

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



Université Kasdi Merbah Ouargla
Faculté des Sciences Appliquées
Département de Génie électrique



THÈSE

Présentée pour l'obtention du diplôme de
DOCTORAT en SCIENCES
Spécialité : Génie électrique

Par : **BELKEBIR Amel**

Thème

Etude d'un isolateur à haute tension par l'intelligence artificielle

Soutenu le 28/10/2023 devant le jury composé de :

Dr. BENYOUSSEF Elakhdar	PRESIDENT	MCA	Univ Ouargla
Pr. AZOUI Boubekeur	EXAMINATEUR	PROF	Univ Batna
Pr. BENSALÉM Ahmed	EXAMINATEUR	PROF	Univ Batna
Dr. BENBOUZA Naima	EXAMINATRICE	MCA	Univ Ouargla
Dr. BOUREK Yacine	Directeur De Thèse	MCA	Univ Ouargla
Dr. BENGUESMIA Hani	Co-Directeur De Thèse	MCA	Univ Msila

Remerciements

Je tiens ,tout d'abord, à remercier le bon Dieu ,le Tout Puissant qui m' a donné le courage, la patience, la force et la sérénité ainsi que la volonté d'accomplir ce modeste travail tout au long de ces années d'études.

Je tiens tout particulièrement à remercier Monsieur **Yacine BOUREK**, Maître de conférences à l'Université de Ouargla, ainsi que mon directeur de thèse, de m'avoir guidé tout au long de ce travail. Je suis extrêmement reconnaissante envers mon co-encadreur, **Hani BENGUESMIA**, Maître de conférences à l'Université de Msila, pour son soutien inestimable et son encadrement exceptionnel. J'ai vraiment eu le grand plaisir de travailler sous sa direction pour réaliser cette thèse de Doctorat. Je lui exprime ma profonde gratitude et mon respect sincère pour son dévouement.

En outre, je souhaite exprimer ma profonde reconnaissance envers le président du jury, Monsieur **Elakhdar BENYOUSSEF**, Maître de conférences à l'Université de Ouargla. Mes remerciements s'adressent également à Monsieur **Boubekeur AZOUI**, professeur à l'Université de Batna2, à Monsieur **Ahmed BENSALEM**, professeur à l'Université de Batna2, et à Madame **Naima BENBOUZA**, Maître de conférences à l'Université de Ouargla, d'avoir accepté de participer au jury de cette thèse et de m'accorder cet honneur.

Je souhaite exprimer ma gratitude à toutes les personnes qui ont contribué directement ou indirectement au développement de ce travail, notamment mes sœurs **Assia** et **Hanane**, ainsi que ma collègue **Naima**. Je remercie également mes collègues du département de génie électrique de l'Université Kasdi Merbeh-Ouargla surtout Monsieur **Mohamed Lakhdar LOUAZENE** pour leur soutien.

Enfin, je suis profondément reconnaissante envers mes chers parents, mes sœurs et mon frère, qui m'ont offert l'opportunité de poursuivre mes études avec succès et m'ont constamment encouragé tout au long de ce parcours. Leur soutien inconditionnel a été essentiel pour mener ce travail à son terme. Je tiens à leur exprimer ici ma gratitude.

إهداء

أهدي هذا العمل المتواضع الى

تزهو به الدنيا وتتجلي الاحزان

الى اغلى حبيب واروع انسان

امي ينبوع الرحمة والحنان

الى اصدق ما نطق به اللسان

- امي -

الى من شق من أنفاسه طريقا لبلوغ منايا الى من عق هواه راحة لنفسي وطاعة لهوايا

الى أبي اسمى لفضة نطقت بها شفتايا الا لكل زينته ووالديا زينة دنيايا

- ابي -

فإنكما في الدنيا الاسم المخلد

والديا اذا ذكر اللسان اسماء مخلدة

تخر لفضلكما النفس وتسجد

واذا ذكر اللسان عظماء الخلق

الى أخي عبد الرزاق وزوجته إسمهان وأولاده: أيمن و إيناس وسلسبيل

الى أختي صمرة وزوجها خليفة وأولادها: آية وعلاء وعبد الرحمان

الى أختي حنان وزوجها حلیم

الى أختي صبرينة وزوجها هشام وأولادها: رونق وأسيل ورهف

الى أختي اسيا وزوجها جلال

أمال بلکبير

المخلص

تهدف هذه الدراسة إلى استخدام طرق الذكاء الاصطناعي في توقع الجهد الفائق لعازل عالي الجهد ملوث اصطناعيا

تم إجراء اختبارات عملية على عازل من نوع 175 لجمع قاعدة بيانات تستخدم في تطبيق طرق الذكاء الاصطناعي. في هذه الاختبارات، تم توزيع كمية محددة من محلول ملحي على ثلاث مناطق في العازل، ثم تم تطبيق جهد معين على العازل. فحدثت ظاهرة القوس الكهربائي ومن ثم الإحاطة من خلال هذه التجارب، تم استخلاص قاعدة بيانات تحتوي على ناقلية العازل وكمية التلوث في كل منطقة، بالإضافة إلى جهد الإحاطة. تم استخدام هذه البيانات لتطبيق طرق الذكاء الاصطناعي المتمثلة في الشبكات العصبية، الاستدلال الضبابي، نظام الاستدلال الضبابي الغامض المتكيف، والطرق الهجينة المعتمدة على الشبكات العصبية وسرب الجسيمات، بالإضافة إلى الشبكات العصبية والبحث كوكو.

أظهرت النتائج المحصل عليها باستخدام طرق الذكاء الاصطناعي فعاليتها في التنبؤ بجهد الإحاطة في العوازل عالية التوتر مقارنةً بالنتائج التجريبية التي تم الحصول عليها في المختبر. تم استخدام عدة مؤشرات لتقييم أداء الطرق المستخدمة وإثبات دقتها، مثل متوسط الخطأ التريعي وجذر متوسط الخطأ المطلق ومعامل التحديد.

تفتح هذه النتائج الباب أمام استخدام الذكاء الاصطناعي في توقع الجهد الفائق للعوازل عالية الجهد، مما يوفر مزايا كبيرة من حيث الكفاءة مقارنةً بالنهج التقليدي المستند إلى الاختبارات العملية.

تسلط هذه الدراسة الضوء على إمكانيات الذكاء الاصطناعي لتحسين أداء وسلامة الأنظمة الكهربائية عالية الجهد من خلال التنبؤ الدقيق بحدوث ظاهرة الإحاطة وتلف العوازل، وبالتالي المساهمة في منع حدوث الأعطال والحوادث

الكلمات المفتاحية : إحاطة عوازل ملوثة ،تلوث اصطناعي، الذكاء الاصطناعي، تقنيات الذكاء الاصطناعي

، تقنيات التحسين ، التلوث، الجهد العالي ، بحث كوكو

Résumé

Dans cette étude, notre objectif est de prédire la tension de contournement (U_c) d'un isolateur de haute tension contaminé de manière artificielle en utilisant des techniques d'intelligence artificielle (IA). Pour atteindre cet objectif, des tests pratiques ont été réalisés sur un isolateur de type 175CTV en appliquant différentes quantités de pollution artificielle sous forme de solution saline, ce qui a permis de constituer une base de données pour l'élaboration des modèles d'IA.

La base de données collectée comprend les valeurs de U_c associées à différentes quantités de pollution artificielle dans chaque zone de l'isolateur, ainsi que leur conductivité. Par la suite, plusieurs approches d'intelligence artificielle ont été utilisées pour estimer de U_c . Ces approches comprennent l'utilisation de réseaux de neurones artificiels (ANN), de systèmes d'inférence floue (FIS) et de deux approches hybrides prédictives : le système d'inférence neuro--floue adaptatif (ANFIS) et une approche combinant les réseaux de neurones avec des techniques d'optimisation telles que les essaims de particules (PSO) et la recherche du coucou (CS).

Les résultats obtenus à partir des différentes méthodes d'intelligence artificielle ont démontré leur efficacité dans la prédiction de U_c . Les critères de validation tels que l'erreur absolue moyenne en pourcentage (MAPE), la racine carrée de l'erreur quadratique moyenne (RMSE) et le coefficient de détermination (R^2) ont été utilisés pour évaluer les performances des méthodes d'IA. Ces méthodes offrent des avantages significatifs en termes d'efficacité et de fiabilité par rapport aux méthodes traditionnelles basées sur les tests pratiques.

Mots-Clés : Contournement des isolateurs pollués, Pollution artificielle, Intelligence artificielle, ANN, ANFIS, FIS, CS, PSO, Pollution, Haute tension, Recherche du coucou.

Abstract

In this study, our objective is to predict the flashover voltage (U_c) of an artificially contaminated high-voltage insulator using artificial intelligence (AI) techniques. To achieve this goal, practical tests were conducted on a 175CTV type insulator by applying different amounts of artificial pollution in the form of saline solution, which resulted in a database for the development of AI models.

The collected database includes U_c values associated with different amounts of artificial pollution in each zone of the insulator, as well as their conductivity. Subsequently, several AI approaches were employed to estimate U_c . These approaches include the use of artificial neural networks (ANN), fuzzy inference systems (FIS), and two predictive hybrid approaches: adaptive neuro-fuzzy inference system (ANFIS) and an approach combining neural networks with optimization techniques such as particle swarm optimization (PSO) and cuckoo search (CS).

The results obtained from the different AI methods demonstrated their effectiveness in predicting U_c . Validation criteria such as mean absolute percentage error (MAPE), root mean square error (RMSE), and coefficient of determination (R^2) were used to evaluate the performance of the AI methods. These methods offer significant advantages in terms of efficiency and reliability compared to traditional methods based on practical tests.

Keywords: flashover, Artificial pollution, Artificial intelligence, ANN, ANFIS, FIS, CS, PSO, Pollution, High voltage, Cuckoo search.



Notion & Symbole

Liste des abréviations et des symboles

CA	Courant alternatif
CC	Courant continu
IA	Intelligence artificielle
ANN	Artificial Neural Networks (Réseaux de neurones artificiels)
FIS	Fuzzy Inference System (système d'inférence flou)
ANFIS	Adaptive Neuro-Fuzzy Inference System (système d'inférence neuro-flou)
PSO	Particle swarm optimisation (optimisation par essaims de particules)
CS	Cuckoo Search (recherche du coucou)
THz	Terahertz
RMSE	Root Mean Square Error (Racine carrée de l'erreur quadratique moyenne)
R^2	Coefficient of determination (coefficient de détermination)
MAPE	Mean Absolute Percentage Error (L'erreur Moyenne de Pourcentage Absolu)
Trimf	Fonction triangulaire
gaussmf	Fonction gaussienne
gbellmf	Fonction bell-shaped
trapmf	Fonction trapé-zoïdale
δ	Conductivities (mS/cm)
Q_i	Quantité de pollution dans les trois zones de l'isolateur
U_c	Tension de contournement
Z	Zones de pollution
MFs	Membership function (Fonction d'appartenance)
ReLU	Rectified Linear Unit (Unité linéaire redressée)
FFNN	Feed Forward Neural Networks (Réseaux de neurones à propagation avant)
MLPNN	MultiLayers Perceptron Neural Networks (Réseaux de neurones à perceptron multicouche)
CFNN	Cascade-Forward Artificial Neural Networks (Réseaux de neurones artificiels en cascade-avant)
RBF	Radial Basis Function (Fonction de base radiale)
GRNN	General Regression Neural Networks (Réseaux neuronaux de régression générale)



Liste des figures

Liste des figures

N° Figures	Page
Chapitre Un	
Figure 1.1 : Isolateur de H.T	6
Figure 1.2 : Isolateur rigide.....	7
Figure 1.3 : Isolateur capot et tige.....	7
Figure 1.4 : Isolateur long fut.....	8
Figure 1.5 : Isolateur électrique en céramique.....	9
Figure 1.6 : Isolateur électrique en verre.....	9
Figure 1.7 : Isolateur électrique en matériaux synthétiques.....	10
Figure 1.8 : Pollution des isolateurs.....	11
Figure 1.9 : Contournement des isolateurs de haute tension.....	14
Figure 1.10 : Processus de contournement des isolateurs pollués.....	15
Figure 1.11 : Revêtements hydrophobe.....	17
Figure 1.12 : Configuration expérimentale à la fréquence industrielle.....	18
Figure 1.13 : Isolant en verre de type "Capot-tige" 175CTV.....	19
Chapitre deux	
Figure 2.1 : L'architecture d'un neurone artificiel	26
Figure 2.2 : Réseau de neurones récurrent.....	28
Figure 2.3 : Réseau de neurones non bouclés.....	28
Figure 2.4 : Apprentissage supervisé.....	29
Figure 2.5 : Apprentissage non-supervisé.....	30
Figure 2.6 : Planification de conception d'un réseau de neurones.....	31
Figure 2.7 : Perceptrons multicouches.....	32
Figure 2.8 : Réseaux de propagation avant	33
Figure 2.9 : Réseaux en cascade et à propagation avant.....	33
Figure 2.10 : structure d'un RBF.....	34
Figure 2.11 . Architecture du GRN.....	37
Figure 2.12 : Architecture de MLP.....	37
Figure 2.13 : Interface de sélection du type de réseau dans MATLAB.....	39
Figure 2.14 : Interface pour les réseaux de neurones à propagation avant.....	40
Figure 2.15 : Interface du réseau de neurones en cascade.....	40

Figure 2.16 : Évaluation des performances de l'approche FFANN pour les tests.....	43
Figure 2.17 : Évaluation des performances de l'approche CFANN pour les tests.....	43
Figure 2.18 : Courbes de régression pour la prédiction de U_c par FFANN	44
Figure 2.19 : Courbes de régression pour la prédiction de U_c par CFANN	44
Figure 2.20 : Implémentation de l'architecture du réseau GRNN avec MATLAB.....	45
Figure 2.21 : Évaluation des performances de GRNN pour les tests.....	47
Figure 2.22 : Comparaison entre les valeurs mesurées et les estimations de U_c	47

Chapitre trois

Figure 3.1 : Utilisation des ensembles flous pour caractériser la température d'un corps	52
Figure 3.2 : Diverses formes de fonctions d'appartenance.....	54
Figure 3.3 : Structure interne d'un système flou.....	55
Figure 3.4 : principe de neuro flou.....	60
Figure 3.5 : Structure d'ANFIS	61
Figure 3.6 : Architecture de SIF	65
Figure 3.7 : processus de contournement observé en laboratoire.....	66
Figure 3.8 : Fenêtre principale de l'éditeur de système d'inférence flou sous MATLAB.....	67
Figure 3.9 : Fonction d'appartenance de δ	69
Figure 3.10 : Fonction d'appartenance de U	69
Figure 3.11 : Fonction d'appartenance de Q_1	70
Figure 3.12 : Fonction d'appartenance de Q_2	70
Figure 3.13 : Fonction d'appartenance de Q_3	70
Figure 3.14 : Fonction d'appartenance de la fréquence des couleurs.....	71
Figure 3.15 : Les règles floues utilisées	73
Figure 3.16 : La fenêtre de visualisation des règles d'inférence.....	74
Figure 3.17 : Correspondance entrée-sortie ANFIS	76
Figure 3.18 : Formes des fonctions d'appartenance pour les variables d'entrée	80
Figure 3.19 : La structure du modèle ANFIS sélectionné sous MATLAB.....	80
Figure 3.20 : La performance du modèle ANFIS pour l'entraînement.....	82
Figure 3.21 : Performance du modèle ANFIS pour les tests expérimentaux	83
Figure 3.22 : Similitude entre les valeurs réelles et estimées de U_c pour l'ensemble de test	83

Chapitre quatre

Figure 4.1 Mouvement de chaque particule	87
---	----

Figure 4.2 : Voisinage géographique.....	88
Figure 4.3: Deux cas de voisinage social.....	89
Figure 4.4: Organigramme de l'algorithme de PSO.....	91
Figure 4.5: Oiseau de coucou.....	93
Figure 4.6: Exploration stochastique avec le Vol de Lévy, Marche aléatoire simple.....	94
Figure 4.7: Organigramme de l'algorithme de la recherche coucou	96
Figure 4.8 : Organigramme de ANN-PSO.....	100
Figure 4.9 : Implémentation de l'architecture de ANN-PSO avec MATLAB.....	100
Figure 4.10 : Performance de ANN-PSO en phase d'apprentissage.....	101
Figure 4.11 : Performance de ANN-PSO en phase de test.....	102
Figure 4.12 Courbe de régression pour l'estimation de U_c	103
Figure 4.13 : Organigramme de l'approche hybride ANN-CS.....	105
Figure 4.14 : Performance de ANN-PSO en phase de test.....	106
Figure 4.15 Courbe de régression pour la prédiction de U_c	107

A decorative frame resembling a scroll, with a black outline and rounded corners. The top and bottom edges are slightly curved, and the right edge has a vertical strip that looks like a scroll's edge. The text is centered within this frame.

