



Amélioration de la fiabilité des méthodes de diagnostic basées sur l'analyse des gaz dissous (DGA) par prise en compte des incertitudes des appareils de mesure

par Bouzar Mouloud

Mémoire présenté à l'Université du Québec à Chicoutimi en vue de l'obtention du grade de Maître ès sciences (M. Sc.) en ingénierie

Québec, Canada

© Mouloud Bouzar, 2024

RÉSUMÉ

Le transformateur de puissance est l'un des composants les plus importants et les plus coûteux du réseau de distribution électrique. Pendant son fonctionnement, il peut être soumis à plusieurs défauts dont la nature, la sévérité et les conséquences diffèrent, pouvant aller jusqu'à la détérioration complète du transformateur, entraînant ainsi des pertes économiques significatives. C'est pourquoi une surveillance et un diagnostic continus sont essentiels.

Plusieurs méthodes de diagnostic ont été développées, dont l'analyse des gaz dissous (DGA), la plus ancienne, datant des années 1950, et également la plus répandue. Cependant, la fiabilité et la précision des méthodes DGA sont susceptibles d'être affectées par plusieurs facteurs, notamment les incertitudes liées aux appareils de mesure, qui peuvent mener à une mauvaise classification des défauts, ou même à leur non-détection, entraînant des dégâts irréversibles pour le transformateur.

À ce titre, le présent projet de recherche a pour objectif principal de développer un outil de diagnostic DGA, dont la fiabilité et la précision sont améliorées, en prenant en considération les incertitudes liées aux appareils de mesure. La réalisation de ce dernier s'est déroulée en plusieurs étapes.

Dans un premier temps, une recherche bibliographique a été effectuée, incluant les mécanismes de formation des gaz dissous dans l'huile, les différents types de méthodes de diagnostic DGA, ainsi que l'incidence des incertitudes liées aux appareils de mesure sur ces méthodes. Ensuite, une base de données DGA a été construite à partir de données collectées dans différents articles de la littérature.

Par la suite, différentes approches ont été explorées afin d'introduire les incertitudes liées aux appareils de mesure dans les méthodes DGA traditionnelles. Les résultats ont montré que ce procédé améliore considérablement la fiabilité du diagnostic, en particulier pour les méthodes basées sur des ratios.

Enfin, un modèle hybride constitué à la fois de méthodes DGA traditionnelles et de méthodes d'intelligence artificielle a été développé. Les résultats d'évaluation ont montré que cette méthode présente une bonne fiabilité ainsi qu'une précision de classification acceptable à différents niveaux d'incertitude, allant jusqu'à ± 30 %. En conclusion, l'incorporation de l'incertitude dans les méthodes de diagnostic basées sur la DGA s'avère être une approche prometteuse.

ABSTRACT

The power transformer is one of the most important and expensive components of the power grid. During its operation, it can be subject to several faults, which vary in type, severity, and consequences, that could lead to the complete deterioration of the transformer, resulting in significant economic losses. This is why continuous monitoring and diagnostics are important.

Several diagnostic methods have been developed, including Dissolved Gas Analysis (DGA), the oldest, dating back to the 1950s, and also the most commonly used. However, the reliability and accuracy of DGA methods can be affected by several factors, such as the uncertainties related to measurement devices, which can lead to the misclassification of faults or even their non-detection, resulting in irreversible damage to the transformer.

The main objective of this research project is to develop a DGA diagnostic tool, with improved reliability and accuracy, by taking into consideration the uncertainties related to measurement devices.

First, a literature review was conducted, including the mechanisms of dissolved gas formation in oil, the different types of DGA diagnostic methods, as well as the impact of uncertainties related to measurement devices on these methods. Then, a DGA database was built using data collected from various studies in the literature.

Subsequently, different approaches were explored to introduce measurement uncertainties into traditional DGA methods. The results demonstrate that this integration significantly improves diagnostic reliability, particularly for ratio based methods.

Finally, a hybrid model combining both traditional DGA methods and artificial intelligence techniques was developed. The evaluation results confirmed that this method has good reliability as well as acceptable classification accuracy at various levels of uncertainty, up to $\pm 30\%$. In conclusion, incorporating uncertainty into DGA based diagnostic methods, proves to be a promising approach.

TABLE DES MATIÈRES

RÉSUMÉ	ii
ABSTRACT.....	iii
TABLE DES MATIÈRES	iv
Liste des tableaux	vii
Liste des figures	ix
Liste des abréviations	x
DÉDICACE	xii
REMERCIEMENTS.....	xiii
CHAPITRE 1	1
INTRODUCTION	1
1.1 INTRODUCTION.....	2
1.2 PROBLÉMATIQUE	4
1.3 OBJECTIFS	8
1.4 ORIGINALITÉ DE LA RECHERCHE.....	8
1.5 MÉTHODOLOGIE DE RECHERCHE.....	10
1.5.1 INTRODUCTION.....	10
1.5.2 PROGRAMMATION DE L'OUTIL DE DIAGNOSTIC	10
1.5.3 ÉTUDE DE L'INFLUENCE DES INCERTITUDES DE MESURE.....	12
1.5.4 COMBINAISON DES RÉSULTATS PROBABILISTES	13
1.6 ORGANISATION DU MÉMOIRE.....	13
CHAPITRE 2.....	14
REVUE DE LA LITTÉRATURE	14
2.1 LE MÉCANISME DE FORMATION DES GAZ DISSOUS	15
2.1.1 RELATION ENTRE TEMPÉRATURE ET FORMATION DES GAZ	16
2.1.2 RELATION ENTRE LES DÉFAUTS ET LES GAZ DISSOUS.....	19
2.1.2.1 PRÉSENTATION DES DÉFAUTS	19
2.1.2.2 RELATION ENTRE DÉFAUTS ET FORMATION DES GAZ	23
2.2 MÉTHODES D'ANALYSES DES GAZ DISSOUS	29
2.2.1 PRÉSENTATION DES MÉTHODES DGA	29
2.2.2 MÉTHODES DGA TRADITIONNELLES.....	31
2.2.2.1 MÉTHODE DES GAZ CLÉS.....	32

2.2.2.2 MÉTHODE DES RATIOS	33
2.2.2.3 MÉTHODE GRAPHIQUE	39
2.2.3 UTILISATION DE L'INTELLIGENCE ARTIFICIELLE	47
2.2.3.1 TRAITEMENT DES DONNÉES DGA	48
2.2.3.2 COMBINAISON DES MÉTHODES	53
2.2.4 INCERTITUDE DES APPAREILS DE MESURE	56
2.2.4.1 FACTEURS INFLUANT SUR LA PRÉCISION ET LA FIABILITÉ DES MÉTHODES DGA	56
2.2.4.2 CONSÉQUENCES DES INCERTITUDES DE MESURE	57
2.2.4.3 RÉOLUTION DES PROBLÈMES D'INCERTITUDE DE MESURE	60
2.3 CONCLUSION	66
CHAPITRE 3	67
AMÉLIORATION DE LA FIABILITÉ DES DIAGNOSTICS PAR ANALYSE DES GAZ DISSOUS (DGA) EN PRENANT EN COMPTE L'INCERTITUDE DES APPAREILS DE MESURE	67
3.1 INTRODUCTION.....	72
3.2 DISSOLVED GAS ANALYSIS METHODS	75
3.3 METHODOLOGY.....	77
3.3.1 INTRODUCTION OF UNCERTAINTY BY GENERATION OF POSSIBLE GAS VALUES	77
3.3.2 INCORPORATING UNCERTAINTIES INTO SELECTED APPROACHES	78
3.3.3 INCORPORATING WEIGHTED FUSION OF DEFECT PROBABILITIES.....	81
3.3.4 APPLICATION OF ARTIFICIAL INTELLIGENCE.....	82
3.4 PERFORMANCE EVALUATION	84
3.4.1 DATA PRESENTATION.....	84
3.4.2 UNCERTAINTY PARAMETERS AND RESULTS VISUALIZATION	86
3.4.3 EVALUATION CRITERIA AND HYPERPARAMETERS OPTIMIZATION FOR AI METHODS	87
3.5 RESULTS AND DISCUSSION	88
3.5.1 IMPACT OF UNCERTAINTY ON FAULT DIAGNOSTICS.....	88
3.5.2 IMPACT OF INTRODUCING UNCERTAINTY IN EACH METHOD	90
3.5.3 IMPACT OF USING COMBINED RESULTS FROM MULTIPLE METHODS WITH UNCERTAINTY ON FAULT DIAGNOSIS.....	92

3.5.4 IMPACT OF USING PROBABILISTIC DATA DERIVED FROM UNCERTAINTY IN TRAINING AI BASED METHODS	94
3.6 CONCLUSION	97
CHAPITRE 4.....	99
CONCLUSION GÉNÉRALE ET RECOMMANDATIONS.....	99
4.1 CONCLUSION	99
4.2 RECOMMANDATIONS.....	101
RÉFÉRENCES	103

LISTE DES TABLEAUX

TABLEAU 1 : CLASSIFICATION DES DEFAUTS DANS LE TP AVEC SYMBOLES ET CONSEQUENCES.	23
TABLEAU 2 : ÉNERGIES DE RUPTURE DES LIAISONS CHIMIQUES DANS LES MOLECULES D'HYDROCARBURES.	24
TABLEAU 3 : CLASSIFICATION DES GAZ PRINCIPAUX, SECONDAIRES ET TRACES FORMES PAR TYPE DE DEFAUT.	27
TABLEAU 4 : CLASSIFICATION DES GAZ PRINCIPAUX, SECONDAIRES ET TRACES ASSOCIES AUX DIFFERENTS TYPES DE DEFAUTS SELON LA LITTERATURE.[39].	28
TABLEAU 5 : LA METHODE DES GAZ CLES DE L'IEEE.	33
TABLEAU 6: LIMITE DES CONCENTRATIONS DE GAZ [10].	35
TABLEAU 7: LA RELATION ENTRE LES DEFAUTS ET LES RATIOS DE DORNENBURG.	36
TABLEAU 8: RELATION ENTRE LES DEFAUTS ET LES RATIOS DE ROGERS, VERSION REVISEE DE 1975.	37
TABLEAU 9: RELATION ENTRE LES DEFAUTS ET LES RATIOS DE ROGERS, VERSION DE L'IEEE, 2019.	38
TABLEAU 10: RELATION ENTRE LES DEFAUTS ET LES RATIOS DE L'IEC, VERSION DE 2022.	39
TABLEAU 11: PROBLEMATIQUES ABORDEES ET REFERENCES ASSOCIEES DANS LA LITTERATURE.	50
TABLEAU 12: TYPES DE DONNEES D'ENTREE UTILISEES POUR LES MODELES D'IA DANS LA LITTERATURE.	52
TABLEAU 13: MODELES D'IA APPLIQUES AU DIAGNOSTIC DGA DANS LA LITTERATURE.	52
TABLEAU 14: METHODES COMBINEES POUR LE DIAGNOSTIC DGA.	55
TABLEAU 15: CRITIQUES DES METHODES DGA UTILISEES POUR LA RESOLUTION DU PROBLEME D'INCERTITUDE.	65
TABLE 16 : TRADITIONAL AND AI METHODS USED IN THE STUDY.	77
TABLE 17: TYPES OF GASES REQUIRED FOR EACH METHOD.	79
TABLE 18: DEFINITION OF DEFECT TYPE SYMBOLS.	80
TABLE 19: CODE ASSOCIATED WITH DEFECT PROBABILITIES BY METHOD. .	80
TABLE 20: CODE BINARY ENCODING OF FAULT TYPES.	83
TABLE 21: NUMBER OF SAMPLES USED PER METHOD.	84
TABLE 22: DISTRIBUTION OF FAULT TYPES IN THE DATABASE.	85
TABLE 23: DISTRIBUTION OF FAULT TYPES IN THE TRAINING, VALIDATION, AND TEST DATABASE.	86
TABLE 24 : OPTIMIZED HYPERPARAMETERS FOR AI-BASED METHODS.	88
TABLE 25: SPECIFIC SELECTED SAMPLES.	88
TABLE 26: CASES FAULT DIAGNOSTIC RESULTS FOR THE SELECTED SAMPLES USING DIFFERENT TRADITIONAL METHODS WITH THE INTRODUCTION OF UNCERTAINTY (I.U) AND WITHOUT ITS INTRODUCTION (W.I).	89
TABLE 27: COMPARISON OF THE DETECTION ACCURACY FOR DGA METHODS AFTER THE INTRODUCTION OF UNCERTAINTY.	91

TABLE 28 : IMPACT OF INTRODUCING UNCERTAINTY ON UNDETERMINED DIAGNOSTICS.....	92
TABLE 29 : COMPARISON OF ACCURACY BETWEEN DTM, DPM, IRM, AND FPML.....	93
TABLE 30 : COMPARISON OF FAULT CATEGORY DETECTION ACCURACY BETWEEN THE COMBINED APPROACH (FPML) AND DRM.....	94
TABLE 31 : MODEL ACCURACY ON THE TRAINING AND VALIDATION DATASETS.....	95
TABLE 32 : MAX-MIN ACCURACY DIFFERENCE ACROSS 300 SIMULATION AT DIFFERENT LEVELS OF UNCERTAINTY.	95

LISTE DES FIGURES

FIGURE 1 : STRUCTURE CHIMIQUE MOLECULAIRE DE LA CELLULOSE [38].	16
FIGURE 2 : RELATION ENTRE LA FORMATION DES GAZ ET LA TEMPERATURE DANS L'HUILE DES TRANSFORMATEURS DE PUISSANCE.	17
FIGURE 3 : EXEMPLE D'UNE REPRESENTATION A L'AIDE DE DTM.	42
FIGURE 4: EXEMPLE D'UNE REPRESENTATION A L'AIDE DE LA METHODE DTM ET DES DEUX TRIANGLES COMPLEMENTAIRES DE LA DTM-4 ET LA DTM-5.	44
FIGURE 5: EXEMPLE D'UNE REPRESENTATION A L'AIDE DE DPM ET DPM-2.	46
FIGURE 6: NOMBRE DE PUBLICATIONS TRAITANT LA PROBLEMATIQUE DE L'INCERTITUDE PAR ANNEE.	63
FIGURE 7 : DIAGRAM OF THE PROCESS FOR CALCULATING DEFECT PROBABILITIES FROM UNCERTAINTY FOR VARIOUS DGA METHODS.....	81
FIGURE 8: OVERVIEW OF THE PROCESS FOR AI-BASED MODELS USING PROBABILISTIC RESULTS FROM DGA METHODS.	83
FIGURE 9 : IMPACT OF UNCERTAINTY ON RESULTS NEAR FAULT BOUNDARIES. (A) UNCERTAINTY OF 30%, (B) UNCERTAINTY OF 5%.	90
FIGURE 10 : IMPACT OF UNCERTAINTY ON RESULTS FAR FROM FAULT BOUNDARIES. (A) UNCERTAINTY OF 30%, (B) UNCERTAINTY OF 50%.	90
FIGURE 11 : COMPLEMENTARY RESULTS FOR SAMPLE 3 DIAGNOSIS.	93
FIGURE 12: MODEL PERFORMANCE ON IEC TC10 DATABASE ACROSS DIFFERENT LEVELS OF UNCERTAINTY.	96

LISTE DES ABRÉVIATIONS

TP	Transformateur de puissance
DGA	Analyse des gaz dissous
IA	Intelligence artificielle
RF	Forêt aléatoire
IEEE	Institute of Electrical and Electronics Engineers
ASTM	American Society for Testing and Materials
CIGRÉ	Conseil international des grands réseaux électriques
DTM	Méthode du Triangle de Duval 1
DPM	Méthode du Pentagone de Duval 1
IEC	Commission Électrotechnique Internationale
IRM	Méthode des ratios de l'IEC
RRM	Méthode des ratios de Rogers
DRM	Méthode des ratios de Dornenburg
PAS	Spectroscopie photo-acoustique
NIR	Spectroscopie proche infrarouge
GC	Chromatographie en phase gazeuse
LF	Logique floue
ANN	Réseau de neurones artificiels
ML	Machine Learning
CGE	Méthode des ensembles de gaz caractéristiques
CEGB	Central Electricity Generation Board
CSUS	California State University de Sacramento
DL	Apprentissage profond
SOM	Cartes de Kohonen
DT	Les arbres de décision
SVM	La machine à vecteurs de support
SMOTE	La technique de suréchantillonnage des minorités synthétiques
RUS	Random Under-Sampling
ADASYN	Approche d'échantillonnage synthétique adaptative
B-SMOTE	Borderline-SMOTE
CGAN	Réseau antagoniste génératif conditionnel
ENN	Méthode des plus proches voisins édités
GP	Programmation génétique
LM	Algorithme Levenberg Marquardt
BR	Régularisation bayésienne
TL	Transformation logarithmique
NB	Naïve Bayes
BO	Optimisation bayésienne
EN	Les méthodes d'ensembles
EIF	Théorie de l'entropie de l'information floue
BCMOPSO	Algorithme d'optimisation par essais particuliers multi-objectifs chaotique-binaire
ABM	Algorithme AdaBoost.M1
BPNN	Réseau de neurones à rétropropagation

ELM	Machine à apprentissage extrême
GA	Algorithme génétique
ANFIS	Système d'inférence neuro-flou
PSO	Optimisation par essaim particulaire
DBSCAN	Algorithme Density-Based Spatial Clustering of Applications with Noise
GRA	Analyse des relations grise
DS	Théorie de Dempster Shafer
HMSVM	Méthode SVM multiclassées à hypersphère
HIA	Algorithme Immunitaire Hybride
KELM	Machine d'Apprentissage Extrême à Noyau
DNN	Un réseau neuronal profond
DBN	Réseau de croyances profondes
MV	Méthode du maximum de vraisemblance
CD	Algorithme de divergence contrastive
FSVM	Méthode Fuzzy Support Vector Machine
FCM	L'algorithme fuzzy c-means clustering
KFCM	Algorithme kernel fuzzy c-means clustering
RBF	Un réseau de neurones à fonction de base radiale
QPSO	L'optimisation par essais particulières inspirée par la mécanique quantique
AANN	Réseaux de neurones autoassociatifs, également connus sous le nom d'auto-encodeurs
ITMS	Algorithme Information Theoretic Mean Shift
GPN	Réseau de prototypes gaussiens
FSL	Technique d'apprentissage par peu d'exemples
CNN	Réseau de neurones convolutifs
TLBO	Méthode d'optimisation basée sur l'apprentissage par enseignement
HD	Technique heuristique de Deb
GWO	Grey Wolf Optimizer
PSO	L'optimisation par essais particulières
CMAC	Contrôleur d'Articulation du Modèle Cérébelleux.
KNN	K-Nearest Neighbor
k-MCA	K-means clustering algorithm
MLP	Multilayer Perceptron Neural Network
FPMI	Weighted Method Fusion with Uncertainty

DÉDICACE

À tous ceux qui m'ont encouragé et soutenu :

Mon père

Ma mère

Mon épouse : Malika

Mes frères et sœurs

Mes tantes : Zina et Fazia

Mon oncle : Mahdi

Mon ami : Anis

Et toute ma famille

REMERCIEMENTS

Ce projet de recherche a été réalisé au sein de la Chaire de recherche du Canada, en vieillissement de l'appareillage rempli d'huile installé sur les lignes à haute tension (ViAHT).

Je tiens à remercier mon directeur de recherche, le professeur Issouf Fofana, titulaire de la Chaire ViAHT, de m'avoir accueilli au sein de son équipe de chercheurs et pour son encadrement ainsi que ses précieuses orientations tout au long de mes travaux. Travailler sous la direction du professeur Issouf Fofana m'a non seulement permis de mener à bien mon projet d'étude, mais également de développer mes compétences en recherche et ma confiance en moi, grâce à la confiance, au temps et au soutien financier qu'il m'a accordés, ainsi qu'à ses encouragements constants durant tout mon parcours.

Je tiens également à remercier le professeur Djamel Rebaïne, mon co-directeur de recherche, qui m'a offert l'opportunité d'étudier à l'UQAC et de mettre en valeur mes compétences. Je le remercie pour ses encouragements, son soutien financier, ainsi que pour son encadrement, ses orientations et sa disponibilité, qui m'ont permis de mener à bien mon projet d'études.

Je tiens aussi à remercier Kouba Marie Lucia Yapi pour son soutien constant et sa disponibilité. Toujours à l'écoute lors des moments difficiles, elle veille à maintenir une ambiance agréable au sein de l'équipe de travail, veillant au bien-être de tous les membres.

Je tiens à exprimer ma gratitude à tous les membres de la chaire de recherche ViAHT pour leur collaboration et leur disponibilité constante. Leurs soutiens, ainsi que l'atmosphère de travail conviviale qu'ils ont su instaurer, ont permis de faire de cette expérience un parcours aussi enrichissant qu'agréable.

Enfin, mais non des moindres, je tiens à exprimer ma profonde gratitude à ma famille, à mon épouse et à mes amis, qui m'ont constamment encouragé et soutenu tout au long de mon parcours académique, me permettant ainsi de mener à bien mes études et de les poursuivre avec succès.

CHAPITRE 1

INTRODUCTION

1.1 INTRODUCTION

Le transformateur de puissance (TP) est l'un des éléments les plus importants du réseau électrique, dont le rôle principal est d'assurer un acheminement efficace de l'énergie électrique. En tant qu'élément clé, des milliards de dollars sont investis pour leur acquisition et pour assurer leur bon fonctionnement à travers la surveillance, le diagnostic et la réparation [1]. Les isolations des TP subissent des contraintes thermiques, électriques, chimiques, mécaniques et environnementales [2]. Ces contraintes dégradent les TP et génèrent divers produits de décomposition [3], parmi lesquels des molécules gazeuses telles que l'hydrogène (H_2), le méthane (CH_4), l'éthylène (C_2H_4), l'acétylène (C_2H_2) et l'éthane (C_2H_6), qui constituent des indicateurs clés de l'état du TP.

L'analyse des gaz dissous (DGA) est l'une des méthodes les plus anciennes et les plus utilisées pour mesurer, identifier et interpréter ces molécules gazeuses. Depuis les années 1970, suite à l'élimination de l'influence du volume du liquide, les premiers rapports de gaz utilisés comme indicateurs de défauts ont été élaborés. Parmi eux, les rapports éthylène/acétylène servent d'indicateurs de défaillances électriques, et le rapport méthane/hydrogène, de défaillances thermiques [4]. Actuellement, avec l'intérêt croissant pour ces techniques, 64 méthodes traditionnelles de DGA ont été développées depuis 1970 à ce jour [5]. De plus, avec la disponibilité de vastes données DGA [6], les techniques d'intelligence artificielle (IA) ont émergé, représentant une évolution notable ces dernières années dans les diagnostics des défauts des TP [7, 8].

Les méthodes traditionnelles et celles utilisant l'IA pour la DGA présentent toutes des limites en précision et fiabilité. Ces dernières sont souvent affectées par plusieurs facteurs, tels que le phénomène de gaz parasites (S) et les incertitudes liées aux appareils de mesure et d'autres qui peuvent conduire à des diagnostics erronés et, par conséquent, à la réduction de la durée de vie des TP, voire, dans certains cas, à leur destruction. En ce qui concerne les méthodes traditionnelles, ces facteurs contribuent à l'insertion d'erreurs tant durant les phases initiales de leur conception que durant leur utilisation, particulièrement du fait qu'elles sont issues d'un vaste ensemble de données empiriques et d'observations de terrain, plutôt que de fondements théoriques rigoureux [9, 10]. Pour les méthodes d'IA, ces mêmes facteurs, en injectant du bruit dans les données, peuvent engendrer plusieurs problèmes dans la relation entre les données et les étiquettes durant les phases d'entraînement, conduisant à un modèle moins robuste.

Afin de remédier à ces problèmes et dans l'objectif d'améliorer la fiabilité des diagnostics, plusieurs études ont été menées, dont certaines tentent de tirer parti des avantages que présentent les méthodes traditionnelles en combinant leurs résultats avec des méthodes d'IA, comme l'étude [11], qui combine les résultats de 22 méthodes traditionnelles avec des méthodes d'IA telles que le modèle de la forêt aléatoire (RF). Dans d'autres études, les concentrations de gaz ne sont pas directement utilisées avec les étiquettes de défauts lors des phases d'entraînement, mais sont plutôt transformées en des coordonnées, telles que réalisé dans l'étude [12], puis utilisées pour l'entraînement des méthodes d'IA.

Cependant, ces méthodes présentent l'inconvénient de ne pas prendre en considération les erreurs liées aux appareils de mesure, qui constituent l'un des facteurs ayant une influence sur la fiabilité des diagnostics. De plus, le nombre d'études ayant tenté de traiter ce problème est limité, bien que la prise en compte de ce facteur soit indispensable [13, 14]. Il est donc nécessaire de s'assurer de l'exactitude du système de surveillance DGA dans son ensemble [15], ce qui met en évidence l'importance d'examiner l'incidence que la précision de ce système peut avoir sur les résultats du diagnostic.

Ce projet étudie comment les incertitudes affectent la fiabilité des diagnostics, avec pour but de réduire leurs impacts. Ces incertitudes sont introduites dès les phases initiales du diagnostic avec des méthodes DGA traditionnelles, permettant ainsi l'obtention de résultats qui prennent en considération ces incertitudes sous forme de probabilités. Ensuite, ces différents résultats sont exploités avec des méthodes telles que la pondération des probabilités obtenues par différentes méthodes, et l'utilisation des méthodes d'IA qui permettent d'apprendre les caractéristiques présentes dans les résultats probabilistes.

1.2 PROBLÉMATIQUE

Depuis les années 1970 jusqu'à aujourd'hui, un nombre important de méthodes DGA a été développé. Parmi elles, certaines sont de types graphiques, d'autres s'appuient sur les ratios de gaz-ou les gaz clés. Cependant, ces méthodes présentent l'inconvénient de ne pas reposer sur des fondements théoriques rigoureux, ce qui conduit à la complexité de l'analyse des gaz dissous pour "détecter" des pannes naissantes et "diagnostiquer" leur cause en

analysant les "gaz de défaut". Ce point a été également souligné par l'IEEE [16] comme suit : "Many techniques for the detection and the measurement of gases have been established. However, it must be recognized that analysis of these gases and interpretation of their significance is at this time not a science, but an art subject to variability". Ensuite, "The result of various ASTM testing round robins indicates that the analytical procedures for gas analysis are difficult, have poor precision, and can be widely inaccurate, especially between laboratories". Finalement, "However, operators must be cautioned that, although the physical reasons for gas formation have a firm technical basis, interpretation of that data in term of the specific cause or causes is not an exact science, but is the result of empirical evidence from which rules for interpretation have been derived". De plus, des gaz parasites compliquent l'analyse en produisant des types et quantités variés de gaz. La présence de ces gaz peut entraîner une interprétation erronée de l'état du TP. En outre, les limites strictes dans les ratios de diagnostics et les zones de défaut, ainsi que la variabilité des méthodes de calcul de ces ratios et des seuils de détection des défauts, compliquent davantage la situation [17, 18].

