. défaut	Signal exp. sain	Signal exp. défaut
<i>Whiten_Timescale</i> (13)	0,941	1,283	0,340	1,375
<i>Stretch_decreasing</i> (17)	0,416	-0,660	5,349	0,200
<i>Embedding_Dist</i> (11)	0,698	-0,213	14,01	-0,044
<i>Centroid_freq</i> (16)	0,302	0,315	0,361	0,354

Afin d'améliorer cette capacité de généralisation, la solution envisagée consiste à enrichir la base d'apprentissage en intégrant une petite proportion de signaux expérimentaux, permettant ainsi au modèle d'apprendre des représentations plus réalistes et compatibles avec les conditions réelles.

La figure Fig.10 illustre l'évolution du F1-Score et la figure Fig.11 l'évolution de l'AUC en fonction de la proportion de données expérimentales introduites dans l'ensemble d'apprentissage. Les résultats montrent qu'une faible proportion de données expérimentales suffit à améliorer significativement les performances du modèle sur des signaux réels.

En particulier, l'AUC progresse de 66,3 % à 82 %, et le F1-score de 90,41% à 91,2%, avec seulement 0,81% de données expérimentales ajoutées. Cette amélioration se poursuit avec l'augmentation progressive de la part des signaux réels : avec 7,31% de données expérimentales, le modèle atteint une AUC

de 96,86% et un F1-score de 93,71%, démontrant ainsi l'efficacité de l'intégration de petites quantités de données réelles pour faciliter le transfert des connaissances acquises en simulation vers des conditions expérimentales.




Fig. 10 Amélioration du F1-score en fonction de la proportion de données expérimentales intégrées à l'apprentissage.




Fig. 11 Amélioration de l'AUC en fonction de la proportion de données expérimentales intégrées à l'apprentissage.

6. CONCLUSION

Cette étude propose une méthode pour la détection des CCISS dans les machines synchrones à rotor bobiné, en s'appuyant sur l'analyse du champ magnétique externe. L'approche repose sur l'extraction de caractéristiques temporelles à partir de signaux simulés par éléments finis, combinée à un classifieur de type forêt aléatoire. Les résultats obtenus sur les données simulées montrent que les caractéristiques extraites via l'algorithme Catch22 permettent une séparation nette entre les états sains et défectueux, démontrant la pertinence de cette représentation dans un environnement numérique contrôlé.

Cependant, lorsqu'il est appliqué à des signaux expérimentaux après un entraînement basé uniquement sur la simulation, le modèle montre une perte notable de performance. L'analyse des caractéristiques les plus influentes met en évidence une cohérence des tendances globales entre simulation et expérimentation, mais des écarts importants apparaissent dans leurs valeurs. Ces différences peuvent s'expliquer par la présence de facteurs non pris en compte dans la simulation, tels que le bruit de mesure, les effets 3D puisque le modèle est 2D, ou les incertitudes mécaniques, créant un décalage entre les distributions des données simulées et expérimentales.

Pour réduire cet écart, une phase d'adaptation a été introduite en intégrant un petit nombre de signaux expérimentaux dans l'apprentissage. Cette démarche s'est révélée particulièrement bénéfique : même une quantité limitée de données réelles a permis d'améliorer sensiblement la capacité du modèle à traiter des cas issus du monde réel, soulignant l'intérêt d'une stratégie

hybride combinant simulation numérique et validation expérimentale ciblée.

Enfin, élargir cette approche à d'autres types de défauts ainsi qu'à diverses topologies de machines permettrait d'évaluer plus en profondeur la robustesse et la capacité de généralisation du modèle. L'intégration d'une configuration multi-capteurs constitue également une piste prometteuse pour renforcer la fiabilité du diagnostic. En effet, puisque la localisation précise du CCISS n'est pas connue, une telle configuration permettrait une meilleure couverture spatiale et une détection plus robuste. Par ailleurs, le développement de méthodes d'extraction de caractéristiques plus résistantes aux variations de domaine, capables de préserver leur pouvoir discriminant sur des données exclusivement simulées, ouvrirait la voie à des systèmes de diagnostic plus autonomes, fiables et peu dépendants des données expérimentales.