Liste des tableaux

Liste des Tableau

N° Tableau	Page
Chapitre Un	
Tableau 1.1 : Niveaux de pollution dans les zones des isolateurs	19
Tableau 1.2 Résultats de tests réalisés au laboratoire	21
Chapitre deux	
Tableau 2.1 Évaluation de l'erreur à partir d'une série de tests.....	38
Tableau 2.2 Paramètres de la structure et de l'apprentissage du MLP	39
Tableau 2.3 : Comparaison du critère de performance (MSE)	42
pour les deux types de MLP.	
Tableau 2.4 : Caractéristiques de GRNN).....	45
Tableau 2.5 : Analyse de la performance de GRNN à travers les indicateurs MSE et MAPE.....	46
Tableau 2.6 : Validation des approches GRNN, FFANN et CFANN à l'aide d'indicateurs statistiques.....	48
Chapitre trois	
Tableau 3.1 : Variables d'entrée et de sortie.....	71
Tableau 3.2 : Les caractéristiques floues.....	71
Tableau 3.3 : L'ensemble des règles floue.....	72
Tableau 3.4 : Résultats de tests réalisés au laboratoire en utilisant SIF.....	75
Tableau 3.5 : Indices statistiques pour l'évaluation des performances des différents types de modèles ANFIS.....	77
Tableau 3.6 : Différents paramètres de l'ANFIS.....	78
Tableau 3.7 : Étude des critères de performance MSE et MAPE pour la méthode ANFIS.....	81
Tableau 3.8 : Statistiques de validation de la performance du modèle.....	84
Chapitre quatre	
Tableau 4.1 : Paramètres de l'algorithme ANN-CS.....	106
Tableau 4.2 : Comparaison des performances de ANN-PSO et ANN-CS à l'aide de MAPE.....	108
Tableau 4.3 : Validation des approches ANN-PSO et ANN-CS proposées à l'aide d'indicateurs statistiques.....	109



Sommaire

Sommaire

Liste des figures	I
Liste des Tableaux.....	IV
Introduction Générale.....	1
Généralités et problématique	1
Objectifs de ce travail	2
Présentation du mémoire	3

Chapitre 1

Généralités sur les isolateurs : Impact de la pollution et phénomène de contournement

1.1 Introduction	5
1.3 Type des isolateurs de haute tension	7
1.3.1 Isolateurs de type rigide	7
1.3.2 Isolateur capot et tige	7
1.3.3 Isolateurs de chaîne	8
1.3.4 Isolateur long fut	8
1.4 Construction des isolateurs électriques	8
1.4.1 Porcelaine	8
1.4.2 Verre.....	9
1.4.3 Matériaux synthétiques	10
1.5 Pollution des isolateurs de H.T	11
1.5.1 Sources de pollution	11
1.5.1.1 Pollution naturelle	11
1.5.1.1.1 Pollution marine	11
1.5.1.1.2 Pollution désertique.....	12
1.5.1.2 Pollution industrielle	12
1.5.1.3 Pollution mixte	13
1.6 Phénomène de contournement	13
1.7 Processus de contournement des isolateurs pollués	14
1.8 Différence entre la tension de tenue et la tension de contournement.....	15
1.9 Prévention des contournements.....	16
1.9.1 Nettoyage régulier	16
1.9.2 Inspection visuelle.....	16
1.9.3 Réparation des défauts	16

1.9.4 Utilisation de revêtements hydrophobes	16
1.9.5 Surveillance continue	17
1.10 Étude expérimentale	18
1.10.1 Équipements de la station de test	18
1.10.2 Objet expérimental	19
1.10.3 Application de la couche de pollution	19
1.10.4 Evolution de la tension de contournement	20
1.10.5 Résultats obtenus	20
1.11 Conclusion	21

Chapitre 2

Prédiction de la tension de contournement par la méthode des réseaux de neurones

2.1 Introduction	23
2.3 Fonctionnement d'un réseau de neurones	25
2.4 Structure d'un neurone artificiel	25
2.5 Types de fonction de transfert	26
2.5.1 Fonction Sigmoidé	26
2.5.2 Fonction Tangente hyperbolique	27
2.5.3 Fonction ReLU (Rectified Linear Unit)	27
2.5.4 Fonction Softmax	27
2.6 Topologies de connexion dans les réseaux de neurones	27
2.6.1 Réseaux de neurones bouclés	27
2.6.2 Réseau de neurones non bouclés	28
2.7 Apprentissage de réseaux de neurones	29
2.7.1 Apprentissage supervisé	29
2.7.2 Apprentissage non-supervisé	29
2.8 Conception d'un réseau de neurones	30
2.9 Quelques types de réseaux de neurones	31
2.9.1 Perceptron multicouche	31
2.9.1.1 Architectures de MLP	32
2.9.1.1.1 Réseaux de propagation avant (Feed Forward Neural Networks-FFNN)	32
2.9.1.1.2 Réseaux en cascade et à propagation avant (Cascade-Forward Artificial Neural Networks- CFNN)	32
2.9.2 Réseau à fonction de base radial (RBF)	34

2.9.2.1	Présentation des réseaux RBF	34
2.9.2.2	Réseaux de neurones de régression généralisée (GRNN).....	35
2.9.2.3	Architecture de GRNN	36
2.10	Prédiction de U_c avec un réseau de neurones à couches multiples.....	37
2.10.1	Elaboration de la structure du réseau de neurones.....	38
2.10.1.1	Nombre de neurones cachés et de couches cachées.....	38
2.10.2	Création du réseau de neurones perceptrons multicouche (MLP) sous l'environnement MATLAB.....	38
2.10.2.1	Type du réseau de neurones	39
2.10.2.1.1	Réseau de neurones à propagation avant (Feed Forward Neural Network FFNN).....	40
2.10.2.1.2	Réseau de neurones artificiel en cascade (<i>cascade-forward artificial neural network</i> –CFNN).....	40
2.10.3	Résultats et discussions.....	41
2.10.3.1	Racine carrée de l'erreur quadratique moyenne (RMSE)	41
2.10.3.2	Coefficient de détermination (R^2)	41
2.10.3.3	L'erreur MAPE	41
2.11	Prédiction de U_c par réseau de neurones de régression généralisée	45
2.11.1	Création du GRNN sous MATLAB	45
2.11.2	Performance du réseau de neurones (GRNN).....	46
2.12	Comparaison entre les trois types GRNN, FFANN et CFANN.....	48
2.13	Conclusion.....	48

Chapitre 3

Prédiction de la tension de contournement par le système Neuro-Flou

3.1	Introduction	49
3.2	Systèmes Neuro--Flous	49
3.2.1	Systèmes flous.....	50
3.2.1.1	Évolution et avancées de la logique floue	50
3.2.1.2	Principe de la logique floue.....	51
3.2.1.3	Variables linguistiques	51
3.2.1.4	Ensembles flous et les Fonctions d'appartenance.....	52
3.2.1.5	Règles linguistiques.....	54
3.2.1.6	Structure interne d'un système flou	55
3.2.1.6.1	Bloc de fuzzification	55

3.2.1.6.2 Bloc de règles	55
3.2.1.6.3 Bloc d'inférence	56
3.2.1.6.4 Bloc de défuzzification	57
3.2.1.7 Différentes classes de modèles flous	58
3.2.1.8 Création du système flou	58
3.2.2 Réseau Neuro--Flou Adaptatif (ANFIS)	59
3.2.2.1 Principe de fonctionnement	60
3.2.2.2 Structure d'ANFIS	61
3.2.2.3 Algorithme d'apprentissage de l'ANFIS	64
3.2.2.4 Algorithme de l'ANFIS	64
3.3 Prédiction de la tension de contournement par système d'inférence flou	65
3.3.1. System d'inférence flou utilisé	67
3.3.2 Entrées et sortie choisie	67
3.3.3 Fonctions d'appartenances	68
3.3.3.1 Fonctions d'appartenances des entrées	69
3.3.3.1.1 Conductivité	69
3.3.3.1.2. Tension d'alimentation	69
3.3.3.1.3. Le niveau de pollution (Q1):	70
3.3.3.1.4. Le niveau de pollution (Q2)	70
3.3.3.1.5. Le niveau de pollution (Q3)	70
3.3.3.2. Fonctions d'appartenances de la sortie	71
3.3.4. Règles d'inférence	73
3.3.5. Fuzzification	73
3.3.6 Défuzzification	74
3.3.7 Tests et validation	74
3.4 Architecture d'un système d'inférence neuro-flou adaptatif : (ANFIS)	76
3.4.1 Résultats et discussions	76
3.4.2 Architecture d'ANFIS	80
3.5 Conclusion	84

Chapitre 4

Prédiction de la tension de contournement par les approches hybrides ANN-PSO & ANN-CS

4.1 Introduction	85
4.2 Optimisation d'Essaim de Particules (Particle Swarm Optimization)	85
4.2.1 Principe de la Technique PSO	86
4.2.2 Formulation Mathématique de l'Algorithme PSO	89

4.3. Recherche de Coucou (CS)	92
4.3.1. Oiseau de coucou.....	92
4.3.2 Principaux composants de recherche coucou	93
4.3.2.1 Nid.....	93
4.3.2.2 Œufs	93
4.3.2.3 Fonction objectif	94
4.3.3. Vol de Lévy	94
4.3.4 Principe de la Technique CS (Cuckoo Search)	94
4.3.5 Algorithme de la recherche Coucou (Cuckoo Search)	95
4.4 Combinaison d'un réseau de neurones et des méthodes CS et PSO.....	97
4.5 Prédiction de la tension de contournement par ANN--PSO et ANN--CS.....	98
4.5.1 Algorithme de l'approche hybride ANN -PSO	98
4.5.1.1 Paramètres de l'algorithme ANN -PSO	99
4.5.1.2 Résultats et discussion	101
4.5.2 Approche hybride réseaux de neurones – recherche coucou (ANN -CS).....	103
4.5.2.1 Algorithme de l'approche hybride ANN -CS.....	104
4.5.2.2 Organigramme de l'approche hybride ANN -CS	104
4.5.2.3 Paramètres de l'algorithme ANN -CS	106
4.5.2.4 Résultats et discussion	106
4.6 Performances de ANN -PSO et ANN -CS	108
4.7 Comparaison entre ANN -PSO et ANN -CS	109
4.8 Conclusion.....	109
Conclusion générale.....	110
Travail effectué.....	110
Perspectives	111
Bibliographie.....	112

Introduction Générale

Généralités et problématique

Les isolateurs jouent un rôle essentiel dans les lignes de haute tension du réseau de transmission en assurant l'isolation entre la ligne et le sol, ainsi qu'entre la ligne et les structures de support. Ils empêchent les courants indésirables de circuler entre la ligne et le sol, assurant ainsi une isolation électrique efficace. La pollution des isolateurs peut avoir un impact significatif sur la performance du réseau de transmission d'énergie électrique.

L'accumulation de polluants sur les isolateurs peut entraîner une détérioration de leur capacité à résister aux surtensions et à maintenir une isolation électrique adéquate. Cela peut entraîner des perturbations dans la qualité de l'énergie transmise, des pannes et des risques pour la sécurité du système électrique. Les impuretés provenant de diverses sources, telles que la pollution industrielle, urbaine, les particules de sel dans les régions côtières ou les fines particules de tempêtes de sable dans les régions désertiques, peuvent s'accumuler sur les isolateurs [1-3]. Cette pollution peut réduire l'efficacité de l'isolation et augmenter les risques de décharge électrique.

Le phénomène de décharge électrique est généralement amorcé par un mécanisme dans lequel une couche de pollution solide se combine avec l'humidité qui existe, créant ainsi un dépôt plus ou moins conducteur. Ce dépôt facilite le passage d'un courant de fuite à travers l'isolant. En raison de la complexité des formes des matériaux isolants, la densité de ce courant varie à la surface, ce qui provoque une élévation de la température dans la couche conductrice de manière inhomogène. Ce processus peut conduire à la création de zones asséchées par évaporation de l'humidité.

Lorsque l'une de ces zones asséchées atteint localement un champ électrique critique, une décharge électrique se produit. Si les conditions électriques le permettent, cette décharge peut rapidement entraîner un court-circuit de l'isolateur [4].

De nombreux chercheurs et ingénieurs ont consacré leurs efforts à explorer les mécanismes impliqués dans le phénomène provoqué par la contamination des isolateurs [5-6-7]. Leur travail remarquable a contribué à approfondir notre compréhension de ces phénomènes.

En réalité, la plupart des études de recherche se sont concentrées sur la mise en évidence du mécanisme de contournement qui se produit dans les isolateurs en présence de pollution, ainsi que sur l'étude des principaux paramètres régissant la tension de contournement [8-9-10]. Ces paramètres comprennent le degré de présence du polluant à la surface polluée et la composition chimique de la couche polluée recouvrant l'isolateur.... etc.

Les modèles théoriques et expérimentaux précis permettant de calculer la tension de claquage sont précieux, car ils permettent aux ingénieurs de faire des prédictions fiables dans diverses conditions de fonctionnement, formes géométriques et matériaux d'isolateurs. Cela améliore les informations obtenues à partir des tests en laboratoire et de l'expérience sur le terrain [11].

Les tests pratiques sont en effet des méthodes d'évaluation qui permettent de simuler des conditions réelles de pollution. Ils prennent en compte les facteurs et les contraintes complexes présents dans un environnement spécifique sur une période de temps prolongée. Bien que la durée nécessaire soit un inconvénient majeur de ces tests, leur réalisation en laboratoire en reproduisant artificiellement les conditions de pollution présente de nombreux avantages. Cela permet aux chercheurs d'obtenir des résultats plus rapidement et de réaliser des comparaisons plus faciles et économiques par rapport aux tests effectués en extérieur.

Les contournements électriques des isolateurs posent un problème considérable aux réseaux électriques aériens de distribution de l'énergie électrique, entraînant des conséquences graves, principalement sous la forme de coupures de courant d'une durée variable, perturbant ainsi la fourniture d'électricité aux utilisateurs.

D'importants travaux de recherche ont été réalisés pour une meilleure compréhension des mécanismes entraînant le contournement des isolateurs pollués. La compréhension de ces processus complexes est essentielle pour élaborer des stratégies efficaces visant à prévenir ces incidents indésirables.

De plus, ces recherches ont également permis le développement d'outils spécialisés qui facilitent la prédiction du phénomène de contournement, offrant ainsi aux gestionnaires de réseau la possibilité d'anticiper et de prendre des mesures préventives pour minimiser les interruptions de service et optimiser la fiabilité du réseau électrique.

Au cours de ces dernières années, beaucoup de méthodes d'intelligence artificielle ont été exploitées dans les applications de haute tension, notamment pour estimer et prédire la tension ou le courant de contournement sur différents types d'isolateurs. Ces techniques peuvent être regroupées en quatre catégories principales : les réseaux de neurones, la logique floue, les algorithmes génétiques et les systèmes experts [12-17].

Objectifs de ce travail

L'objectif de cette étude est de prédire la tension de contournement d'un isolateur de type 175CTV en tenant compte de la variation de la conductivité et du niveau de pollution des différentes zones de sa surface. Cette prédiction est réalisée en utilisant des techniques

d'intelligence artificielle telles que le système d'inférence flou, les réseaux de neurones artificiels et le système d'inférence neuro-flou (ANFIS). De plus, l'étude a également employé des techniques d'optimisation, notamment l'optimisation par essaims de particules (PSO) et la recherche coucou(CS), dans le but d'améliorer la précision de la méthode des réseaux de neurones artificiels (ANN) dans la prédiction de la tension de contournement.

L'utilisation de la logique floue et des réseaux de neurones, ainsi que leur hybridation, nécessite la collecte de données numériques ou expérimentales. La considération de divers types d'entrées/sorties dans les applications du système d'inférence flou, des réseaux neuronaux et d'ANFIS ouvre la voie à de nouvelles études sur la prédiction de la tension de contournement des isolateurs.

Dans de nombreux travaux de recherche, l'application des techniques d'intelligence artificielle pour prédire et comprendre le phénomène de contournement des isolateurs dans les systèmes de haute tension a été explorée. Ces études ont souvent considéré le courant de fuite comme l'un des paramètres les plus importants pour étudier ce phénomène. Le courant de fuite est largement utilisé comme indicateur pour évaluer l'intégrité des isolateurs et prédire leur comportement sous des tensions élevées.

Cependant, dans notre travail, nous avons pris en compte d'autres paramètres différents de ceux utilisés dans ces travaux antérieurs. Nous avons considéré la tension appliquée, la conductivité et la quantité de pollution artificielle dans l'isolateur comme des paramètres essentiels influençant le contournement des isolateurs.

La détermination des paramètres internes du système d'inférence flou (FIS), des réseaux de neurones artificiels (ANN), du système d'inférence neuro-flou adaptatif (ANFIS) et de l'approche hybride entre les réseaux de neurones artificiels (ANN) et les techniques d'optimisation par essaim de particules (PSO) et de recherche de coucou (CS) est une étape essentielle lors de leur implémentation. L'utilisation de l'interface graphique de MATLAB peut faciliter cette tâche.

Présentation du mémoire

Notre travail est structuré en quatre chapitres distincts comme suit :

Dans le premier chapitre, nous présenterons l'importance des isolateurs, leurs utilisations et leurs principaux types. Nous examinerons également les notions fondamentales du phénomène de pollution des isolateurs de haute tension. Nous mettrons en évidence les différentes sources de pollution auxquelles les isolateurs peuvent être confrontés, telles que la pollution atmosphérique, les dépôts de poussière et les décharges partielles, ainsi que leurs

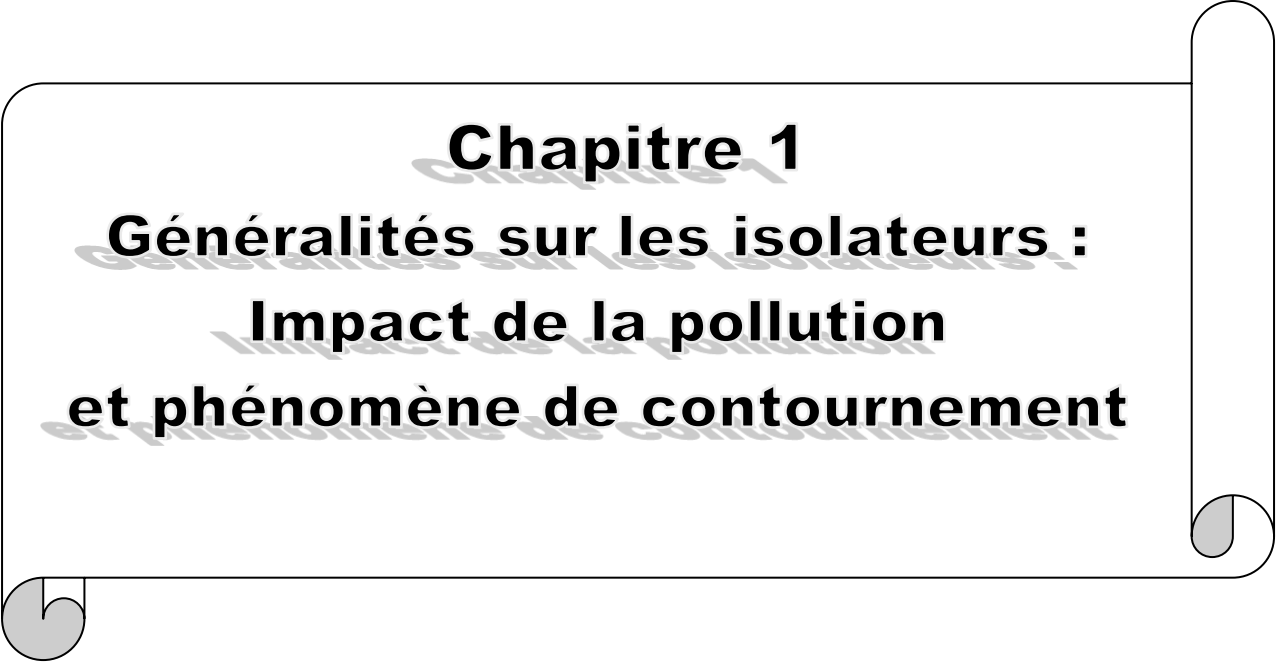
effets néfastes potentiels. Une attention particulière sera accordée au contournement des isolateurs. De plus, nous présenterons une étude expérimentale du processus d'arc électrique et du contournement des isolateurs sous une tension de 50 Hz. Cette étude sera réalisée à l'aide d'un modèle réel simulant un isolateur de haute tension de type 175CTV. L'objectif principal sera d'analyser l'influence de la conductivité et de la distribution de la pollution sur le comportement de ce modèle. Pour cela, une pollution artificielle composée d'une solution saline et d'eau distillée sera introduite dans chaque zone de l'isolateur de type 175CTV. Les résultats pratiques présentés dans ce chapitre ont été obtenus au laboratoire de haute tension de l'université de Biskra.

Dans le deuxième chapitre, nous utiliserons les données expérimentales du chapitre 1 afin de développer un modèle basé sur différentes architectures de réseaux de neurones artificiels (ANN), notamment le réseau de neurones à régression généralisée (GRNN), le réseau de neurones en cascade (CFANN) et le réseau de neurone à propagation avant (FFNN). Ces méthodes nous permettront de prédire la tension de contournement en utilisant des variables d'entrée telles que la conductivité (δ), les zones de pollution (Z_i). Enfin, nous concluons ce chapitre par une comparaison entre l'approche GRNN et les approches FFANN et CFANN.