Les techniques ayant émergé et représentant une évolution notable ces dernières années dans le domaine de la DGA sont les méthodes de l'Intelligence Artificielle (IA), qui ont démontré leur efficacité à travers plusieurs études [12, 19-22]. Cependant, il reste important de souligner que la fiabilité de ces modèles peut être compromise par plusieurs facteurs. Parmi eux, l'incertitude liée aux appareils de mesure, qui pourrait avoir une incidence significative à la fois sur la fiabilité des méthodes d'IA et des méthodes DGA traditionnelles. Ce facteur, peu étudié, est souvent la cause principale de diagnostics erronés dans certaines

situations. En effet, cette incertitude entraîne des altérations notables dans les mesures de gaz, avec des imprécisions allant de $\pm 5\%$ à $\pm 30\%$ [14]. Dans certains cas, pour les laboratoires aux performances médiocres, les imprécisions peuvent atteindre des valeurs de $\pm 60\%$ à $\pm 65\%$ [10, 23]. Ces différences dans la précision des mesures sont principalement liées à la diversité des appareils de mesure utilisés, chacun ayant sa propre précision et son seuil de détection [24, 25].

L'incertitude des appareils de mesure se manifeste dès les phases initiales de conception, tant pour les méthodes d'IA que pour les méthodes DGA traditionnelles. Les méthodes traditionnelles exploitent des données empiriques, qui incluent les concentrations de gaz susceptibles d'être altérées par les incertitudes de mesure, pour élaborer différentes zones de défauts. L'étude [13] examine la redondance des erreurs des méthodes DGA traditionnelles et propose des améliorations par l'introduction de nouveaux codes d'interprétation manquants pour les méthodes basées sur des ratios, ainsi que des modifications des zones spécifiques de défauts dans la méthode DTM. Pour les méthodes d'IA, l'incertitude des appareils de mesure s'introduit durant les phases d'entraînement, où le modèle pourrait apprendre des relations erronées entre les données d'entraînement et les étiquettes de défauts, notamment en cas de grandes altérations dans les mesures des gaz. Cela peut conduire à des problèmes de surapprentissage, où le modèle performe bien sur les données d'entraînement, mais montre une faible capacité de généralisation avec de nouvelles données, résultant ainsi en une diminution de la précision et de la fiabilité des diagnostics.

Après la phase de conception, l'effet de l'incertitude persiste lors de l'utilisation des méthodes DGA traditionnelles ou des méthodes d'IA, notamment lors de la prise d'échantillons d'huile du TP pour effectuer une analyse des gaz dissous ou à travers les systèmes de mesure en ligne. Les incertitudes associées à ces systèmes demeurent présentes. Des mesures de concentration de gaz très imprécises peuvent mener à une évaluation incorrecte de la gravité ou du type de la panne. Dans les cas extrêmes, ces erreurs peuvent entraîner des décisions coûteuses, comme le retrait prématuré du TP du service. Elles peuvent également empêcher la détection de défauts naissants, conduisant à des pannes inutiles, des dommages ou des défaillances [10]. Le même point est rapporté par Duval et Durkam dans l'étude [23], qui précise qu'il y a toujours une certaine imprécision associée aux mesures DGA en laboratoire. Cette imprécision affecte les ratios de gaz, les concentrations ainsi que d'autres calculs sur lesquels s'appuie l'évaluation de l'état du TP. L'étude souligne également l'importance d'ajouter un facteur de confiance à chaque diagnostic, ce qui se fait en calculant les intervalles d'incertitude liés à chaque mesure, permettant ainsi d'obtenir des diagnostics plus fiables.

Cependant, jusqu'à présent, l'importance accordée à ce facteur reste marginale, comme en témoigne le nombre limité d'études réalisées sur cette thématique. Bien que l'association d'un facteur de confiance aux mesures et les modifications apportées aux codes d'interprétation des défauts ou aux limites des zones de défauts ne soient pas suffisantes, ces études contribuent néanmoins à souligner l'importance des erreurs liées à l'incertitude des appareils de mesure et proposent des alternatives pour essayer de résoudre cette problématique. Des outils plus avancés, tels que l'utilisation de l'IA, pourraient s'avérer

intéressants afin d'exploiter les différentes caractéristiques qui lient les diagnostics de défauts aux incertitudes de mesure.

1.3 OBJECTIFS

L'objectif principal de ce travail est de trouver des solutions permettant de prendre en compte l'incertitude liée aux appareils de mesure lors de l'utilisation des méthodes DGA dans le diagnostic des défauts des TP, réduisant ainsi son effet sur la fiabilité et la précision des diagnostics. Pour la réalisation de ce projet, les objectifs spécifiques suivants ont été fixés :

- Programmation d'un outil de diagnostic incluant cinq méthodes DGA traditionnelles et prenant en compte l'incertitude liée aux appareils de mesure.
- Étudier l'incidence de l'incertitude liée aux appareils de mesure sur la fiabilité des diagnostics des méthodes DGA traditionnelles.
- Utilisation de différentes méthodes permettant d'exploiter les résultats obtenus après l'introduction de l'incertitude, visant à améliorer la fiabilité et la précision des diagnostics.

1.4 ORIGINALITÉ DE LA RECHERCHE

L'originalité de cette recherche réside dans l'analyse approfondie des répercussions des incertitudes liées aux appareils de mesure sur les diagnostics de défauts dans les méthodes DGA traditionnelles. Cette étude adopte une approche distinctive d'intégration des incertitudes, se démarquant par la manière spécifique dont elle traite et génère les

distributions de probabilité. En simulant une gamme étendue de valeurs possibles pour chaque mesure de gaz, cette méthode permet l'obtention de diagnostics plus fiables.

Suite à cette analyse approfondie, un outil a été développé pour exploiter les résultats obtenus par différentes méthodes DGA, tout en prenant en compte les incertitudes de mesure pour générer des diagnostics sous forme de probabilités. Par la suite, les résultats sont utilisés pour aboutir à une conclusion unique sur l'état du TP, intégrant notamment l'utilisation des méthodes d'IA. À notre connaissance, aucune recherche n'a jusqu'à présent tenté d'utiliser des méthodes d'IA pour analyser les probabilités issues des méthodes DGA traditionnelles dans le cadre des incertitudes liées aux appareils de mesure.

Les méthodes DGA, étant une des techniques les plus utilisées dans le diagnostic des TP, les divers résultats et conclusions de ce projet, auxquels nous avons abouti, permettraient sans nul doute une avancée notable dans la compréhension des conséquences de l'incertitude liée aux appareils de mesure sur la fiabilité des diagnostics. De plus, ce projet propose de nouvelles méthodologies qui pourraient être améliorées et exploitées ultérieurement pour diminuer l'effet de l'incertitude liée aux appareils de mesure.

1.5 MÉTHODOLOGIE DE RECHERCHE

1.5.1 INTRODUCTION

La réalisation de ce projet de recherche a débuté par une revue de littérature couvrant plusieurs aspects, notamment le mécanisme de formation des gaz dissous dans l'huile des TP, les différentes méthodes DGA traditionnelles existantes, l'utilisation de l'IA dans la DGA, ainsi que les travaux portant sur les problématiques d'incertitude liées aux appareils de mesure et leurs conséquences sur les diagnostics des TP. Enfin, une base de données a été constituée en collectant les mesures de gaz issues de plusieurs études, pour servir de fondement à ce projet.

Afin de réaliser l'objectif principal fixé, cette recherche se concentre sur trois volets principaux : la programmation d'un outil de diagnostic prenant en compte les incertitudes liées aux appareils de mesure, l'étude approfondie de l'effet de ces incertitudes sur les diagnostics issus des méthodes DGA traditionnelles, ainsi que l'évaluation des nouvelles méthodes élaborées et leur comparaison avec les méthodes traditionnelles. Enfin, l'utilisation d'approches supplémentaires, telles que les méthodes d'IA, pour combiner les différents résultats probabilistes et obtenir un diagnostic unique final.

1.5.2 PROGRAMMATION DE L'OUTIL DE DIAGNOSTIC

La première étape dans la programmation consistait à choisir le langage à utiliser. Pour cela, différents critères ont été pris en compte, tels que les performances, le coût et

l'accessibilité. Pour ce projet, le langage Python a été sélectionné pour plusieurs raisons : il est open source, il offre des performances accrues par rapport à certains autres langages comme MATLAB, et il est bien adapté au traitement de grandes quantités de données. En effet, Python dispose de bibliothèques optimisées, comme "Numpy", qui sont programmées en langage C, ce qui permet un traitement rapide. De plus, Python est le langage dominant en matière d'IA, grâce à des bibliothèques puissantes comme "TensorFlow" et "PyTorch", ce qui fait une solution idéale dans le cadre de ce projet qui intègre des méthodes d'IA. De nombreuses études dans le domaine des diagnostics des TP utilisant l'IA dans la DGA ont également adopté ce langage, telles que [26-28].

La seconde étape consiste à sélectionner les méthodes DGA traditionnelles et les méthodes d'IA à utiliser pour ce projet. Pour les méthodes traditionnelles, une recherche concernant les méthodes les plus couramment utilisées et adoptées par les normes a été réalisée. Quant aux méthodes d'IA, elles ont été sélectionnées en fonction de leur prévalence dans la littérature.

Enfin, pour la prise en compte des incertitudes liées aux appareils de mesure, une étude a été réalisée afin d'examiner leur amplitude ainsi que les facteurs influençant leur variation. Dans le cadre de ce projet, plusieurs solutions ont été expérimentées pour intégrer ces incertitudes ; elles ont ensuite été évaluées, et la plus adaptée aux objectifs du projet a été sélectionnée.

1.5.3 ÉTUDE DE L'INFLUENCE DES INCERTITUDES DE MESURE

Initialement, une analyse est effectuée sur plusieurs échantillons d'huile dans l'objectif de montrer l'influence des incertitudes liées aux appareils de mesure sur la fiabilité des diagnostics des TP. Les résultats individuels de chaque méthode, avant et après l'introduction de l'incertitude, ont été comparés. Par la suite, une seconde comparaison s'est concentrée sur la fiabilité et la précision du diagnostic final, en combinant les résultats obtenus par les différentes méthodes.

Ensuite, une analyse approfondie a été réalisée sur les méthodes graphiques et celles basées sur les ratios, en utilisant la base de données collectée à partir de diverses études. L'objectif de cette analyse était de comprendre avec plus de précision les résultats obtenus lors de la comparaison des résultats individuels de chaque méthode, et d'identifier les raisons des différences observées.

Enfin, des méthodes complémentaires, telles que le Triangle de Duval 5 (DTM-5), ont été employées, permettant d'étudier la relation entre l'utilisation des résultats probabilistes, avec la prise en compte de l'incertitude, ainsi que l'effet du nombre de méthodes utilisées sur la précision et la fiabilité du diagnostic final.

1.5.4 COMBINAISON DES RÉSULTATS PROBABILISTES

Dans un premier temps, les méthodes les plus couramment utilisées dans la littérature pour la combinaison des résultats des méthodes DGA traditionnelles ont été sélectionnées. Ensuite, ces mêmes méthodes ont été appliquées pour la combinaison des résultats probabilistes, en effectuant différentes simulations afin de permettre une comparaison adéquate. Pour les approches basées sur les méthodes d'IA, une base de données adaptée, couramment utilisée dans l'évaluation des performances de ces modèles, a été sélectionnée.

1.6 ORGANISATION DU MÉMOIRE

Ce mémoire est structuré en quatre chapitres. Le premier chapitre présente une introduction générale du projet. Il présente également la problématique, les objectifs visés, l'originalité de la recherche ainsi que la méthodologie suivie pour la réalisation du projet. Le deuxième chapitre est dédié à la revue de la littérature, qui aborde plusieurs points essentiels, notamment le mécanisme de formation des gaz dissous dans l'huile des TP, les méthodes DGA traditionnelles, l'application de l'IA dans la DGA, les problématiques liées aux incertitudes des appareils de mesure et leurs conséquences sur la fiabilité des diagnostics DGA et enfin les différentes recherches traitant la même thématique que ce projet. Le troisième chapitre, présenté sous forme d'un article intitulé "Improving the Reliability of Dissolved Gas Analysis (DGA) Diagnostics Through Consideration of Measurement Device Uncertainty", décrit la méthodologie utilisée, les résultats obtenus et leur discussion. Le quatrième chapitre présente la conclusion générale et propose des recommandations pour les travaux futurs.

CHAPITRE 2

REVUE DE LA LITTÉRATURE

2.1 LE MÉCANISME DE FORMATION DES GAZ DISSOUS

Dans les TP émergés, la formation des gaz provient de la décomposition de l'isolation liquide et de l'isolation solide. L'isolation solide inclut le papier, le carton pressé et les blocs de bois. En ce qui concerne l'isolation liquide, plusieurs types existent, parmi lesquels l'huile d'origine pétrolière, appelée huile minérale, est le principal liquide utilisé dans les TP et les systèmes électriques industriels en général, depuis les années 1900, en raison de son bon comportement au vieillissement, de sa faible viscosité, de sa disponibilité et de son faible coût [29, 30].

L'huile minérale est créée à partir d'un mélange de plusieurs molécules d'hydrocarbures contenant des groupes CH_3 , CH_2 , CH , qui sont soit de nature paraffinique, soit aromatique. Lors de la rupture de certaines liaisons C-H et C-C, des petits fragments instables sous forme de radicaux ou d'ions sont créés [31]. Ces derniers vont se combiner rapidement à travers des réactions complexes pour former des molécules gazeuses telles que le H_2 , le CH_4 , le C_2H_4 , le C_2H_2 et le C_2H_6 [32], permettant l'obtention d'une indication clé de l'état du TP en les analysant [33]. Scientifiquement parlant, la rupture des liaisons C-H et C-C peut être due à plusieurs causes telles que la contamination, la présence de défauts thermiques et/ou électriques, et même dans des conditions de fonctionnement normales, en raison de l'oxydation et du vieillissement naturel [34, 35].

Quant aux isolants solides, ils sont principalement constitués de cellulose, dont la structure moléculaire est illustrée dans la Figure 1. La décomposition de la cellulose peut être due à plusieurs facteurs tels que l'hydrolyse, l'oxydation et les pyrolyses [36]. Cependant, le principal facteur influençant sa dégradation ou sa détérioration est la pyrolyse [37]. Lors de la dégradation de la cellulose, des ruptures se produisent dans les liaisons H₂, conduisant ainsi à la formation de produits chimiques tels que les dérivés de furanes, le monoxyde de carbone (CO) et le dioxyde de carbone (CO₂), qui se dissolvent plus tard dans l'huile isolante [38].

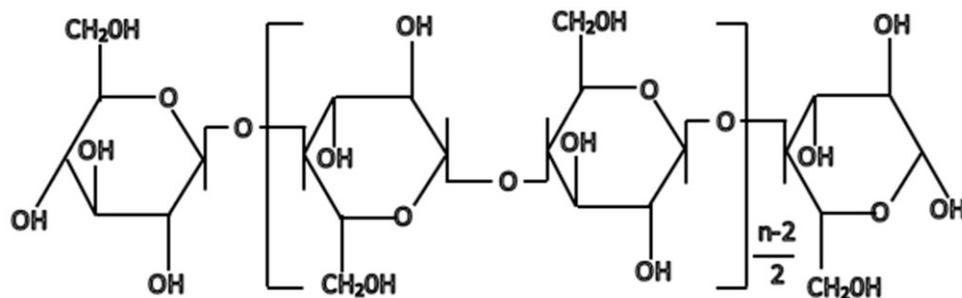


Figure 1 : Structure chimique moléculaire de la cellulose [38].

2.1.1 RELATION ENTRE TEMPÉRATURE ET FORMATION DES GAZ

La relation entre la température et la formation des gaz peut être expliquée par la théorie de la formation des gaz, qui permet de lier chaque gaz à une température spécifique de formation [39]. La Figure 2 illustre cette relation.

Le H₂ et le CH₄ commencent à se former à partir d'une température de 150°C, mais en petite quantité. Pour des températures comprises entre 200°C et 300°C, la production de CH₄ dépasse celle du H₂, tandis que la production de H₂ augmente continuellement avec l'augmentation de la température. À 450°C, la formation de H₂ atteint son maximum, surpassant celle de tous les autres gaz jusqu'à environ 750 °C-800°C. Le C₂H₆ commence à se former à partir de 250°C, et à 275 °C, il dépasse le CH₄. Quant au C₂H₄, il commence à se former à partir de 350°C, et au-delà de 700°C, il devient le gaz prédominant par rapport au C₂H₆. Cependant, que ce soit pour le CH₄, le C₂H₆ ou le C₂H₄, leur production diminue à mesure que la température augmente après qu'ils aient atteint leurs pics. Enfin, la production de C₂H₂ débute entre 500°C et 700°C, avec des concentrations importantes au-delà de 700°C, accompagnées d'une production accrue du H₂ à des températures comprises entre 750°C et 800°C [40-43].

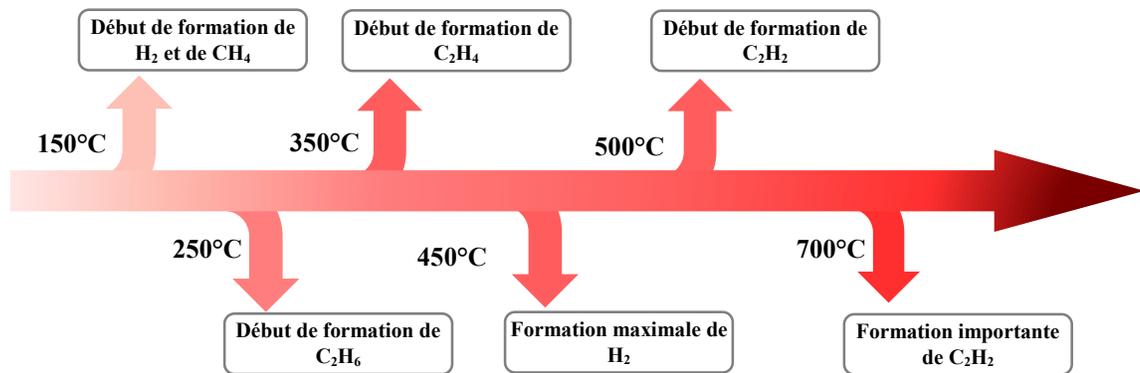


Figure 2 : Relation entre la formation des gaz et la température dans l'huile des transformateurs de puissance.

Pour le papier isolant, il est couramment admis que les principaux facteurs conduisant à sa dégradation sont la température, l'eau (H₂O), l'oxygène (O₂) ainsi que les acides et les contaminants [44]. Cependant, avec les systèmes modernes de conservation de l'huile, les contributions de facteurs tels que l'humidité et l'O₂ sont minimisées, laissant ainsi la température comme le principal facteur influençant la dégradation de l'isolation [37]. En effet, sous l'influence thermique, un processus de déshydratation est déclenché dans le papier, conduisant à la formation de plusieurs produits de décomposition tels que le CO, CO₂, O₂ et H₂O [45, 46]. La quantité du CO et du CO₂ dissous dans l'huile est fortement liée à l'augmentation de la température [47-50]. Le CO₂ est généré à basse température, tandis que le CO à haute température en raison de la solubilité du CO, qui est proportionnelle à la température, et la solubilité du CO₂, qui diminue avec l'augmentation de la température [51, 52].

Les molécules de la cellulose sont constituées de différents groupes CO, CH₂ et CH, parmi lesquels les liaisons C-O sont les plus faibles, entraînant la formation de gaz à des températures inférieures à 100°C [53]. Cependant, dans l'étude [54], l'auteur indique que la formation de CO et de CO₂ commence à partir de 100°C, avec une quantité de CO₂ généralement deux fois supérieure à celle du CO, en raison de la plus grande solubilité du CO₂ par rapport au CO.

Dans la littérature, les températures de formation des gaz résultant de la dégradation du papier peuvent varier, l'une des causes étant le type de papier utilisé. Les résultats de

l'étude [55] montrent l'influence du type de papier sur la production de CO et de CO₂ : le papier aramide, thermiquement stable, est plus résistant aux hautes températures, tandis que le papier cellulose produit des quantités importantes d'oxydes de carbone sous l'effet des hautes températures.

2.1.2 RELATION ENTRE LES DÉFAUTS ET LES GAZ DISSOUS

2.1.2.1 PRÉSENTATION DES DÉFAUTS

Le TP est soumis à des défaillances de différentes natures et de sévérités pendant son fonctionnement, chacune ayant une répercussion potentielle et des dommages qu'elle pourrait engendrer. En général, la littérature distingue deux grandes catégories de défauts : les défauts thermiques (T) et les défauts électriques, ces derniers incluant les décharges électriques (D) et les décharges partielles (PD).

a) DÉCHARGES PARTIELLES

Les défauts de type PD sont des décharges électriques localisées dont l'intensité est faible. Elles apparaissent sous forme de courtes impulsions, souvent accompagnées de son, de lumière et de chaleur [52], ainsi que d'émission d'ondes électromagnétiques de haute et de très haute fréquence [56]. Les sources de ce type de défauts varient en fonction du type de PD.

Dans le cas des PD de type Corona, celles-ci résultent principalement de défauts diélectriques. Leur intensité est influencée par la géométrie de la zone de décharge, la température, l'humidité et la présence de bulles dans lesquelles les conditions sont propices aux décharges, sachant que ces bulles présentent une permittivité plus faible que l'isolation environnante [57]. Ce type de défaut peut entraîner des dépôts de "X_Wax " sur l'isolation en papier [58]. Quant aux PD de type étincelle, elles sont souvent provoquées par des particules conductrices, de l'humidité, des surfaces irrégulières, ainsi que par des fissures et des vides d'air dans l'isolation solide, où l'air peut être contenu [57]. Ce type de défaut provoque des micro-trous dans le papier qui sont difficiles à détecter [41]. Que ce soit pour les défauts PD de type Corona ou étincelle, l'intensité de ces décharges augmente avec le temps, jusqu'à se transformer en décharges d'arc [52, 59].

b) DÉCHARGES ÉLECTRIQUES

Les décharges électriques surviennent lorsque le courant circule dans un chemin anormal, suite à plusieurs raisons telles que des courts-circuits, des connexions lâches et des boucles fermées de deux conducteurs adjacents autour d'un flux magnétique commun [60, 61]. Ces décharges électriques peuvent être de faible énergie (D_1) ou de haute énergie (D_2). Dans le cas des défauts de type D_1 , leur sévérité est intermédiaire entre celle des PD et des défauts de type D_2 . Ce type de défaut se produit dans l'huile et/ou le papier isolant, provoquant d'importantes perforations carbonisées dans le papier, une carbonisation de sa surface, ou la présence de particules de carbone dans l'huile [41, 58]. En ce qui concerne les défauts de types D_2 , ils se manifestent lorsque des tensions élevées créent un plasma dans l'huile, à travers lequel le courant circule librement sous forme d'arc, atteignant des

températures pouvant aller jusqu'à 5000 °C. Cela peut entraîner une pression excessive dans le réservoir du TP, pouvant même provoquer une explosion si ce défaut n'est pas surveillé [52].

C) DÉFAUTS THERMIQUES

Les défauts de type T se produisent dans le TP suite à plusieurs facteurs tels que : la surchauffe des conducteurs, des courts-circuits, la surchauffe des enroulements due aux courants de Foucault, de mauvaises connexions, les charges non linéaires, la contamination de l'huile, la formation de boues, la défaillance des composants ou encore un refroidissement insuffisant [59, 61]. Ces défauts sont classés en trois sous-catégories, selon la température :

- Défauts thermiques de basse température (T_1) : ces défauts se produisent à des températures inférieures à 300 °C, affectant l'huile et/ou le papier isolant. Ce type de défaut réduit la durée de vie future du système d'isolation, bien qu'il soit généralement considéré comme moins urgent [10]. Il peut être identifié par la couleur brunâtre du papier isolant.
- Défauts thermiques de moyenne température (T_2) : caractérisés par une température comprise entre 300°C et 700°C, ces défauts sont plus sévères que ceux de type T_1 . Lorsqu'ils affectent le papier isolant, ils conduisent à sa carbonisation.
- Défauts thermiques de haute température (T_3) : ces défauts sont les plus graves parmi les défauts T, avec des températures supérieures à 700°C. Ils apparaissent dans l'huile et/ou le papier isolant, provoquant la carbonisation du papier et de l'huile, ainsi

qu'une coloration du métal à 800 °C, suivie de sa fusion lorsque la température atteint environ 1000 °C [58].

En général, les défauts de type T_1 et T_2 sont souvent regroupés, car ils affectent principalement le papier. En revanche, les défauts T_3 provoquent des points chauds dans l'huile, également appelés défauts thermiques localisés, en raison de la circulation des courants dans diverses parties du TP [62]. Les températures des points chauds sur les surfaces métalliques peuvent atteindre jusqu'à 1500°C, entraînant un échauffement localisé de l'huile environnante [52, 59]. Les défauts de type T_3 ou D_2 sont les plus dangereux dans un TP, et lorsqu'ils sont identifiés, surtout si l'isolation en papier est impliquée, une intervention immédiate est nécessaire [10]. Le Tableau 1 présente une classification des défauts observés dans le TP, leurs symboles correspondants ainsi qu'une description des conséquences de chaque défaut.

Tableau 1 : Classification des défauts dans le TP avec symboles et conséquences.

Défaut	Symbole	Conséquence
Décharge partielle	PD	<ul style="list-style-type: none">• Dépôt de "X_Wax " sur le papier isolant.• Apparition des micro-trous dans le papier.
Décharge électrique de faible énergie	D ₁	<ul style="list-style-type: none">• Apparition d'importantes perforations carbonisées dans le papier.• Carbonisation de la surface du papier.
Décharge électrique de haute énergie	D ₂	<ul style="list-style-type: none">• Entraînement d'une pression excessive dans le réservoir.• Risque d'explosion du TP.
Défauts thermiques de basses températures T < 300 °C	T ₁	<ul style="list-style-type: none">• Réduction de la durée de vie de l'isolation.
Défauts thermiques de températures moyennes 300°C < T < 700 °C	T ₂	<ul style="list-style-type: none">• Carbonisation du papier.• Réduction de la durée de vie de l'isolation.
Défauts thermiques de haute température T > 700 °C	T ₃	<ul style="list-style-type: none">• Carbonisation du papier et/ou de l'huile.• Fusion des métaux.• Réduction de la durée de vie de l'isolation.

2.1.2.2 RELATION ENTRE DÉFAUTS ET FORMATION DES GAZ

La présence d'un défaut dans un TP engendre la formation d'hydrocarbures de types et de quantités différents [42]. Les gaz ainsi produits et leurs concentrations dépendent du type de défaut, tels que les PD, les arcs électriques associés aux défauts D et la défaillance des systèmes de refroidissement [63]. De plus, d'autres facteurs entrent en jeu, tels que la température du défaut, son intensité, sa durée, son énergie, la solubilité, les types de matériaux en contact avec le défaut interne, ainsi que les conditions variables associées à l'échantillonnage et aux procédures de mesure [43, 46]. Parmi ces facteurs, les plus essentiels

sont la température et l'énergie, car ils perturbent la structure chimique de l'huile isolante [64].