7. REMERCIEMENT

Ce travail de recherche, soutenu et financé par l'ANR (Agence Nationale pour la Recherche), entre dans le cadre du Labcom (Laboratoire Commun) MYEL (MobilitY and Reliability of Electrical chain Lab) associant le LSEE, le LGI2A et la société CRITTM2A (Projet ANR- 22-LCV2-0001).

8. REFERENCES

- [1] P. O. Donnell, C. Heising, C. Singh, and S. J. Wells, "Report of Large Motor Reliability Survey of Industrial and Commercial Installations: Part 3," *IEEE Trans. Ind. Appl.*, vol. 1A-23, no. 1, pp. 153–158, Jan. 1987.
- [2] O. V. Thorsen and M. Dalva, "A Survey of Faults on Induction Motors in Offshore Oil Industry, Petrochemical Industry, Gas Terminals, and Oil Refineries," *IEEE Trans. Ind. Appl.*, vol. 31, no. 5, pp. 1186–1196, 1995.
- [3] G. C. Stone, I. Culbert, E. A. Boulter, and H. Dhirani, *Electrical Insulation for Rotating Machines*. Wiley, 2014.
- [4] H. Henao *et al.*, "Trends in Fault Diagnosis for Electrical Machines: A Review of Diagnostic Techniques," *IEEE Ind. Electron. Mag.*, vol. 8, no. 2, pp. 31–42, Jun. 2014.
- [5] A. O. Louzada, W. A. Souza, A. L. O. Vitor, M. F. Castoldi, and A. Goedtel, "Detection of Stator Faults in Three-Phase Induction Motors Using Stray Flux and Machine Learning," *Energies*, vol. 18, no. 6, p. 1516, Mar. 2025.
- [6] L. Li, S. Liao, B. Zou, and J. Liu, "Mechanism-Based Fault Diagnosis Deep Learning Method for Permanent Magnet Synchronous Motor," *Sensors*, vol. 24, no. 19, p. 6349, Sep. 2024.
- [7] A. U. Rehman *et al.*, "Current and flux correlation analysis for detection, location, and phase identification of stator inter-turn short-circuit fault in doubly-fed induction generator," *Comput. Electr. Eng.*, vol. 117, p. 109281, Jul. 2024, doi: 10.1016/j.compeleceng.2024.109281.
- [8] V. Fireteanu, "Detection of the short-circuit faults in the stator winding of induction motors based on harmonics of the neighboring magnetic field," *J. Phys. Conf. Ser.*, vol. 450, no. 1, p. 012021, Jun. 2013.
- [9] J. Penman, H. G. Sedding, and W. T. Fink, "Detection and Location of Interturn Short Circuits in the Stator Windings of Operating Motors," *IEEE Trans. Energy Convers.*, vol. 9, no. 4, pp. 652–658, 1994.
- [10] A. Ceban, R. Pusca, R. Romary, and J. Lecoite, "Diagnosis of Inter-Turn Short Circuit Fault in Induction Machine," *Ann. Univ. Craiova, Electr. Eng. Ser.*, no. 35, pp. 103–110, 2011, doi: 10.13140/2.1.1120.7367.
- [11] M. Irhoumah, R. Pusca, E. Lefevre, D. Mercier, and R. Romary, "Detection of the Stator Winding Inter-Turn Faults in Asynchronous and Synchronous Machines Through the Correlation Between Harmonics of the Voltage of Two Magnetic Flux Sensors," *IEEE Trans. Ind. Appl.*, vol. 55, no. 3, pp. 2682–2689, May 2019.
- [12] C. H. Lubba, S. S. Sethi, P. Knaute, S. R. Schultz, B. D. Fulcher, and N. S. Jones, "catch22: CAnonical Time-series CHaracteristics: Selected through highly comparative time-series analysis," *Data Min. Knowl. Discov.*, vol. 33, no. 6, pp. 1821–1852, 2019.