Dans le troisième chapitre, nous présenterons les principes théoriques des différentes techniques d'intelligence artificielle, notamment le système d'inférence floue (SIF) et le système d'inférence floue basé sur les réseaux de neurones adaptatifs (ANFIS). Nous exposerons la théorie de ces techniques ainsi que la méthodologie utilisée pour prédire la tension de contournement d'un modèle réel d'isolateur de haute tension de type 175CTV dans diverses conditions, telles que la conductivité et les niveaux de pollution. Ensuite, nous présenterons et interpréterons les résultats obtenus dans le cadre de notre étude.

Dans le quatrième et dernier chapitre, nous présenterons deux approches hybrides pour estimer la tension de contournement. Nous combinerons les capacités des réseaux de neurones avec les techniques d'optimisation utilisant les essaims de particules (ANN-PSO) et la recherche du coucou (ANN-CS). Ces approches hybrides exploitent les principes de l'intelligence artificielle et de l'apprentissage statistique, offrant ainsi une solution prometteuse pour prédire avec précision la tension de contournement. À la fin du chapitre, nous procéderons à une comparaison entre les deux méthodes.

Enfin, nous rassemblerons les différentes facettes de ce travail en présentant une conclusion générale qui résumera les résultats obtenus et abordera les perspectives évoquées par cette étude.



Chapitre 1
Généralités sur les isolateurs :
Impact de la pollution
et phénomène de contournement

1.1 Introduction

L'utilisation de la haute tension dans les réseaux aériens de transport de l'énergie électrique engendre divers problèmes tels que le claquage, l'effet couronne, le contournement des isolateurs et les pertes diélectriques. Ces problèmes peuvent avoir un impact significatif sur le bon fonctionnement des lignes électriques de haute tension.

Le claquage se produit lorsque la tension dépasse la capacité d'isolation de l'équipement, ce qui entraîne une décharge électrique indésirable. L'effet couronne se produit lorsque l'air environnant est ionisé près des conducteurs de haute tension. Le contournement des isolateurs se réfère à l'accumulation de pollution sur la surface des isolateurs, ce qui diminue leur capacité à assurer une isolation efficace. Enfin, les pertes diélectriques sont des pertes d'énergie qui se produisent lors de la conversion de l'énergie électrique en chaleur dans les matériaux isolants.

Pour maintenir un fonctionnement fiable des lignes aériennes de haute tension, il est essentiel de développer des isolateurs capables de résister à ces problèmes et d'assurer une isolation efficace dans divers environnements [18].

Dans la première partie de ce chapitre, nous examinons l'importance et l'utilité des isolateurs, ainsi que les principaux types et matériaux utilisés. La deuxième partie est dédiée à la présentation du phénomène de la pollution et de ses effets sur le comportement des isolateurs. Dans la troisième partie, nous présentons le contournement des isolateurs ainsi que les différentes méthodes de prévention utilisées. Enfin, la quatrième partie de ce chapitre se concentre sur une étude expérimentale du processus de contournement des isolateurs.

1.2 Isolateurs de haute tension

Les isolateurs de haute tension, également appelés chaînes isolantes, sont des dispositifs utilisés dans les lignes électriques à haute tension pour isoler les conducteurs et les équipements électriques. Ils sont conçus pour supporter des tensions élevées, généralement supérieures à 1000 volts, et pour empêcher les fuites de courant et les décharges électriques indésirables. Ils sont utilisés dans les systèmes de transmission et de distribution d'électricité, tels que les lignes aériennes à haute tension, les pylônes, les transformateurs et les postes électriques. Dans la conception des isolateurs de haute tension, plusieurs anneaux isolants sont empilés et reliés entre eux par des tiges métalliques. Les anneaux isolants sont utilisés pour créer une barrière électrique entre le conducteur à haute tension et la structure de support dans le but de prévenir le passage du courant électrique. Les tiges métalliques assurent la rigidité mécanique de l'isolateur [19-20].

L'isolateur de H.T est composé d'un matériau isolant tel que la porcelaine, le verre trempé ou un polymère, auquel sont fixées deux pièces métalliques, généralement appelées pièces A et B.

La pièce métallique A est fixée au pylône ou à la structure de support, tandis que la pièce métallique B porte le conducteur électrique. L'isolateur assure ainsi deux rôles principaux [21-22] :

- Un rôle mécanique : L'isolateur de haute tension joue un rôle mécanique en portant le conducteur électrique. La pièce B, fixée à l'isolant, soutient le conducteur et lui permet de rester à une distance adéquate du pylône ou de la structure de support, assurant ainsi la sécurité mécanique du système.
- Un rôle électrique : Les isolateurs de haute tension jouent un rôle électrique essentiel dans les systèmes de transmission d'électricité. Leur fonction principale est d'assurer une isolation électrique efficace entre les conducteurs à haute tension et les structures de support, tels que les pylônes.




Figure 1.1 : Isolateur de H.T

1.3 Type des isolateurs de haute tension

1.3.1 Isolateurs de type rigide

Les isolateurs de type rigide sont généralement utilisés dans les lignes de transmission aériennes de haute tension. Ils sont constitués d'un seul isolateur rigide, qui peut être en porcelaine, en verre ou en composite, fixé à un support. Les isolateurs rigides sont conçus pour résister aux charges mécaniques et aux contraintes environnementales tout en maintenant une distance de sécurité entre le conducteur et la structure de support [23].



Figure 1.2 : Isolateur rigide.

1.3.2 Isolateur capot et tige

Ce type d'isolateur est composé d'un capot en porcelaine ou en composite qui recouvre la partie supérieure de l'isolateur, et d'une tige métallique qui le relie à la structure de support. Le capot offre une isolation électrique supplémentaire et une protection contre les dépôts de contaminants, tandis que la tige métallique fournit la rigidité mécanique nécessaire [24].



Figure 1.3 : Isolateur capot et tige

1.3.3 Isolateurs de chaîne

Les isolateurs de chaîne, également appelés éléments de chaîne, sont utilisés dans les applications de haute tension nécessitant une plus grande distance d'isolation. Ils se composent d'une série d'éléments isolants en porcelaine, en verre ou en composite, généralement reliés par des tiges métalliques ou des liens en acier inoxydable. Les éléments de chaîne sont suspendus en série pour fournir une isolation électrique appropriée tout en permettant une plus grande distance entre le conducteur et la structure de support [23].

1.3.4 Isolateur long fut

Aussi connu sous le nom d'isolateur à longue tige, cet élément de chaîne se compose d'un seul élément isolant de forme allongée, généralement en porcelaine ou en composite. Il est fixé à la structure de support par une tige métallique [24].



Figure 1.4: Isolateur long fut

1.4 Construction des isolateurs électriques

Les isolateurs de H.T sont fabriqués à partir de différents matériaux isolants pour assurer une isolation électrique efficace et fiable. Il existe plusieurs matériaux isolants utilisés dans la fabrication des isolateurs de haute tension:

1.4.1 Porcelaine

La porcelaine est largement utilisée pour les isolateurs de haute tension en raison de sa grande résistance mécanique, de sa durabilité et de sa capacité à résister aux conditions environnementales difficiles [25].



Figure 1.5: Isolateur électrique en céramique

1.4.2 Verre

Le verre est un autre matériau isolant largement utilisé dans la fabrication des isolateurs de haute tension. Il est reconnu pour ses excellentes propriétés d'isolation électrique, sa résistance chimique et sa transparence optique [26].



Figure 1.6: Isolateur électrique en verre

1.4.3 Matériaux synthétiques

Les matériaux utilisés comme isolants pour les lignes à haute tension sont généralement choisis en fonction de leurs propriétés d'isolation électrique élevées et de leur capacité à résister aux contraintes mécaniques [27-28]. Les matériaux les plus utilisés comme isolants de haute tension sont :

1. Polymères : Les polymères synthétiques tels que le polyéthylène (PE), le polypropylène (PP), le polytétrafluoroéthylène (PTFE) et le polyvinylchlorure (PVC) sont largement utilisés comme isolants de haute tension. Ces matériaux présentent une bonne résistance à l'usure, aux produits chimiques et aux intempéries, ce qui les rend adaptés aux applications en extérieur.
2. Silicone : Le silicone est un matériau synthétique couramment utilisé comme isolant pour les câbles de haute tension. Il offre une excellente stabilité thermique et une bonne résistance, ce qui en fait un choix populaire pour les applications à haute température.
3. Caoutchouc synthétique : Les caoutchoucs synthétiques, tels que l'éthylène-propylène-diène monomère (EPDM) et le caoutchouc de silicone, sont utilisés comme isolants pour les câbles et les joints d'étanchéité des lignes à haute tension.
4. Fibres de verre et époxy : Les composites à base de fibres de verre renforcées par une résine époxy sont utilisés dans la fabrication de certains isolateurs de haute tension. Ces matériaux offrent une excellente résistance mécanique, une faible conductivité électrique et une bonne résistance à la corrosion.



Figure 1.7: Isolateur électrique en matériaux synthétiques

1.5 Pollution des isolateurs de H.T

La pollution des isolateurs de haute tension crée un problème majeur dans les systèmes de transmission d'électricité. Les isolateurs sont utilisés pour limiter la circulation des courants électriques depuis les lignes de haute tension vers la terre ou d'autres parties du réseau électrique. Lorsque ces isolateurs se trouvent dans des conditions de pollution, tels que la poussière, la saleté, la pluie, le brouillard, la pollution atmosphérique ou même des excréments d'oiseaux, leur capacité à isoler correctement les lignes électriques peut être diminuée [29-30].

L'accumulation de pollution sur les isolateurs peut engendrer d'une couche conductrice qui facilite la circulation des courants de fuite, créant ainsi des arcs électriques et des décharges partielles. Cela peut entraîner des pannes de courant, des courts-circuits et des impacts négatifs sur les équipements électriques [31-32].



Figure 1.8: Pollution des isolateurs [33]

1.5.1 Sources de pollution

La nature de la pollution peut être influencée par divers facteurs géographiques et climatiques. Différentes sources de pollution sont souvent observées sur les isolateurs et peuvent être regroupées en trois catégories principales :

1.5.1.1 Pollution naturelle

1.5.1.1.1 Pollution marine

Lorsque les lignes de H.T passent près de la mer, les embruns marins, composés de petites gouttelettes d'eau salée, peuvent être transportés par le vent et se déposer sur les surfaces des isolateurs [34]. Cette accumulation de sel et d'autres substances marines peut provoquer une couche polluante sur les isolateurs, ce qui peut entraîner plusieurs problèmes :

1. Réduction de l'isolation électrique : Le sel est un bon conducteur électrique. Lorsqu'il se dépose sur les isolateurs, il peut réduire leur capacité à isoler efficacement les conducteurs électriques, augmentant ainsi le risque de court-circuit ou d'arc électrique.
2. Corrosion des matériaux : La présence de sel peut accélérer la corrosion des matériaux métalliques utilisés dans les isolateurs et les structures de support des lignes électriques. La corrosion peut diminuer la résistance des composants, réduire leur durée de vie et nécessiter des réparations ou des remplacements fréquents [35].

1.5.1.1.2 Pollution désertique

Dans les régions désertiques, les particules de sable, de terre et de poussière peuvent également se déposer sur les isolateurs des lignes électriques. Cela peut entraîner des problèmes électriques. Les facteurs climatiques peuvent contribuer à ce phénomène de différentes manières :

- Vent : Les vents forts dans les régions désertiques peuvent entraîner le transport de particules de sable et de poussière en suspension dans l'air. Ces particules peuvent ensuite être transportées sur de longues distances et se déposer sur les isolateurs des lignes électriques. Progressivement, ces dépôts peuvent s'accumuler et former une couche sur la surface de l'isolateur.
- Température : Les variations de température entre le jour et la nuit dans les régions désertiques peuvent entraîner un phénomène de condensation sur les dépôts de particules présents sur les isolateurs. Pendant la journée, les températures élevées peuvent causer l'évaporation de l'humidité, ce qui entraîne le dépôt des particules sur les isolateurs. La nuit, lorsque les températures chutent, l'humidité présente dans l'air peut se condenser sur les dépôts, formant une couche conductrice.

Ces dépôts sur les isolateurs peuvent provoquer des problèmes d'isolement électrique. La couche conductrice formée par les particules et la condensation peut créer des chemins de fuite pour le courant électrique, réduisant ainsi l'efficacité de l'isolation et augmentant les risques d'arc électrique, des courts circuits [35-36].

1.5.1.2 Pollution industrielle

Les émissions provenant des usines, des raffineries et des cimenteries, ainsi que les fumées industrielles, contiennent des substances polluantes. Lorsqu'elles se déposent sur les

lignes électriques, ces substances polluantes peuvent entraîner des problèmes de corrosion, de détérioration des isolateurs et de réduction de l'efficacité de l'isolation électrique.

Les substances toxiques présentes dans ces émissions, telles que les oxydes d'azote, les particules fines et les composés organiques volatils, peuvent également causer des problèmes de corrosion et d'isolation lorsqu'elles se déposent sur les lignes électriques à proximité. Quant aux terrains agricoles, l'utilisation d'engrais peut entraîner une pollution des sols et des eaux. Lorsque les lignes électriques traversent ces zones, il y a un risque de contamination par les nitrates présents dans les engrais. Les nitrates peuvent corroder les composants métalliques des lignes électriques et augmenter le risque de défaillance des équipements [36].

1.5.1.3 Pollution mixte

Comme son nom l'indique, est une combinaison de différents types de pollution qui se produisent simultanément. La pollution mixte peut résulter de la convergence de la pollution marine et industrielle lorsque des installations industrielles sont situées près des zones côtières. Lorsque ces deux types de pollution se superposent, des interactions peuvent se produire, amplifiant les impacts négatifs sur l'environnement et la santé humaine [36].

1.6 Phénomène de contournement

Les contournements sur la surface des isolateurs de haute tension se réfèrent aux chemins électriques indésirables qui se forment sur la surface externe des isolateurs utilisés dans les systèmes de transmission et de distribution d'électricité à haute tension. Ces isolateurs sont conçus pour limiter le passage du courant électrique à travers eux, afin d'isoler les conducteurs électriques et de prévenir les décharges électriques indésirables. Cependant, en raison de divers facteurs tels que la pollution atmosphérique, la poussière, l'humidité ou la présence d'impuretés, des dépôts peuvent se former sur la surface des isolateurs.

Les contournements sur la surface des isolateurs peuvent avoir plusieurs conséquences. Ils peuvent réduire l'efficacité de l'isolation, provoquer des arcs électriques, des courts circuits ou des défaillances des équipements électriques. De plus, les contournements peuvent augmenter les pertes d'énergie et réduire la fiabilité et la stabilité du système électrique [37].

Lorsqu'un défaut se produit dans l'isolateur, créant ainsi une possibilité de phénomène de contournement, cela crée une trajectoire supplémentaire pour le courant électrique, entraînant ainsi un courant de fuite. Le courant de fuite peut détériorer les isolateurs et augmenter les problèmes associés au contournement, tels que les décharges partielles et les risques d'arcs électriques. [38-39].




Figure 1.9: Contournement des isolateurs de haute tension

1.7 Processus de contournement des isolateurs pollués

Le processus de contournement des isolateurs pollués peut être décrit en quatre grandes phases [40]:

- Dépôt de la couche de pollution : Initialement, une couche solide composée de sels et de matériaux insolubles se forme sur la surface des isolateurs. Cependant, dans le cas d'une pollution marine, la pollution se présente sous la forme d'embruns marins.
- Humidification de la couche de pollution : La couche de pollution devient humide en raison de l'humidité ambiante ou des précipitations, ce qui entraîne la dissolution des sels présents dans le dépôt. Cela crée un électrolyte, permettant ainsi la circulation d'un courant électrique.
- Apparition de bandes sèches et décharges locales : Lorsque le courant circule à travers la couche de pollution humidifiée, des bandes sèches se forment en raison de l'échauffement par effet Joule résultant de la circulation du courant. Ces bandes sèches sont des zones de haute résistance électrique. En conséquence, des décharges locales, également appelées arcs partiels, peuvent se produire.
- Contournement de l'isolateur : Il se produit lorsque l'arc électrique se propage le long de la surface de l'isolateur, ce qui peut entraîner une propagation progressive des décharges locales et, finalement, un court-circuit complet de l'isolateur.




Figure 1.10: Processus de contournement des isolateurs pollués

1.8 Différence entre la tension de tenue et la tension de contournement

- ✚ Tension de tenue (ou tension de rupture) : Il s'agit de la tension maximale qu'un isolant peut supporter sans subir de défaillance ou de rupture diélectrique. La tension de tenue est la mesure de la résistance d'un isolant à une tension appliquée continue sans provoquer de décharge ou de passage d'arc. Elle est généralement exprimée en volts (V) et est essentielle pour assurer une isolation électrique fiable.
- ✚ Tension de contournement: est la valeur maximale de tension qu'un isolant ou un matériau diélectrique peut supporter avant de se produire une décharge électrique à travers lui. C'est le seuil au-delà duquel l'isolant ne peut plus maintenir une isolation efficace et où une rupture diélectrique se produit. La tension de contournement est généralement mesurée en kilovolts (kV) ou en mégavolts (MV) et varie en fonction des propriétés diélectriques du matériau utilisé.

1.9 Prévention des contournements

Pour prévenir les contournements sur la surface des isolateurs haute tension, il y a quelques mesures à prendre :

1.9.1 Nettoyage régulier

Le nettoyage régulier des isolateurs électriques est essentiel pour maintenir leur performance et éviter les problèmes potentiels tels que les contournements électriques, les décharges partielles et les risques de défaillance [41].

Il est essentiel de mettre en place un programme d'entretien régulier et de suivre les protocoles de nettoyage appropriés pour assurer la fiabilité et la durabilité des isolateurs de H.T.

1.9.2 Inspection visuelle

Permet d'identifier d'éventuels défauts ou problèmes visibles tels que des fissures, des fractures, des déformations ou tout autre dommage. Elle peut également être utilisée pour détecter l'accumulation de poussière, de pollution ou d'autres substances qui pourraient avoir un impact sur la performance de l'isolateur [41-43]. Le processus d'inspection visuelle nécessite l'examen de la surface de l'isolateur par observation directe, en utilisant des outils d'assistance tels que des loupes ou des caméras thermiques pour détecter les détails ou les défauts mineurs.

1.9.3 Réparation des défauts

La réparation des défauts sur les isolateurs de haute tension fait référence aux actions entreprises pour corriger tout dommage ou défaut identifié sur l'isolateur.

Lorsqu'un isolateur présente des signes de détérioration, tels que des fissures, des éclats, des déformations. ...ect, il est essentiel de les réparer rapidement pour préserver les performances de l'isolateur.

La réparation des défauts sur les isolateurs de haute tension peut varier en fonction de la nature et de l'étendue des dommages. Dans certains cas, il peut être nécessaire de remplacer complètement l'isolateur endommagé par un nouveau. Dans d'autres cas, des réparations ciblées peuvent être effectuées pour restaurer la fonctionnalité de l'isolateur [42-43].