D'un point de vue chimique, l'énergie ainsi que la température des défauts nécessaires pour la rupture des liaisons entre les atomes constituant les molécules de l'huile sont différentes, comme illustré dans le Tableau 2. En effet, les défauts de basse énergie, tels que les PD, favorisent la rupture des liaisons C-H, qui sont les plus faibles, conduisant ainsi à l'accumulation de gaz de type H₂. Par contre, plus d'énergie et/ou une température plus élevée sont nécessaires pour la rupture des autres liaisons, à savoir C-C, C=C et C≡C, comme dans le cas de la formation de C₂H₂ qui contient une liaison C≡C nécessitant une grande énergie et/ou une température élevée pour sa formation. Le C₂H₂ est essentiellement formé à des températures d'au moins 800 °C à 1200 °C, comme dans le cas des arcs électriques. Bien qu'il puisse être formé à des températures inférieures à 800 °C, cela se produit uniquement en petites quantités [58].

Tableau 2 : Énergie de rupture des liaisons chimiques dans les molécules d'hydrocarbures.

Type de liaison	Énergie de rupture (kJ/mol)
C-H	338
C-C	607
C=C	720
C≡C	960

Après la formation des gaz, un autre facteur intervient : la solubilité des gaz, qui représente leur capacité à se dissoudre dans l'huile. Cette solubilité dépend fortement de facteurs tels que la température, la pression et la composition chimique. Par exemple, pour des gaz comme le H_2 et CO , elle est proportionnelle à la température, tandis que pour des gaz tels que CO_2 , C_2H_2 , C_2H_4 et C_2H_6 , elle diminue avec l'augmentation de la température [52].

C'est pourquoi, au fur et à mesure que la décharge passe de faible énergie à haute énergie, les concentrations de C_2H_2 augmentent considérablement. Les gaz tels que le CH_4 , le C_2H_4 et le C_2H_6 nécessitent moins d'énergie que le C_2H_2 et ils sont généralement formés à des températures de défaut supérieures à $400^\circ C$, mais leur production diminue à mesure que la température augmente significativement [43, 65]. Cela explique que, lors de défauts impliquant des contacts directs entre l'huile et des surfaces métalliques chaudes, tels que le cas des joints surchauffés entre les conducteurs, des courants de circulation excessifs et la surchauffe du noyau, il se produit une décomposition thermique de l'huile et la formation de grandes quantités de gaz tels que le C_2H_4 et le C_2H_6 , également appelés gaz de métal chaud [43, 66].

En général, les défauts qui se produisent dans le papier isolant sont considérés comme plus graves que ceux affectant l'huile, car la destruction du papier peut entraîner d'énormes problèmes tels que des courts-circuits ou des arcs électriques [42]. De plus, les liaisons moléculaires du papier, telles que les liaisons C-O et glycosidiques, sont thermiquement

moins stables que les liaisons moléculaires de l'huile. Elles nécessitent uniquement des températures modérément élevées de 150°C ou plus afin de produire du CO et du CO₂, et une température de 300°C pour une décomposition complète et la carbonisation du papier, contrairement à l'huile, qui nécessite généralement des températures supérieures à 400°C [58, 66]. Cependant, la formation du CO et du CO₂ n'est pas exclusivement due à des défauts, mais également au vieillissement. En cas de défauts dans le papier, en plus du CO et du CO₂, des gaz tels que O₂, H₂ et CH₄ peuvent également se former, tandis qu'en cas de vieillissement, on observe la présence de H₂O [41]. D'autres facteurs peuvent également altérer les concentrations de gaz issus du papier. Par exemple, l'étude [67] montre l'influence du type du liquide utilisé ainsi que l'âge du liquide dans lequel le papier est imprégné sur les gaz dissous.

Chaque type de défaut est généralement caractérisé par des gaz principaux, secondaires, ainsi que des traces de gaz. Cependant, des différences peuvent être remarquées dans la littérature concernant les gaz associés à chaque type de défaut. Cela a également été souligné par l'IEEE, où il est indiqué que, bien que les raisons physiques de la formation des gaz aient une base technique solide, les opérateurs doivent toutefois être conscients que l'interprétation de ces données en termes de causes spécifiques n'est pas une science exacte, mais le résultat d'une preuve empirique à partir de laquelle des règles d'interprétation ont été dérivées [16]. Le Tableau 3 établit une classification des gaz principaux, secondaires et des traces de gaz associés à chaque défaut, en tenant compte de la relation entre la température des défauts et la formation des gaz (section 2.1.2.2), ainsi que la fréquence des observations rapportées dans la littérature et résumées dans le Tableau 4.

Tableau 3 : Classification des gaz principaux, secondaires et traces formés par type de défaut.

Défaut	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆
PD	+	+	T	-	-
T₁	*	+	-	T	+
T₂	*	*	T	+	+
T₃	+	-	*	+	-
D₁	+	+	-	T	-
D₂	+	-	+	*	-

Remarque : + : gaz principal ; * : gaz secondaire ; T : trace de gaz ; - : pas important.

Tableau 4 : Classification des gaz principaux, secondaires et traces associés aux différents types de défauts selon la littérature.

Défaut	Gaz principal	Gaz secondaire	Trace de Gaz
PD	H ₂ [10, 24, 39, 41-43, 46, 52, 59, 61, 63-66, 68-75].	CH ₄ [46, 65].	C ₂ H ₂ [41, 43, 59, 65, 69, 76].
	CH ₄ [39, 41, 52, 59, 61, 63, 69, 71, 73].		
	C ₂ H ₂ [75].		
T₁	H ₂ [25, 39, 41, 65, 72].	H ₂ [43].	C ₂ H ₄ [25, 41, 43].
	CH ₄ [25, 39, 41, 43, 65, 66, 72, 74].	C ₂ H ₄ [39].	
	C ₂ H ₆ [25, 41, 43, 65, 66, 74, 76].		
	C ₂ H ₄ [65, 70].		
T₂	H ₂ [39, 41, 65, 75].	H ₂ , [25, 43, 63].	C ₂ H ₂ [41, 43, 72, 76].
	CH ₄ [25, 39, 41, 63, 65, 66, 74, 75, 77].	CH ₄ [43, 63].	
	C ₂ H ₄ [25, 39, 41, 43, 65, 70, 72, 74, 75, 77].		
	C ₂ H ₆ [25, 65, 66, 74].	C ₂ H ₆ [39, 43, 63, 75].	
T₃	H ₂ [25, 39, 41, 65].	H ₂ , C ₂ H ₂ [43].	C ₂ H ₂ [72, 76].
	CH ₄ [25, 39, 41].		
	C ₂ H ₂ [25, 39, 41, 65].		
	C ₂ H ₄ [25, 39, 41, 43, 65, 66, 70, 72, 74, 77].		
D₁	H ₂ [25, 39, 43, 51, 67, 74, 76, 77].	C ₂ H ₄ [25, 43].	CH ₄ [25, 39, 77].
	CH ₄ [51, 67].		C ₂ H ₂ [67].
	C ₂ H ₂ [25, 39, 43, 74, 76].		C ₂ H ₄ [39, 51, 67].
D₂	H ₂ [25, 39, 41-43, 51, 52, 59, 67, 71, 74, 76].	C ₂ H ₄ [39, 43, 51].	C ₂ H ₆ [39].
	CH ₄ [41, 67].	CH ₄ [25, 39, 51].	
	C ₂ H ₂ [10, 25, 39, 41-43, 51, 52, 59, 66, 67, 70, 71, 73, 74, 76].		
	C ₂ H ₄ [25, 41, 67].		

2.2 MÉTHODES D'ANALYSES DES GAZ DISSOUS

2.2.1 PRÉSENTATION DES MÉTHODES DGA

Les méthodes DGA sont reconnues comme étant parmi les plus utilisées pour la détection des défauts ainsi que pour l'évaluation de l'état général des TP immergés dans l'huile. Leur popularité provient de leur efficacité, leur simplicité et leur fiabilité dans la détection des défauts naissants et le diagnostic des défauts internes [41, 72, 78, 79]. Selon l'IEEE [10], cette technique consiste en la détection, la mesure et l'interprétation des gaz dissous dans l'huile isolante des appareils électriques. Ces gaz dissous peuvent être collectés et mesurés par différentes techniques, telles que la spectroscopie photo-acoustique (PAS), la spectroscopie proche infrarouge (NIR) et la chromatographie en phase gazeuse (GC) [62]. Cela permet ensuite de déterminer les défaillances potentielles à l'intérieur des TP en analysant les différentes concentrations de gaz.

Cette analyse permet de différencier les défauts T des défauts électriques, ainsi que ceux produits dans l'huile de ceux dans le papier imprégné d'huile, grâce à certaines théories et règles qui relient les proportions de ces gaz aux différents types de défauts possibles. Ces concepts ont conduit au développement de diverses méthodes et normes, y compris la norme IEEE [66, 80, 81]. En général, la distribution relative des gaz est utilisée pour évaluer le type de défaut, tandis que leurs concentrations permettent d'évaluer l'intensité du défaut [42].

L'histoire de la DGA a commencé à la fin des années 1950. Cependant, ce n'est qu'à partir des années 1970, après l'élimination de l'influence du volume du liquide, que diverses méthodes pour déterminer les défaillances de l'isolation des TP, basées sur différents rapports de concentrations de gaz, ont émergé [4]. En 1993, l'IA a été introduite l'une des premières fois dans la DGA par Durkam [82], utilisant à la fois la logique floue (LF) ainsi que les réseaux de neurones artificiels (ANN). Cependant, ce n'est que ces dernières années que l'utilisation de l'IA est devenue populaire, en raison du développement de la technologie informatique, des big data et du stockage cloud, qui ont permis l'élaboration de divers algorithmes intelligents. Ces algorithmes se distinguent par leur capacité à établir des relations complexes et non linéaires entre les gaz dissous et les défauts des TP, faisant ainsi de leur application dans l'analyse des gaz dissous une tendance dans la recherche et le diagnostic des défauts [81, 83-85].

Plusieurs classifications ont été adoptées dans la littérature concernant les méthodes DGA. Certaines études, telles que [5, 18, 20], les classent en deux catégories : les méthodes traditionnelles ou conventionnelles et les méthodes intelligentes. Dans d'autres études, elles sont classées en trois catégories. Par exemple, dans l'étude [86], elles sont classées en méthodes traditionnelles, méthodes intelligentes et méthodes de Machine Learning (ML), tandis que dans [70], elles sont classées en méthodes traditionnelles, méthodes intelligentes et méthodes hybrides.

2.2.2 MÉTHODES DGA TRADITIONNELLES

Les méthodes traditionnelles sont issues de vastes ensembles de données empiriques et d'observations de terrain [5, 9, 10, 87]. Initialement, les rapports de concentration des gaz étaient utilisés pour détecter les défaillances. Le rapport éthylène/acétylène servait d'indicateur des défaillances électriques, tandis que le rapport méthane/hydrogène était utilisé pour les défaillances thermiques. Quelques années plus tard, les premières tables de codes de défaillances ont été créées en tenant compte des rapports de concentration de différents gaz [4]. Les méthodes DGA traditionnelles sont généralement divisées en trois catégories : les méthodes des gaz clés, les méthodes des ratios, et les méthodes graphiques.

Un total de 64 méthodes a été développé entre 1970 et 2024 [5], parmi lesquelles 27 sont des méthodes graphiques [88], tandis que les autres se répartissent entre les méthodes des gaz clés et les méthodes des ratios de gaz. Les premières méthodes élaborées étaient celles des gaz clés, suivies des méthodes de ratios de gaz, puis des méthodes graphiques [62]. En général, les résultats de plusieurs méthodes sont combinés afin de réaliser une évaluation globale, car ces différentes méthodes présentent des avantages et des limitations variés, ce qui rend difficile le choix d'une méthode unique [89, 90].

Les méthodes DGA traditionnelles présentant plusieurs avantages, tels que la nécessité de moins de puissance de calcul, la capacité à identifier des défauts même en l'absence d'étiquettes, et la simplicité de mise en œuvre [91-94]. Cependant, elles présentent

également des inconvénients, tels que la nature empirique des méthodes, des frontières de codage trop rigides, l'incapacité de diagnostiquer des défauts multiples, des performances non optimales [25, 72, 74, 78, 85, 92-97], la sensibilité aux bruits présents dans les mesures, et leur dépendance en grande partie à l'expérience des ingénieurs sur le terrain [23, 91, 98].

2.2.2.1 MÉTHODE DES GAZ CLÉS

Lorsqu'un défaut se produit dans un TP, il entraîne la formation d'un ou plusieurs gaz en fonction du type de défaut. Le gaz dont la concentration est la plus élevée est appelé "gaz clé", et permet d'identifier le type de défaut en question [99]. Cette méthode a été utilisée pour la première fois au milieu des années 1950 avec les travaux de Howe. Depuis, d'autres méthodes basées sur cette approche ont été développées telles que [5] :

- La méthode des gaz clés de l'IEEE
- La méthode LCIE
- La méthode de la California State University de Sacramento (CSUS)
- La méthode des ensembles de gaz caractéristiques (CGE) de Davidenko et al
- La méthode des gaz clés de Muller et al.

Cependant, ce type de méthodes n'est généralement pas très utilisé, car elles présentent plusieurs inconvénients. Parmi ceux-ci figurent la difficulté à déterminer le gaz principal et le gaz secondaire formé en raison de la présence fréquente de traces d'autres gaz [76, 89], certaines méthodes nécessitant une grande quantité de gaz dans l'échantillon d'huile [78], et le CO n'est pas toujours un bon indicateur de défaut pour le papier isolant [10]. De

plus, dans certains cas, le gaz prédominant ne fait pas partie des gaz utilisés par la méthode.

La méthode des gaz clés adoptée par la norme IEEE est présentée dans le Tableau 5.

Tableau 5 : Méthode des gaz clés de l'IEEE.

Défaut	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	CO	CO ₂
Thermique dans l'huile minérale	*	*	T ^(a)	+	*	-	-
Thermique dans l'huile minéral et la cellulose	*	*	-	+	*	+	-
Décharge partielle électrique à basse énergie (PD)	+	*	-	T	T	-	-
Électrique de haute énergie (arc électrique)	+	T	+	T	T	+(b)	-

Remarque : + : gaz principal ; * : gaz secondaire ; T : trace ; - : non considéré ; (a) : Trace de C₂H₂ lorsque le défaut thermique est à haute température ; (b) : Présence du CO lorsque le papier est affecté par le défaut.

2.2.2.2 MÉTHODE DES RATIOS

Les méthodes de ratios de gaz sont des méthodes qui utilisent les ratios de gaz clés pour effectuer le diagnostic des défauts. Ces méthodes s'appuient principalement sur la corrélation entre les ratios des gaz liés aux défauts afin d'identifier le type et/ou la gravité du défaut [5, 100].

En 1970, dans l'étude [101] de Dornenburg, les ratios de C₂H₄/C₂H₂ et CH₄/H₂ ont été utilisés pour la première fois afin de distinguer entre les défauts de nature thermique ou

électrique. Cette méthode, appelée la méthode des ratios de Dornenburg (DRM), est considérée comme la première utilisant les ratios de gaz, et son apparition a eu lieu lors de la conférence internationale du CIGRE sur les systèmes électriques à haute tension [102]. Quatre ans plus tard, en 1974, après la publication de Dornenburg [103], cette méthode fut généralisée et largement adoptée. En 1973, dans la publication [104], l'entreprise Central Electricity Generation Board (CEGB) propose la deuxième méthode basée sur les ratios. Deux ans plus tard, Rogers publia sa méthode populaire dans [105], qui est encore utilisée de nos jours, connue sous le nom de méthode des ratios de Rogers (RRM).

Ces méthodes sont considérées comme les premières méthodes DGA utilisant les ratios de gaz dans le diagnostic des défauts. Depuis, un grand nombre de méthodes basées sur des ratios ont été développées. Bien que ces méthodes présentent des avantages, tels que le fait d'être indépendantes du volume d'huile [90], elles comportent plusieurs inconvénients, tels que l'existence de zones non diagnostiquées dans des intervalles non définis [23, 76, 83, 89], l'absence de certaines combinaisons de ratios de gaz dans les codes prédéfinis [62, 80, 81, 83, 90, 106], ainsi qu'une faible précision [62, 107]. Malgré leurs inconvénients, les méthodes DGA basées sur les ratios sont encore utilisées et adaptées par plusieurs sociétés pour le diagnostic des TP. Parmi les méthodes les plus couramment employées figurent les méthodes DRM, RRM et la méthode des ratios de l'IEC (IRM) [58], cette dernière offrant la meilleure précision parmi ces méthodes [60].

A) MÉTHODE DE DORNENBURG

Bien que cette méthode soit la plus ancienne des méthodes basées sur les ratios, elle est toujours utilisée et même recommandée par la norme IEEE. La méthode DRM permet la détection de différents types de défauts, notamment les défauts T, les D et les PD. Dans sa version la plus récente adoptée par l'IEEE, la méthode DRM utilise quatre ratios de gaz : $R1=CH_4/H_2$, $R2=C_2H_2/C_2H_4$, $R3=C_2H_2/CH_4$ et $R4=C_2H_6/C_2H_2$. Initialement, selon les recommandations de l'IEEE [10], les concentrations des gaz doivent être comparées aux limites indiquées dans le Tableau 6. Si les concentrations de H_2 , CH_4 , C_2H_2 et C_2H_4 dépassent deux fois leurs limites respectives, et si les concentrations de CO et de C_2H_6 excèdent également leurs seuils, cela indique la présence d'un défaut dans le TP. Il est alors nécessaire de calculer les ratios des gaz et de les comparer au Tableau 7 pour identifier le type de défaut.

Tableau 6: Limite des concentrations de gaz [10].

Gaz clé	Concentration limite (ppm)
H_2	100
CH_4	120
CO	350
C_2H_2	1
C_2H_4	50
C_2H_6	65
CO_2	2500

Tableau 7: La relation entre les défauts et les ratios de Dornenburg.

Défaut	R1	R2	R3	R4
PD	< 0.1	-	< 0.3	> 0.4
T	> 1	< 0.75	< 3	> 0.4
D	0.1 Jusqu'a 1	> 0.75	> 0.3	< 0.4

Remarque : '-' : ratio non important pour la détection du défaut.

Tel qu'illustré dans les Tableaux 6 et 7, cette méthode présente certains inconvénients tels que l'absence de diagnostics pour certains intervalles, l'incapacité à détecter la sévérité du défaut, ainsi que la non-détection de défauts si les gaz n'atteignent pas les limites spécifiées. Dans ce cas, le résultat obtenu indiquera que le TP ne présente pas de défaut.

B) MÉTHODE DES RATIOS DE ROGERS

La méthode RRM a été publiée par Rogers en 1975 dans la publication [105]. Le développement de cette méthode repose essentiellement sur l'étude produite par Halstead en 1970, qui propose une évaluation thermodynamique théorique sur la formation des hydrocarbures gazeux simples résultant de la décomposition de l'huile minérale, ainsi que sur les travaux de Dornenburg et la publication de CEGB [108]. Les ratios utilisés initialement étaient : $R1=CH_4/H_2$, $R2=C_2H_6/CH_4$, $R3=C_2H_4/C_2H_6$ et $R4=C_2H_2/C_2H_4$. Contrairement à la méthode DRM, celle-ci permet de détecter la sévérité des défauts et d'identifier 11 défauts ainsi que l'état de fonctionnement normal du TP. De plus, elle peut être utilisée même lorsque les concentrations des gaz dissous atteignent des valeurs seuils

[109]. Les relations entre les défauts et les ratios du gaz utilisé dans la version de 1975 de RRM sont illustrées dans le Tableau 8.

Tableau 8: Relation entre les défauts et les ratios de Rogers, version révisée de 1975.

R1	R2	R3	R4	Diagnostic
0	0	0	0	Détérioration normale
5	0	0	0	PD
1/2	0	0	0	Surchauffe légère de température $T < 150^{\circ}\text{C}$
1/2	1	0	0	Surchauffe légère de température $150^{\circ}\text{C} < T < 200^{\circ}\text{C}$
0	1	0	0	Surchauffe légère de température $200^{\circ}\text{C} < T < 300^{\circ}\text{C}$
0	0	1	0	Surchauffe générale du conducteur
1	0	1	0	Courants de circulation dans les enroulements
1	0	2	0	Courants de circulation dans le noyau et le réservoir, joints surchauffés
0	0	0	1	Arc électrique de surface sans passage de puissance
0	0	1/2	1/2	Arc électrique avec passage de puissance
0	0	2	2	Étincelage continu vers un potentiel flottant
5	0	0	1/2	Décharge partielle avec suivi

La méthode RRM a subi plusieurs modifications, la première datant de la publication de 1975 [105]. L'une des versions les plus récentes est celle adoptée par la norme IEEE C57.104 [10]. Dans cette version, le ratio $\text{C}_2\text{H}_6/\text{CH}_4$ a été éliminé, et le nombre de défauts détectables a été réduit à cinq. La relation entre les ratios de gaz et les défauts est illustrée dans le Tableau 9.

Tableau 9: Relation entre les défauts et les ratios de Rogers, version de l'IEEE, 2019.

R4	R1	R3	Diagnostic de défaut suggéré
< 0,1	0,1 – 1,0	< 1,0	Unité normale
< 0,1	< 0,1	< 1,0	Arc à faible densité d'énergie — PD
0,1 – 3,0	0,1 – 1,0	> 3,0	Arc — Décharge à haute énergie (D ₂)
< 0,1	0,1 – 1,0	0,1 – 3,0	Défaillance thermique à basse température
< 0,1	> 1,0	0,1 – 3,0	Thermique < 700 °C
< 0,1	> 1,0	> 3,0	Thermique > 700 °C (T ₃)

C) Méthode des ratios de l'IEC

En 1978, une nouvelle version révisée de la méthode RRM, publiée en 1975, a été corrigée. Cette nouvelle version se caractérisait par la suppression du rapport C_2H_6/CH_4 dans le but de simplifier l'analyse des défaillances [102]. Elle a été incluse dans la norme IEC 60599 [110], et est devenue connue sous le nom de la méthode des ratios de l'IEC. Initialement, cette méthode permettait d'identifier huit défauts dans les TP, en plus de l'état normal. Cependant, après plusieurs modifications, la dernière version de la méthode IRM, utilisée dans la norme IEC 60599-2022 [58], permet l'identification de seulement six défauts, comme illustrés dans le Tableau 10. Toutefois, pour utiliser cette méthode, au moins l'un des gaz doit dépasser la valeur limite indiquée dans le Tableau 6.

Tableau 10: Relation entre les défauts et les ratios de l'IEC, version de 2022.

Défaut	R4	R1	R3
PD	-	< 0, 1	< 0,2
D ₁	> 1,0	0,1 - 0,5	> 1,0
D ₂	0,6 - 2,5	0,1 to 1,0	> 2,0
T ₁	-	> 1,0	< 1,0
T ₂	< 0,1	> 1,0	1,0 - 4,0
T ₃	< 0,2	> 1,0	> 4,0

2.2.2.3 MÉTHODE GRAPHIQUE

Les méthodes graphiques visualisent les défauts grâce à des formes géométriques. L'identification des défauts est réalisée en projetant un point dans ces formes géométriques, dont les coordonnées sont déterminées en fonction de la méthode utilisée. Par exemple, dans la méthode de l'heptagone de Gouda [111], les pourcentages relatifs de sept gaz sont d'abord calculés, suivis d'opérations supplémentaires pour déterminer le point de défaut. En revanche, dans la méthode du triangle de Gouda [43], les ratios de cinq gaz sont calculés en premier. La position de ce point à l'intérieur de la forme géométrique fournit des informations sur le type et/ou la sévérité de défaut présent dans le TP.

Depuis 1970, 26 méthodes graphiques ont été développées [88]. Parmi les plus anciennes, figure le schéma de Potthoff, développé en 1969, suivi de la méthode du graphique

trilinéaire et de la méthode graphique de Shanks en 1970. Cependant, ces méthodes ne sont plus utilisées aujourd'hui [5]. En 1974, Duval a développé la méthode graphique connue sous le nom de la méthode du Triangle de Duval 1 (DTM), conçue pour surmonter les inconvénients des méthodes basées sur les ratios [89, 90, 112]. De nos jours, les méthodes les plus populaires et couramment utilisées sont la méthode DTM, le Pentagone de Duval (DPM), ainsi que le Triangle de Gouda et le Pentagone de Mansour [113]. La méthode DTM est également adoptée par les normes IEEE et IEC, tandis que la méthode DPM est adoptée par l'IEEE.

Bien que les méthodes graphiques soient relativement supérieures aux méthodes basées sur les ratios, elles présentent néanmoins certains inconvénients, tels que la rigidité des zones de défauts [62], et la difficulté à interpréter les données aux frontières [81, 114].

A) MÉTHODE DU TRIANGLE DE DUVAL 1

La méthode DTM est une méthode empirique graphique, développée en 1974 par Michael Duval, basée sur une base de données contenant des milliers d'analyses des gaz dissous ainsi que des diagnostics liés à des problèmes dans les TP [115]. Au fil des années, plusieurs révisions ont été apportées à cette méthode. La version adoptée par les deux normes IEC et IEEE est la version de 1993.

Cette méthode utilise trois gaz clés, à savoir le CH_4 , C_2H_2 et C_2H_4 , ainsi qu'un triangle équilatéral à l'intérieur duquel sont tracées sept zones distinctes, chacune représentant un

défaut à savoir le défaut T₁, T₂, T₃, D₁, D₂, PD et la zone des défauts mixtes électrique et thermique (DT). Chaque côté du triangle est gradué de 0 % à 100 % suivant le sens des aiguilles d'une montre, et il représente le pourcentage relatif de l'un des gaz clés. Ensuite, une droite est tracée à partir de chaque côté du triangle en fonction du pourcentage calculé pour chaque gaz, et la zone à laquelle appartient le point d'intersection de ces trois droites indique le défaut présent dans le TP. Cependant, l'utilisation de cette méthode nécessite que certains gaz dépassent les limites établies dans le Tableau 6, sinon le TP est considéré comme étant sans défaut.

Les pourcentages relatifs de chaque gaz sont calculés en utilisant la formule (2.1), où les concentrations de gaz en partie par million (ppm) sont utilisées. La Figure 3 illustre un exemple de la représentation à l'aide de DTM.

$$\left\{ \begin{array}{l} \% CH_4 = \frac{CH_4}{CH_4 + C_2H_2 + C_2H_4} \times 100 \\ \% C_2H_2 = \frac{C_2H_2}{CH_4 + C_2H_2 + C_2H_4} \times 100 \\ \% C_2H_4 = \frac{C_2H_4}{CH_4 + C_2H_2 + C_2H_4} \times 100 \end{array} \right. \dots \quad (2.1)$$

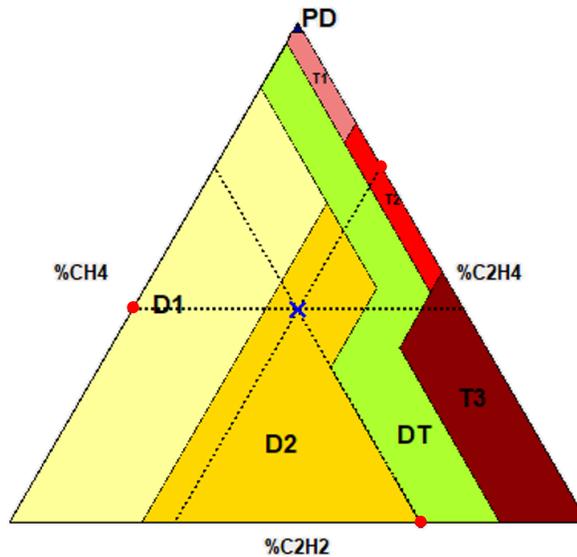


Figure 3 : Exemple d'une représentation à l'aide de DTM.