1.9.4 Utilisation de revêtements hydrophobes

Les revêtements hydrophobes sont des matériaux spécialement conçus pour repousser l'eau et réduire la formation de gouttelettes ou de films d'eau sur la surface des isolateurs. Ces revêtements créent une barrière protectrice qui empêche l'eau de s'accumuler et de causer des

problèmes d'isolation. Lorsque les isolateurs de haute tension sont exposés à des conditions humides, tels que la pluie, la rosée ou la condensation, les revêtements hydrophobes empêchent l'eau de se fixer et de former un chemin conducteur. Cela réduit les risques de contournements électriques et de décharges partielles. De plus, les revêtements hydrophobes peuvent également repousser les contaminants tels que la poussière, le sel ou les polluants atmosphériques, qui peuvent autrement s'accumuler sur la surface des isolateurs. Cela contribue à maintenir la propreté de l'isolateur et à préserver ses performances électriques [43]

1.9.5 Surveillance continue

Grâce à une surveillance continue, il est possible de détecter rapidement les contournements et les défaillances potentielles avant qu'ils ne causent des dommages importants. Les systèmes de surveillance peuvent mesurer et surveiller les paramètres de l'isolateur tels que le courant, la tension, les décharges partielles et la température, ce qui peut indiquer des variations anormales et fournir des avertissements précoces de tout problème potentiel. En utilisant les données recueillies et une analyse appropriée, des mesures adéquates peuvent être prises pour réparer ou remplacer les isolateurs défectueux, avant qu'ils ne provoquent des accidents électriques graves. De plus, des travaux de maintenance réguliers et des réparations préventives peuvent être planifiés pour assurer le bon fonctionnement et la sécurité du système électrique [44-45].



Figure 1.11: Revêtements hydrophobe

1.10 Étude expérimentale

Il existe deux méthodes pour réaliser des tests de pollution. La première méthode consiste à soumettre l'isolateur à sa tension de fonctionnement et à l'exposer aux polluants naturels. Cependant, cette méthode présente des limites telles que des coûts élevés et une longue durée des tests. La deuxième méthode consiste à polluer artificiellement l'isolateur, puis à le soumettre à une tension croissante jusqu'à ce qu'il subisse une rupture diélectrique. Cette approche est moins coûteuse et permet d'obtenir rapidement des résultats [46].

1.10.1 Équipements de la station de test

La station de test comprend les composants suivants :

- Un transformateur d'essai de haute tension (250/100 kV, 5 kVA) utilisé pour alimenter l'isolateur avec la tension de stress requise.
- Un transformateur de régulation (220/250 kV) utilisé pour varier la tension aux bornes du transformateur d'essai.
- Un panneau de contrôle utilisé pour réguler automatiquement la tension d'essai.
- Un équipement de protection : différents types d'équipements sont utilisés pour la protection des personnes, tels qu'une cage de Faraday et des relais thermiques.
- Des instruments de mesure : un voltmètre numérique est utilisé pour mesurer la tension, et un diviseur capacitif est utilisé pour mesurer la tension à la fréquence industrielle (50 Hz).

La figure 1.12 montre le matériel expérimental utilisé.




Figure 1.12 : Configuration expérimentale à la fréquence industrielle.


T : Transformateur d'isolement. T.O : Objet de test (isolant 175CTV).

R.T : Transformateur de régulation. H.T : Transformateur de haute tension.

C_m : Un condensateur pour mesurer la tension appliquée.

1.10.2 Objet expérimental

L'objet d'essai utilisé est un isolateur en verre de haute tension de type 175CTV, comme illustré dans la figure 1.13.



a) Présentation de l'isolant (b) Zones de l'isolant (c) Niveaux de l'isolant

Figure 1.13 : Isolateur en verre de type "Capot-tige" 175CTV

1.10.3 Application de la couche de pollution

Cet isolateur est soumis à des tests de pollution artificielle au laboratoire de haute tension de l'Université de Biskra. Pour simuler les conditions réelles, une pollution artificielle est créée en utilisant une solution saline mélangée à de l'eau distillée. Cette pollution artificielle est introduite dans chaque zone ou nervure de l'isolateur, comme indiqué dans le Tableau 1.1.

Tableau 1.1 : Niveaux de pollution dans les zones des isolateurs.

	Z1 (ml)	Z 2(ml)	Z 3(ml)
Niveau 1	11.6	13.3	23.3
Niveau 2	23.3	26.6	46.6
Niveau 3	34.9	39.9	69.9

1.10.4 Evolution de la tension de contournement

Lorsqu'une tension alternative est appliquée aux isolateurs et augmentée progressivement à partir de 0 kV, différents phénomènes se produisent. Au départ, à une tension initiale, des arcs se forment entre les électrodes en raison de la densité élevée de courant près des électrodes de H.T. Cela entraîne l'évaporation de la solution saline par effet Joule, créant ainsi des régions sèches sur la surface de l'isolateur. Si la tension continue à augmenter, les arcs se propagent de manière aléatoire vers l'électrode opposée. Lorsque la tension augmente encore, les arcs se développent progressivement jusqu'à occuper toute la surface de l'isolateur, entraînant ainsi le phénomène de contournement de l'isolateur [46].

Après chaque test, la surface de l'isolateur est nettoyée en la lavant avec de l'alcool isopropylique et en la rinçant à l'eau distillée, afin d'éliminer toute trace de saleté. Ce nettoyage est essentiel pour assurer des conditions de test précises et pour éviter la présence de contaminants pouvant influencer les résultats. L'utilisation de l'alcool isopropylique permet de dissoudre et d'éliminer les résidus de saleté présents sur la surface de l'isolateur. Ensuite, le rinçage à l'eau distillée permet de s'assurer qu'aucun résidu d'alcool ou de contaminants ne reste sur l'isolateur. Ce processus de nettoyage est réalisé après chaque test, afin de maintenir la propreté de la surface de l'isolateur et d'assurer des conditions optimales pour les tests ultérieurs.

Les tests sont effectués cinq fois en utilisant différentes valeurs de conductivité de la solution saline dans chaque nervure isolante. La valeur de tension de contournement prise en compte est la moyenne des cinq mesures effectuées. Cela permet d'obtenir une mesure plus précise et représentative de la capacité de l'isolateur à résister à la tension appliquée. En prenant la moyenne des cinq mesures, cela permet de réduire l'impact des variations ou des erreurs potentielles qui peuvent survenir lors des tests individuels. Ainsi, la valeur moyenne de la tension de contournement est utilisée comme référence pour évaluer la performance et la résistance de l'isolateur dans différentes conditions de conductivité de la solution saline.

1.10.5 Résultats obtenus

Les résultats obtenus dans cette étude sont présentés dans le tableau ci-dessous

Tableau 1.2 Résultats de tests réalisés au laboratoire

Zones Conductivité	Zone1 (ml)	Zone2 (ml)	Zone3 (ml)	Tension appliqué (kV)
7.5	11.6	13.3	23.3	45,80
	23.3	26.6	46.6	39,70
	34.9	39.9	69.9	34,80
20	11.6	13.3	23.3	34
	23.3	26.6	46.6	26
	34.9	39.9	69.9	23
50	7.2	15	10	19
	4.1	19.4	33.2	19.70
	5.5	7.5	14	17.5
80	11.6	13.3	23.3	39,50
	23.3	26.6	46.6	36,20
	34.9	39.9	69.9	33,70
100	8.2	38.8	67.4	39.40
	14.4	30	20	38
	10.1	15	28	35
120	11.6	13.3	23.3	38,50
	23.3	26.6	46.6	35,40
	34.9	39.9	69.9	33,60

Selon le tableau (1.2), qui présente la variation de la valeur efficace de U_c en fonction des niveaux de pollution et de la conductivité, on observe une diminution linéaire de U_c avec la conductivité. Cela entraîne une diminution de la capacité de l'isolateur à supporter des

niveaux élevés de pollution, ce qui indique clairement une dégradation de ses propriétés isolantes.

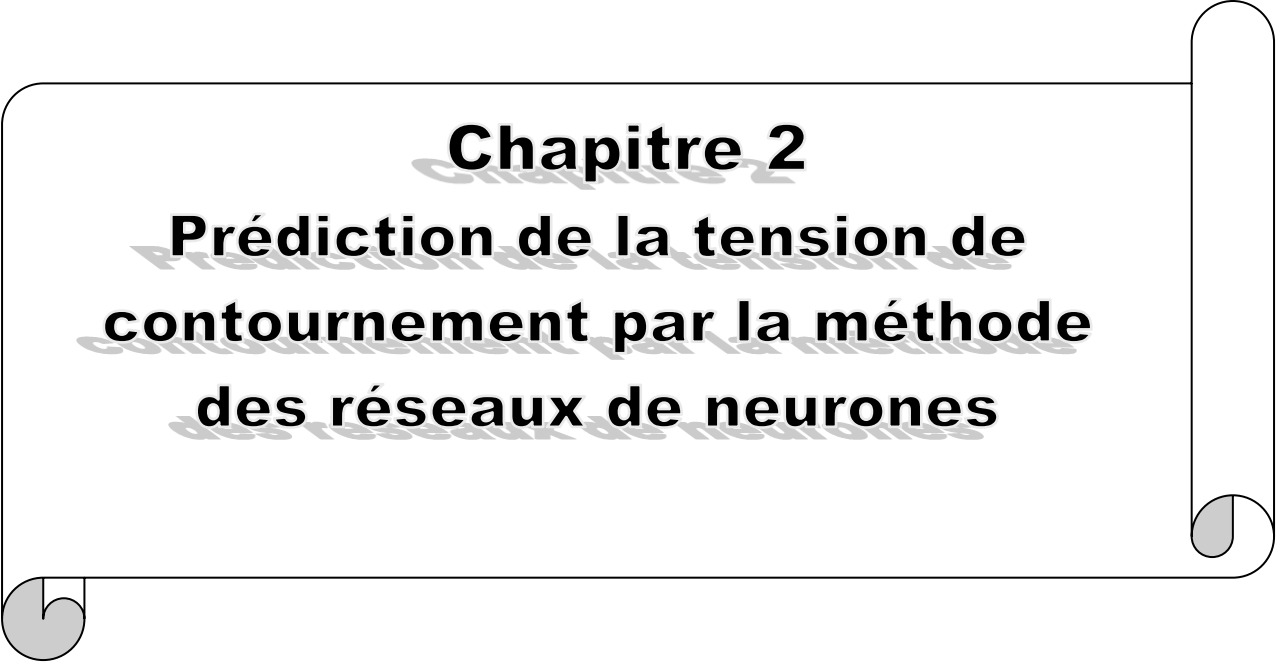
1.11 Conclusion

Dans ce chapitre, nous avons également étudié les effets de la pollution sur les matériaux d'isolation des lignes électriques de haute tension. La présence de pollution, tels que la poussière, la saleté, les dépôts atmosphériques et les polluants industriels, peut modifier les propriétés isolantes des matériaux utilisés dans les isolateurs. Cela peut entraîner une diminution de la résistance diélectrique, une augmentation de la conductivité et une augmentation du risque de décharges partielles.

Les résultats expérimentaux ont démontré que l'augmentation de la conductivité des solutions salines utilisées dans les tests en laboratoire a un impact significatif sur le comportement des isolateurs. Lorsque la conductivité augmente, le risque de formation de contournement augmente, ce qui peut entraîner une détérioration de l'isolateur.

Ces résultats soulignent l'importance de prendre en compte la pollution lors de la conception et de l'exploitation des lignes électriques de haute tension. Des méthodes de prévention, telles que la surveillance régulière de l'état des isolateurs, le nettoyage périodique et l'utilisation de matériaux résistants à la pollution, peuvent contribuer à minimiser les effets négatifs de la pollution sur les isolateurs.

Dans les prochains chapitres, nous appliquerons des approches basées sur l'intelligence artificielle pour vérifier la concordance entre les résultats issus de ces méthodes et les données expérimentales.



Chapitre 2
**Prédiction de la tension de
contournement par la méthode
des réseaux de neurones**

2.1 Introduction

Les isolateurs de haute tension sont utilisés pour supporter et isoler les conducteurs, et ils sont exposés à différentes conditions environnementales telles que l'humidité, la température et la pollution. La pollution, en particulier, peut s'accumuler sur les surfaces des isolateurs, ce qui réduit leur résistance diélectrique et augmente le risque de décharge et de contournement diélectrique.

Le contournement diélectrique peut entraîner une déviation du courant électrique, contournant ainsi le chemin prévu et pouvant provoquer des perturbations, des défauts dans le système électrique. Il est donc essentiel de prédire avec précision la tension de contournement des isolateurs pollués. Cependant, la réalisation de tests pour étudier le comportement des isolateurs en présence de pollution peut être longue et coûteuse. Par conséquent, l'utilisation d'expressions analytiques et de modèles informatiques, tels que les réseaux de neurones artificiels (ANN), est très utile pour évaluer les performances des isolateurs dans des conditions de pollution.

L'objectif principal de ce chapitre est d'utiliser la méthode de ANN pour prédire la tension de contournement des isolateurs pollués des lignes de H.T.

2.2 Réseaux de Neurones Artificiels

Un réseau de neurones artificiels (ANN) est un modèle mathématique inspiré du fonctionnement du cerveau humain. Il est composé de plusieurs couches de neurones artificiels interconnectés, qui sont capables de traiter de grandes quantités de données pour effectuer des tâches complexes telles que la reconnaissance de motifs, la classification d'images, la prédiction de séries temporelles, etc.

Chaque neurone dans un ANN traite les informations qu'il reçoit et les transmet à d'autres neurones en utilisant des fonctions mathématiques non linéaires. L'apprentissage du ANN se fait en ajustant les poids de connexion entre les neurones, en utilisant des algorithmes d'optimisation tels que la descente de gradient.

Le ANN est souvent utilisé dans des domaines tels que l'apprentissage automatique, la vision par ordinateur, la reconnaissance de la parole, la traduction automatique, la prédiction financière, etc.

Dans un réseau de neurones, chaque sous-groupe de neurones effectue un traitement indépendamment des autres et transmet le résultat de son analyse au sous-groupe suivant. Cela permet à l'information donnée au réseau de se propager couche par couche, de la couche d'entrée

à la couche de sortie, en passant éventuellement par plusieurs couches intermédiaires (appelées couches cachées).

Généralement, chaque neurone dans une couche est connecté à tous les neurones de la couche précédente et de la couche suivante, à l'exception des couches d'entrée et de sortie. Ces connexions sont pondérées par des poids qui sont ajustés pendant l'apprentissage pour optimiser les performances du réseau [47].

Les origines des réseaux de neurones artificiels remontent aux travaux de Warren McCulloch et Walter Pitts en 1943. Ils ont publié un article décrivant un modèle mathématique de neurone, montrant comment des neurones idéalisés pouvaient être connectés pour effectuer des calculs logiques. Ce modèle a jeté les bases de la théorie des réseaux de neurones.

En 1958, Frank Rosenblatt a conçu le premier modèle de réseau de neurones pratique, connu sous le nom de perceptron. Il s'agissait d'un réseau à une seule couche composé de neurones binaires, capable d'apprendre et de classer des données en fonction de leurs caractéristiques. Cependant, dans les années 1960, les limites des réseaux de neurones à une seule couche ont été mises en évidence par Marvin Minsky et Seymour Papert dans leur livre intitulé "Perceptrons". Ils ont montré que ces réseaux étaient limités dans leur capacité à résoudre des problèmes non linéaires complexes. La recherche sur les réseaux de neurones a connu un renouveau dans les années 1980 grâce aux travaux de John Hopfield. Il a proposé des réseaux de neurones associatifs, également appelés réseaux de Hopfield, qui étaient capables de stocker et de récupérer des motifs à partir de mémoires.

En 1986, David Rumelhart, Geoffrey Hinton et Ronald Williams ont publié un article majeur introduisant l'algorithme de rétropropagation de l'erreur. Cet algorithme permettait de former efficacement des réseaux de neurones à plusieurs couches en ajustant les poids des connexions en fonction de l'erreur de prédiction. Cela a ouvert la voie aux réseaux de neurones profonds, capables de modéliser des relations complexes et de résoudre des problèmes plus difficiles.

Au cours des années 1990, la recherche sur les réseaux de neurones a été stimulée par des avancées significatives dans les algorithmes d'apprentissage, les architectures de réseau et les capacités de calcul. Les réseaux de neurones étaient utilisés dans des domaines tels que la reconnaissance de la parole, la vision par ordinateur, la modélisation du langage naturel et la prédiction de séries temporelles.

Au début des années 2000, l'apprentissage profond est devenu une branche importante des réseaux de neurones. Des architectures plus complexes, telles que les réseaux de neurones convolutifs (CNN) pour le traitement d'images et les réseaux de neurones récurrents (RNN)

pour le traitement de séquences, ont été développées. Ces avancées ont permis des percées dans des domaines tels que la reconnaissance d'objets, la traduction automatique et la génération de texte.

2.3 Fonctionnement d'un réseau de neurones

Le fonctionnement d'un réseau de neurones commence par la présentation des données à la couche d'entrée du réseau. Chaque neurone de cette couche reçoit une ou plusieurs valeurs d'entrée, qui sont ensuite pondérées par des poids de connexion spécifiques à ce neurone. Les poids déterminent l'importance relative de chaque entrée pour le neurone [48].

Ensuite, chaque neurone de la couche d'entrée transmet ses sorties pondérées à tous les neurones de la couche suivante, qui appliquent chacun une fonction d'activation non linéaire aux entrées pondérées. Cette fonction d'activation permet aux neurones de prendre des décisions non linéaires basées sur leurs entrées pondérées.

Le processus de pondération et de transmission des sorties se répète couche après couche jusqu'à ce que les sorties atteignent la couche de sortie du réseau, où elles sont interprétées comme la réponse du réseau à l'entrée présentée.

Durant l'apprentissage du réseau, les poids de connexion sont ajustés de façon itérative en utilisant des méthodes d'optimisation telles que la descente de gradient. L'objectif principal est de trouver les valeurs de poids qui minimisent la fonction de coût, qui mesure l'écart entre les sorties prédites par le réseau et les sorties attendues pour les données d'entraînement.

Une fois que le réseau a été entraîné sur un ensemble de données, il peut être utilisé pour effectuer des prédictions sur de nouvelles données qui n'ont pas été utilisées lors de l'apprentissage [49].

2.4 Structure d'un neurone artificiel

Un neurone artificiel est une unité de traitement d'informations dans un réseau de neurones artificiels. Il est généralement composé de trois parties principales : les entrées, la fonction de sommation pondérée et la fonction d'activation.

Les entrées du neurone artificiel sont les valeurs qui sont présentées à l'unité pour être traitées. Chaque entrée est associée à un poids qui représente l'importance relative de cette entrée pour le neurone. Ces poids sont ajustés pendant l'apprentissage pour optimiser les performances du réseau.

La fonction de sommation pondérée calcule la somme pondérée des entrées et de leurs poids. Cette somme pondérée est ensuite utilisée comme entrée pour la fonction d'activation du neurone [50-51].

La fonction d'activation du neurone est une fonction non linéaire qui transforme la somme pondérée des entrées en une sortie. Cette fonction permet au neurone de prendre des décisions non linéaires sur la base de ses entrées pondérées.

Le neurone artificiel est donc un bloc de construction essentiel des réseaux de neurones, qui permet de transformer des entrées en sorties en utilisant des poids et des fonctions non linéaires.




Figure .2.1 : L'architecture d'un neurone artificiel.

La formulation mathématique du neurone est donnée par la relation suivante :

$$s = \sum_{i=1}^n w_i In_i \quad (2.1)$$

Avec : S : La sortie du neurone

In_i ($i=1..n$) : Les entrées du neurone

w_i : poids synaptiques reliant les entrées aux neurones

f : représente la fonction d'activation

2.5 Types de fonction de transfert

Les fonctions de transfert, également appelées fonctions d'activation, sont des fonctions mathématiques qui sont appliquées à la somme pondérée des entrées d'un neurone pour calculer sa sortie. En général, Les réseaux de neurones artificiels utilisent couramment différents types de fonctions d'activation [52-53]. Voici quelques exemples :

2.5.1 Fonction Sigmoidé

La fonction sigmoïde est une fonction en forme de S et elle produit une sortie dans l'intervalle $[0, 1]$, ce qui la rend utile pour modéliser des problèmes de classification binaire.

2.5.2 Fonction Tangente hyperbolique

La fonction tangente hyperbolique est similaire à la fonction sigmoïde, mais elle comprime les valeurs d'entrée dans la plage $[-1, 1]$. Elle est souvent utilisée dans les réseaux de neurones pour effectuer une classification multiclassée.

2.5.3 Fonction ReLU (Rectified Linear Unit)

La fonction ReLU est une fonction non linéaire qui renvoie la valeur d'entrée si elle est positive, et 0 sinon. Elle est actuellement l'une des fonctions de transfert les plus populaires dans les réseaux de neurones en raison de sa simplicité et de son efficacité.

2.5.4 Fonction Softmax

La fonction softmax est une fonction qui transforme les valeurs d'entrée en une distribution de probabilité en sortie. Elle est souvent utilisée pour effectuer une classification multiclassée.

Il existe également de nombreuses autres fonctions de transfert, chacune avec ses avantages et ses inconvénients en fonction de la tâche à réaliser et de l'architecture du réseau.

2.6 Topologies de connexion dans les réseaux de neurones

On classe généralement les réseaux de neurones en deux grandes familles: les réseaux de neurones non bouclés et les réseaux de neurones bouclés.

2.6.1 Réseaux de neurones bouclés

Les réseaux bouclés, également appelés réseaux récurrents, sont des types de réseaux de neurones où les sorties des neurones sont réintroduites comme entrées pour les mêmes neurones ou d'autres neurones dans la même couche ou dans une couche précédente. Cette boucle de rétroaction permet au réseau de prendre en compte l'historique des entrées et de produire des sorties qui dépendent de l'état précédent du réseau [54].

Les réseaux récurrents, également connus sous le nom de réseaux de neurones récurrents, sont un type de modèle de ANN qui utilisent des connexions récurrentes pour traiter des données séquentielles ou temporelles.

Les réseaux bouclés sont particulièrement utiles pour les tâches de traitement de séquences, telles que la reconnaissance de la parole, la traduction automatique et la prédiction de séries temporelles.

La Figure 2.2 présente un exemple de réseau de neurones récurrents comprenant deux entrées, une couche cachée de trois neurones et une couche de sortie de deux neurones. Les connexions de rétroaction de ce réseau sont établies à la fois entre les neurones de la couche cachée et ceux de la couche de sortie [55]




Figure 2.2 : Réseau de neurones récurrent

2.6.2 Réseau de neurones non bouclés

Dans les réseaux non bouclés, les connexions entre les neurones se font uniquement dans une direction, de l'entrée vers la sortie, sans boucles de rétroaction. Les signaux se propagent à travers les couches de neurones de manière unidirectionnelle, sans tenir compte de la dynamique temporelle des données en entrée.

Les réseaux non bouclés sont souvent utilisés dans des tâches de classification, de reconnaissance de motifs et de prédiction, où les données d'entrée peuvent être traitées indépendamment les unes des autres. Par exemple, dans la classification d'images, chaque image est traitée individuellement sans tenir compte de son ordre ou de son contexte par rapport aux autres images [55-56].

Dans la figure 2.3, on peut observer un exemple de réseau de neurones non bouclés avec trois couches. [57].




Figure. 2.3 : Réseau de neurones non bouclé

2.7 Apprentissage de réseaux de neurones

L'apprentissage de réseaux de neurones est en effet un domaine de l'intelligence artificielle qui se concentre sur l'entraînement de RNA afin de leur permettre d'effectuer des tâches spécifiques.

Le processus d'apprentissage des réseaux de neurones consiste à ajuster les poids et les biais des neurones du réseau afin de minimiser l'erreur entre les prédictions du réseau et les valeurs de référence [58].

On distingue deux grandes classes d'apprentissage :

- L'apprentissage supervisé.
- L'apprentissage non supervisé

2.7.1 Apprentissage supervisé

Dans ce type d'apprentissage, les données d'entraînement sont fournies avec des étiquettes ou des réponses connues, ce qui permet au réseau de neurones de trouver une correspondance entre les entrées et les sorties [04].

Lors de l'apprentissage supervisé, la tâche de la machine consiste à trouver la fonction de correspondance entre les entrées et les sorties. Le réseau de neurones apprend à partir d'un ensemble de données d'entraînement et utilise ces données pour généraliser et effectuer des prédictions précises sur des données inconnues.

Les applications courantes de l'apprentissage supervisé incluent la classification, la régression, la reconnaissance vocale et la reconnaissance d'images.

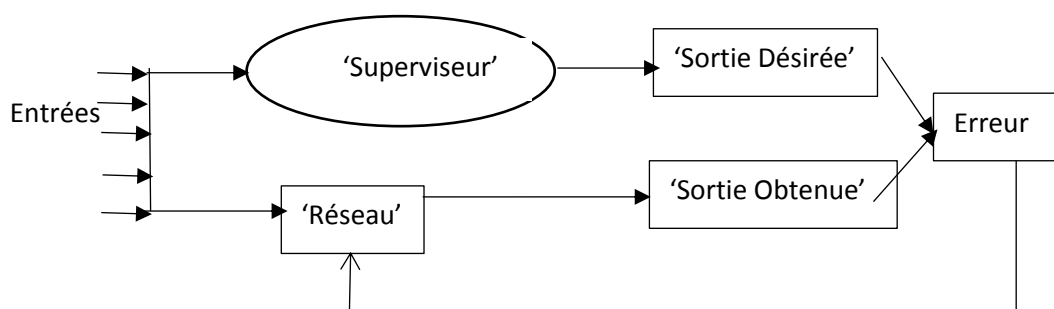


Figure .2.4 : Apprentissage de réseaux de neurones supervisé

2.7.2 Apprentissage non-supervisé

L'apprentissage non supervisé est une méthode d'apprentissage automatique où les données d'entraînement ne sont pas étiquetées avec des réponses connues. Son objectif principal

est de découvrir des structures intéressantes dans les données, telles que des motifs et des groupes.

Contrairement à l'apprentissage supervisé, le réseau de neurones n'est pas alimenté avec des étiquettes de sortie pendant le processus d'apprentissage. Au lieu de cela, le réseau apprend directement à partir des caractéristiques des données elles-mêmes, sans la supervision d'un expert humain [58-59].

L'apprentissage non supervisé est largement utilisé dans divers domaines tels que la détection d'anomalies, la segmentation d'images, la compression de données et la réduction de dimensionnalité. Cette méthode permet de découvrir des relations cachées et des structures intéressantes dans les données, ce qui peut améliorer la compréhension et la prise de décision.

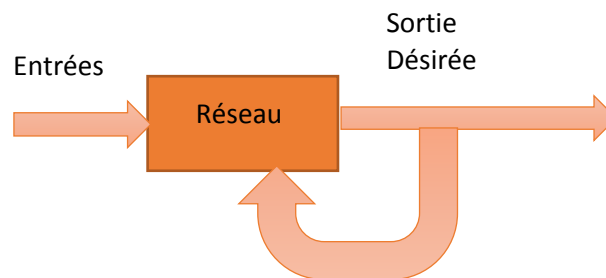


Figure 2.5 : Apprentissage non-supervisé

2.8 Conception d'un réseau de neurones

La conception d'un réseau de neurones implique les étapes suivantes (figure 2.6) [60-61-62]:

- Déterminer les entrées et les sorties pertinentes : il s'agit d'identifier les variables ou grandeurs qui ont une influence significative sur le phénomène que l'on cherche à modéliser. Ces entrées seront les données d'entrée du réseau, et les sorties seront les résultats attendus.
- Collecter les données : il est nécessaire de rassembler les données pour l'apprentissage d'un réseau de neurones.
- Sélectionner le nombre de neurones cachés: il est important de choisir le nombre approprié de neurones dans la couche cachée du réseau pour obtenir une approximation satisfaisante du phénomène étudié. Cela peut nécessiter des ajustements et des tests pour trouver la configuration optimale.
- Réaliser l'apprentissage : cette étape consiste à entraîner le RNA en utilisant les données collectées. Les poids et les biais des neurones sont ajustés itérativement à l'aide d'algorithmes d'apprentissage tels que la rétropropagation du gradient, afin de minimiser

l'erreur entre les sorties du réseau et les résultats attendus.

- Évaluer les performances du réseau de neurones : une fois l'apprentissage terminé, il est important d'évaluer les performances du réseau en utilisant des données de validation ou de test.

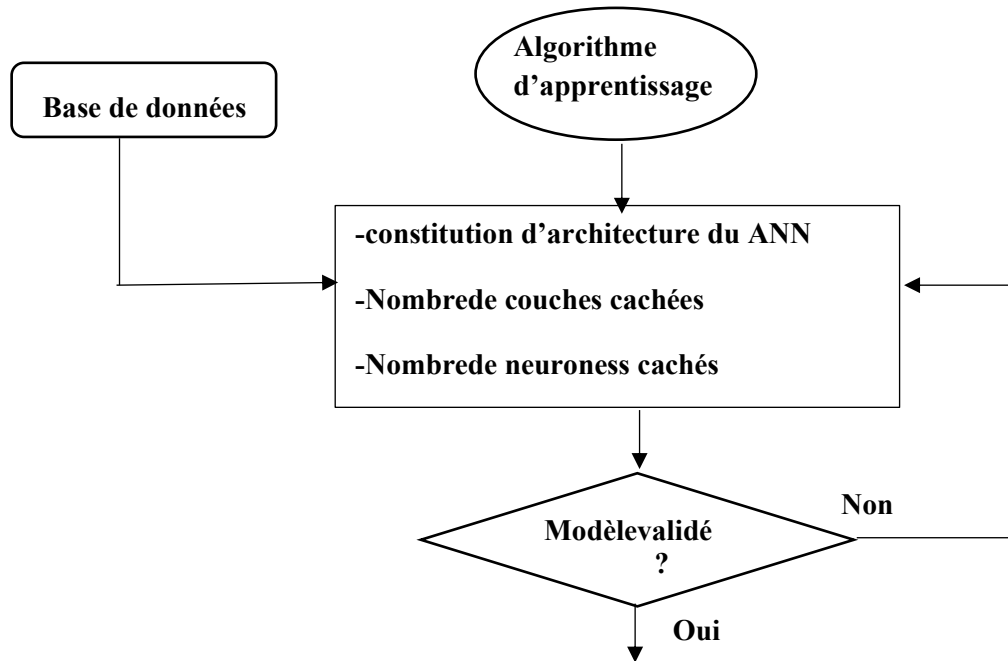


Figure. 2.6 : Planification de conception d'un réseau de neurones.

2.9 Quelques types de réseaux de neurones

Il existe plusieurs types de réseaux de neurones, chacun étant adapté à des tâches spécifiques, les types les plus courants sont:

2.9.1 Perceptron multicouche

Le perceptron multicouche, également connu sous le nom de MLP (Multi-Layer Perceptron), est un type de réseau de neurones artificiels qui comprend une ou plusieurs couches de neurones intermédiaires, appelées couches cachées, en plus de la couche d'entrée et de la couche de sortie. Dans un MLP, chaque neurone dans une couche est connecté à tous les neurones de la couche précédente et de la couche suivante par des connexions pondérées. Ces poids, représentés par les notations (W_{ij} et W_{jk}) [63-64-65].

L'exemple d'un MLP (Perceptron Multi-Couches) présenté dans la figure 2.7.




Figure 2.7: Perceptrons multicouches.

2.9.1.1 Architectures de MLP

Les MLP sont utilisés pour les tâches de classification et de régression, et peuvent avoir différentes architectures, notamment :

2.9.1.1.1 Réseaux de propagation avant (Feed Forward Neural Networks-FFNN)

Les réseaux de propagation avant (ou feedforward networks en anglais) sont une classe de réseaux de neurones artificiels dans lesquels l'information circule de manière unidirectionnelle, de l'entrée vers la sortie, sans boucles de rétroaction. [66].

Un réseau de propagation avant est constitué de différentes couches de neurones, comprenant généralement une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie.

Les réseaux FFNN sont souvent utilisés pour des tâches de classification et de régression, ainsi que pour des tâches plus complexes telles que la reconnaissance d'images et la compréhension du langage naturel [67].

2.9.1.1.2 Réseaux en cascade et à propagation avant (Cascade-Forward Artificial Neural Networks- CFNN)

Sont un type de réseau de neurones artificiels qui combinent les caractéristiques des réseaux de neurones en cascade et des réseaux d'alimentation avant (FFNN). Les CFNN ont été proposés pour résoudre les problèmes de classification et de régression.

Le principe de base des CFNN consiste à utiliser un réseau de neurones en cascade pour filtrer les données en entrée avant de les transmettre à un réseau d'alimentation avant (FFNN) pour la classification ou la régression. Dans le réseau de neurones en cascade, chaque couche est formée de neurones qui effectuent une opération de seuillage sur les entrées. Cette opération permet de sélectionner les caractéristiques les plus importantes pour la tâche à accomplir [68].

Les avantages des CFNN sont qu'ils peuvent traiter des données complexes, tout en réduisant le nombre de caractéristiques d'entrée. De plus, la structure en cascade permet d'obtenir une architecture de réseau de neurones plus simple et plus efficace, réduisant ainsi les coûts de calcul.

Cependant, la conception d'un CFNN nécessite une expertise en matière de sélection de caractéristiques et de réglage des paramètres de seuillage, ce qui peut être difficile. De plus, les performances des CFNN peuvent être sensibles au choix de l'ordre de cascade et au nombre de couches, nécessitant une exploration approfondie de l'espace des hyperparamètres pour obtenir les meilleurs résultats.




Figure 2.8: Réseaux de propagation avant




Figure 2.9: Réseaux en cascade et à propagation avant

2.9.2 Réseau à fonction de base radiale (RBF)

2.9.2.1 Présentation des réseaux RBF

Les réseaux de neurones à fonctions de base radiales (Radial Basis Function Neural Networks - RBFNN) ont été en effet proposés pour la première fois par Broomhead et Lowe en 1988. Ils ont introduit cette approche qui utilise des fonctions de base radiales pour effectuer des calculs dans le cadre des réseaux de neurones. Contrairement au MLP, qui utilise des fonctions d'activation pour modéliser les relations non linéaires, le réseau RBF utilise des fonctions de base radiales pour représenter les motifs et les relations des données. [68-69].

Le réseau RBF est généralement composé de trois couches (figure 2.10). La première couche est la couche d'entrée qui reçoit les données d'entrée. La deuxième couche est la couche cachée qui contient des neurones appelés "neurones de base radiale". La troisième couche est la couche de sortie qui génère les prédictions ou les estimations [70-71].

Les neurones de base radiale sont des neurones spécialisés qui utilisent des fonctions de base radiales pour calculer leurs activations. La fonction de base radiale la plus couramment utilisée est la fonction gaussienne. Chaque neurone de base radiale a un centre et une largeur définis, et sa sortie est basée sur la distance entre l'entrée et son centre, calculée en utilisant la fonction gaussienne.

Les réseaux RBF se distinguent par leur architecture spécifique. Chaque nœud dans la couche d'entrée est connecté à tous les nœuds de la couche cachée, formant ainsi une connexion complète [72]. Cependant, il n'y a pas de connexions directes entre les nœuds de la même couche.




Figure. 2.10 : structure d'un RBFNN

Le modèle de réseau de neurones à fonctions de base radiales (RBF) est caractérisé par quatre paramètres principaux sont :

- Les centres des neurones de base radiale
- Les largeurs des neurones de base radiale
- Les poids des connexions entre la couche cachée et la couche de sortie
- Les fonctions de base radiales qui sont utilisées pour calculer les activations des neurones de la couche cachée. Elles dépendent de la distance entre l'entrée et le centre associé à chaque neurone.

Le réseau RBF est souvent utilisé pour des tâches de classification, de régression. Il est particulièrement adapté aux problèmes où les relations entre les variables d'entrée et de sortie sont non linéaires et complexes. Cependant, le réseau RBF peut nécessiter un réglage minutieux des hyperparamètres, tels que le nombre de neurones de base radiale et les valeurs de leurs centres et de leurs largeurs, pour obtenir de bonnes performances [73].

2.9.2.2 Réseaux de neurones de régression généralisée (GRNN)

Les réseaux de neurones de régression généralisée (Generalized Regression Neural Networks - GRNN) sont un type spécifique de réseau de neurones utilisé pour effectuer des tâches de régression. Ils ont été introduits par Specht en 1991[73-74].

La particularité des réseaux GRNN réside dans leur approche non linéaire pour la régression. Contrairement aux réseaux de neurones traditionnels, les GRNN utilisent une fonction de base radiale (RBF) spécifique appelée la fonction de base radiale gaussienne (Gaussian Radial Basis Function - GRBF).

L'architecture des réseaux GRNN comprend une couche d'entrée, une couche cachée et une couche de sortie. La couche d'entrée reçoit les données d'entrée et les transmet à la couche cachée. Chaque neurone de la couche cachée est associé à un vecteur de poids et à un centre de RBF. La couche cachée calcule les distances entre les données d'entrée et les centres RBF, puis applique la fonction de base radiale gaussienne pour produire les activations des neurones de la couche cachée.

La couche de sortie des réseaux GRNN effectue une moyenne pondérée des activations des neurones de la couche cachée, en utilisant des poids de sortie. Cette moyenne pondérée donne une estimation de la valeur de sortie pour une tâche de régression.

Les avantages des GRNN sont leur capacité à modéliser des fonctions non linéaires complexes et leur rapidité d'apprentissage. Cependant, ils peuvent présenter une complexité computationnelle élevée lorsque le nombre de données est important, et leur utilisation nécessite une connaissance préalable de la méthode de sélection des centres de neurones.

Les GRNN sont largement utilisés dans des applications telles que la prédiction de séries temporelles, la modélisation de données environnementales et la reconnaissance de formes.