Une version encore plus récente a été développée en 2022 par Michael Duval et Jerzy Buchacz [116]. Dans cette nouvelle version, en plus des sept zones présentes dans la version de 1993, de nouvelles sous-zones ont été ajoutées, permettant de détecter si les décharges à faible ou haute énergie sont localisées dans l'huile ou le papier.

La méthode DTM a gagné en popularité grâce à sa précision et sa fiabilité. Elle offre plusieurs avantages, notamment le fait de toujours fournir un diagnostic avec un faible pourcentage d'erreur [112, 115, 117, 118]. De plus, en raison de sa simplicité, la programmation de logiciels de diagnostic utilisant cette méthode peut être réalisée en peu de temps avec divers langages de programmation, ce qui explique la disponibilité de nombreux logiciels utilisant cette méthode, offrant ainsi aux utilisateurs une utilisation facile et économique [56, 119]. Cependant, cette méthode présente également des désavantages. En

effet, des incertitudes existent dans le diagnostic des défauts de surchauffe de faible température et des PD, car les gaz C_2H_6 et H_2 , qui correspondent à ces types de défauts, ne sont pas pris en compte. De plus, la présence de dégazage parasite peut entraîner des confusions dans ces deux zones de défauts [120, 121].

Afin de remédier à certains de ces problèmes, Duval a proposé le Triangle de Duval 4 (DTM-4) et le Triangle de Duval 5 en 2008 [122]. Ces deux méthodes sont utilisées en complément avec la méthode classique DTM, également appelée Triangle de Duval 1, afin d'améliorer le diagnostic des TP émergés dans l'huile minérale. Des conditions spécifiques doivent être remplies pour utiliser ces triangles. L'utilisation du DTM-4 nécessite que la méthode DTM indique un défaut de type T_1 , T_2 ou PD, et cette méthode permet de détecter les gaz parasites, les défauts de PD, ou d'indiquer s'il existe une possibilité de carbonisation du papier (C) ou de surchauffe de l'huile à une température inférieure à $250^\circ C$ sans carbonisation du papier (O). Quant au DTM-5, son utilisation nécessite que le défaut identifié par DTM soit T_2 ou T_3 , et il permet d'identifier cinq défauts : T_2 , T_3 , C, O, S ainsi que le défaut PD. Cependant, contrairement à la méthode DTM, ces deux méthodes incluent une zone où le défaut est indéterminé (ND). La méthode DTM-4 utilise des gaz dits à faible énergie, à savoir H_2 , CH_4 et C_2H_6 , tandis que la méthode DTM-5 se base sur des gaz liés à la température comme C_2H_4 , CH_4 et C_2H_6 [112, 121]. La Figure 4 illustre un exemple de la représentation avec les trois méthodes DTM, DTM-4 et DTM-5.

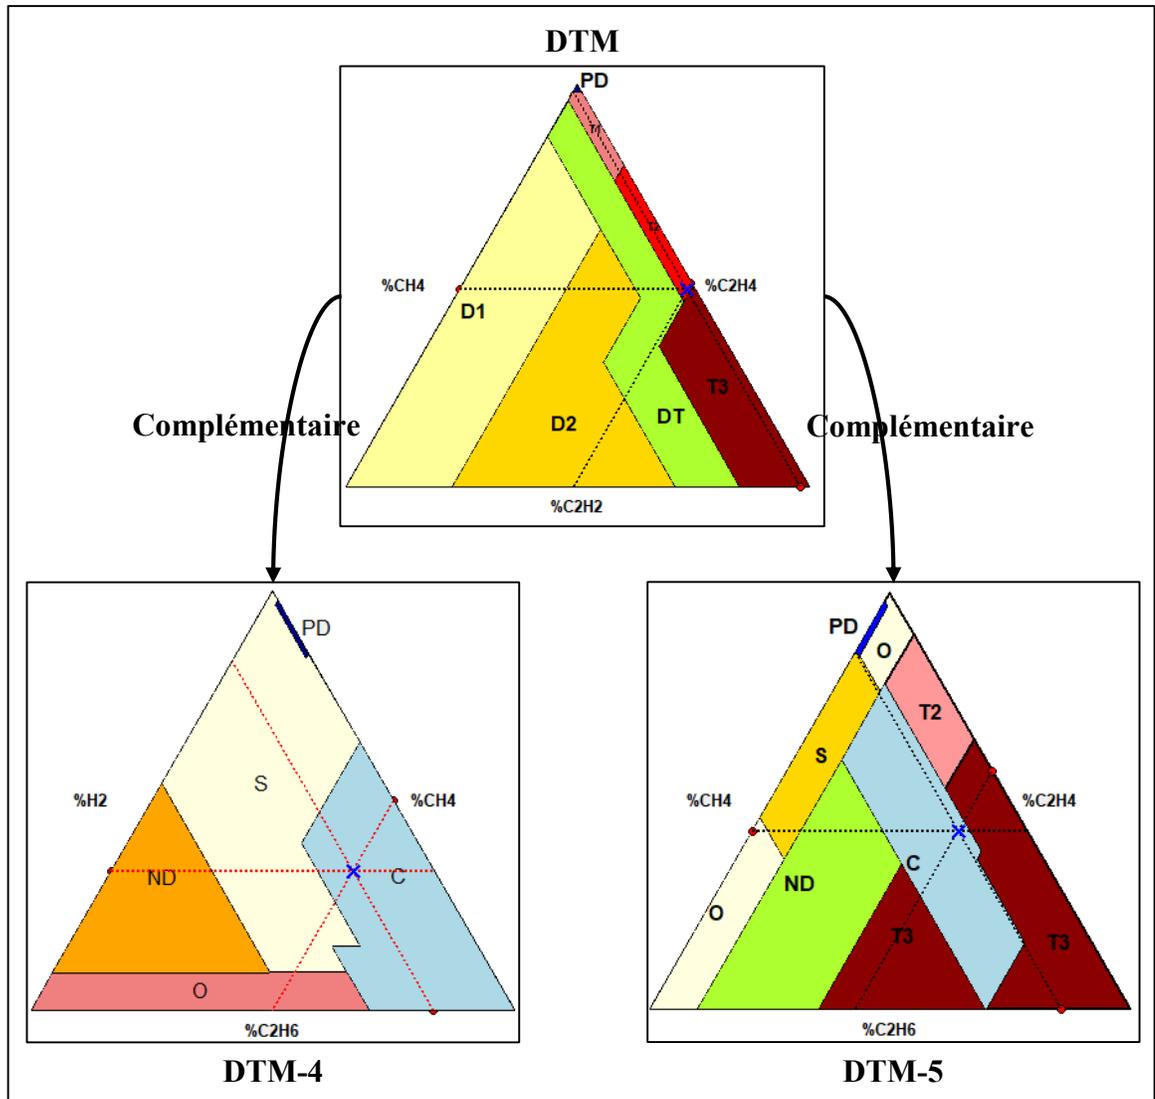


Figure 4: Exemple d’une représentation à l’aide de la méthode DTM et des deux triangles complémentaires de la DTM-4 et la DTM-5.

B) MÉTHODE DU PENTAGONE DE DUVAL

En 2014, Duval et Lamarre ont développé la méthode DPM ainsi que la méthode du Pentagone de Duval 2 (DPM-2), complémentaire à la méthode DPM [123]. Ces deux méthodes empiriques graphiques s’appuient sur l’analyse d’environ 180 résultats DGA

provenant de défauts identifiés par des inspections visuelles des TP remplis d'huile minérale, ainsi que sur les résultats de 20 analyses DGA effectuées en laboratoire sur le phénomène de gaz parasites, afin d'identifier les différentes zones de défaut.

Contrairement aux trois triangles de Duval, qui s'appuient chacun sur trois gaz clés, cette nouvelle méthode utilise cinq gaz, à savoir H₂, CH₄, C₂H₂, C₂H₄ et C₂H₆. Selon Duval, ces deux méthodes peuvent être utilisées seules, mais elles ont été principalement développées pour fournir des informations complémentaires.

La méthode DPM utilise cinq axes gradués de 0 % à 100 %, où chaque axe représente le pourcentage relatif d'un gaz. Le centre du pentagone correspond à 0 %, tandis que l'extrémité de chaque axe représente 100 % pour le gaz correspondant. En fonction des pourcentages relatifs des cinq gaz, cinq points sont placés sur chaque axe correspondant à ces valeurs. Ensuite, la surface du pentagone (A), obtenue en reliant ces cinq points, ainsi que les coordonnées de ces points, sont utilisés pour calculer les coordonnées du centroïde du pentagone à l'aide d'un système de coordonnées (x, y) défini à partir du centre du pentagone, en utilisant l'équation (2.2). Enfin, la zone à laquelle appartient le centroïde du pentagone détermine le type de défaut dans le TP. La Figure 5 illustre un exemple de représentation utilisant DPM et DPM-2.

$$\begin{cases} C_x = \frac{1}{6 \times A} \times \sum_i^{n-1} (x_i + x_{i+1}) \times (x_i \times y_{i+1} - x_{i+1} \times y_i) \\ C_y = \frac{1}{6 \times A} \times \sum_i^{n-1} (y_i + y_{i+1}) \times (x_i \times y_{i+1} - x_{i+1} \times y_i) \end{cases} \quad (2.2)$$

Où : x_i et y_i = les coordonnées associées aux cinq points.

C_x et C_y = les coordonnées du centroïde du pentagone.

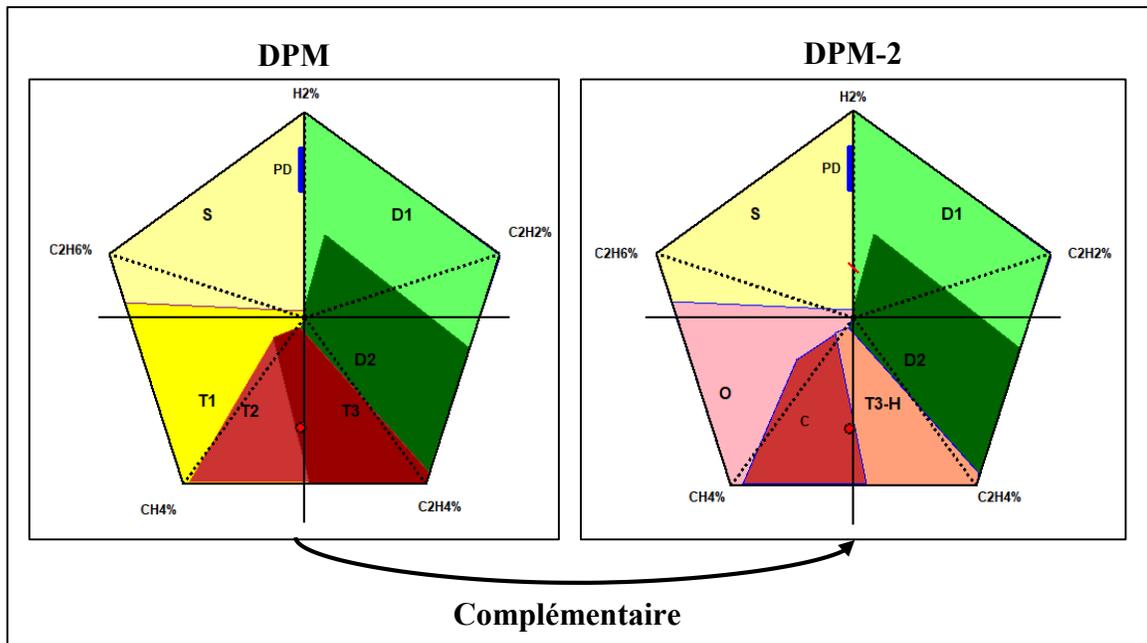


Figure 5: Exemple d'une représentation à l'aide de DPM et DPM-2.

La méthode DPM se distingue par une précision supérieure à celle des méthodes traditionnelles précédentes [80, 121]. Cependant, elle présente également des inconvénients tels que le chevauchement des interfaces entre deux zones de défauts, entraînant la coexistence de plusieurs défauts dans certaines zones du pentagone. Cela peut conduire à une variation de la précision de la prédiction en fonction des degrés de chevauchement des différents types de défauts dans ces zones [62, 81].

2.2.3 UTILISATION DE L'INTELLIGENCE ARTIFICIELLE

L'IA regroupe un ensemble de techniques et d'algorithmes utilisés pour rendre une machine capable d'accomplir des tâches humaines intelligentes. Parmi ces techniques, les systèmes experts, les algorithmes génétiques, les algorithmes d'apprentissage automatique, les méthodes d'apprentissage profond (Deep Learning, DL) et bien d'autres. Ces dernières années, avec le développement de l'IA, diverses méthodes de diagnostic intelligent ont été utilisées dans le domaine du diagnostic des défauts des TP, afin de remédier aux limitations des méthodes DGA traditionnelles. Ces méthodes intelligentes de diagnostic offrent plusieurs avantages, tels qu'une précision élevée comparée aux méthodes DGA traditionnelles [80, 86, 91], ainsi que leur autonomie, nécessitant peu d'intervention humaine [28]. Cela s'explique par le fait que ces modèles intelligents sont développés en extrayant les caractéristiques présentes dans les ensembles de données, plutôt que de manière empirique, ce qui leur permet de réaliser une classification plus fiable et précise des défauts des TP [78, 83, 98].

Les méthodes d'IA ont été introduites parmi les premières dans la DGA en 1993, lorsque Durkam a utilisé la LF et les ANN pour automatiser les méthodes DGA standard [82]. Cependant, il précise que l'utilisation des ANN seules nécessite une base de données étendue pour l'entraînement et la validation. Deux ans plus tard, dans [124], la méthode ANN a été utilisée seule pour extraire les relations présentes dans les données DGA et les défauts des TP. Ensuite, en 1997, les réseaux polynomiaux auto-organiseurs (RPAO) furent utilisés pour la première fois dans la DGA [125], suivis en 2000 par l'utilisation des cartes de

Kohonen (SOM) [126]. Depuis, le nombre d'études utilisant les différentes méthodes d'IA dans le DGA n'a cessé de croître. Parmi les méthodes d'IA les plus utilisées figurent les ANN, les arbres de décision (DT), la machine à vecteurs de support (SVM) et Naïve Bayes (NB), les ANN produisant les résultats les plus précis dans la majorité des études [127].

Les concentrations de gaz ont souvent été utilisées avec les premiers modèles d'IA destinés au diagnostic des défauts des TP. Cependant, pour les problèmes de classification et lors de l'apparition d'un nouveau défaut, ces méthodes classent ce dernier parmi les défauts existants en se basant sur les données d'expériences passées, ce qui entraîne une diminution de la précision du diagnostic. En effet, les données DGA ne reflètent pas pleinement l'état du TP et doivent être combinées à de nouvelles données de surveillance pour un diagnostic plus efficace [78]. Les critères fixés par l'IEC et le CIGRE confirment cela, recommandant l'utilisation des ratios de gaz clés plutôt que des concentrations de gaz, qui, avec le temps, se sont avérés ne pas être le choix le plus optimal [84]. De plus, le prétraitement des données avant leur utilisation [85], ainsi que la combinaison de plusieurs modèles d'IA, permet d'obtenir des modèles de diagnostic dont la robustesse est renforcée et la précision améliorée [78, 81, 98].

2.2.3.1 TRAITEMENT DES DONNÉES DGA

Le traitement des données à utiliser pour les méthodes d'IA est crucial. La distribution originale de l'ensemble des données a une conséquence notable sur le modèle de diagnostic. En cas de déséquilibre dans le nombre d'échantillons des classes représentant chaque état du

TP, cela pourrait amener les algorithmes de classification à privilégier la classe ayant le plus grand nombre d'échantillons, ce qui entraînerait une dégradation des performances de classification [81, 83, 107].

Pour remédier au problème de déséquilibre des classes, plusieurs études ont été menées. Lin Wang, dans [83], utilise six méthodes d'échantillonnage synthétique différentes, à savoir la technique de suréchantillonnage des minorités synthétiques (SMOTE), l'échantillonnage aléatoire sous-représenté (RUS), l'approche d'échantillonnage synthétique adaptative (ADASYN), Borderline-SMOTE (B-SMOTE), le réseau antagoniste génératif conditionnel (CGAN) et SMOTEENN, qui combine à la fois SMOTE et la méthode des plus proches voisins édités (ENN). Ces méthodes sont utilisées directement avec les données de concentrations de gaz en tant que phase de prétraitement pour résoudre le problème de déséquilibre. Ensuite, les données traitées sont utilisées avec trois modèles d'IA différents : SVM, DT et KNN. Les résultats obtenus ont montré que non seulement le prétraitement des données est important, mais aussi le choix de la méthode d'échantillonnage à utiliser pour chaque modèle d'IA. Par exemple, pour DT, le choix optimal est ADASYN, pour SVM c'est SMOTE, tandis que pour KNN, c'est B-SMOTE. Dans [128], la méthode Bootstrap est utilisée pour compenser le manque d'échantillons dans certaines classes, et la programmation génétique (GP) est employée pour la sélection des caractéristiques pertinentes qui seront fournies aux modèles d'IA.

En plus des phases de prétraitement des données, les techniques d'entraînement des modèles d'IA sont également cruciales. Dans l'approche suivie par [69], après l'augmentation des données à l'aide de la technique Bootstrap, la régularisation bayésienne (BR) ainsi que l'algorithme Levenberg Marquardt (LM) ont été utilisés pour entraîner un modèle ANN, ce qui a permis d'augmenter significativement la précision du modèle. Le Tableau 11 présente les problématiques abordées et les références associées dans la littérature sur la DGA.

Tableau 11: Problématiques abordées et références associées dans la littérature.

Problématique	Référence
Déséquilibre de classe	[12, 32, 69, 83, 106, 107, 125, 128-130]
Optimisation d'hyperparamètres	[7, 32, 69, 84, 86, 91, 131-134]
Manque de données	[9, 22, 93, 94, 107, 129, 135-138]
Sélection des caractéristiques	[11, 21, 84, 85, 91, 128, 132, 134, 139, 140]

De nombreuses études se sont également intéressées à l'utilisation de données autres que les concentrations de gaz avec les modèles d'IA. Certaines recherches, en plus des concentrations de gaz, intègrent également d'autres types de données complémentaires pour améliorer la précision des diagnostics. L'étude [135] présente les différents types d'entrées utilisées pour la méthode SOM, en s'appuyant sur 33 études différentes. Elle propose également une nouvelle combinaison de données constituée de divers ratios de gaz, qui sont utilisés dans le modèle SOM après un prétraitement par la méthode de normalisation HistD. Tandis que dans [86], quatre techniques de transformation de données ont été utilisées : la transformation logarithmique (TL), la normalisation, la standardisation et la transformation des concentrations de gaz en pourcentage relatifs. Les données obtenues ont ensuite été

utilisées pour l'entraînement de six modèles d'IA différents : DT, NB, SVM, KNN et les méthodes d'ensembles (EN), dont les hyperparamètres ont été optimisés à l'aide de l'optimisation bayésienne (BO).

Dans l'étude [85], un vecteur d'entrée composé de 46 caractéristiques, incluant les proportions relatives de gaz, les ratios, les concentrations de gaz ainsi que d'autres éléments, a été utilisé. Dans cette approche, les fonctions de pertinence et de redondance des caractéristiques sont établies en s'appuyant sur la théorie de l'entropie de l'information floue (EIF). Ces fonctions sont ensuite optimisées à l'aide de l'algorithme d'optimisation par essaims particuliers multi-objectifs chaotique-binaire (B-CMOPSO) afin de créer des sous-ensembles de caractéristiques qui seront utilisés pour l'entraînement et la validation de quatre méthodes d'IA : le SVM, l'algorithme AdaBoost.M1 (ABM), le réseau de neurones à rétropropagation (BPNN) et la machine à apprentissage extrême (ELM). De même, dans l'étude [84], 26 ratios de gaz différents sont utilisés. Cependant, cette fois-ci, la sélection des ratios optimaux ainsi que des paramètres du modèle SVM est effectuée avec l'algorithme génétique (GA). Les Tableaux 12 et 13 illustrent respectivement les types de données employés dans les études DGA pour l'amélioration des diagnostics et les différentes méthodes d'IA appliquées au DGA.

Tableau 12: Types de données d'entrée utilisées pour les modèles d'IA dans la littérature.

Référence	Type des données d'entrée des modèles d'IA			
	Concentration de gaz	Ratios de gaz	Proportions relatives de gaz	Autres
[86, 130, 141]	•		•	
[11, 18, 21, 27, 70, 77, 85, 91, 132, 139, 142]	•	•	•	•
[7, 125, 135]	•	•		
[80, 84]		•	•	•
[134]	•	•		•
[39, 94, 113]	•	•	•	
[20, 28, 69, 83, 93, 97, 106, 107, 131, 140]	•			
[9, 32, 95, 133, 137]		•		
[22, 89]			•	
[12, 92, 138]				•
[98]			•	•
[128]		•		•
[143]	•		•	•

Tableau 13: Modèles d'IA appliqués au diagnostic DGA dans la littérature.

Référence	Modèle IA utilisé										
	SVM	DT	KNN	ANN	NB	EN	CNN	SOM	FIS	FL	RF
[128]	•		•	•							
[20, 69, 77, 89, 133, 137, 140]				•							
[86]	•	•	•		•	•					
[84, 113, 130, 142, 144]	•										
[28, 145]	•			•							
[135]	•							•			
[107]				•							•
[79, 91, 97, 146]									•		
[70, 139]			•								
[27, 80, 138]							•				
[12, 98]											•
[39]		•									
[71, 82]										•	

Remarque : FIS : Système d'inférence neuro-flou.

2.2.3.2 COMBINAISON DES MÉTHODES

Les études récentes se sont également intéressées à la combinaison de plusieurs méthodes d'IA ou des méthodes d'IA avec des méthodes traditionnelles DGA. Cette approche vise à surmonter les désavantages propres à chaque méthode, permettant ainsi d'obtenir des modèles de diagnostic dont la robustesse et la précision sont renforcées [78, 81, 98].

Par exemple, dans l'étude [92], les méthodes SVM, DPM et l'optimisation par essaim particulière (PSO) sont combinées, puis une seconde combinaison utilise les méthodes KNN et DPM. Dans cette approche, les coordonnées du centroïde, calculées via la méthode DPM, sont fournies à la fois aux méthodes SVM et KNN pour la classification. Dans le cas de la méthode SVM, l'algorithme PSO est utilisé pour optimiser les hyperparamètres du modèle. Une approche similaire est également adoptée dans l'étude [62]. Dans ce cas, les coordonnées du centroïde sont utilisées avec la méthode du perceptron multicouche (MLP) lorsque le point de défaut se trouve à proximité des frontières des zones de défaut définies par la méthode DPM. Cependant, dans l'étude [98], les coordonnées du centroïde obtenues via la méthode DPM sont d'abord traitées par l'algorithme Density-Based Spatial Clustering of Applications with Noise (DBSCAN), qui permet de calculer la distance entre le centroïde et le point représentant le centre de chaque région de défaut dans la méthode DPM. Par la suite, les distances obtenues, ainsi que les concentrations de gaz, sont utilisées comme entrées pour la méthode de la forêt aléatoire (RF). Par contre, dans l'étude [72], deux méthodes d'IA et deux méthodes mathématiques sont combinées. Dans un premier temps, LF, BPNN, ainsi que la

méthode de l'analyse des relations grises (GRA) sont employées pour générer un pré-diagnostic à partir des concentrations de gaz. Ensuite, les résultats de chaque méthode sont fusionnés à l'aide de la théorie de Dempster Shafer (DS), permettant d'obtenir un diagnostic final plus précis. La même théorie pour la fusion des résultats de plusieurs méthodes est utilisée dans plusieurs autres approches. Dans [141], la méthode DS est utilisée pour combiner les résultats des méthodes SVM multiclassés à hypersphère (HMSVM), de l'Algorithme Immunitaire Hybride (HIA) et de la Machine d'Apprentissage Extrême à Noyau (KELM).

L'un des problèmes couramment abordés dans la littérature, auquel la combinaison de plusieurs méthodes peut apporter une solution, est le manque de données étiquetées. Ce manque est souvent dû au coût élevé des inspections visuelles approfondies ainsi qu'au temps considérable nécessaire pour identifier avec fiabilité le défaut réel dans le TP [106]. Plusieurs méthodes, basées principalement sur le DL, ont été développées afin de remédier à ce problème. Par exemple, l'étude [93], propose une méthode hybride combinant DTM, IEC 60599 et un réseau neuronal profond (DNN). Initialement, les données représentant un état de défaillance sont identifiées à l'aide de la méthode IEC 60599. Ces données sont ensuite étiquetées à l'aide de la méthode DTM, avant d'être utilisées pour l'apprentissage profond du DNN. Une branche auxiliaire non supervisée est également combinée afin de réduire les effets des pseudo-étiquettes erronées. De son côté, l'étude [95] utilise un réseau de croyances profondes (DBN) entraîné à l'aide de l'algorithme de divergence contrastive (CD). Durant la phase initiale de l'entraînement, des données non étiquetées sont exploitées pour ajuster les paramètres du modèle. Ensuite, dans la seconde phase, les données étiquetées sont utilisées

pour optimiser ces paramètres. Finalement, la sortie du modèle DBN est connectée à un BPNN pour la classification finale.

D'autres approches, visant spécifiquement à surmonter les limitations des méthodes traditionnelles en les combinant avec les méthodes d'IA, sont également explorées. L'étude [71] utilise la méthode LF pour résoudre le problème des changements brusques des codes dans les méthodes DGA traditionnelles basées sur les ratios de gaz. Tandis que dans [146], la méthode ANFIS est employée pour combler les lacunes de ces méthodes. D'autres, comme dans l'étude [79], adoptent la méthode ANFIS pour fournir des résultats de diagnostic supplémentaires en parallèle avec les méthodes de ratios. Le Tableau 14 présente une synthèse des différentes méthodes combinées dans la littérature pour le diagnostic DGA.

Tableau 14: Méthodes combinées pour le diagnostic DGA.