2.9.2.3 Architecture de GRNN

L'architecture de réseau de neurones de régression généralisée (GRNN) est composée de quatre couches principales :

- La couche d'entrée : cette couche reçoit les données d'entrée et les transmet à la couche suivante. Chaque nœud dans cette couche correspond à une variable d'entrée.
- La couche de modélisation de densité de probabilité (Probability Density Model - PDM) : cette couche est la partie centrale de l'architecture GRNN. Elle est composée de neurones ayant une fonction d'activation gaussienne qui modélisent la densité de probabilité des données d'entrée.
- La couche de sommation pondérée (Weighted Sum - WS) : cette couche calcule une somme pondérée des sorties de la couche PDM, en utilisant les poids qui ont été calculés lors de l'entraînement.
- La couche de sortie : cette couche calcule la sortie finale du réseau de neurones, qui est une estimation de la valeur de sortie souhaitée.

L'utilisation de la fonction de type kernel dans les GRNN permet d'accélérer la phase d'apprentissage du réseau. De plus, la sortie de cette fonction kernel fournit une estimation du degré de correspondance entre le vecteur d'entrée inconnu et la distribution déterminée par le modèle [74].

Tout comme le réseau MLP, le réseau GRNN nécessite également un entraînement avant d'être utilisé pour des tâches de prédiction ou de modélisation, il faut fixer un unique paramètre : le « spread ». Ce paramètre définit la largeur des fonctions de base radiale (RBF) utilisées dans le réseau.

Lors de l'entraînement d'un réseau GRNN, il est nécessaire de fixer un paramètre appelé "spread" ou "écart-type". Ce paramètre détermine la largeur des fonctions de base radiale (RBF) utilisées dans le réseau.

Il est important de noter que le réseau GRNN a tendance à être plus lent à l'entraînement que d'autres types de réseaux de neurones, en raison de la nécessité de calculer les distances entre chaque point de données d'entraînement et chaque neurone RBF. Cependant, une fois que le réseau GRNN est correctement entraîné, il peut être très efficace pour prédire des valeurs pour de nouvelles données. [73-74].

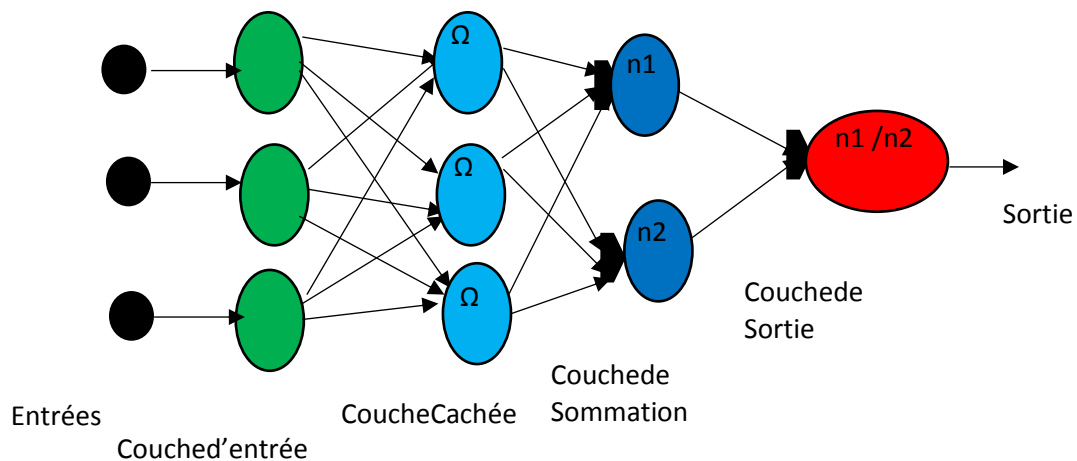


Figure. 2.11. Architecture du GRN

2.10 Prédiction de U_c avec un réseau de neurones à couches multiples

La figure 2.12 présente l'architecture du MLP, où Les variables d'entrée sont la quantité de pollution ($Q1, Q2, Q3$) et la conductivité (δ), tandis que la variable de sortie est U_c .




Figure 2. 12 : Architecture de MLP

Nous utilisons deux bases de données distinctes. La première est destinée à l'apprentissage du ANN et comprend $4 \cdot 10^3$ entrées correspondantes ($\delta, Q1, Q2, Q3$) et 10^3 sorties correspondantes (valeurs " U_c " choisies). La seconde est utilisée pour évaluer la capacité du ANN à prédire U_c et est constituée de $4 \cdot 18$ entrées.

2.10.1 Elaboration de la structure du réseau de neurones

Le processus d'élaboration d'un réseau de neurones commence toujours par le choix et la préparation des échantillons de données. La structure de l'échantillon détermine le type de réseau, le nombre de neurones en entrée, le nombre de neurones en sortie, ainsi que la méthode d'apprentissage, de test et de validation.

Il est nécessaire de déterminer le nombre de couches cachées et le nombre de neurones dans chaque couche.

2.10.1.1 Nombre de neurones cachés et de couches cachées

Nous avons effectué une série de tests afin de déterminer les paramètres optimaux du réseau, notamment le nombre de neurones cachés et le nombre de couches cachées, dans le but d'obtenir une prédiction satisfaisante.

Nous avons varié le nombre de neurones cachés de 2 à 10 et le nombre de couches cachées de 2 à 6, avec 6000 itérations, comme présenté dans le tableau (2.1).

Tableau 2.1 Évaluation de l'erreur à partir d'une série de tests

Nombre de couches \ Nombre de neurones	2	3	4	6
2	1.7481	0.7622	0.2045	0.1812
4	0.813	0.0457	0.0154	0.245
6	0.146	0.422	$1.564 \cdot 10^{-3}$	0.2866
8	0.8133	0.6543	$2.55 \cdot 10^{-4}$	0.1553
10	$6.5734 \cdot 10^{-3}$	0.3645	0.0435	0.0436

Selon le tableau 2.1, qui présente les résultats de la série d'apprentissage pour différents réseaux, on observe que l'erreur la plus faible est de $2.55 \cdot 10^{-4}$. Ces résultats suggèrent que le réseau de neurones atteint son optimum avec 04 couches et 08 neurones dans les couches cachées.

2.10.2 Création du réseau de neurones perceptrons multicouche (MLP) sous l'environnement MATLAB

Voici les paramètres que nous avons utilisés pour le réseau de neurones (MLP) :

Tableau 2.2 Paramètres de la structure et de l'apprentissage du MLP

Nombre d'entrées disponibles	04*103
Nombre de sortie	01*103
Algorithme d'entraînement.	Levenberg-Marquardt (TRAINLM)
Fonction d'ajustement des poids et des seuils.	LEARNGDM
Fonction de Performance	Erreur-quadratique-moyenne (MSE)
Fonctions de Transfert	Fonction de transfert sigmoïde (LOGSIG) pour les couches cachées. Fonction de transfert linéaire (PURELIN) pour la couche de sortie.
Nombre d'itération	6000
Nombre de couches intermédiaires	04
Nombre de neurones par couches cachées	08

2.10.2.1 Type du réseau de neurones

Pour sélectionner le type de réseau, il est possible d'utiliser un menu disponible dans l'environnement MATLAB (figure 2.13). Ce menu présente trois fonctions différentes

FFANN: *Feedforward artificial neural networks*

CFANN: *Cascade-forward artificial neural networks*

GRNN : *General regression neural networks*

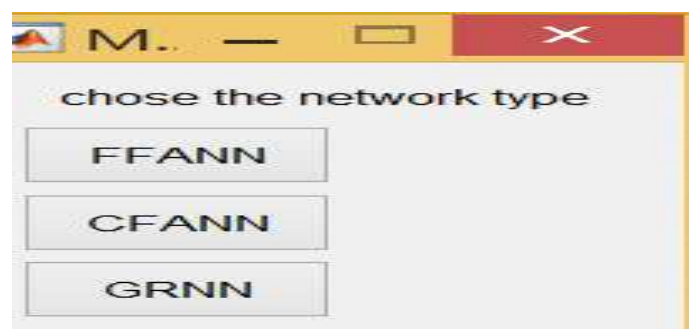


Figure 2. 13 : Interface de sélection du type de réseau dans MATLAB

2.10.2.1.1 Réseau de neurones à propagation avant (Feed Forward Neural Network FFNN)

Lorsque la fonction FFANN est sélectionnée, l'interface de l'approche de réseau de neurones à propagation avant est représentée dans la figure 2.14

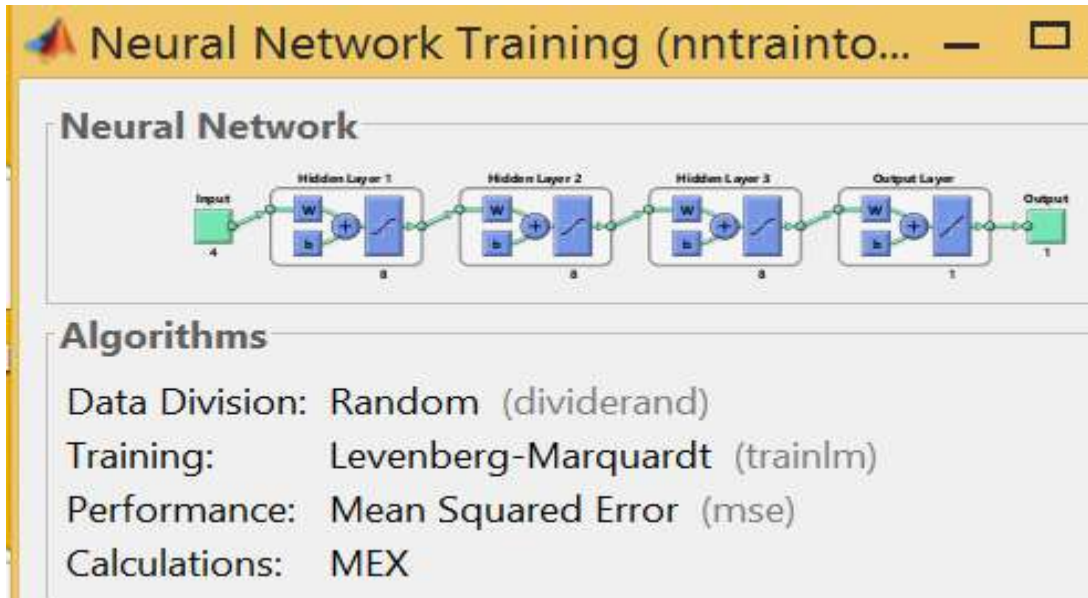


Figure 2.14 : Interface pour le réseau de neurones à propagation avant.

2.10.2.1.2 Réseau de neurones artificiel en cascade (*cascade-forward artificial neural network* –CFNN)

Si l'on utilise la fonction CFANN (figure 2.13), l'interface de l'approche en cascade pour le réseau de neurones est représentée dans la figure 2.15.

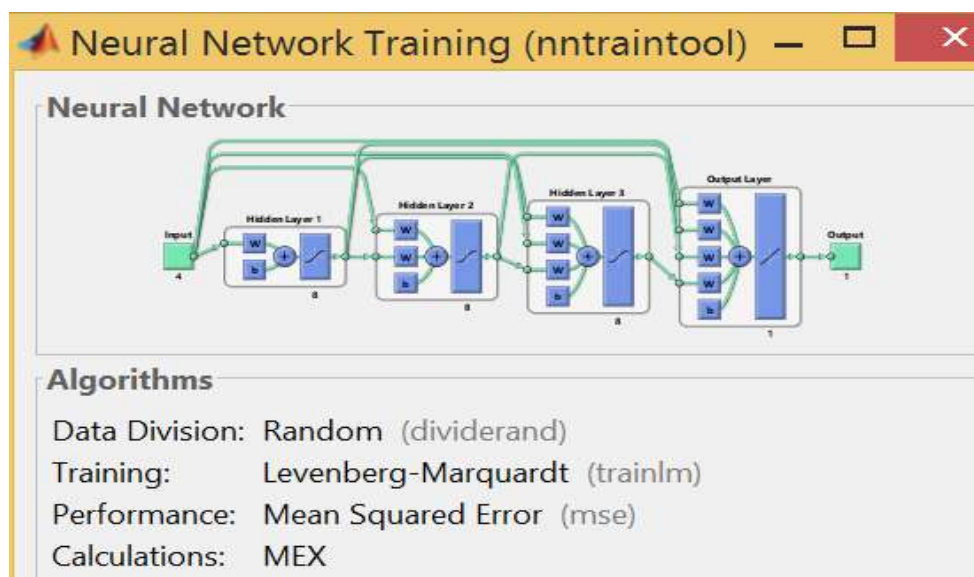


Figure 2.15 : Interface du réseau de neurones en cascade

2.10.3 Résultats et discussions

2.10.3.1 Racine carrée de l'erreur quadratique moyenne (RMSE)

Le RMSE (Root Mean Square Error), ou erreur quadratique moyenne, est une mesure qui prend en compte chaque erreur en la multipliant par elle-même (élevée au carré). Cette approche accorde un poids plus important aux erreurs importantes par rapport aux erreurs mineures, offrant ainsi une mesure plus sensible aux écarts importants entre les valeurs réelles et prédites [75].

L'erreur RMSE est calculée en prenant la racine carrée de la moyenne des erreurs quadratiques:

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2} \quad 2.2$$

Où y_t représente la valeur réelle de l'observation t , \hat{y}_t est la valeur prédite correspondante, et N est le nombre total d'observations.

2.10.3.2 Coefficient de détermination (R^2)

Le coefficient de détermination, noté R^2 , est une mesure statistique utilisée pour évaluer à quel point les valeurs observées sont proches des valeurs prédites par un modèle de régression.

R^2 égal à 1 indique que le modèle explique parfaitement la variance de la variable dépendante, tandis qu'un R^2 égal à 0 indique que le modèle ne fournit aucune explication de la variance de la variable dépendante.

$$R^2 = 1 - \frac{\sum_{i=1}^{NU} (y_{tes,k} - \overline{y_{pre,k}})^2}{\sum_{i=1}^{NU} (y_{tes,k} - \overline{y_{tes,k}})^2} \quad 2.3$$

Où $\overline{y_{tes,k}}$ est la valeur moyenne de toutes les données.

2.10.3.3 L'erreur MAPE

L'erreur MAPE (Mean Absolute Percentage Error) est une mesure de l'erreur utilisée pour évaluer la précision d'un modèle de prévision. Elle quantifie la moyenne des pourcentages d'écarts absolus entre les valeurs réelles et les valeurs prédites, exprimée en pourcentage.

L'erreur moyenne de pourcentage absolu est calculée à l'aide de l'équation suivante:

$$MAPE = 100\% \cdot \frac{\sum_{k=1}^m |y_{tes,k} - y_{pre,k}| / y_{tes,k}}{m} \quad 2.4$$

Le tableau 2.3 présente les erreurs quadratiques moyennes (MSE) calculées par les deux types de réseaux de neurones.

Tableau 2.3 : Comparaison du critère de performance (MSE) pour les deux types de MLP

Valeur de tension lors des tests (kV)	Prédiction de la tension à l'aide de FFANN (kV)	Erreur quadratique (MSE) à l'aide de FFANN	Prédiction de la tension à l'aide de CFANN (kV)	Erreur quadratique (MSE) à l'aide de FFANN
45.8000	46.0935	0.0861	46.28816	0.2383
39.7000	40.60138	0.8125	39.536349	0.0268
34.8000	35.2860	0.2362	35.91840	1.2508
34.0000	33.75978	0.0577	33.72823	0.0739
26.0000	25.73298	0.0713	30.29949	18.4856
23.0000	21.93337	1.1377	23.55617	0.3093
19.0000	18.99919	0.0000	18.893236	0.0114
19.7000	19.6845	0.0002	19.93376	0.0546
17.5000	17.43215	0.0046	18.017199	0.2675
39.5000	39.52849	0.0008	39.50283	0.0000
36.2000	36.25003	0.0025	36.197549	0.0000
33.7000	33.710197	0.0001	33.99922	0.0895
39.4000	39.44040	0.0016	39.58932	0.0358
38.0000	37.98404	0.0003	38.16707	0.0279
35.0000	34.81860	0.0329	34.52403	0.2265
38.5000	38.59728	0.0095	38.58630	0.0074
35.4000	35.45309	0.0028	35.33363	0.0044
33.6000	33.548702	0.0026	33.65753	0.0033
	MSE=0.1366 RMSE= 0.3696		MSE =1.1730 RMSE= 1.0830	

Les figures 2.16 et 2.17 illustrent la comparaison entre les valeurs prédites de U_c et les valeurs de test, afin d'évaluer les performances des deux types de réseaux de neurones (FFANN et CFANN).

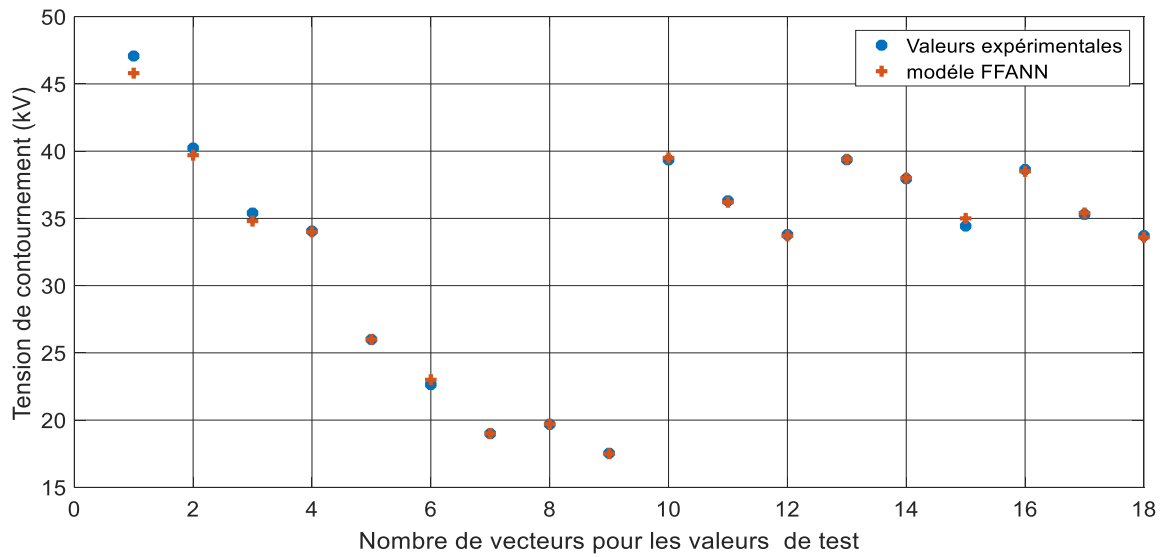


Figure 2.16 : Évaluation des performances de l'approche FFANN pour les tests

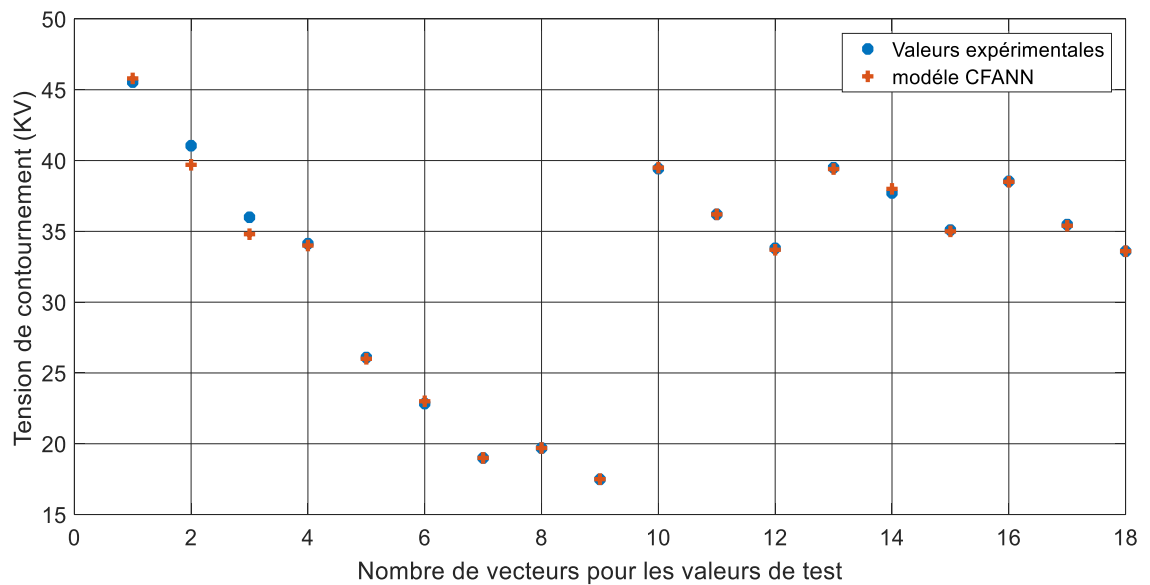


Figure 2.17 : Évaluation des performances de l'approche CFANN pour les tests

On peut observer sur les figures 2.16 et 2.17 une adaptation remarquable des réseaux de neurones aux données de test correspondantes.

Les figures 2.18 et 2.19 présentent la corrélation entre les valeurs estimées et réelles de U_c .

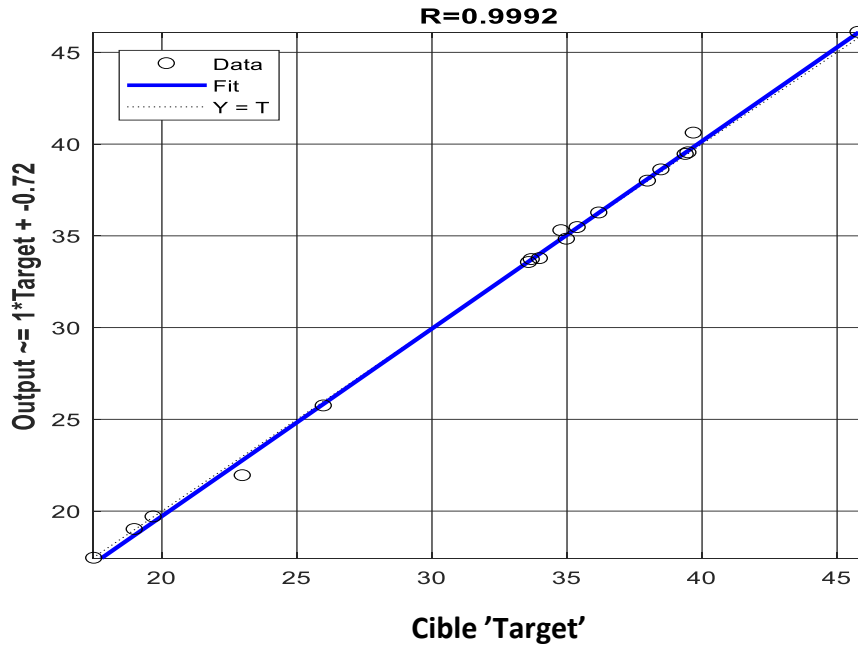


Figure 2.18 : Courbes de regression pour la prédiction de Uc par FFANN.

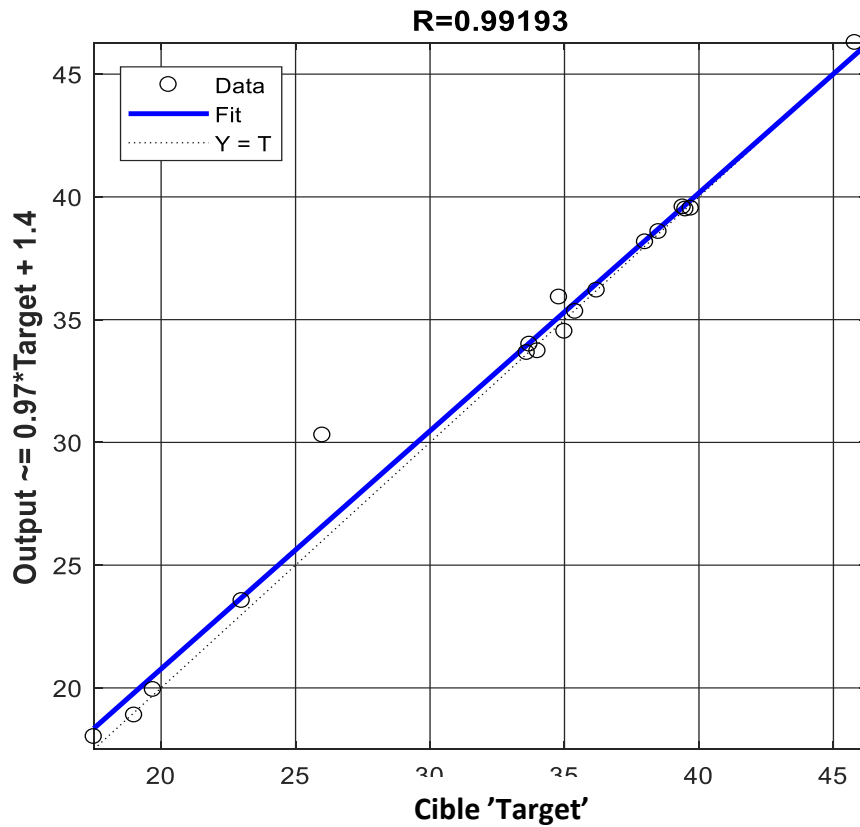


Figure 2.19 : Courbes de regression pour la prédiction de Uc par CFANN

La validation de la performance du réseau construit peut être effectuée à l'aide des courbes de régression (Figure 2.19), où les sorties du réseau sont représentées sur l'axe des ordonnées et les valeurs désirées sur l'axe des abscisses.

- Les cercles noirs sur le graphique correspondent aux valeurs désirées
- Les lignes continues illustrent l'approximation effectuée par le réseau.
- Les lignes en pointillé sur le graphique représentent la courbe d'approximation idéale,

2.11 Prédiction de U_c par réseau de neurones de régression généralisée

2.11.1 Création du GRNN sous MATLAB

En appliquant l'instruction `newgrnn` aux données d'apprentissage et de test, le réseau GRNN est généré. Les caractéristiques de GRNN sont détaillées dans le tableau 2.4.

Tableau 2.4 : Caractéristiques de GRNN

Nombre d'entrées disponibles	04*103
Nombre de sortie	01*103
Valeur du paramètre « spread »	01
Entrées	$\delta, Z1, Z2, Z3$
Sortie	U_c

La représentation graphique de l'architecture du réseau GRNN sous MATLAB est présentée dans la figure 2.20.

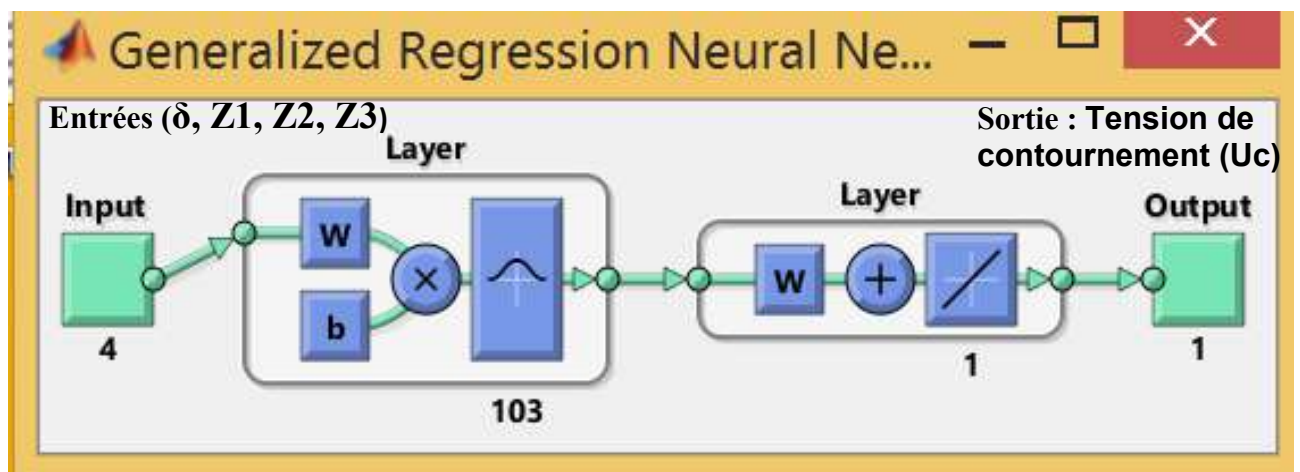


Figure 2.20: Implémentation de l'architecture du réseau GRNN avec MATLAB

2.11.2 Performance du réseau de neurones (GRNN)

Les erreurs quadratiques (MSE) et absolues sont calculées et exposées dans le tableau (2.5).

Tableau 2.5 : Analyse de la performance de GRNN à travers les indicateurs MSE et MAPE.

Valeur de tension lors des tests (kV)	Prédiction de la tension à l'aide d'un GRNN (kV)	Erreur absolue (%)	Erreur quadratique
45,80	45,67720	0,26820	0,01510
39,70	39,32410	0,94690	0,14130
34,80	34,60420	0,56260	0,03830
34	34,3182	0,9360	0,1013
26	26,3544	1,3630	0,1256
23	23,0330	0,1436	0,0011
19	19,0134	0,0704	0,0002
19,7000	19,7137	0,0695	0,0002
17,5000	17,5134	0,0765	0,0002
39,5000	39,5094	0,0239	0,0001
36,2000	36,2094	0,0261	0,0001
33,7000	33,7166	0,0492	0,0003
39,4000	39,4145	0,0367	0,0002
38	38,1089	0,2866	0,0119
35	35,1089	0,3112	0,0119
38,5000	38,4847	0,0398	0,0002
35,4000	35,3847	0,0433	0,0002
33,6000	33,5847	0,0456	0,0002
		MAPE= 0,2944	MSE=0,0249
			RMSE= 0,1578

Dans la Figure 2.21, les résultats expérimentaux de U_c sont présentés, ainsi que la sortie estimée obtenue à l'aide du réseau de neurones (GRNN proposé).




Figure 2.21 : Évaluation des performances de GRNN pour les tests

La Figure 2.21 illustre une excellente adaptation du réseau GRNN à la base de données de test utilisée.

La Figure 2.22 présente la comparaison entre les valeurs mesurées et les estimations de U_c obtenues à l'aide de l'approche GRNN




Figure 2.22: Comparaison entre les valeurs mesurées et les estimations de U_c

La valeur du coefficient de corrélation (R) étant très élevée, de l'ordre de 0.99982, on peut s'attendre à ce que la valeur du coefficient de détermination (R^2) soit encore plus élevée, plus proche de 0.99964. Cette valeur est considérée comme très proche de la valeur idéale de 1 pour le coefficient de détermination, ce qui suggère que la méthode GRNN utilisé est très performante.

2.12 Comparaison entre les trois types GRNN, FFANN et CFANN

En comparant les résultats obtenus à partir de l'approche FFANN et de l'approche CFANN avec ceux obtenus à partir du réseau de neurones GRNN (tableau 2.6), on a pu observer que ce dernier présentait des performances supérieures. En effet, son coefficient de détermination R^2 était d'environ 0.99964, ce qui est non seulement acceptable mais également plus élevé que celui obtenu avec les autres méthodes (FFANN et CFANN).

Tableau 2.6 : Validation des approches GRNN, FFANN et CFANN à l'aide d'indicateurs statistiques

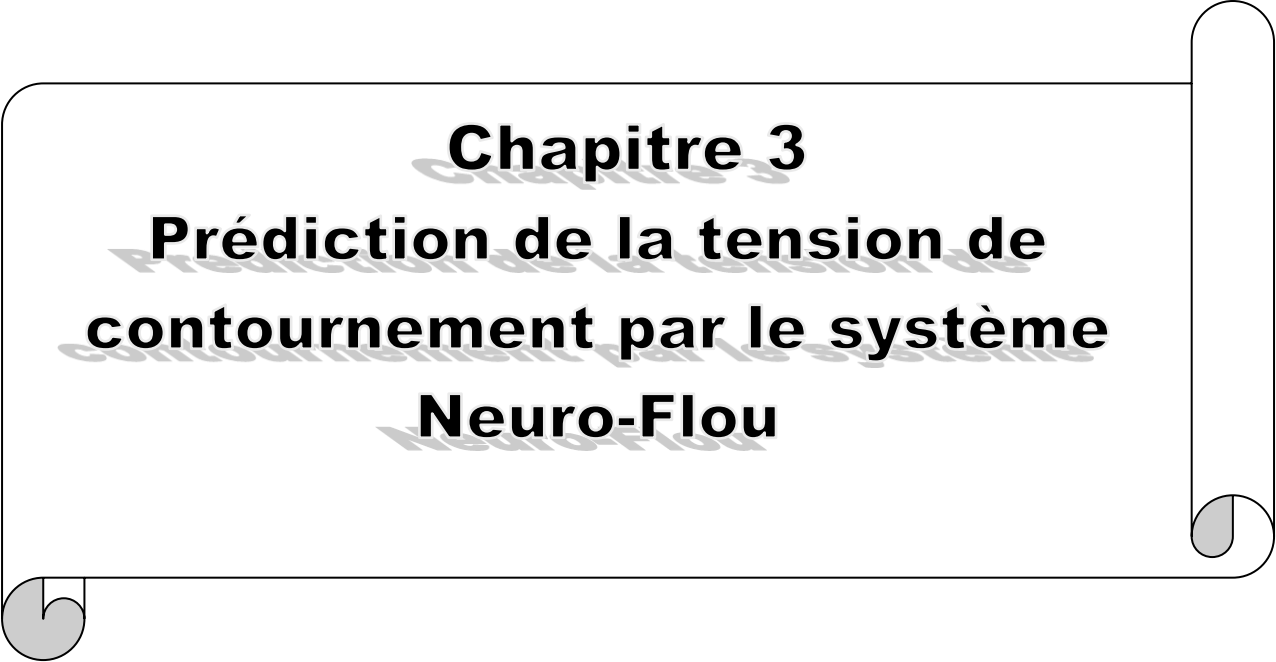
Modèle	Coff. de corrélation (r_{train})	Coff. de corrélation r_{test}	Coff. de détermination (R_{train}) ²	Coff. de détermination (R_{test}) ²	MAPE_test	RMS_test
FFNNA	0.99934	0.9992	0.9986804	0.9984	0.70045	0.369651
CFNNA	0.99508	0.99193	0.9901842	0.983925	1.828589	1.083033
GRNN	0.99991	0.99982	0.99982	0.99964	0.294396	0.157820

L'algorithme d'apprentissage utilisé pour le réseau GRNN est beaucoup plus simple que celui du réseau MLP, ce qui entraîne un temps d'apprentissage nettement plus court pour le GRNN. De plus, la précision obtenue avec le réseau GRNN ne dépend pas des valeurs initiales de ses poids et biais, contrairement au réseau MLP.

2.13 Conclusion

Dans ce chapitre, nous avons utilisé la méthode du réseau de neurones de régression généralisée et du perceptron multicouche pour prédire la tension de contournement. Les résultats de l'étude ont permis d'évaluer la performance des deux types de réseaux.

Le réseau de neurones de type GRNN a montré une performance supérieure par rapport aux FFANN et CFANN, avec un coefficient de détermination (R^2) de 0,99960 lors de la phase de test, tandis que celui du CFANN était d'environ 0,983925.



Chapitre 3
**Prédiction de la tension de
contournement par le système
Neuro-Flou**

3.1 Introduction

ANFIS (Adaptive Neuro-Fuzzy Inference System) est un système d'inférence neuro--flou adaptatif. Il s'agit d'une combinaison de réseaux de neurones artificiels et de systèmes d'inférence flous, qui permet de résoudre des problèmes de classification, de prédiction et de contrôle.

Dans ce chapitre, nous présentons la technique d'intelligence artificielle ANFIS, ainsi que la méthodologie que nous avons suivie pour utiliser le système d'inférence flou et ANFIS afin de prédire la tension U_c des isolateurs pollués des lignes de HT. Nous allons également présenter et interpréter les résultats obtenus au cours de notre travail.

3.2 Systèmes Neuro--Flous

Les systèmes d'inférences flous (SIF) et les réseaux de neurones artificiels (ANN) présentent chacun des avantages distincts. Toutefois, les méthodes hybrides neuronales et floues permettent de combiner ces avantages, en exploitant notamment la capacité d'apprentissage des ANN et la lisibilité et la flexibilité des SIF. De nombreuses combinaisons de ces deux approches ont été étudiées et développées dans la littérature. [76-77].

ANFIS a été développé dans les années 1990 par Jang et al. et depuis ces années a été utilisé dans de nombreux domaines tels que la modélisation de processus, la reconnaissance de formes, la commande de systèmes, la prédiction de séries temporelles, la classification de données, etc. ANFIS est considéré comme une méthode efficace pour la résolution de problèmes complexes, en raison de sa capacité à combiner les avantages des réseaux de neurones et des systèmes d'inférence flous [78-79].

Les systèmes neuro--flous, qui résultent de la combinaison de réseaux de neurones et de logique floue, sont principalement utilisés pour la commande de systèmes complexes et la résolution de problèmes de classification. On peut généralement distinguer quatre grandes catégories de combinaisons entre réseaux de neurones et logique floue :

1. Réseaux de neurones adaptatifs avec des entrées floues : dans cette catégorie, des ensembles flous sont utilisés pour définir les entrées du réseau de neurones. Les ensembles flous permettent de représenter des données incertaines ou imprécises et de les intégrer dans le processus d'apprentissage du réseau de neurones.
2. Réseaux de neurones adaptatifs avec des sorties floues : dans cette catégorie, les sorties du réseau de neurones sont représentées par des ensembles flous. Cette approche permet d'obtenir des résultats plus facilement interprétables et compréhensibles par les humains.

3. Réseaux de neurones adaptatifs avec des entrées et des sorties floues : cette approche combine les deux premières catégories en utilisant des ensembles flous à la fois pour les entrées et les sorties du réseau de neurones.
4. Réseaux de neurones avec des systèmes d'inférences flous : dans cette catégorie, les réseaux de neurones sont intégrés dans des systèmes d'inférences flous pour permettre une prise de décision plus souple et plus adaptée aux données incertaines. Cette approche est particulièrement utile pour la modélisation de systèmes complexes et la prise de décision en temps réel.