Référence	Combinaison de méthodes			
	IA	DGA traditionnelles	Mathématiques et/ou statistiques	Optimisation
[92, 132, 134, 142, 145]	•	•		•
[11, 62, 70, 71, 79, 93, 137, 146, 147]	•	•		
[22, 72, 94, 97, 106, 128, 130, 136, 138-140]	•		•	
[7, 32, 84, 91, 95, 131]	•			•
[114]		•	•	
[18, 21, 141]	•		•	•
[9, 12, 40, 98, 113, 148]	•	•	•	

2.2.4 INCERTITUDE DES APPAREILS DE MESURE

2.2.4.1 FACTEURS INFLUANT SUR LA PRÉCISION ET LA FIABILITÉ DES MÉTHODES DGA

Lors du diagnostic des TP à l'aide de la méthode DGA, plusieurs facteurs interviennent et réduisent la précision et la fiabilité des résultats. Cela peut conduire à une mauvaise classification des défauts, entraînant parfois l'arrêt ou la destruction du TP.

Parmi ces facteurs, le phénomène de gaz parasites qui est défini, selon la norme ASTM D7150 [149], comme la production de gaz dans l'isolation liquide due à la surchauffe et/ou à la contamination. Selon les normes IEC et IEEE [10, 58], il est défini comme la formation de gaz dans l'huile isolante lorsqu'elle est chauffée à des températures inférieures à 200°C. L'huile à l'intérieur du TP a souvent tendance à produire des gaz parasites de types et de quantités différents, en fonction du type d'huile utilisée [150, 151]. D'autres paramètres peuvent également influencer la formation de ces gaz, tels que l'incompatibilité de l'huile avec les matériaux utilisés à l'intérieur du TP ou l'ajout de passivateurs [152-154]. Bien que les gaz parasites ne nuisent pas au bon fonctionnement du TP, leur présence peut entraîner une interprétation erronée de son état. Par exemple, une augmentation de la concentration de H₂ dans l'huile, due aux gaz parasites, pourrait être interprétée par les méthodes DGA comme un défaut PD.

En plus de ce phénomène, d'autres facteurs viennent également affecter la précision du diagnostic DGA tels que : la complexité du système d'isolation du TP, des limites de l'interprétation humaine des données de mesure et de la possibilité de présence de plusieurs défauts simultanés [130]. De plus, les différents additifs dans l'huile peuvent provoquer des taux de dégazage différents [83], ainsi que les températures élevées générées lors des soudures pendant les réparations ou l'entretien des équipements. Ces températures peuvent entraîner la production de gaz tels que C_2H_2 et H_2 , perturbant ainsi la détection des défauts de type D_2 [65].

L'un des facteurs souvent négligés est l'incertitude liée aux appareils de mesure. Ces incertitudes varient en fonction de plusieurs paramètres, notamment d'un laboratoire à un autre et d'un appareil à un autre [13]. Cette incertitude peut provenir lors de l'échantillonnage ainsi que de l'analyse en raison des erreurs humaines, des procédures de mesure non rigoureuses, des opérations de calibration non effectuées et de l'influence de l'environnement [13, 94, 155].

2.2.4.2 CONSÉQUENCES DES INCERTITUDES DE MESURE

Les incertitudes liées aux appareils de mesures peuvent avoir plusieurs conséquences sur la précision et la fiabilité des diagnostics des méthodes DGA traditionnelles et/ou des méthodes utilisant l'IA. Cependant, ce facteur n'a pas été largement étudié dans la littérature et est souvent négligé.

Les résultats expérimentaux de l'étude [156] ont montré que pendant le stockage et le transfert des échantillons d'huile vers les laboratoires, de nombreux facteurs peuvent fausser les concentrations de gaz, tels que la température, la lumière, la présence de bulles dans l'échantillon, la technique d'extraction des gaz et le temps de stockage. Ces facteurs peuvent entraîner des incertitudes allant jusqu'à $\pm 14\%$, tandis que les incertitudes de mesure se situent autour de $\pm 5\%$ [80]. Cela fait que l'incertitude globale des données DGA peut atteindre $\pm 20\%$ en prenant en compte l'ensemble de ces différents facteurs [96]. McGrail, dans [15], souligne l'importance de connaître la précision du système de surveillance DGA dans son ensemble, et non uniquement celle du capteur. Il précise que la plupart des laboratoires ont une précision de $\pm 15\%$. Cependant, selon Duval, il est préférable de prendre en considération les valeurs de précision de DGA fournies par chaque laboratoire. Dans le cas où elles ne sont pas disponibles, les valeurs de précision moyennes fournies par CIGRE peuvent être utilisées par défaut, en appliquant la formule (2.3) [23].

$$\left\{ \begin{array}{l} \text{Hydrocarbures} \rightarrow \pm 15\% \text{ ou } 1 \text{ ppm, selon la valeur la plus élevée} \\ H_2 \quad \quad \quad \rightarrow \pm 15\% \text{ ou } 5 \text{ ppm, selon la valeur la plus élevée} \\ CO \quad \quad \quad \rightarrow \pm 15\% \text{ ou } 25 \text{ ppm, selon la valeur la plus élevée.} \end{array} \right. \quad (2.3)$$

D'autre part, les systèmes de mesure en ligne DGA sont également soumis à des incertitudes de mesure. Dans [75], des expériences ont été menées pour comparer les mesures de gaz en ligne et en laboratoire sous des défauts thermiques et électriques simulés. Les résultats ont montré que les mesures par surveillance en ligne des gaz sont comparables aux analyses en laboratoire, avec une marge d'erreur de $\pm 30\%$. La principale cause de cet écart est attribuée au fait que, lors de l'analyse en laboratoire, des fuites de gaz et des infiltrations

d'air peuvent se produire pendant le transport des échantillons et les retards de mesure, ce qui dépend fortement de l'efficacité de l'étanchéité des seringues d'échantillonnage individuelles. Les incertitudes de mesure liées aux appareils de mesure en ligne sont attribuées au manque d'entretien général des moniteurs en ligne, conduisant au vieillissement et à la dégradation des composants d'étanchéité [13]. Selon l'étude [25], l'incertitude de mesure totale dans des conditions de répétabilité à travers toutes les étapes de la procédure d'analyse des systèmes de DGA en ligne se situe entre $\pm 15\%$ et $\pm 20\%$.

Pour les méthodes DGA traditionnelles, qui présentent déjà une précision limitée, l'introduction d'incertitudes dans les données d'entrée réduit encore davantage leur précision, les rendant ainsi impraticables [96]. Duval et Durkam, dans [23], ajoutent qu'une mauvaise qualité des données augmente les coûts de maintenance et de réparation en raison de tests inutiles à la suite de faux positifs. De plus, la non-détection de défauts naissants à cause de cette incertitude pourrait également entraîner des coûts de réparation élevés à la suite de défaillances soudaines.

L'incidence de l'incertitude sur les méthodes DGA traditionnelles diffère en fonction du type de méthode utilisée. Par exemple, dans le cas des méthodes basées sur les ratios de gaz, cela peut mener à des ratios erronés et/ou à des résultats qui sortent des zones de diagnostic spécifiquement définies par ces méthodes [13]. Pour les méthodes graphiques, qui s'appuient généralement sur le calcul des pourcentages relatifs des gaz afin de déterminer la position du point représentant le défaut, l'incertitude entraîne le déplacement de ce point, ce

qui peut conduire à une identification erronée du défaut [13, 15]. En revanche, les méthodes d'IA sont sensibles aux données d'entraînement utilisées lors de leur mise en œuvre. Par conséquent, toute incertitude dans ces données affecte négativement la précision du diagnostic des défauts [155], en raison de l'apprentissage de relations erronées et/ou imprécises entre ces données et les défauts réels [13, 96, 130].

2.2.4.3 RÉOLUTION DES PROBLÈMES D'INCERTITUDE DE MESURE

Bien que les incertitudes liées aux appareils de mesure puissent avoir des conséquences significatives, voire catastrophiques, sur les TP, le nombre d'études ayant tenté de traiter ce problème spécifique reste limité.

Parmi les premières études ayant évalué l'effet de l'incertitude sur les méthodes DGA intelligentes figure l'étude [125] publiée par Hong en 1997, dans laquelle les RPAO et la LF ont été évalués à trois niveaux d'incertitude, soit $\pm 5\%$, $\pm 10\%$ et $\pm 20\%$. Dans l'étude [13], une incertitude de $\pm 10\%$ est prise en compte pour générer deux valeurs possibles pour chaque concentration de gaz mesurée. Ensuite, l'incidence de l'incertitude sur les méthodes DTM, IRM, DRM et RRM est analysée. Enfin, trois nouvelles zones d'incertitude, où la probabilité de fausse classification est élevée, sont ajoutées à la méthode DTM. L'étude [23] propose l'utilisation de méthode statistique standard pour déterminer l'incertitude d'un résultat calculé à partir de variables de mesure, puis représenter, à l'aide d'un polygone, la zone dans laquelle les concentrations réelles de gaz devraient se situer dans la méthode DTM.

Tandis que [155] propose une méthode basée sur la technique de probabilité conditionnelle, où les données d'entraînement sont utilisées pour calculer des paramètres probabilistes tels que la moyenne et l'écart-type associés à chaque type de défaut. La méthode a été évaluée à quatre niveaux d'incertitude différents, à savoir $\pm 5\%$, $\pm 10\%$, $\pm 15\%$ et $\pm 20\%$. Les résultats montrent que la précision de la méthode proposée diminue de 83,12% pour une incertitude de $\pm 5\%$ à 80,89% pour une incertitude de $\pm 20\%$. En revanche, dans [14], la méthode du maximum de vraisemblance (MV) est utilisée pour formuler la fonction de densité de probabilité correcte pour l'évaluation des ratios de gaz, en prenant en considération les incertitudes liées aux appareils de mesure, afin d'obtenir la meilleure estimation du véritable rapport de gaz.

Des méthodes utilisant l'IA ont également été employées pour tenter de résoudre les problèmes liés à l'incertitude. L'étude [130] exploite la méthode Fuzzy SVM (FSVM). Cette méthode est combinée avec l'algorithme fuzzy c-means clustering (FCM) pour former le modèle FCM-FSVM, et avec l'algorithme kernel fuzzy c-means clustering (KFCM) pour former le modèle KFCM-FSVM. Les résultats obtenus montrent que KFCM-FSVM fournit les meilleurs résultats pour la détection des catégories de défauts, ainsi qu'une bonne robustesse face aux incertitudes. Dans [131], un réseau de neurones à fonction de base radiale (RBF), la méthode FCM ainsi que l'optimisation par essaims particulaires inspirée de la mécanique quantique (QPSO) sont combinés. Tandis que dans [136], les réseaux de neurones autoassociatifs, également connus sous le nom d'auto-encodeurs (AANN) ont été combinés

avec l'algorithme Information Theoretic Mean Shift (ITMS). Dans [94], un réseau de prototypes gaussiens (GPN) basé sur la distance de Mahalanobis et la technique d'apprentissage par peu d'exemples (FSL) est proposé.

Contrairement aux autres méthodes, l'approche proposée dans [80] prend en compte les incertitudes dès les phases initiales. Cette approche utilise les réseaux de neurones convolutifs (CNN) pour remédier au problème d'incertitude. Initialement, quatre niveaux d'incertitude sont appliqués aux données de concentration de gaz, à savoir $\pm 5\%$, $\pm 10\%$, $\pm 15\%$ et $\pm 20\%$. Ensuite, les données originales ainsi que celles générées sont transformées sous différentes formes, telles que des ratios et des proportions relatives, puis diverses combinaisons d'entrées sont utilisées pour l'entraînement de la méthode CNN. Cette méthode a été évaluée à ces quatre niveaux d'incertitude, obtenant des précisions respectives de 97,7%, 97,2%, 96,5% et 95,8%, soit une diminution de 1,9% entre $\pm 5\%$ et $\pm 20\%$ d'incertitude.

D'autres approches utilisant des algorithmes d'optimisation, combinés à des méthodes traditionnelles, ont également été explorées pour résoudre le problème de l'incertitude. L'étude [74] utilise la méthode d'optimisation basée sur l'apprentissage par enseignement (TLBO) en combinaison avec la technique heuristique de Deb (HD) pour définir de nouvelles limites des intervalles pour les pourcentages relatifs des gaz clés ainsi que pour les ratios de gaz. Cette méthode a été évaluée à deux niveaux d'incertitude appliqués sur la concentration de H_2 , à savoir $\pm 5\%$ et $\pm 20\%$. Les résultats ont montré une précision de 88,34% pour une incertitude de $\pm 5\%$ et 85,23% pour une incertitude de $\pm 20\%$, soit une baisse de 3,11%. Tandis

que dans l'étude [96], un système flou est utilisé pour relier les pourcentages des gaz aux types de défauts, en s'appuyant sur des fonctions d'appartenance et des règles de diagnostic. Les limites de classification des pourcentages de gaz sont optimisées à l'aide de la méthode HGWO, qui combine le Grey Wolf Optimizer (GWO) et le GA. Ensuite, la méthode PSO est appliquée en complément pour améliorer les résultats, en conservant les meilleures positions locales et globales. La méthode proposée a été évaluée à quatre niveaux d'incertitude : $\pm 5\%$, $\pm 10\%$, $\pm 15\%$ et $\pm 20\%$, avec des précisions respectives de 98,77%, 98,03%, 95,09% et 93,12%, soit une baisse de 5,65% entre $\pm 5\%$ et $\pm 20\%$ d'incertitude. La Figure 6 présente le nombre de publications par année concernant les études traitant l'incertitude liée aux appareils de mesure pour l'analyse DGA et l'amélioration de la fiabilité.

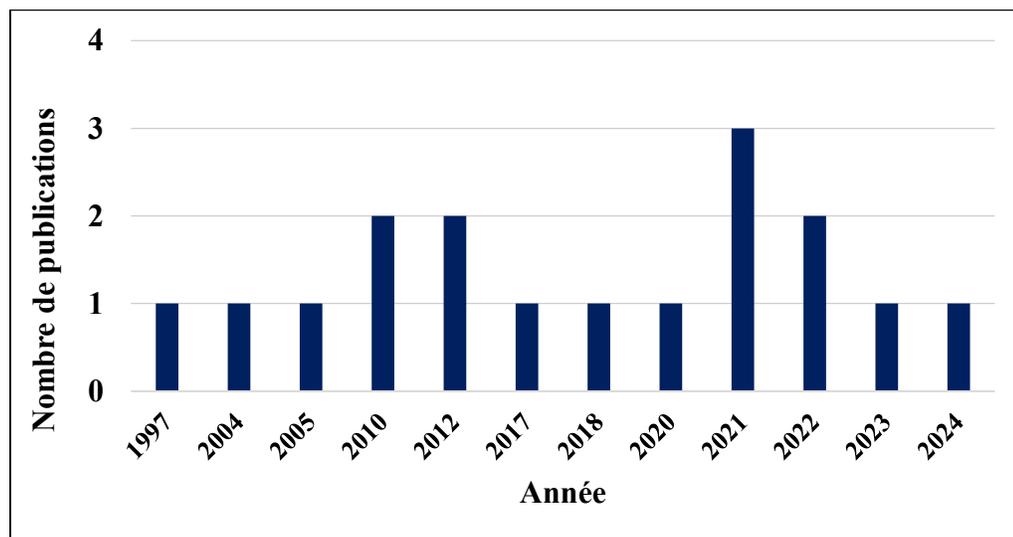


Figure 6: nombre de publications traitant la problématique de l'incertitude par année.

Toutefois, il n'est pas possible de tirer une conclusion définitive sur la robustesse de ces méthodes pour plusieurs raisons. Tout d'abord, les bases de données de test utilisées varient entre les études, ce qui rend difficile une comparaison directe des résultats. De plus,

le nombre de valeurs générées après l'introduction de l'incertitude dans les ensembles de tests est souvent insuffisant pour évaluer pleinement les modèles face à différents scénarios. Une évaluation plus complète nécessiterait plusieurs simulations pour chaque niveau d'incertitude, en raison de la nature aléatoire de l'incertitude associée à chaque mesure, qui varie dans l'intervalle d'incertitude de chaque appareil de mesure. Enfin, lorsque plusieurs quantités sont mesurées, chaque incertitude est traitée indépendamment, car chaque paramètre mesuré peut avoir sa propre incertitude [157-159]. Cela signifie que, même si les concentrations de gaz sont mesurées par le même appareil, les erreurs dues à des fluctuations aléatoires, comme les bruits dans les capteurs, affecteront chaque gaz de manière différente. Cependant, certaines études appliquent l'incertitude uniquement sur un type de gaz, tandis que d'autres appliquent le même niveau d'incertitude à toutes les valeurs de gaz, ce qui maintient les ratios et les pourcentages constants. Le Tableau 15 illustre une synthèse des critiques formulées à partir de l'analyse des différentes méthodes utilisées pour traiter les incertitudes.

Tableau 15: Critiques des méthodes DGA pour la résolution du problème d'incertitude.

Référence	Année	Méthodes utilisées	Commentaires
[130]	2012	KFCM-FSVM	<ul style="list-style-type: none"> • Méthode non évaluée pour de différents niveaux d'incertitude.
[155]	2017	Technique de probabilité conditionnelle	<ul style="list-style-type: none"> • une seule simulation réalisée pour chaque niveau d'incertitude, résultats peu généralisés.
[74]	2021	TLBO et DB	<ul style="list-style-type: none"> • L'incertitude est appliquée uniquement sur la concentration du H₂. • Une seule simulation réalisée pour chaque niveau d'incertitude, résultats peu généralisés.
[96]	2020	HGWO et PSO	<ul style="list-style-type: none"> • Une seule simulation réalisée pour chaque niveau d'incertitude, résultats peu généralisés.
[107]	2022	SMOTE, KPCA, FNN et RF	<ul style="list-style-type: none"> • Une seule simulation réalisée pour chaque niveau d'incertitude, résultats peu généralisés.
[80]	2021	CNN	<ul style="list-style-type: none"> • Une seule simulation réalisée pour chaque niveau d'incertitude, résultats peu généralisés.
[136]	2012	ANNN et ITMS	<ul style="list-style-type: none"> • Une seule simulation réalisée pour chaque niveau d'incertitude, résultats peu généralisés.
[144]	2010	Weighted SVM	<ul style="list-style-type: none"> • Méthode non évaluée pour de différents niveaux d'incertitude. • Nombre de données utilisées insuffisant.
[148]	2021	FL, DS, ANN, DTM, IRM et RRM	<ul style="list-style-type: none"> • Méthode évaluée pour uniquement 10% d'incertitude.
[131]	2010	FCM, RBF et QPSO	<ul style="list-style-type: none"> • Méthode évaluée pour uniquement une incertitude sous forme de bruit gaussien de 5 %. • Nombre de données utilisées insuffisant.
[137]	2004	CMAC et IEC	<ul style="list-style-type: none"> • Nombre de données utilisées insuffisant. • une seule simulation réalisée pour chaque niveau d'incertitude, résultats peu généralisés.
[94]	2024	GPN et FSL	<ul style="list-style-type: none"> • une seule simulation réalisée pour chaque niveau d'incertitude, résultats peu généralisés.
[12]	2023	RF, SMOTE, DPM et DPM-2	<ul style="list-style-type: none"> • Une seule simulation réalisée pour chaque niveau d'incertitude, résultats peu généralisés. • Manque de détails à propos de la méthodologie de génération de bruits dans les données.

Remarque : CMAC : Contrôleur d'Articulation du Modèle Cérébelleux.

2.3 CONCLUSION

Ce chapitre présente les différents concepts généraux liés à notre projet d'études. Tout d'abord, le mécanisme de formation des gaz ainsi que sa relation avec la température et les différents types de défauts ont été abordés.

Ensuite, les différents types de méthodes d'analyse des gaz dissous (DGA) ont été présentés en détail, incluant leur historique, avantages et inconvénients. Par la suite, les différentes techniques utilisées dans la littérature pour pallier ces inconvénients ont également été explorées.

Enfin, les différents facteurs affectant la fiabilité des méthodes DGA ont été discutés en mettant l'accent sur les conséquences des incertitudes liées aux appareils de mesure, et les différentes études ayant traité cette problématique.

À travers ce chapitre, et en examinant les différentes études effectuées dans la littérature, j'ai pu approfondir ma compréhension du fonctionnement des méthodes de diagnostic basées sur la DGA ainsi que de leurs limitations. De plus, l'analyse des nombreuses méthodologies employées pour résoudre ces problèmes m'a permis de bien appréhender comment ces défis sont généralement abordés, tant du point de vue des techniques que des méthodologies adoptées. Cela m'a également conduit à identifier ce qui a déjà été accompli et les aspects encore non étudiés.

CHAPITRE 3
AMÉLIORATION DE LA FIABILITÉ DES DIAGNOSTICS PAR ANALYSE DES
GAZ DISSOUS (DGA) EN PRENANT EN COMPTE L'INCERTITUDE DES
APPAREILS DE MESURE

Article publié dans IEEE Transactions on Dielectrics and Electrical Insulation, Novembre
2024

doi : 10.1109/TDEI.2024.3495585

AMÉLIORATION DE LA FIABILITÉ DES DIAGNOSTICS PAR ANALYSE DES GAZ DISSOUS (DGA) EN PRENANT EN COMPTE L'INCERTITUDE DES APPAREILS DE MESURE

Résumé

Lors de son fonctionnement, en raison de circonstances imprévues, un transformateur en service peut subir des défauts, d'origine électrique ou thermique. Le diagnostic et la surveillance des transformateurs via l'analyse des gaz dissous (DGA) constituent une approche indispensable pour une distribution d'énergie durable et fiable. Cette méthode est utilisée pour la détection précoce des défauts dans les systèmes de puissance remplis de liquide. Dans cette contribution, une nouvelle approche intégrant l'incertitude dans la DGA pour les transformateurs de puissance est proposée. En modifiant des méthodes empiriques traditionnelles telles que le triangle et le pentagone de Duval pour inclure l'incertitude, cette étude démontre comment ces modifications affectent le diagnostic des défauts. Les résultats indiquent que l'intégration de l'incertitude liée à la chromatographie en phase gazeuse améliore la précision des diagnostics pour les méthodes IEC, Rogers et Dornenburg, améliorant ainsi l'efficacité de la détection des défauts. De plus, les modèles d'intelligence artificielle (IA) tels que la forêt aléatoire (RF), le MLP et le SVM, entraînés avec des probabilités issues des méthodes modifiées, montrent des améliorations significatives dans la performance du diagnostic. Ces modèles ont démontré une robustesse accrue face à différents niveaux d'incertitude, atteignant une précision de 87,76 % pour le modèle de forêt

aléatoire et 86,73 % pour le modèle SVM avec un niveau d'incertitude de 30 % sur la base de données IEC TC10. Par conséquent, l'incorporation de l'incertitude liée à la chromatographie en phase gazeuse dans les méthodes de diagnostic DGA semble être une approche prometteuse pour soutenir la surveillance des transformateurs et le diagnostic des défauts, tant pour les propriétaires que pour les producteurs de transformateurs.

IMPROVING THE RELIABILITY OF DISSOLVED GAS ANALYSIS (DGA) DIAGNOSTICS THROUGH CONSIDERATION OF MEASUREMENT DEVICE UNCERTAINTY

Abstract

During operation, due to an unforeseen circumstance, an in-service transformer could experience some faults, which could be of electrical or thermal origin. Transformers diagnostic and monitoring through Dissolved Gas Analysis (DGA) is an imperative way for sustainable and reliable power distribution. This method is used in the early detection of faults in liquid filled power systems. In this contribution, a novel approach integrating uncertainty into DGA for power transformers is proposed. By modifying traditional empirical methods like the Duval's Triangle and Duval's Pentagon to include uncertainty, this study demonstrates how these modifications affect fault diagnostics. The results indicate that incorporating gas chromatograph's uncertainty enhances diagnostic accuracy for IEC, Rogers, and Doernenburg methods, improving effective fault detection. Additionally, artificial intelligence (AI) models such as Random Forest, MLP, and SVM, trained with probabilities derived from the modified methods, show significant improvements in diagnostic performance. These models demonstrated increased robustness against different levels of uncertainty, achieving 87.76% accuracy for the Random Forest model and 86.73% for the SVM model with a 30% uncertainty level on the IEC TC10 Database. Therefore, the incorporation of the Gas chromatograph's uncertainty in DGA diagnostic methods appear to

be a promising approach to support transformer monitoring and fault diagnostic both for transformer owners and the producer.

Index Terms— Power Transformers, Measurement Uncertainty, Dissolved Gas Analysis (DGA), Fault Diagnostics, Artificial Intelligence (AI).

3.1 INTRODUCTION

Power transformers play a crucial role in the electrical grid by securing efficient energy transmission [160]. Although the insulating oils inside these transformers are meticulously refined by the petroleum industry, the impact of electrical, thermal, and chemical stresses leads to the formation of various decomposition products during service. These impurities reduce the lifespan and service reliability of transformers, raising concerns about the stability and reliability of the electrical grid. The result of degradation leads to the formation of gases, acids, waxes, and other colloidal products in the oil. Incipient electrical and/or thermal failures cause the formation of dissolved gases in the oil, such as hydrogen (H_2), methane (CH_4), ethylene (C_2H_4), acetylene (C_2H_2), and ethane (C_2H_6). Analyzing these gases provides important information about the transformer's condition [32]. Dissolved Gas Analysis (DGA) has been a diagnostic tool for many years [161] and is one of the most widely used methods in recent years [153]. Since the late 1920s, undissolved gases have been employed for protection purposes with the Buchholz relay. Starting in the late 1950s, dissolved gases began to be used for failure detection. By establishing specific relationships between certain gas concentrations in the early 1970s, the influence of liquid volume was eliminated. The ratios used were the ethylene/acetylene ratio as an indicator of electrical failures and the methane/hydrogen ratio as an indicator of thermal failures. A few years later, the first fault code tables were created based on the ratios of different gas concentrations. Since then, various methods have emerged to identify transformer insulation faults based on different gas concentration ratios [4]. These methods include key gas analysis, gas ratio methods, and graphical methods, all collectively

referred to as traditional DGA methods [5], which provides the capability to detect various faults and their severities [162].

However, the accuracy and reliability of these methods can be reduced due to various factors during their use and even during their development, since conventional methods rely on extensive empirical data sets and field observations instead of rigorous theoretical foundations [163]. Among these factors are the stray gassing, the presence of strict limits in diagnostic ratios, fault zones, variability in ratio calculation methods, and fault detection thresholds may lead to ambiguities in the interpretation of results and complexities when using these methods [18]. Besides, the challenges of dissolved gas analysis to "detect" incipient faults and "diagnose" their causes by analyzing "fault gases" is highlighted in [16] as follows: "Many techniques for the detection and measurement of gases have been established. However, it must be recognized that the analysis of these gases and the interpretation of their significance is at this time not a science, but an art subject to variability."

In recent years, the adoption of artificial intelligence (AI) has marked a notable progression in the diagnosis of power transformer faults [7], aiming to address the uncertainty related to the interpretation of DGA results and increase accuracy [164], as demonstrated by numerous studies [12, 20-22]. However, it is necessary to point out that these models are also subject to the impact of measurement uncertainties, which can compromise diagnostic reliability. The use of various measuring devices, each with its own precision and detection threshold [24], further increases the likelihood of errors affecting measurement accuracy.

This introduces significant uncertainty in the training data for machine learning algorithms [130], as gas measurements can be affected by inaccuracies, which can range from 5% to 30% [14], and in some cases, for the worst performing laboratories, it can reach 60% to 65% [10, 23]. Whether for traditional or AI-based methods, accounting for uncertainty is crucial for the reliability of diagnostics and avoiding severe consequences. Studies [13-15, 23] also bring attention to this issue, indicating that it is crucial to ensure the overall accuracy of the DGA monitoring system and assess the potential impact it could have on diagnostic results.

There are only a few studies in the literature that have attempted to address this issue. In study [13], three uncertainty zones are added to the Duval Triangle, accounting for an uncertainty of $\pm 10\%$. An approach using the conditional probability theorem is applied in [155] to determine the likelihood of fault occurrence. Furthermore, study [130] combines the Support Vector Machine (SVM) method with Fuzzy Logic (FL) to generate diagnostic results as probabilities. Other approaches based on fault code optimization and gas limit adjustments are also used [74, 96]. Although these methods have shown good results across different levels of uncertainty, the number of generated points does not sufficiently cover various scenarios for a more accurate and reliable evaluation of uncertainty's impact. Additionally, in some studies, the same degree of uncertainty is applied to all gases, which keeps the gas ratios and their relative percentages constant, thereby masking the actual effect of uncertainty.

This paper addresses this issue by considering the various possible scenarios related to uncertainty. Initially, 12,000 different values are generated for each type of gas in each sample, within the uncertainty interval, to cover various possibilities. The generated points

are then analyzed by a code employing traditional DGA methods selected for this study, to provide the results of each method in the form of probabilities associated with each fault. Subsequently, the impact of different uncertainty levels on the diagnostic reliability of various traditional DGA methods is analyzed. Finally, for the first time, the probabilistic results obtained from these methods are leveraged through two distinct approaches. The first approach merges the probabilistic results by assigning weights to each method, while the second approach employs AI to analyze the features that link uncertainty probabilities with actual fault labels. The IEC TC10 database is utilized in this study to compare and evaluate the performance of AI models trained with fault probabilities and those trained with gas concentrations across different levels of uncertainty, demonstrating that the use of probabilistic results improves accuracy and could potentially eliminate the impact of measurement uncertainties.

3.2 DISSOLVED GAS ANALYSIS METHODS

Although it is widely accepted that an increase in the concentration of dissolved gases is a precursor to local insulation deterioration, there is a divergence of opinions on interpreting the symptoms. The lack of consensus becomes even more evident when trying to identify the precise cause of the phenomenon based on the chemical composition of the dissolved gases. This divergence is reflected in the number of methods developed: from 1970 to 2024, 64 methods have been created [5], of which 27 are graphical methods [88], while the rest are split between key gas methods and gas ratio methods. There is also a significant number of AI methods used for DGA interpretation. The most commonly used in recent years include Multilayer Perceptron Neural Network (MLP), SVM, Decision Tree (DT), and K-

Nearest Neighbor (KNN) [143]. A list of empirical methods proposed from the inception of dissolved gas analysis to the present day can be found in [90, 165] :

Some methods use a combination of different approaches, known as hybrid methods, which have shown good results. The study [147] employs a Naïve Bayes Model to combine the results of four traditional methods, demonstrating a significant improvement in diagnostic accuracy. Meanwhile, study [18] utilizes fifteen traditional gas ratio methods with the k-means clustering algorithm (k-MCA), leveraging the strengths of both approaches. These studies and others have proven that the integration of traditional methods with AI improve both accuracy and reliability. Furthermore, the use of data other than gas concentrations as input for training AI methods has also proven effective. In [12], the centroid coordinates for the two Duval Pentagons were calculated and subsequently used as inputs to train various AI models. The results showed that the Random Forest (RF) model presented the best accuracy and was resistant to uncertainties that may be related to measuring devices. This demonstrates that it is not only important to combine these methods but also to choose the right strategy for doing so. This highlights the importance of selecting the appropriate training data types to improve AI methods.

In this article, five traditional methods and three AI-based methods, among the most commonly adopted in the literature, are used [90, 143], which are presented in Table 16.

Table 16 : Traditional and AI methods used in the Study.

Methods	Type	Symbol
Triangle of Duval 1	Graphical	DTM
Pentagon of Duval 1	Graphical	DPM
Dornenburg Ratio	Ratio	DRM
Rogers Ratio	Ratio	RRM
IEC Ratio	Ratio	IRM
Random Forest	AI	RF
Multilayer Perceptron Neural Network	AI	MLP
Support Vector Machine	AI	SVM

3.3 METHODOLOGY

3.3.1 INTRODUCTION OF UNCERTAINTY BY GENERATION OF POSSIBLE GAS VALUES

Let U_a be the uncertainty of the measuring device stated as a percentage and X_m be the vector that includes the gas measurement. Based on these two parameters, the maximum deviation Δ between the measured value and the real value X_R can be determined by using (3.1):

$$\left\{ \Delta = \frac{U_a \times X_m}{100} \right. \quad (3.1)$$

This enable the determination of the uncertainty interval where the real measured gas value X_R lies. Then, a matrix X_g^j is created to store all the generated values within this uncertainty interval, related to each type of gas, is established. In this matrix, i is corresponds to each gas

needed as input for the methods, and j represents the values generated within the uncertainty interval. This matrix is constructed according to (3.2):

$$X_{gi}^j = \begin{cases} X_{m_i} - \frac{\Delta \times (L_M - j)}{L_M}, & \text{for } j < L_M \\ X_{m_i}, & \text{for } j = L_M \\ X_{m_i} + \frac{\Delta \times (j - L_M)}{L_M}, & \text{for } j > L_M \\ \text{ND}, & \text{for } X_R = \text{ND} \end{cases} \quad (3.2)$$

Where ND (Non-Determined) refers to data points where the gas measurement is indeterminate or missing, n is the total number of points generated, L_M represents half of the total number of points generated, with $L_M = n/2$.

However, as the selected methods depend on ratios calculations, presenting the matrix X_g in its initial order would keep these ratios remain constant, which would hide errors related to measurement. To resolve this limitation, a random function is implemented to shuffle the values in each column, making sure that uncertainties are better reflected in the final results.

3.3.2 INCORPORATING UNCERTAINTIES INTO SELECTED APPROACHES

The selected methods each, require a single sample that contains the necessary gas for fault diagnosis and identification. The types of gases required for each diagnostic method are presented in Table 17.

Table 17: Types of gases required for each method.

Methods	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	CO
DTM	-	+	+	+	-	-
DPM	+	+	+	+	+	-
IRM	+	+	+	+	+	-
RRM	+	+	+	+	+	-
DRM	+	+	+	+	+	+

Note: "+" indicates the gas is required, "-" indicates it is not required.

The generated gas values stored in the matrix Xg , serve as input for each method. Only the required gas types for each method are selected. These gas values are then sequentially injected into each method. The results for each generated value are handled by a counter, which counts the occurrences of each defect type before proceeding to the next generated value. Once all points have been processed, the counted values for each method are recorded in a matrix D_t^L , where t is linked to each defect type that the method can detect, and L denotes the method number, organized as follows: 1 for DTM, 2 for DPM, 3 for IRM, 4 for RRM, and 5 for DRM. Following that, the failure probability related to the uncertainty for each defect type is performed for each method using (3.3), and the result is stored in a vector P_t^L associated with each method. Tables 18 and 19 present the symbols corresponding to each defect type and shows the coding for the results of each method for each identified defect type respectively. Also, Fig. 7 provides an overview of the entire process of calculating defect probabilities from uncertainty.

$$P_t^L(X) = \frac{D_t^L}{n} \times 100 \quad (3.3)$$

Table 18: Definition of defect type symbols.

Fault type	symbols
Partial Discharge	PD
Low Energy Discharge	D ₁
High Energy Discharge	D ₂
Discharge	D
Thermal Fault of low temperature T < 300 °C	T ₁
Thermal Fault of medium temperature 300°C < T < 700 °C	T ₂
Thermal Fault of high temperature T > 700 °C	T ₃
Thermal Fault	T
Mixed Fault	DT
Undetermined	ND
Normal Operation	NM
Impossible Diagnosis	NP
Stray Gassing	S

Table 19: Code associated with defect probabilities by method.

Fault type	Codes associated with each defect based on the methods				
	DTM	DPM	IRM	RRM	DRM
D ₁	P_1^1	P_1^2	P_1^3	-	-
D ₂	P_2^1	P_2^2	P_2^3	-	-
PD	P_3^1	P_3^2	P_3^3	P_3^4	P_3^5
T ₁	P_4^1	P_4^2	P_4^3	P_4^4	-
T ₂	P_5^1	P_5^2	P_5^3	P_5^4	-
T ₃	P_6^1	P_6^2	P_6^3	P_6^4	-
DT	P_7^1	-	-	-	-
S	-	P_7^2	-	-	-
Normal	-	-	-	P_2^4	P_2^5
D	-	-	-	P_1^4	P_1^5
T	-	-	-	-	P_4^5

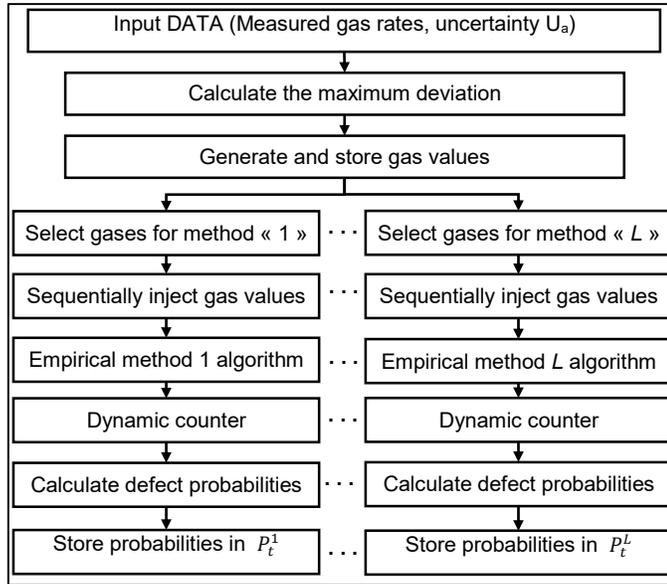


Figure 7 : Diagram of the process for calculating defect probabilities from uncertainty for various DGA methods.

3.3.3 INCORPORATING WEIGHTED FUSION OF DEFECT PROBABILITIES

Once the defect probabilities for each method are calculated, a weighted fusion of these results was performed to determine an overall defect probability for each defect type. To ensure a balanced combination of the probabilities from each method, equal weighting is used. The overall probability $P_{overall}$ for a given defect type is calculated using (3.4).

$$P_{overall} = \frac{1}{N} \sum_{L=1}^N (P_t^L) \quad (3.4)$$

Where P_t^L is the probability determined by method L for defect type t , with N being the total number of methods used.

In this study, only the probabilities from DTM, DPM, and IRM were considered to detect subcategories fault. For the defect category, all five selected methods were used.

3.3.4 APPLICATION OF ARTIFICIAL INTELLIGENCE

Generally, AI-based methods are trained with gas rates that are directly associated with real defect labels. However, this study proposes a new, employing the probabilistic results from each empirical method for the training. Let P_t^L be the matrix containing the probabilistic results associated with each method. These results are transformed to create a matrix Z_β^L , where L is associated with each method, and β with each sample. The size of Z corresponds to the total number of defect types available, noted as A , multiplied by the number of samples. When a defect type is detected by one method but not by another, a probability of 0% is given to that defect. These vectors are then merged to form a matrix T which contains the probabilities of the methods. For this study, only the probabilistic results coming from the DTM and DPM will be used for AI-based methods. In this case, since the methods have some fault that they can detect who are not similar between them, this can cause a problem. The DTM can detect the following defects: T₁, T₂, T₃, D₁, D₂, PD, DT. For the DPM it detects the following defects: T₁, T₂, T₃, D₁, D₂, PD, S. To solve this problem, a matrix Z is created, containing the probabilities of the following defects: [P(T₁), P(T₂), P(T₃), P(D₁), P(D₂), P(PD), P(DT), P(S)]. For the DTM, the vector Z_β^1 is: [P(T₁), P(T₂), P(T₃), P(D₁), P(D₂), P(PD), P(DT), 0%] because it does not detect S. For the DPM, the vector Z_β^2 is: [P(T₁), P(T₂), P(T₃), P(D₁), P(D₂), P(PD), 0%, P(S)] because it does not detect DT.

The training labels is created by using a binary code that will be linked to each type of fault. Suppose the database contains the following fault types: T₁, T₂, T₃, D₁, D₂, PD, DT, S. A unique binary vector is then given to each one of them as illustrated in Table 20. To do prediction on new data the same procedure that was used for the training data creation will be used there. Fig. 8 provides an overview of the entire process.

Table 20: CODE BINARY ENCODING OF FAULT TYPES.

Fault type	Binary Code
D ₁	1 0 0 0 0 0 0 0
D ₂	0 1 0 0 0 0 0 0
PD	0 0 1 0 0 0 0 0
T ₁	0 0 0 1 0 0 0 0
T ₂	0 0 0 0 1 0 0 0
T ₃	0 0 0 0 0 1 0 0
DT	0 0 0 0 0 0 1 0
S	0 0 0 0 0 0 0 1

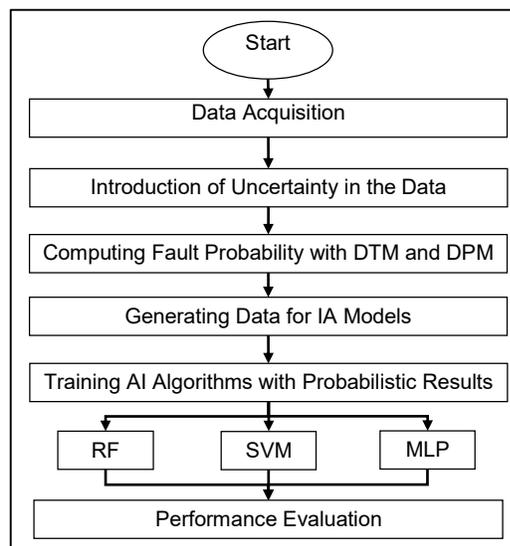


Figure 8: Overview of the Process for AI-based Models Using Probabilistic Results from DGA Methods.

3.4 PERFORMANCE EVALUATION

3.4.1 DATA PRESENTATION

The database used in this study was compiled from various articles and comprises a total of 650 samples. These samples show the dissolved gas rates in oil expressed in parts per million and the real fault associated. However, not all samples will be used. First, the sample representing a normal operation are removed, after that, sample who have missing values are excluded. The number of data used for each method is different.

This difference is caused by the type of fault detectable by the method, and the types of gases required as input for each method. Tables 21 and 22 illustrate, respectively, the number of samples used for each method and associated with each fault type, as well as their relative proportion to the total samples.

Table 21: Number of samples used per method.

Method	PD	D ₁	D ₂	D	T ₁	T ₂	T ₃	T	T ₁ & T ₂	DT	Total
DTM	62	91	131	-	35	44	109	-	47	8	527
DPM	62	89	128	-	35	44	108	-	46	-	512
IRM	57	81	127	-	34	43	107	-	45	-	494
RRM	57	-	127	-	34	43	107	-	45	-	413
DRM	12	109			36					-	157

Table 22: Distribution of fault types in the database.

FAULT TYPES	NUMBER	PERCENTAGE
T	39	6
T ₁	35	5.38
T ₂	44	6.77
T ₃	110	16.92
T ₁ & T ₂	52	8
D	26	4
D ₁	92	14.15
D ₂	131	20.15
PD	68	10.46
DT	7	1.08
NM	46	7.08
TOTAL	650	100

For the data used in AI-based methods, only the sample associated to the fault of types T₁, T₂, T₃, D₁, D₂, PD, and T₁ & T₂ will be used. Since IEC TC 10 database will be used for the test, where T₁ and T₂ faults are grouped under the labels “T₁ & T₂”, the same thing will be done to all the labels associated to the data that will be used for AI-based methods. Furthermore, only samples containing the gas values H₂, CH₄, C₂H₂, C₂H₄, and C₂H₆ will be considered. All the samples that have one of these gases missing will be eliminated. Table 23 shows the distribution of faults in the training and validation dataset, as well as the test dataset that will be used to evaluate the performance of the trained methods.

Table 23: Distribution of fault types in the training, validation, and test database.

Fault Type	Training	Validation	IEC TC10 database
PD	42	11	4
D ₁	51	13	24
D ₂	66	16	45
T ₁ & T ₂	89	23	10
T ₃	74	18	15
Total	322	81	98

3.4.2 UNCERTAINTY PARAMETERS AND RESULTS

VISUALIZATION

To introduce the uncertainty into the analysis, it is essential to know the precision of each measurement apparatus used to measure gas concentrations in the dataset. Unfortunately, the uncertainty is often not reported, and thus, it is not considered. In the IEC-60599 standard, for average gas concentrations, the recommended uncertainty to consider is $\pm 15\%$ for gas concentrations that are 10 times higher than the detection limit of measurement devices. It is emphasized that as the gas concentration approaches this limit, the uncertainty increases. Meanwhile, the IEEE standard recommends achieving accuracies better than $\pm 15\%$ to avoid misidentification of faults. Duval and Durkam, in [23], also note that an uncertainty of $\pm 15\%$ can be considered, representing the average accuracy of CIGRE laboratories. Based on the various recommendations, a measurement uncertainty of $\pm 15\%$ is considered. The number of values created for each gas measurement within its uncertainty interval is 12,000. This choice is made based on the law of large numbers, making certain that the variance of probability estimates will not be significant. The results obtained by each

traditional method are visualized through a graphical interface developed in Python with the Tkinter library, which includes a graphical representation of both the generated points and the measured points, as well as the probabilities associated with each type of fault resulting from the uncertainty.

3.4.3 EVALUATION CRITERIA AND HYPERPARAMETERS

OPTIMIZATION FOR AI METHODS

The performance of the different AI methods is evaluated using classification accuracy on the IEC TC10 dataset, which is widely adopted in various studies for method evaluation. Uncertainty levels ranging from 5% to 30% were applied to assess their impact on the models' reliability and accuracy. Additionally, for AI methods using gas concentrations, 300 simulations are conducted for each uncertainty level. The uncertainty values applied to the test data are randomly selected using Python's random function, allowing for the simulation of various possible scenarios. The mean, maximum, and minimum accuracies from these simulations are then calculated. The validation dataset presented in Table 23 was used through the Grid Search method to determine the optimal hyperparameters for each selected AI method, and the results are illustrated in Table 24.

Table 24 : Optimized hyperparameters for Ai-based methods.

Method	Hyperparameter	Optimized value (probability)	Optimized value (gas rates)
MLP	Hidden layer sizes	[100]	[100, 100]
	Function of activation	Tanh	ReLU
	Solver	Lbfgs	Adam
	Alpha	0.00001	0.0001
	Learning rate	0.0001	0.001
	Validation fraction	0.1	0.2
SVM	C	10	100
	Kernel	Poly	Rbf
	Gamma	0.1	10
	Class weight	None	None
RF	Number of tree	30	7
	max_features	Sqrt	None
	min_samples_split	11	2
	min_samples_leaf	3	2

3.5 RESULTS AND DISCUSSION

3.5.1 IMPACT OF UNCERTAINTY ON FAULT DIAGNOSTICS

The impact of uncertainty on the reliability of the diagnosis is shown in different situations, especially at the boundaries of fault categories. The results obtained from analyzing sample 1 of the Table 25 illustrated in Table 26, highlight this point.

Table 25: Specific selected samples.

Sample number	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	CO	CO ₂	Real fault
1	645	59	317	110	13	74	114	D ₁
2	150	130	30	55	9	120	200	D ₂
3	109	102	0.001	91	28	-	-	T ₃
4	400	940	24	820	210	390	1700	T ₃

Table 26: Cases fault diagnostic results for the selected samples using different traditional methods with the introduction of uncertainty (I.U) and without its introduction (W.I).

Sample number	DTM	DPM		IRM			RRM		DRM	
	I.U (%)	W.I	I.U (%)	W.I	I.U (%)	W.I	I.U (%)	W.I	I.U (%)	W.I
1	D ₁ = 56.9 D ₂ = 43.1	D ₁	D ₁ = 100	D ₁	D ₁ =25 ND=75	ND	D ₂ =15.4 ND=84.6	ND	NM = 100	NM
2	D ₁ =9 D ₂ =66.88 DT=24.12	D ₂	S=1.25 D ₁ =0.03 D ₂ =18.12 T ₁ =39.87 T ₃ =40.71	T ₃	D ₂ =20.32 ND=79.68	ND	D ₂ =86.53 ND=13.47	D ₂	NM= 100	NM
3	T ₂ =80.9 T ₃ =19.1	T ₂	T ₃ =100	T ₃	ND=69.7 T ₂ =28.65 T ₃ =1.65	ND	ND=50.8 T ₃ =22.1 T ₂ =8.2 T ₁ =18.9	ND	NP	NP
4	T ₂ =89.9 T ₃ =10.1	T ₂	T ₂ =31.61 T ₃ =68.39	T ₃	T ₂ =57.01 T ₃ =42.99	T ₂	T ₃ =99.27 T ₂ =0.73	T ₃	T=100	T

The original point of the fault is situated near the limit between fault of type D₁ and D₂ for DTM. In this situation, as illustrated in Fig. 9, despite the presence of a low uncertainty of 5%, the results obtained indicate that there are two possible defects, with a probability of 70.4% given to D₁ and 29.6% to D₂. For a 30% uncertainty, the ambiguity increases, and identifying the fault becomes impossible. Conversely, when the fault point is far from the boundaries, the results obtained with the DPM for the same sample show that the majority of the points generated in the uncertainty interval indicate a high probability of a D₁ fault. Even when increasing the uncertainty to 50 %, the probability associated to D₁ remains low, as shown in Fig. 10. This confirms that when the original point is far from the boundaries of the fault, the diagnosis obtained is not impacted by the uncertainty.

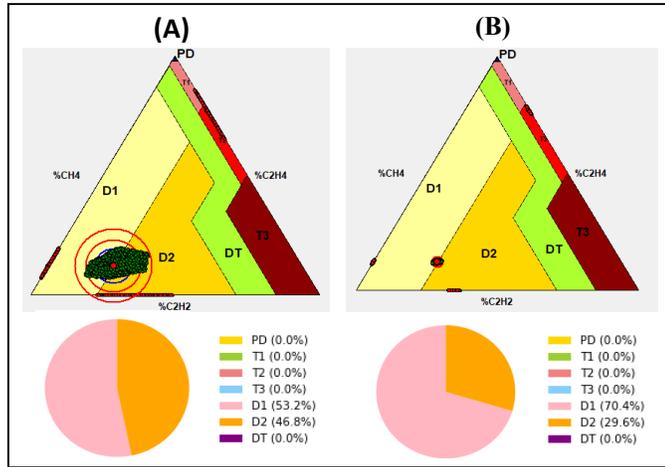


Figure 9 : Impact of uncertainty on results near fault boundaries. (A) Uncertainty of 30%, (B) Uncertainty of 5%.

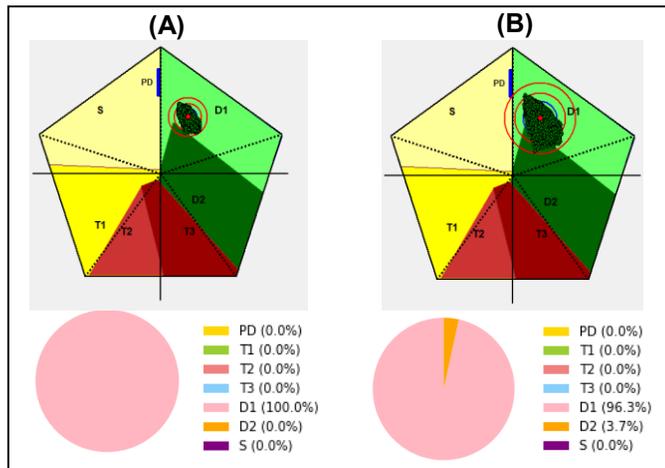


Figure 10 : Impact of uncertainty on results far from fault boundaries. (A) Uncertainty of 30%, (B) Uncertainty of 50%.

3.5.2 IMPACT OF INTRODUCING UNCERTAINTY IN EACH METHOD

The impact of introducing uncertainty in the different selected methods is illustrated in Table 27, where is observed that this impact is different for each method. This Table shows

the detection accuracy of DGA methods after introducing uncertainty. Detection (+) is associated with situations where this introduction has led to the apparition of probability between 10% to 50 % of the real fault that initially is not detected by the method. Detection (-) is linked to cases where methods have identified the real fault correctly, but after introducing the uncertainty, a probability between 10% to 50% is given to a false fault.

Table 27: Comparison of the detection accuracy for DGA methods after the introduction of uncertainty.

Methods	DTM	DPM	IRM	RRM	DRM
Detection +	37 %	47 %	70 %	62 %	61 %
Detection -	63 %	53 %	30 %	38 %	39 %

The results demonstrate that for DTM and DPM, the introduction of uncertainty has led to an increase in the diagnostic error. The presence of alternative faults that were not actually reel was observed in 63% and 53% of cases analyzed respectively by DTM and DPM. While, for IRM, RRM, and DRM, the introduction of uncertainty has led to improving the accuracy of these methods with positive detection probability of 70 %, 62%, and 61% respectively for each one of them. Furthermore, a deep analysis was conducted on the 494 samples that were given to the IRM and RRM, both without and with the introduction of uncertainty. Initially, 140 of those samples were not determined for IRM and 126 for RRM. However, after the introduction of uncertainty, some of those results changed and became usable. As illustrated in Table 28. These results show that after introducing uncertainty and generating 12,000 potential values of gas for every gas type in each sample, 12,000 potential combinations of ratios were created instead of being limited to the initial ratio. This allows

for a broader exploration of possible diagnostics, helping to exit the undetermined zone of these methods and provide a diagnostic result that would otherwise escape detection.

Table 28 : Impact of introducing uncertainty on undetermined diagnostics.

Method	Initial Undetermined Total	Results with Uncertainty	Correct results	Incorrect results
IRM	140	53	27	26
RRM	126	34	23	11

3.5.3 IMPACT OF USING COMBINED RESULTS FROM MULTIPLE METHODS WITH UNCERTAINTY ON FAULT DIAGNOSIS

The impact of using combined results from each method can be observed when introducing uncertainty and weighting the results obtained from the methods. For sample 4 in Table 26, initially, two methods indicated T₃ faults and two others indicated T₂ faults; therefore, a final decision could not be made. After weighing the different probability results, it was observed that the highest probability is given to a T₃ fault with 55.1%, which is the actual fault. The same scenario is illustrated with sample 3, where the probability results for each method are distributed between faults of types T₂ and T₃. In such cases, the precise determination of the fault type is complex, but by using more complementary methods like the Duval Triangle 5, which distinguishes between faults of type T₃ and T₂, the results show that all the points of fault generated fall within the zone of T₃ fault, as shown in Fig.11. It is therefore possible to conclude a T₃ fault. Furthermore, the introduction of uncertainty in this scenario with the Duval Triangle 5 reveals potential signs of paper carbonization that would

not be detected without this introduction. Another example is the case of sample 2, where the initial diagnosis indicated a D_2 fault with DTM and a T_3 fault according to DPM. However, these results cannot be taken into consideration due to the initial fault position being near the boundaries. The introduction of uncertainty reveals additional fault possibilities, indicating DT and D_1 for DTM and D_2 , T_1 for DPM, as shown in Table 26.

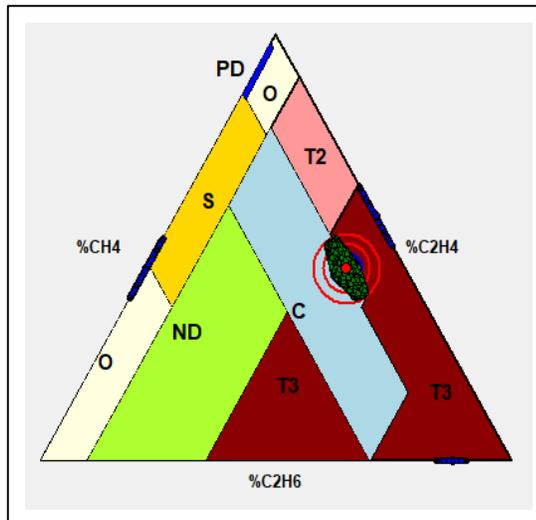


Figure 11 : Complementary Results for Sample 3 Diagnosis.

However, after integrating the results from the RRM and IRM methods, which indicate a high probability for a D_2 fault, the real fault is detected with high probability, significantly reducing the ambiguity of the diagnosis. To illustrate the advantages of using combined methods, Table 29 presents a comparison between the DTM, DPM, IRM, and the new approach of Weighted Method Fusion with Uncertainty (FPMI).

Table 29 : Comparison of accuracy between DTM, DPM, IRM, AND FPMI.

Method	D_1		D_2		PD		T_1		T_2		T_3		$T_1 \& T_2$		Total	
	CA	Nb	CA	Nb	CA	Nb	CA	Nb	CA	Nb	CA	Nb	CA	Nb	CA	Nb
DTM	59.32	55	88.63	89	50	21	36.84	16	36.84	39	86.66	87	39.024	39	68.2	346

DPM	59.32	55	79.06	89	34.61	21	42.1	16	50	39	85.39	87	26.82	39	66.18	346
IRM	68.51	55	29.41	89	68.42	21	68.75	16	84.21	39	79.069	87	48.71	39	61.27	346
FPMI	67.27	55	79.77	89	61.9	21	62.5	16	53.84	39	87.35	87	25.64	39	68.78	346

Note: Nb: Number of data; CA: classification accuracy in %.

Additionally, Table 30 compares the detection accuracy rates between the new approach and the DRM. Table 29 shows a slight increase in the accuracy of the FPMI method. It is important to note that this approach also allows for the consideration of various probabilities associated with uncertainty, which offers a broader and more accurate fault analysis. The results illustrated in Table 30 demonstrate a high accuracy in fault category detection with the FPMI method. An improvement of 36% in accuracy is observed for the same samples that were analyzed using the DRM.

Table 30 : Comparison of fault category detection accuracy between the combined approach (FPMI) and DRM.

Method	D		T		PD		Total	
	CA	Nb	CA	Nb	CA	Nb	CA	Nb
DRM	44.57%	83	72.91%	48	14.28%	7	52.89%	138
FPMI	87.95%	83	89.65%	48	42.85%	7	88.65%	138
	87.5%	248	90.1%	273	37.09%	62	88.86%	583

Note: Nb: Number of data; CA: classification accuracy in %.

3.5.4 IMPACT OF USING PROBABILISTIC DATA DERIVED FROM UNCERTAINTY IN TRAINING AI BASED METHODS

The performance of RF, MLP, and SVM models trained with gas rates and those trained with fault probabilities is compared in this section. The accuracy results on the training and validation sets are presented in Table 31 for AI models. Fig.12 shows the

accuracy of models trained with probabilities (PR), as well as the maximum, minimum, and average accuracy obtained from 300 simulations for models trained with gas concentrations (GC), performed at different levels of uncertainty on the IEC TC10 database. Finally, Table 32 presents the difference between the maximum and minimum accuracy obtained for models trained with GC across different levels of uncertainty.

Table 31 : Model accuracy on the training and validation datasets.

Dataset	RF		MLP		SVM	
	GR	PR	GR	PR	GR	PR
Training (%)	92.32	78.88	68.32	81.99	81.99	71.43
Validation (%)	69.13	70.37	65.43	65.43	66.67	66.67

Table 32 : MAX-MIN accuracy difference across 300 simulation at different levels of uncertainty.

Uncertainty (%)	5	10	15	20	25	30
RF-GR	7.14	8.16	10.20	11.22	11.22	15.30
MLP-GR	5.10	6.12	8.17	9.19	10.21	14.29
SVM-GR	4.08	6.12	8.16	10.20	10.20	13.27

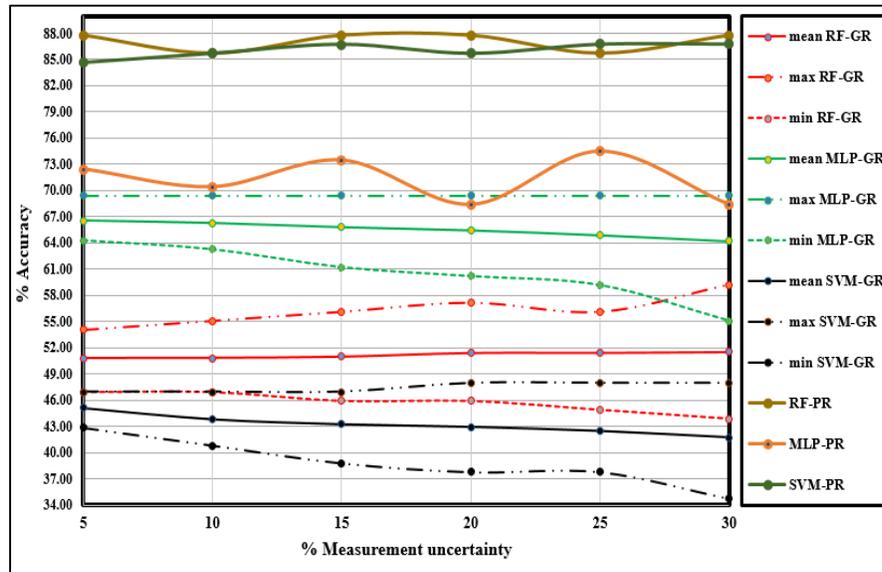


Figure 12: Model Performance on IEC TC10 Database across different Levels of Uncertainty.

For the training dataset, the RF and SVM models trained with GC demonstrated the best results, achieving classification accuracies of 92.32% and 81.99%, respectively. However, for the MLP model, the version trained with PR data outperformed the one trained with GC. For the validation data, the MLP and SVM models, whether trained with GC or PR, showed the same accuracy. The difference between the RF-PR and RF-GR models was negligible. However, when applied to the IEC TC10 dataset, the RF-PR and SVM-PR models achieved the best results. For uncertainties ranging from 5% to 30%, the accuracy for the RF-PR model fluctuated between 85.71% and 87.76%, while for the SVM-PR model, it ranged from 84.69% to 86.73%. In contrast, the MLP-PR model exhibited greater amplitude in its oscillations and lower accuracy, with classification accuracies ranging between 68.37% and 74.49%. For models trained with GC, the accuracy varied across the 300 simulations. The average accuracy for the MLP-GR and SVM-GR models started at 66.54% and 45.10% with 5% uncertainty, decreasing to 64.21% and 41.76%, respectively, as uncertainty increased to

30%. Moreover, the results in Table 32 show that the gap between the maximum and minimum classification accuracies increases as the level of uncertainty rises.

These findings indicate that using GC in AI methods makes the models sensitive to uncertainties. In contrast, the RF-PR and SVM-PR models demonstrated strong resilience to uncertainty. This is likely due to the fact that all possible scenarios were considered, and these models were trained using probabilities derived after introducing 15% uncertainty, a value that is considered the average measurement uncertainty across laboratories according to several standards.

3.6 CONCLUSION

This article introduces a novel approach integrating uncertainty into dissolved gas analysis (DGA), leveraging probabilistic outcomes to enhance the diagnostic reliability of power transformers. The impact of uncertainty on various traditional DGA models was examined in this paper through a different approach, using uniform discretization to generate 12,000 possible scenarios for each sample. This allowed for a thorough analysis of uncertainty impacts, confirming that the proximity of the original fault point to fault boundaries significantly amplifies the effect of uncertainty, leading to a higher likelihood of erroneous results as the uncertainty percentage increases. Furthermore, the incorporation of uncertainty has been demonstrated to confer significant advantages in ratio method such as IEC. Analysis of samples processed using these methods illustrates that integrating uncertainty transforms initially indeterminate diagnoses into actionable insights.

Furthermore, the integration of results from various diagnostic methods, accounting for uncertainty, diminishes ambiguity and enhances diagnostic accuracy. This synergistic approach markedly augments the precision of fault category diagnoses, evidencing a 36% improvement over the Dornenburg method. Finally, using probabilities derived from traditional methods with Random Forest and Support Vector Machine allowed to account for a significant number of possible scenarios related to uncertainty. This enhances the models' ability to withstand measurement uncertainty across different levels, while demonstrating good generalization to new data and maintaining high accuracy. Additionally, this paper introduces a more suitable methodology for analyzing the impact of uncertainties on AI methods trained with gas concentrations, which can also be applied to gas ratios, relative percentages, and other similar input data.

CHAPITRE 4

CONCLUSION GÉNÉRALE ET RECOMMANDATIONS

4.1 CONCLUSION

Le diagnostic et la surveillance des transformateurs de puissance immergés sont essentiels pour garantir la continuité et la qualité du transport d'énergie électrique. L'une des méthodes de diagnostic les plus utilisées et adoptées par les différentes compagnies est basée sur les techniques d'analyse des gaz dissous (DGA) traditionnelles. Cependant, ces méthodes présentent plusieurs limitations, et leur fiabilité est sujette à divers facteurs, dont l'incertitude liée aux appareils de mesure, ce qui réduit leur fiabilité. C'est pourquoi le développement d'outils de diagnostic visant à pallier ces limitations et à diminuer l'effet de ces facteurs est essentiel.

Dans cette étude, un nouvel outil de diagnostic DGA, dont la fiabilité est améliorée grâce à la prise en compte des incertitudes liées aux appareils de mesure, a été développé.

L'utilisation de cet outil a permis de conclure :

1. L'introduction de l'incertitude dans les méthodes DGA basées sur les ratios de gaz permet de transformer des résultats initialement non déterminés en des résultats exploitables, améliorant ainsi considérablement leur précision.

2. La fiabilité d'un diagnostic issu des méthodes DGA traditionnelles dépend essentiellement de la proximité du point d'origine du défaut par rapport aux frontières des autres défauts, ainsi que du niveau d'incertitude.

En outre, en utilisant à la fois des méthodes avancées d'intelligence artificielle (IA) et des méthodes DGA traditionnelles, le nouveau modèle hybride développé présente une robustesse accrue face aux incertitudes liées aux appareils de mesure, tout en offrant une précision acceptable pour des niveaux d'incertitude allant jusqu'à $\pm 30\%$. Il a été conclu que l'utilisation de l'IA, en particulier le modèle de forêt aléatoire et le modèle de machine à vecteurs de support, pour extraire les différentes caractéristiques présentes dans les données probabilistes issues des méthodes DGA traditionnelles après l'introduction de l'incertitude, améliore significativement la précision, la généralisation et la fiabilité de ces modèles, ainsi que leur robustesse face aux incertitudes.

Cette étude présente un intérêt évident pour les compagnies de production, de transport et de distribution de l'énergie électrique, en incorporant une nouvelle approche dans le développement des diagnostics basés sur la DGA. Cette recherche ouvre de nouvelles perspectives pour de futures études, visant à améliorer davantage les méthodes de diagnostic DGA tout en prenant en compte les incertitudes liées aux appareils de mesure.

4.2 RECOMMANDATIONS

Le nouveau modèle développé a permis d'améliorer significativement la fiabilité des diagnostics. Cependant, seules trois méthodes d'intelligence artificielle (IA) et deux méthodes d'analyse des gaz dissous (DGA) traditionnelles ont été utilisées. De plus, la modélisation des différents scénarios liés à l'incertitude des appareils de mesure a été réalisée en utilisant uniquement la méthode de la discrétisation uniforme.

Pour les études futures, il serait pertinent d'explorer les différentes approches pour modéliser les scénarios d'incertitude, telles que l'utilisation de distributions statistiques variées pour générer les points représentant les différentes valeurs possibles des concentrations de gaz dissous à partir des valeurs mesurées.

Bien que le nombre de méthodes DGA traditionnelles développées jusqu'à présent dépasse les 60, seules cinq d'entre elles ont été étudiées dans ce projet. Il serait donc important d'analyser l'incidence de l'introduction de l'incertitude sur un plus grand nombre de méthodes.

L'outil de diagnostic développé exploite exclusivement les résultats probabilistes issus de deux méthodes graphiques traditionnelles DGA, combinés à un seul modèle d'IA à la fois. Il serait intéressant, dans les travaux futurs, de tirer parti d'un plus large éventail de résultats probabilistes issus de diverses méthodes DGA traditionnelles et les combiner avec différents

types d'entrées, telles que les concentrations de gaz, les ratios de gaz et les proportions relatives associées à chaque gaz. De plus, la sélection des entrées les plus pertinentes pour chaque modèle d'IA pourrait être optimisée à l'aide d'algorithmes avancés, tels que la Programmation Génétique ou l'Optimisation par Essaims Particulaires. En outre, il serait utile d'explorer des méthodes de combinaison des résultats de différentes approches d'IA, comme la théorie de Dempster Shafer.

Enfin, une base de données plus étendue, constituée d'un plus grand nombre d'échantillons DGA, pourrait être utilisée pour approfondir l'évaluation des performances de l'outil de diagnostics développé.

RÉFÉRENCES

- [1] L. Loïselle, I. Fofana, J. Sabau, S. Magdaleno-Adame, and J. C. Olivares-Galvan, "Comparative studies of the stability of various fluids under electrical discharge and thermal stresses," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 22, no. 5, pp. 2491-2499, 2015.
- [2] A. R. Abbasi, "Fault detection and diagnosis in power transformers: a comprehensive review and classification of publications and methods," *Electric Power Systems Research*, vol. 209, p. 107990, 2022.
- [3] L. S. Oumert, A. Boucherit, A. H. Z. Zafour, and I. Fofana, "Comparative study of the degradation rate of new and regenerated mineral oils following electrical stress," *IET Generation, Transmission & Distribution*, vol. 12, no. 21, pp. 5891-5897, 2018.
- [4] I. Fofana, "The gassing of insulating fluids," in *2021 International Conference on Electrical Materials and Power Equipment (ICEMPE)*, 2021: IEEE, pp. 1-8.
- [5] A. Nanfak, E. Samuel, I. Fofana, F. Meghnefi, M. G. Ngaleu, and C. Hubert Kom, "Traditional fault diagnosis methods for mineral oil-immersed power transformer based on dissolved gas analysis: Past, present and future," *IET Nanodielectrics*, 2024.
- [6] N. A. Bakar, A. Abu-Siada, and S. Islam, "A review of dissolved gas analysis measurement and interpretation techniques," *IEEE Electrical Insulation Magazine*, vol. 30, no. 3, pp. 39-49, 2014.
- [7] J. Li, C. Hai, Z. Feng, and G. Li, "A transformer fault diagnosis method based on parameters optimization of hybrid kernel extreme learning machine," *IEEE Access*, vol. 9, pp. 126891-126902, 2021.
- [8] J. Jiang, R. Chen, M. Chen, W. Wang, and C. Zhang, "Dynamic fault prediction of power transformers based on hidden Markov model of dissolved gases analysis," *IEEE Transactions on Power Delivery*, vol. 34, no. 4, pp. 1393-1400, 2019.
- [9] Z. Yang, W. Tang, A. Shintemirov, and Q. Wu, "Association rule mining-based dissolved gas analysis for fault diagnosis of power transformers," *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 39, no. 6, pp. 597-610, 2009.
- [10] "IEEE Guide for the Interpretation of Gases Generated in Mineral Oil-Immersed Transformers," IEEE Std C57.104-2019, 1 Nov. 2019.
- [11] A. Hechifa *et al.*, "Improved intelligent methods for power transformer fault diagnosis based on tree ensemble learning and multiple feature vector analysis," *Electrical Engineering*, pp. 1-20, 2023.

- [12] R. A. Prasajo *et al.*, "Precise transformer fault diagnosis via random forest model enhanced by synthetic minority over-sampling technique," *Electric Power Systems Research*, vol. 220, p. 109361, 2023.
- [13] C. Wei, H. Long, and L. Yan, "Investigate transformer fault diagnosis performance of dissolved gas analysis with measurement error," *Electric Power Components and Systems*, vol. 45, no. 8, pp. 894-904, 2017.
- [14] B. Stewart and J. Aizpurua, "Uncertainty analysis of two gas measurement DGA ratios for improved diagnostics applications," in *2022 IEEE International Conference on High Voltage Engineering and Applications (ICHVE)*, 2022: IEEE, pp. 1-4.
- [15] T. McGrail, "DGA monitor accuracy–Data and decisions," *Transformers Magazine*, vol. 10, no. 4, pp. 34-38, 2023.
- [16] "IEEE Guide for Acceptance and Maintenance of Insulating Mineral Oil in Electrical Equipment," IEEE Std C57.106-2015, 23 March 2016. [Online]. Available: <https://ieeexplore.ieee.org/stampPDF/getPDF.jsp?tp=&arnumber=7442048&ref=>
- [17] S. A. Wani, A. S. Rana, S. Sohail, O. Rahman, S. Parveen, and S. A. Khan, "Advances in DGA based condition monitoring of transformers: A review," *Renewable and Sustainable Energy Reviews*, vol. 149, p. 111347, 2021.
- [18] A. Nanfak, S. Eke, F. Meghnefi, I. Fofana, G. M. Ngaleu, and C. H. Kom, "Hybrid DGA method for power transformer faults diagnosis based on evolutionary k-means clustering and dissolved gas subsets analysis," *IEEE Transactions on Dielectrics and Electrical Insulation*, 2023.
- [19] Z. Liu, W. He, H. Liu, L. Luo, D. Zhang, and B. Niu, "Fault identification for power transformer based on dissolved gas in oil data using sparse convolutional neural networks," *IET Generation, Transmission & Distribution*, 2023.
- [20] H. Zheng and R. Shioya, "A comparison between artificial intelligence method and standard diagnosis methods for power transformer dissolved gas analysis using two public databases," *IEEJ Transactions on Electrical and Electronic Engineering*, vol. 15, no. 9, pp. 1305-1311, 2020.
- [21] X. Han, S. Huang, X. Zhang, Y. Zhu, G. An, and Z. Du, "A transformer condition recognition method based on dissolved gas analysis features selection and multiple models fusion," *Engineering Applications of Artificial Intelligence*, vol. 123, p. 106518, 2023.
- [22] F. Jiao, Z. Ma, Q. Chen, F. Zhang, and D. Zhao, "A Causal Reasoning Approach for Power Transformer Failure Diagnosis," *Frontiers in Energy Research*, vol. 12, p. 1340421.
- [23] M. Duval and J. Dukarm, "Improving the reliability of transformer gas-in-oil diagnosis," *IEEE Electrical Insulation Magazine*, vol. 21, no. 4, pp. 21-27, 2005.

- [24] S. Bustamante, M. Manana, A. Arroyo, P. Castro, A. Laso, and R. Martinez, "Dissolved gas analysis equipment for online monitoring of transformer oil: A review," *Sensors*, vol. 19, no. 19, p. 4057, 2019.
- [25] J. Schübel, "Dissolved gas analysis: Early fault indication and trend analysis," *Transformers Magazine*, vol. 10, no. 1, pp. 89-95, 2023.
- [26] E. Moradi, "A Data-Driven based Robust Multilayer Perceptron Approach for Fault Diagnosis of Power Transformers," in *2024 20th CSI International Symposium on Artificial Intelligence and Signal Processing (AISP)*, 2024: IEEE, pp. 1-5.
- [27] X. Shi, T. Li, F. Fang, Y. Zhu, W. Yang, and B. Luo, "Dissolved Gas Analysis for Power Transformer Fault Diagnosis Combining Domain Knowledge and Capsule Network," *IEEE Transactions on Dielectrics and Electrical Insulation*, 2024.
- [28] D. Saravanan, A. Hasan, A. Singh, H. Mansoor, and R. N. Shaw, "Fault prediction of transformer using machine learning and DGA," in *2020 IEEE international conference on computing, power and communication technologies (GUCON)*, 2020: IEEE, pp. 1-5.
- [29] I. Fofana, "50 years in the development of insulating liquids," *IEEE Electrical Insulation Magazine*, vol. 29, no. 5, pp. 13-25, 2013.
- [30] J. C. da Silva, "Analysis of the application of Insulating Vegetable Oil in electric power distribution transformers," *Academic Journal on Computing, Engineering and Applied Mathematics*, vol. 1, no. 3, pp. 1-10, 2020.
- [31] V. Mentlik, R. Polansky, and P. Prosr, "Influence of temperature aging on oxidation stability and activation energy of insulating liquids," in *2008 Annual Report Conference on Electrical Insulation and Dielectric Phenomena*, 2008: IEEE, pp. 52-55.
- [32] S. Li, G. Wu, B. Gao, C. Hao, D. Xin, and X. Yin, "Interpretation of DGA for transformer fault diagnosis with complementary SaE-ELM and arctangent transform," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 23, no. 1, pp. 586-595, 2016.
- [33] D. Paul, P. Sen, and A. K. Goswami, "A probabilistic approach of fault detection through dissolved gas analysis in transformer and reactor," in *2020 IEEE International Conference on Power Electronics, Smart Grid and Renewable Energy (PESGRE2020)*, 2020: IEEE, pp. 1-6.
- [34] M. Meira, C. Verucchi, R. Álvarez, and L. Catalano, "Dissolved gas analysis in mineral oil and natural ester liquids from thermal faults," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 28, no. 4, pp. 1317-1325, 2021.

- [35] I. Fofana, A. Bouaïcha, M. Farzaneh, C. Volat, and J. Sabau, "On the stability of mineral insulating oils under electrical stress," in *2009 IEEE Electrical Insulation Conference*, 2009: IEEE, pp. 482-486.
- [36] N. Lelekakis, D. Martin, W. Guo, and J. Wijaya, "Comparison of dissolved gas-in-oil analysis methods using a dissolved gas-in-oil standard," *IEEE Electrical Insulation Magazine*, vol. 27, no. 5, pp. 29-35, 2011.
- [37] T. C. IEEE Power & Energy Society, "IEEE Guide for Loading Mineral-Oil-Immersed Transformers and Step-Voltage Regulators," USA, IEEE Std C57.91-2011, 2012.
- [38] A. A. Adekunle, S. O. Oparanti, and I. Fofana, "Performance assessment of cellulose paper impregnated in nanofluid for power transformer insulation application: A review," *Energies*, vol. 16, no. 4, p. 2002, 2023.
- [39] M. M. Araujo, O. M. Almeida, F. R. Barbosa, and A. G. Menezes, "Enhancing gas formation theory assessment in power transformers by using decision tree transparency and new guess into decomposition temperatures of insulating mineral oil," *Neural Computing and Applications*, vol. 36, no. 7, pp. 3259-3266, 2024.
- [40] S. A. Ward *et al.*, "Towards precise interpretation of oil transformers via novel combined techniques based on DGA and partial discharge sensors," *Sensors*, vol. 21, no. 6, p. 2223, 2021.
- [41] J. Golarz, "Understanding dissolved gas analysis (DGA) techniques and interpretations," in *2016 IEEE/PES Transmission and Distribution Conference and Exposition (T&D)*, 2016: IEEE, pp. 1-5.
- [42] S. Singh and M. Bandyopadhyay, "Dissolved gas analysis technique for incipient fault diagnosis in power transformers: A bibliographic survey," *IEEE Electrical insulation magazine*, vol. 26, no. 6, pp. 41-46, 2010.
- [43] O. E. Gouda, S. H. El-Hoshy, and H. H. EL-Tamaly, "Condition assessment of power transformers based on dissolved gas analysis," *IET Generation, Transmission & Distribution*, vol. 13, no. 12, pp. 2299-2310, 2019.
- [44] C. T. Force, "Ageing of cellulose in mineral-oil insulated transformers," in *CIGRE: Paris, France, 2007*.
- [45] V. Arakelian, "Effective diagnostics for oil-filled equipment," *IEEE Electrical Insulation Magazine*, vol. 18, no. 6, pp. 26-38, 2002.
- [46] S. S. Dessouky, A. E. Kalas, R. Abd El-Aal, and A. M. M. Hassan, "Study and examination of transformer oil while exposed to air during operation," in *2017 Nineteenth International Middle East Power Systems Conference (MEPCON)*, 2017: IEEE, pp. 445-450.

- [47] R. A. Prasajo, K. Diwyacitta, and H. Gumilang, "Correlation of transformer paper deterioration to oil characteristics and dissolved gases," in *2017 International Conference on High Voltage Engineering and Power Systems (ICHVEPS)*, 2017: IEEE, pp. 40-45.
- [48] K. Diwyacitta, R. A. Prasajo, and H. Gumilang, "Effects of lifetime and loading factor on dissolved gases in power transformers," in *2017 International Conference on Electrical Engineering and Computer Science (ICECOS)*, 2017: IEEE, pp. 243-247.
- [49] L. R. Lewand, "Practical experience gained from furanic compound analysis," in *Proceedings of the 73rd Annual International Doble Client Conference, Boston, MA, USA*, 2006, pp. 8-14.
- [50] I. Höhlelein-Atanasova and R. Frotscher, "Carbon oxides in the interpretation of dissolved gas analysis in transformers and tap changers," *IEEE Electrical Insulation Magazine*, vol. 26, no. 6, pp. 22-26, 2010.
- [51] R. Soni and B. Mehta, "Review on asset management of power transformer by diagnosing incipient faults and faults identification using various testing methodologies," *Engineering Failure Analysis*, vol. 128, p. 105634, 2021.
- [52] J. A. Gomez, "Experimental investigations on the dissolved gas analysis method (DGA) through simulation of electrical and thermal faults in transformer oil," *Essen: Universidad de Duisburg-Essen*, 2014.
- [53] A. J. Amalanathan, R. Sarathi, M. Zdanowski, R. Vinu, and Z. Nadolny, "Review on gassing tendency of different insulating fluids towards transformer applications," *Energies*, vol. 16, no. 1, p. 488, 2023.
- [54] J. Scheirs, G. Camino, W. Tumiatti, and M. Avidano, "Study of the mechanism of thermal degradation of cellulosic paper insulation in electrical transformer oil," *Die Angewandte Makromolekulare Chemie*, vol. 259, no. 1, pp. 19-24, 1998.
- [55] K. S. Kassi, I. Fofana, F. Meghnefi, and Z. Yéo, "Impact of local overheating on conventional and hybrid insulations for power transformers," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 22, no. 5, pp. 2543-2553, 2015.
- [56] R. Krishnan and K. Nair, "Review of the Monitoring Diagnostic Methods of Oil Immersed Transformers," *Int. J. Eng. Res. Technol*, vol. 7, pp. 304-310, 2018.
- [57] L. Loisel, U. M. Rao, and I. Fofana, "Influence of aging on oil degradation and gassing tendency for mineral oil and synthetic ester under low energy discharge electrical faults," *Energies*, vol. 13, no. 3, p. 595, 2020.
- [58] I. E. C. (IEC). "Mineral oil-filled electrical equipment in service - Guidance on the interpretation of dissolved and free gases analysis," Geneva, Switzerland., IEC 60599:2022-05, 2022.

- [59] G. S. Sarma, R. Reddy, P. M. Nirgude, and V. Naidu, "A review on real time fault detection and intelligent health monitoring techniques of transformer," *International Journal of Engineering Research and Applications*, vol. 11, pp. 40-47, 2021.
- [60] J. Faiz and M. Soleimani, "Dissolved gas analysis evaluation in electric power transformers using conventional methods a review," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 24, no. 2, pp. 1239-1248, 2017.
- [61] A. Vatsa, A. S. Hati, and A. K. Rathore, "Enhancing Transformer Health Monitoring With AI-Driven Prognostic Diagnosis Trends: Overcoming Traditional Methodology's Computational Limitations," *IEEE Industrial Electronics Magazine*, 2023.
- [62] K. Chatterjee, S. Dawn, V. K. Jadoun, and R. Jarial, "Novel prediction-reliability based graphical DGA technique using multi-layer perceptron network & gas ratio combination algorithm," *IET Science, Measurement & Technology*, vol. 13, no. 6, pp. 836-842, 2019.
- [63] S. Ranjan, P. L. Narayana, and M. Kirar, "Dissolved Gas Analysis based Incipient Fault Diagnosis of Transformer: A Review," *Impending Power Demand and Innovative Energy Paths-ISBN: 978-93-83083-84*, vol. 8, 2015.
- [64] H.-C. Sun, Y.-C. Huang, and C.-M. Huang, "A review of dissolved gas analysis in power transformers," *Energy Procedia*, vol. 14, pp. 1220-1225, 2012.
- [65] C. Sun, P. R. Ohodnicki, and E. M. Stewart, "Chemical sensing strategies for real-time monitoring of transformer oil: A review," *IEEE Sensors Journal*, vol. 17, no. 18, pp. 5786-5806, 2017.
- [66] N. J. Lybeck, V. Agarwal, B. T. Pham, H. D. Medema, and K. Fitzgerald, "Online monitoring technical basis and analysis framework for large power transformers; Interim report for FY 2012," Idaho National Lab.(INL), Idaho Falls, ID (United States), 2012.
- [67] L. Loisel, U. Mohan Rao, and I. Fofana, "Gassing tendency of fresh and aged mineral oil and ester fluids under electrical and thermal fault conditions," *Energies*, vol. 13, no. 13, p. 3472, 2020.
- [68] Z. Ayalew, K. Kobayashi, S. Matsumoto, and M. Kato, "Dissolved gas analysis (DGA) of arc discharge fault in transformer insulation oils (ester and mineral oils)," in *2018 IEEE Electrical Insulation Conference (EIC)*, 2018: IEEE, pp. 150-153.
- [69] M. M. Modi and R. A. Patel, "Intelligent approach to interpret incipient faults of power transformer from DGA database," *Journal of The Institution of Engineers (India): Series B*, vol. 104, no. 4, pp. 869-876, 2023.

- [70] O. Kherif, Y. Benmahamed, M. Tegar, A. Boubakeur, and S. S. Ghoneim, "Accuracy improvement of power transformer faults diagnostic using KNN classifier with decision tree principle," *IEEE Access*, vol. 9, pp. 81693-81701, 2021.
- [71] S. Genc and S. Karagol, "Fuzzy logic application in DGA methods to classify fault type in power transformer," in *2020 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA)*, 2020: IEEE, pp. 1-4.
- [72] C. Sun, Y. Chen, and N. Tang, "Fault diagnosis of power transformer based on DGA and information fusion," in *2022 IEEE/IAS Industrial and Commercial Power System Asia (I&CPS Asia)*, 2022: IEEE, pp. 247-251.
- [73] G. Karthigaiselvi and B. Vigneshwaran, "Recognition of Type of Faults in Power Transformer Using Dissolved Gas Analysis," in *2024 Third International Conference on Intelligent Techniques in Control, Optimization and Signal Processing (INCOS)*, 2024: IEEE, pp. 1-5.
- [74] S. S. Ghoneim, K. Mahmoud, M. Lehtonen, and M. M. Darwish, "Enhancing diagnostic accuracy of transformer faults using teaching-learning-based optimization," *Ieee Access*, vol. 9, pp. 30817-30832, 2021.
- [75] Z. Wang, X. Yi, X. Wang, S. Li, J. V. Hinshaw, and J. Noakhes, "Comparison between online and laboratory measurements of fault gases for mineral oil and natural ester," *International Journal on Electrical Engineering and Informatics*, vol. 5, no. 2, p. 173, 2013.
- [76] M. M. Emara, G. D. Peppas, and I. F. Gonos, "Two graphical shapes based on DGA for power transformer fault types discrimination," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 28, no. 3, pp. 981-987, 2021.
- [77] M. Meira, I. Carlucho, R. Álvarez, L. Catalano, and G. Acosta, "DGA: A novel strategy for key gases identification in power transformers," in *2020 IEEE Electrical Insulation Conference (EIC)*, 2020: IEEE, pp. 290-293.
- [78] Y. Zhang, Y. Tang, Y. Liu, and Z. Liang, "Fault diagnosis of transformer using artificial intelligence: A review," *Frontiers in Energy Research*, vol. 10, p. 1006474, 2022.
- [79] A. R. Hussein, A. M. Dakhil, J. R. Rashed, and M. Othman, "Intelligent expert system for diagnosing faults and assessing quality of power transformer insulation oil by DGA method," *Misan Journal of Engineering Sciences*, vol. 1, no. 1, pp. 47-57, 2022.
- [80] I. B. Taha, S. Ibrahim, and D.-E. A. Mansour, "Power transformer fault diagnosis based on DGA using a convolutional neural network with noise in measurements," *IEEE Access*, vol. 9, pp. 111162-111170, 2021.
- [81] C.-h. Ge, H.-y. Cui, S.-j. Huo, W.-c. Guo, H.-w. Ma, and L.-m. Qin, "Improved DGA methods of power transformer fault diagnosis: a review," in *2018 7th International*

Conference on Energy and Environmental Protection (ICEEP 2018), 2018: Atlantis Press, pp. 1765-1768.

- [82] J. J. Dukarm, "Transformer oil diagnosis using fuzzy logic and neural networks," in *Proceedings of Canadian Conference on Electrical and Computer Engineering*, 1993: IEEE, pp. 329-332.
- [83] L. Wang, T. Littler, and X. Liu, "Hybrid AI model for power transformer assessment using imbalanced DGA datasets," *IET Renewable Power Generation*, vol. 17, no. 8, pp. 1912-1922, 2023.
- [84] J. Li, Q. Zhang, K. Wang, J. Wang, T. Zhou, and Y. Zhang, "Optimal dissolved gas ratios selected by genetic algorithm for power transformer fault diagnosis based on support vector machine," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 23, no. 2, pp. 1198-1206, 2016.
- [85] S. Yu, W. Tan, C. Zhang, Y. Fang, C. Tang, and D. Hu, "Research on hybrid feature selection method of power transformer based on fuzzy information entropy," *Advanced Engineering Informatics*, vol. 50, p. 101433, 2021.
- [86] I. B. Taha and D. Mansour, "Novel power transformer fault diagnosis using optimized machine learning methods," *Intelligent Automation & Soft Computing*, vol. 28, no. 3, pp. 739-752, 2021.
- [87] I. FOFANA and J. S. N'CHO, "Liquides isolants en électrotechnique - Caractérisation et propriétés," *Techniques de l'ingénieur*, vol. 1, 2024, doi: <https://doi.org/10.51257/a-v1-d2473>.
- [88] S. Bustamante, M. Manana, A. Arroyo, A. Laso, and R. Martinez, "Evolution of graphical methods for the identification of insulation faults in oil-immersed power transformers: A review," *Renewable and Sustainable Energy Reviews*, vol. 199, p. 114473, 2024.
- [89] N. Verma and A. K. Chandel, "Incipient Fault Diagnosis of Power Transformer Based on Duval Pentagon Using Medium Neural Network," in *2022 1st International Conference on Sustainable Technology for Power and Energy Systems (STPES)*, 2022: IEEE, pp. 1-5.
- [90] J. S. N'cho, I. Fofana, Y. Hadjadj, and A. Beroual, "Review of physicochemical-based diagnostic techniques for assessing insulation condition in aged transformers," *Energies*, vol. 9, no. 5, p. 367, 2016.
- [91] M. S. Katooli and A. Koochaki, "Detection and classification of incipient faults in three-phase power transformer using DGA information and rule-based machine learning method," *Journal of Control, Automation and Electrical Systems*, vol. 31, no. 5, pp. 1251-1266, 2020.

- [92] Y. Benmahamed, M. Tegar, and A. Boubakeur, "Application of SVM and KNN to Duval Pentagon 1 for transformer oil diagnosis," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 24, no. 6, pp. 3443-3451, 2017.
- [93] S. Kim, J. Park, W. Kim, S.-H. Jo, and B. D. Youn, "Learning from even a weak teacher: Bridging rule-based Duval method and a deep neural network for power transformer fault diagnosis," *International Journal of Electrical Power & Energy Systems*, vol. 136, p. 107619, 2022.
- [94] W. Deng, W. Xiong, Z. Lu, X. Yuan, C. Zhang, and L. Wang, "Few-Shot power transformers fault diagnosis based on Gaussian prototype network," *International Journal of Electrical Power & Energy Systems*, vol. 160, p. 110146, 2024.
- [95] D. Zou *et al.*, "Transformer fault classification for diagnosis based on DGA and deep belief network," *Energy Reports*, vol. 9, pp. 250-256, 2023.
- [96] A. Hoballah, D.-E. A. Mansour, and I. B. Taha, "Hybrid grey wolf optimizer for transformer fault diagnosis using dissolved gases considering uncertainty in measurements," *Ieee Access*, vol. 8, pp. 139176-139187, 2020.
- [97] T. Kari *et al.*, "An integrated method of ANFIS and Dempster-Shafer theory for fault diagnosis of power transformer," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 25, no. 1, pp. 360-371, 2018.
- [98] N. Haque, A. Jamshed, K. Chatterjee, and S. Chatterjee, "Accurate sensing of power transformer faults from dissolved gas data using random forest classifier aided by data clustering method," *IEEE Sensors Journal*, vol. 22, no. 6, pp. 5902-5910, 2022.
- [99] A.-M. Aciu, S. Enache, and M.-C. Nițu, "A Reviewed Turn at of Methods for Determining the Type of Fault in Power Transformers Based on Dissolved Gas Analysis," *Energies*, vol. 17, no. 10, p. 2331, 2024.
- [100] A. Nanfak, S. Eke, C. H. Kom, R. Mouangue, and I. Fofana, "Interpreting dissolved gases in transformer oil: A new method based on the analysis of labelled fault data," *IET Generation, Transmission & Distribution*, vol. 15, no. 21, pp. 3032-3047, 2021.
- [101] B. Fallou, F. Viale, I. Davies, R. Rogers, and E. Dornenburg, "Application of physico-chemical methods of analysis to the study of deterioration in the insulation of electrical apparatus," in *Cigre Session*, 1970, pp. 15-07.
- [102] A. Rangel Bessa, J. Farias Fardin, P. Marques Ciarelli, and L. Frizera Encarnação, "Conventional dissolved gases analysis in power transformers," *Energies*, vol. 16, no. 21, p. 7219, 2023.
- [103] E. Dornenburg and W. Strittmatter, "Monitoring oil-cooled transformers by gas-analysis," *Brown Boveri Review*, vol. 61, no. 5, pp. 238-247, 1974.

- [104] B. Barraclough, E. Bayley, I. Davies, K. Robinson, R. Rogers, and E. Shanks, "CEGB experience of the analysis of dissolved gas in transformer oil for the detection of incipient faults," in *IEE Conference Publication*, 1973, no. 94.
- [105] R. Rogers, "UK experiences in the interpretation of incipient faults in power transformers by dissolved gas-in-oil chromatography analysis (a progress report)," in *Minutes of Forty-Second International Conference of Doble Clients*, 1975, pp. 10-201.
- [106] D. Yang, J. Qin, Y. Pang, and T. Huang, "A novel double-stacked autoencoder for power transformers DGA signals with an imbalanced data structure," *IEEE Transactions on Industrial Electronics*, vol. 69, no. 2, pp. 1977-1987, 2021.
- [107] X. Wang *et al.*, "Power Transformer Defect Prediction Method Based on SMOTE and Random Forest Algorithm," in *2022 IEEE International Conference on High Voltage Engineering and Applications (ICHVE)*, 2022: IEEE, pp. 1-4.
- [108] A. R. Hussein, M. Yaacob, and M. A. Alsaedi, "Faults diagnosis and assessment of transformer insulation oil quality: intelligent methods based on dissolved gas analysis a-review," *International Journal of Engineering & Technology*, vol. 4, no. 1, p. 54, 2015.
- [109] E. T. Mharakurwa, "In-Service Power Transformer Life Time Prospects: Review and Prospects," *Journal of Electrical and Computer Engineering*, vol. 2022, no. 1, p. 9519032, 2022.
- [110] I. IEC, "599-Interpretation of the Analysis of Gases in Transformer and Other Oil-Filled Electrical Equipment in Service," *International Electro-technical Commission, Geneva, Switzerland*, 1978.
- [111] O. E. Gouda, S. H. El-Hoshy, and H. H. El-Tamaly, "Proposed heptagon graph for DGA interpretation of oil transformers," *IET Generation, Transmission & Distribution*, vol. 12, no. 2, pp. 490-498, 2018.
- [112] A.-M. Aciu, S. Enache, and M.-C. Nițu, "A Reviewed Turn at of Methods for Determining the Type of Fault in Power Transformers Based on Dissolved Gas Analysis," *Energies*, vol. 17, no. 10, 2024, doi: 10.3390/en17102331.
- [113] A. Nanfak, A. Hechifa, S. Eke, A. Lakehal, C. H. Kom, and S. S. Ghoneim, "A combined technique for power transformer fault diagnosis based on k-means clustering and support vector machine," *IET Nanodielectrics*, 2024.
- [114] S. Sreelakshmi, L. Tharamal, and P. Preetha, "Maximum Likelihood Classification for Transformer Fault Diagnosis Using Dissolved Gas Analysis," in *2021 IEEE Electrical Insulation Conference (EIC)*, 2021: IEEE, pp. 381-384.
- [115] M. Bandyopadhyay, "A review on transformer diagnostics," in *Proceedings of the 37th Annual North American Power Symposium, 2005.*, 2005: IEEE, pp. 304-309.

- [116] M. Duval and J. Buchacz, "Gas formation from arcing faults in transformers—Part II," *IEEE Electrical Insulation Magazine*, vol. 38, no. 6, pp. 12-15, 2022.
- [117] A. Akbari, A. Setayeshmehr, H. Borsi, and E. Gockenbach, "A software implementation of the Duval Triangle method," in *Conference record of the 2008 IEEE international symposium on electrical insulation*, 2008: IEEE, pp. 124-127.
- [118] V. Cheemala, A. N. Asokan, and P. Preetha, "Transformer incipient fault diagnosis using machine learning classifiers," in *2019 IEEE 4th International Conference on Condition Assessment Techniques in Electrical Systems (CATCON)*, 2019: IEEE, pp. 1-6.
- [119] M. S. Taneja, K. Pandey, and S. Sehrawat, "A review on prognosis and diagnosis of transformer oil quality using intelligent techniques based on dissolved gas analysis," in *2016 7th India International Conference on Power Electronics (IICPE)*, 2016: IEEE, pp. 1-6.
- [120] Z. Shen, F. Wang, Z. Wang, and J. Li, "A critical review of plant-based insulating fluids for transformer: 30-year development," *Renewable and Sustainable Energy Reviews*, vol. 141, p. 110783, 2021.
- [121] K. Chatterjee, V. K. Jadoun, and R. Jarial, "DGA Techniques: Recent Advancements," *Cellulose*, vol. 2, p. C2H6, 2017.
- [122] M. Duval, "The duval triangle for load tap changers, non-mineral oils and low temperature faults in transformers," *IEEE Electrical Insulation Magazine*, vol. 24, no. 6, pp. 22-29, 2008.
- [123] M. Duval and L. Lamarre, "The duval pentagon—a new complementary tool for the interpretation of dissolved gas analysis in transformers," *IEEE Electrical Insulation Magazine*, vol. 30, no. 6, pp. 9-12, 2014.
- [124] X. Ding, E. Yao, Y. Liu, and P. Griffin, "ANN based transformer fault diagnosis using gas-in-oil analysis," 1995: American Power Conference, Chicago, IL (United States).
- [125] H.-T. Yang and Y.-C. Huang, "Intelligent decision support for diagnosis of incipient transformer faults using self-organizing polynomial networks," in *Proceedings of the 20th International Conference on Power Industry Computer Applications*, 1997: IEEE, pp. 60-66.
- [126] K. Thang, R. Aggarwal, D. Esp, and A. McGrail, "Statistical and neural network analysis of dissolved gases in power transformers," in *2000 Eighth International Conference on Dielectric Materials, Measurements and Applications (IEE Conf. Publ. No. 473)*, 2000: IET, pp. 324-329.

- [127] N. N. Ravi, S. M. Drus, and P. S. Krishnan, "Data mining techniques for transformer failure prediction model: A systematic literature review," in *2019 IEEE 9th Symposium on Computer Applications & Industrial Electronics (ISCAIE)*, 2019: IEEE, pp. 305-309.
- [128] A. Shintemirov, W. Tang, and Q. Wu, "Power transformer fault classification based on dissolved gas analysis by implementing bootstrap and genetic programming," *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 39, no. 1, pp. 69-79, 2008.
- [129] S. M. de Andrade Lopes, R. A. Flauzino, and R. A. C. Altafim, "Incipient fault diagnosis in power transformers by data-driven models with over-sampled dataset," *Electric Power Systems Research*, vol. 201, p. 107519, 2021.
- [130] H. Ma, C. Ekanayake, and T. K. Saha, "Power transformer fault diagnosis under measurement originated uncertainties," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 19, no. 6, pp. 1982-1990, 2012.
- [131] K. Meng, Z. Y. Dong, D. H. Wang, and K. P. Wong, "A self-adaptive RBF neural network classifier for transformer fault analysis," *IEEE Transactions on Power Systems*, vol. 25, no. 3, pp. 1350-1360, 2010.
- [132] M. Zhang and W. Chen, "Fault diagnosis of power transformer based on SSA—MDS pretreatment," *IEEE Access*, vol. 10, pp. 92505-92515, 2022.
- [133] V. Rokani, S. D. Kaminaris, P. Karaisas, and D. Kaminaris, "Power transformer fault diagnosis using neural network optimization techniques," *Mathematics*, vol. 11, no. 22, p. 4693, 2023.
- [134] Z. He, T. Kari, Y. Yaermaimait, L. Du, Y. Zhou, and Z. Liu, "Hybrid Feature Selection Approach for Power Transformer Fault Diagnosis Based on Whale Optimization Algorithm and Extreme Learning Machine," *Progress in Electromagnetics Research C*, vol. 127, 2022.
- [135] S. Misbahulmunir, V. K. Ramachandramurthy, and Y. H. M. Thayoob, "Improved self-organizing map clustering of power transformer dissolved gas analysis using inputs pre-processing," *IEEE Access*, vol. 8, pp. 71798-71811, 2020.
- [136] V. Miranda, A. R. G. Castro, and S. Lima, "Diagnosing faults in power transformers with autoassociative neural networks and mean shift," *IEEE Transactions on Power Delivery*, vol. 27, no. 3, pp. 1350-1357, 2012.
- [137] C.-P. Hung and M.-H. Wang, "Diagnosis of incipient faults in power transformers using CMAC neural network approach," *Electric power systems research*, vol. 71, no. 3, pp. 235-244, 2004.
- [138] Z. Liu, W. He, H. Liu, L. Luo, D. Zhang, and B. Niu, "Fault identification for power transformer based on dissolved gas in oil data using sparse convolutional neural

- networks," *IET Generation, Transmission & Distribution*, vol. 18, no. 3, pp. 517-529, 2024.
- [139] F. D. Samirmi, W. Tang, and H. Wu, "Feature selection in power transformer fault diagnosis based on dissolved gas analysis," in *IEEE PES ISGT Europe 2013*, 2013: IEEE, pp. 1-5.
- [140] M.-T. Yang and L.-S. Hu, "Intelligent fault types diagnostic system for dissolved gas analysis of oil-immersed power transformer," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 20, no. 6, pp. 2317-2324, 2013.
- [141] H. Shang, J. Xu, Z. Zheng, B. Qi, and L. Zhang, "A novel fault diagnosis method for power transformer based on dissolved gas analysis using hypersphere multiclass support vector machine and improved D-S evidence theory," *Energies*, vol. 12, no. 20, p. 4017, 2019.
- [142] T. Kari *et al.*, "Hybrid feature selection approach for power transformer fault diagnosis based on support vector machine and genetic algorithm," *IET Generation, Transmission & Distribution*, vol. 12, no. 21, pp. 5672-5680, 2018.
- [143] M. Demirci, M. Saka, H. Gözde, and M. Taplamacıoğlu, "Fault Analysis with Data Pre-Processing Methods in Power Transformers," *Turkish Journal of Electrical Power and Energy Systems*, vol. 3, no. 3, 2023.
- [144] H. Ma, T. K. Saha, and C. Ekanayake, "Power transformer insulation diagnosis under measurement originated uncertainties," in *IEEE PES General Meeting*, 2010: IEEE, pp. 1-8.
- [145] Y. Hua, Y. Sun, G. Xu, S. Sun, E. Wang, and Y. Pang, "A fault diagnostic method for oil-immersed transformer based on multiple probabilistic output algorithms and improved DS evidence theory," *International Journal of Electrical Power & Energy Systems*, vol. 137, p. 107828, 2022.
- [146] S. A. Khan, M. D. Equbal, and T. Islam, "A comprehensive comparative study of DGA based transformer fault diagnosis using fuzzy logic and ANFIS models," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 22, no. 1, pp. 590-596, 2015.
- [147] R. A. Prasojo, H. F. W. Azizi, I. Kurniawan, H. Sutikno, and I. Ridzki, "Naïve Bayes Model for Combining Results from Multi-Methods Fault Identification of Power Transformer," in *2023 4th International Conference on High Voltage Engineering and Power Systems (ICHVEPS)*, 2023: IEEE, pp. 199-203.
- [148] S.-A. Ahmadi and M. Sanaye-Pasand, "A robust multi-layer framework for online condition assessment of power transformers," *IEEE Transactions on Power Delivery*, vol. 37, no. 2, pp. 947-954, 2021.

- [149] A. International, "ASTM D7150-13 - Standard Test Method for the Determination of Gassing Characteristics of Insulating Liquids Under Thermal Stress," ASTM International, West Conshohocken, PA, 2020.
- [150] M. Duval and T. Heizmann, "Identification of stray gassing of inhibited and uninhibited mineral oils in transformers," *Energies*, vol. 13, no. 15, p. 3886, 2020.
- [151] T. Buchacz, J. Buchacz, and M. Duval, "Stray gassing of oil in HV transformers," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 28, no. 5, pp. 1729-1734, 2021.
- [152] T. Piotrowski, P. Rozga, and R. Kozak, "Analysis of excessive hydrogen generation in transformers in service," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 22, no. 6, pp. 3600-3607, 2015.
- [153] S. Eeckhoudt, S. Autru, and L. Lerat, "Stray gassing of transformer insulating oils: impact of materials, oxygen content, additives, incubation time and temperature, and its relationship to oxidation stability," *IEEE Electrical Insulation Magazine*, vol. 33, no. 6, pp. 27-32, 2017.
- [154] F. Scatiggio, M. Pompili, and R. Bartnikas, "Effects of metal deactivator concentration upon the gassing characteristics of transformer oils," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 18, no. 3, pp. 701-706, 2011.
- [155] I. B. Taha, D. E. A. Mansour, S. S. Ghoneim, and N. I. Elkalashy, "Conditional probability-based interpretation of dissolved gas analysis for transformer incipient faults," *IET Generation, Transmission & Distribution*, vol. 11, no. 4, pp. 943-951, 2017.
- [156] J. Aragon-Patil, M. Fischer, Z. Wang, and I. H. Atanasova, "Investigation on Sampling, Measurement and Interpretation of Gas-in-Oil Analysis for Power Transformers S. Tenbohlen."
- [157] I. Bpm, I. Ifcc, and I. IUPAC, "OIML. Guide to the Expression of Uncertainty in Measurement," *International Organization for Standardization, Geneva, Switzerland*, vol. 1, 1995.
- [158] G. ISO, "ISO/IEC GUIDE 98-3: 2008, Guide to the expression of uncertainty in measurement," *International Organisation for Standardisation, Geneva, Switzerland*, 2008.
- [159] I. ISO. and B. OIML, *Guide to the Expression of Uncertainty in Measurement*. Aenor, 1993.
- [160] S. O. Oparanti, U. M. Rao, and I. Fofana, "Natural Esters for Green Transformers: Challenges and Keys for Improved Serviceability," *Energies*, vol. 16, no. 1, p. 61, 2022.

- [161] S. Kim, H. Seo, and J. Jung, "Advanced dissolved gas analysis method with stray gassing diagnosis," in *2016 International Conference on Condition Monitoring and Diagnosis (CMD)*, 2016: IEEE, pp. 522-525.
- [162] M. Chakraborty, N. Baruah, R. Sangineni, S. K. Nayak, and P. K. Maiti, "Dissolved gas analysis (DGA) of thermally aged blended transformer oil," in *2020 IEEE Conference on Electrical Insulation and Dielectric Phenomena (CEIDP)*, 2020: IEEE, pp. 204-207.
- [163] K. N. Rajesh, U. M. Rao, I. Fofana, P. Rozga, and A. Paramane, "Influence of data balancing on transformer DGA fault classification with machine learning algorithms," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 30, no. 1, pp. 385-392, 2022.
- [164] A. A. Pollok, R. Frotscher, M. Foata, and M. Dolles, "A New Approach for AI-Based DGA for Transformers and Tap-Changers," in *2023 IEEE Electrical Insulation Conference (EIC)*, 2023: IEEE, pp. 1-5.
- [165] L. Lewand, "Techniques for Interpretation of Data for DGA from Transformers," in *Proceedings of IEEE/PES Transformers Committee Meeting, Montreal, QC, Canada*, 2006, vol. 26.