3.2.1. Systèmes flous

Les systèmes flous se basent sur des règles linguistiques pour établir des relations entre les variables d'entrée et de sortie.

3.2.1.1 Évolution et avancées de la logique floue

La logique floue a évolué de la manière suivante :

- Dans les années 1960 La logique floue a été développée par Lotfi Zadeh, un mathématicien et informaticien américano-iranien.
- 1965 : Lotfi Zadeh publie l'article fondateur "Fuzzy sets" introduisant les ensembles flous, dans lequel il introduit pour la première fois les ensembles flous en tant que base de la logique floue. Il présente le concept d'appartenance partielle des éléments à un ensemble [80].
- Années 1970 : Les bases théoriques de la logique floue sont développées, avec l'introduction d'opérateurs flous et de règles d'inférence floue.
- 1974 : le professeur Mamdani propose la première application industrielle de la logique floue en définissant la structure de base des régulateurs flous et les principes de la commande floue pour contrôler un générateur de vapeur [81]
- Années 1980 : La logique floue est mise en pratique industrielle, avec des exemples tels que le contrôle d'un four à ciment par l'entreprise Smidth et Co. A.S en 1980.
- 1985 : la logique floue est de plus en plus adoptée dans le milieu industriel, démontrant son efficacité. Elle est utilisée dans des applications de contrôle, de prise de décision et de modélisation dans différents secteurs [82-83].
- 1987 : Le Japon connaît une "explosion du flou" avec de nombreuses applications, notamment le contrôle du métro de Sendai. [84-85].
- Depuis lors, la logique floue continue de se développer et de trouver de nouvelles applications à travers le monde. Elle est utilisée dans des domaines tels que le contrôle

de processus, la robotique, la prise de décision, les systèmes de recommandation, l'intelligence artificielle, etc. Son potentiel pour traiter des situations complexes et incertaines en fait un outil précieux dans de nombreux domaines.

3.2.1.2 Principe de la logique floue

Le principe du réglage par logique floue est basé sur le traitement de variables linguistiques plutôt que de variables logiques binaires. En effet, les variables linguistiques sont plus proches du langage naturel utilisé par les êtres humains, ce qui facilite leur compréhension et leur interprétation.

De plus, les règles utilisées dans la logique floue font souvent référence à une connaissance du comportement du système. Ces règles sont basées sur l'expertise des personnes qui connaissent le système et qui peuvent décrire le comportement attendu de manière intuitive, même si elles ne peuvent pas le définir précisément.

Ainsi, le réglage par logique floue permet de modéliser des systèmes complexes en utilisant une approche plus proche de la manière dont les êtres humains raisonnent [85-86]. Cette approche est souvent plus efficace que les méthodes traditionnelles basées sur la logique binaire.

3.2.1.3 Variables linguistiques

Dans certaines situations, il peut être difficile de donner une description précise d'un phénomène ou d'une grandeur physique. Dans ces cas, il est fréquent d'utiliser des expressions relatives ou floues telles que "grand", "petit", "positif", "négatif", etc. Ces expressions floues peuvent être regroupées en ensembles flous appelés variables linguistiques.

Une variable linguistique est définie par un ensemble comprenant les éléments suivants :

- x : le nom de la variable.
- $T(x)$: l'ensemble des valeurs linguistiques que la variable peut prendre, souvent définies de manière floue. Par exemple, une variable représentant la taille peut avoir des valeurs linguistiques telles que "très grand", "assez petit", etc.
- U : l'univers du discours associé à la valeur de base, c'est-à-dire l'ensemble des valeurs possibles que peut prendre la grandeur physique associée à la variable.
- G : la règle syntaxique pour générer les valeurs linguistiques de la variable. Cette règle peut être définie mathématiquement ou linguistiquement.
- M : la règle sémantique pour associer un sens à chaque valeur linguistique de la variable. Cette règle permet de préciser la signification de chaque terme flou utilisé dans l'ensemble $T(x)$ [86].

La notion de variable linguistique a été introduite par Zadeh, qui a proposé que les valeurs de cette variable ne soient pas numériques, mais plutôt symboliques, en termes de mots ou d'expressions du langage naturel.

Dans de nombreux phénomènes ou processus, il est fréquent d'utiliser des expressions floues telles que "quelque chose", "beaucoup", "souvent", "chaud", "froid", "rapide", "lent", "grand", "petit", etc. Ces expressions forment ce qu'on appelle des termes linguistiques de la logique floue.

La figure (3.1) illustre un exemple de variable linguistique "température" avec quatre termes linguistiques : très froid, froid, chaud et très chaud. Les variables linguistiques et les termes flous associés sont couramment utilisés dans les systèmes d'inférence flous, qui sont utilisés pour modéliser des situations complexes dans lesquelles les données sont incertaines ou imprécises [86].

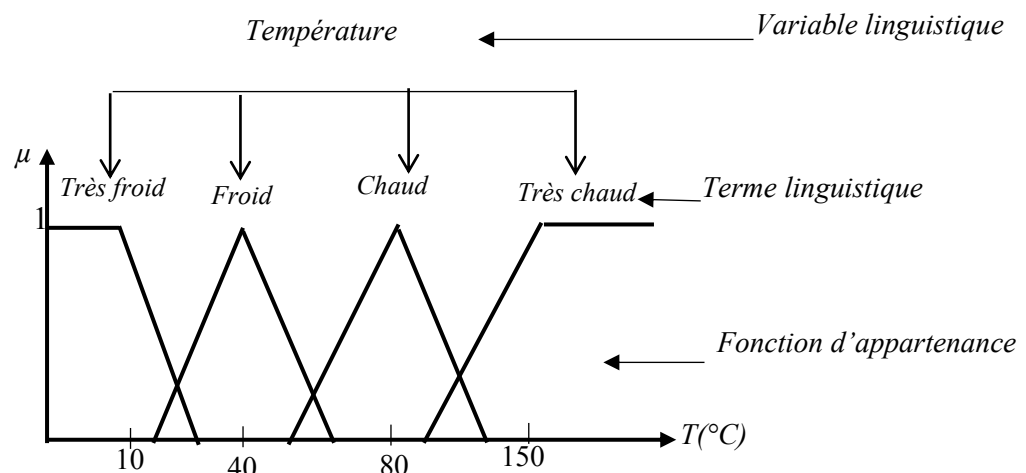


Figure 3.1 : Utilisation des ensembles flous pour caractériser la température d'un corps

3.2.1.4 Ensembles flous et les Fonctions d'appartenance

La notion d'ensemble flou a été proposée par Zadeh en 1965 en réponse au caractère graduel de l'appartenance des éléments à un ensemble donné, ce qui permet une représentation plus précise des termes et des connaissances vagues que nous, les humains, utilisons quotidiennement [87].

La caractérisation d'un ensemble flou (A_f), appartenant à un univers de discours U_f , s'effectue mathématiquement à travers une fonction d'appartenance μ_A . Cette fonction associe à chaque élément x de U_f un degré d'appartenance $\mu_A(x)$ compris dans l'intervalle $[0,1]$, [87] permettant ainsi de mesurer le niveau d'appartenance de x à A_f . Les valeurs $\mu_A(x) = 1$ et $\mu_A(x) = 0$ correspondent respectivement à l'appartenance et la non-appartenance de x à l'ensemble A_f .

Les fonctions d'appartenance peuvent prendre différentes formes en fonction de l'application considérée. Elles peuvent être triangulaires, trapézoïdales ou en forme de cloche, comme illustré dans la Figure (3.2) [86].

1. Fonction d'appartenance triangulaire : cette fonction d'appartenance est définie par une pente linéaire croissante jusqu'à un point maximum, puis une pente linéaire décroissante jusqu'à zéro. Elle est souvent utilisée pour modéliser des ensembles dont la forme est triangulaire.
2. Fonction d'appartenance trapézoïdale : cette fonction d'appartenance est définie par deux points maximum et deux points minimum, reliés par des segments de droite. Elle est souvent utilisée pour modéliser des ensembles dont la forme est trapézoïdale.
3. Fonction d'appartenance gaussienne : cette fonction d'appartenance est définie par une courbe en forme de cloche, qui représente une distribution de probabilité normale. Elle est souvent utilisée pour modéliser des ensembles qui ont une distribution normale.
4. Fonction d'appartenance en forme de S : cette fonction d'appartenance est définie par une courbe en forme de S, qui est une fonction sigmoïde. Elle est souvent utilisée pour modéliser des ensembles qui ont une transition douce entre l'appartenance et la non-appartenance.
5. Fonction d'appartenance en forme de Z : cette fonction d'appartenance est définie par deux fonctions en forme de S symétriques par rapport à un point de transition. Elle est souvent utilisée pour modéliser des ensembles qui ont une transition douce entre l'appartenance et la non-appartenance, mais qui peuvent être asymétriques.

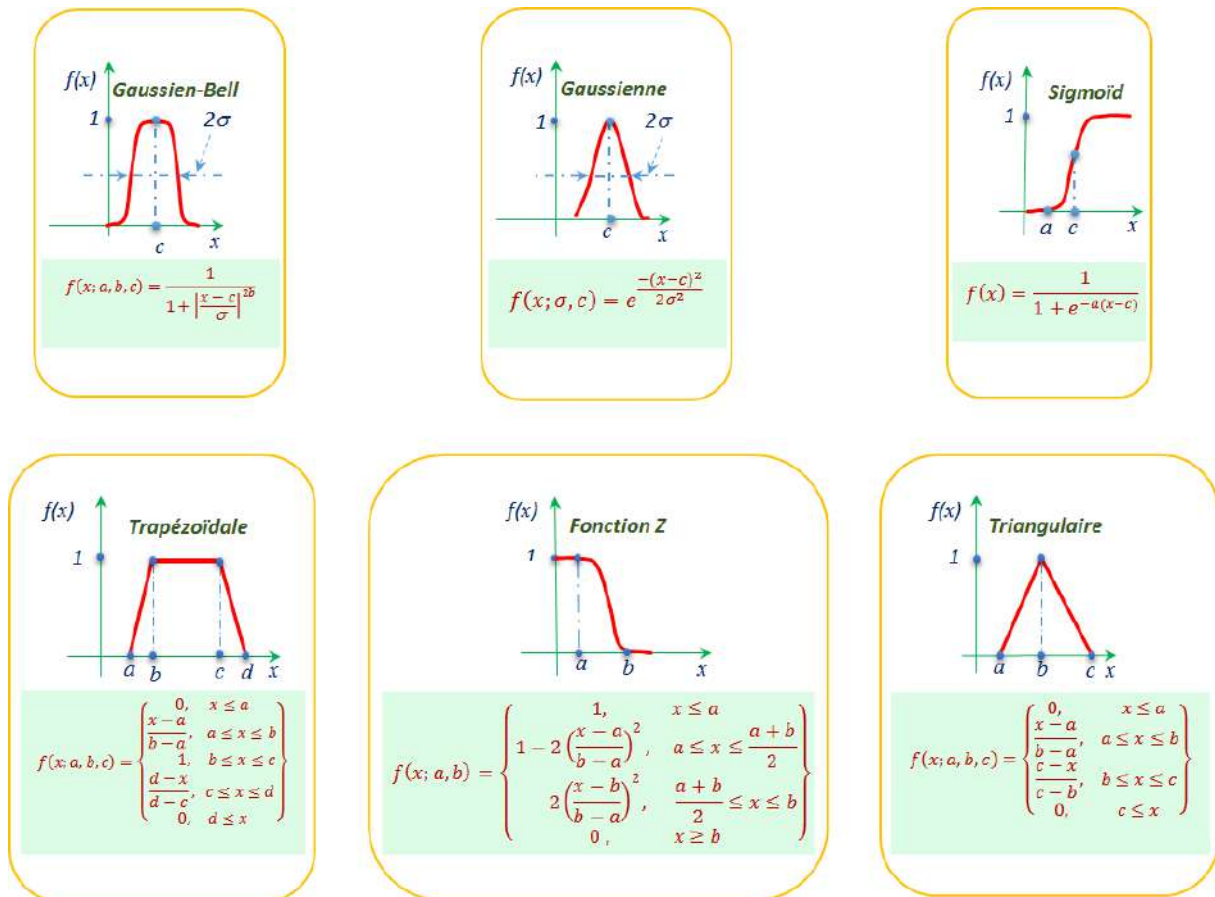


Figure 3.2 : Diverses formes de fonctions d'appartenance

3.2.1.5 Règles linguistiques

L'idée principale des systèmes basés sur la logique floue est d'exprimer la connaissance humaine sous la forme de règles linguistiques "Si...alors...". Chaque règle est composée de deux parties distinctes : une partie conditionnelle, qui décrit les conditions dans lesquelles la règle doit s'appliquer, et une partie conséquente, qui décrit l'action à prendre si les conditions sont satisfaites [80].

Une règle floue prend la forme suivante : SI x est A, ALORS y est B, où x et y sont des variables linguistiques et A et B sont des valeurs linguistiques déterminées par des ensembles flous sur les ensembles X et Y [80,88, 89]. Par exemple, dans le domaine du contrôle de la température d'une pièce, nous pourrions avoir une règle floue telle que : "SI la température est froide, ALORS le chauffage doit être fort". Ici, la température (x) et l'intensité du chauffage (y) sont les variables linguistiques, tandis que "froide" (A) et "fort" (B) sont les valeurs linguistiques déterminées par des ensembles flous sur les ensembles X et Y.

3.2.1.6 Structure interne d'un système flou

La structure interne d'un système flou repose généralement sur une architecture composée de quatre blocs, comme présentée dans la figure (3.3) [90-91]:

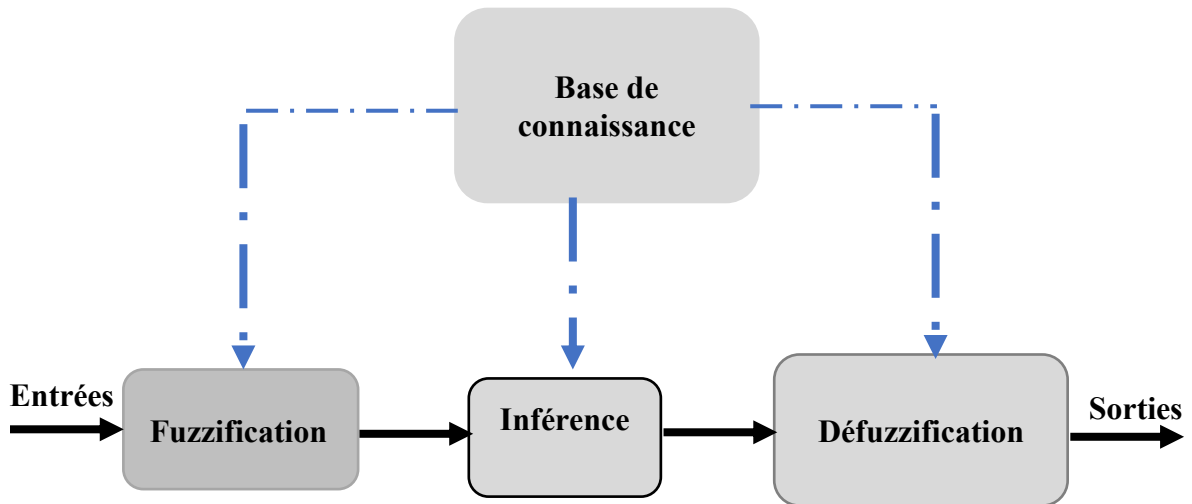


Figure 3.3 : Structure interne d'un système flou

3.2.1.6.1 Bloc de fuzzification

Ce bloc convertit les entrées numériques en variables linguistiques floues. Cela implique l'utilisation de fonctions d'appartenance pour déterminer le degré d'appartenance de chaque entrée à différentes variables linguistiques floues.

La fuzzification implique l'utilisation de fonctions d'appartenance pour déterminer le degré d'appartenance d'une valeur numérique à une variable linguistique floue. Les fonctions d'appartenance sont des fonctions mathématiques qui prennent une valeur numérique en entrée et renvoient un degré d'appartenance, généralement compris entre 0 et 1, qui mesure le degré de ressemblance de la valeur numérique à la variable linguistique floue. Par exemple, si une entrée numérique est la température d'un moteur, la fuzzification peut convertir cette entrée en une variable linguistique floue "chaud" en utilisant une fonction d'appartenance qui évalue le degré d'appartenance de la température à la variable linguistique floue "chaud". Cette variable linguistique floue peut ensuite être utilisée dans les règles et l'inférence du système de logique floue pour déterminer la sortie correspondante.

3.2.1.6.2 Bloc de règles

Ce bloc contient la base de connaissances floue, qui consiste en un ensemble de règles conditionnelles de la forme "SI ... ALORS ...". Chaque règle spécifie une relation entre les variables d'entrée et de sortie, en utilisant des variables linguistiques floues.

La base de connaissances peut être construite à partir de connaissances expertes ou de données empiriques, ou une combinaison des deux. Elle peut être mise à jour en fonction des nouvelles données ou des nouvelles connaissances acquises.

Dans un système de logique floue, la base de connaissances est utilisée pour effectuer l'inférence, qui est le processus de déduction des valeurs de sortie à partir des valeurs d'entrée en utilisant les règles stockées dans la base de connaissances. L'inférence utilise les variables linguistiques floues définies dans le bloc de fuzzification et les règles stockées dans la base de connaissances pour déterminer les sorties correspondantes.

3.2.1.6.3 Bloc d'inférence

Ce bloc utilise les variables linguistiques floues d'entrée et les règles floues pour calculer une valeur linguistique floue de sortie. Cela implique la combinaison des degrés d'appartenance des variables d'entrée aux différentes variables linguistiques floues, en utilisant des opérateurs de logique floue tels que la conjonction, la disjonction et l'implication.

Les inférences floues reposent sur l'utilisation de l'implication floue de type modus ponens généralisé, qui permet de lier les grandeurs mesurées et les variables de sortie à l'aide de règles linguistiques. Ces dernières sont combinées en utilisant les connecteurs logiques "et" et "ou". Imaginons un système flou à deux entrées x et y , ainsi qu'une sortie z , pour lequel n règles linguistiques ont été définies de la manière suivante :

Si $x=A1$ et $y=B1$ alors $z=C1$

Si $x=A2$ et $y=B2$ alors $z=C2$

Si $x=An$ et $y=Bn$ alors $z=Cn$

Où x , y et z sont des variables linguistiques qui représentent les variables d'état de processus et variables de contrôle ; A_i , B_i et C_i ($i=1, n$) sont les sous-ensembles flous définis dans les ensembles de référence pour x , y et z respectivement. En général, n'importe quelle combinaison des opérateurs "ou", "et" et "non" peut apparaître dans la condition d'une règle, en fonction des contraintes imposées par le système à régler.

Les inférences floues peuvent être exprimées de différentes manières, notamment par description linguistique, symbolique, matrices d'inférence ou tableau d'inférence. Il existe également plusieurs options pour la réalisation des opérateurs de la logique floue qui s'appliquent aux fonctions d'appartenance. À partir de ces possibilités, on peut utiliser différentes méthodes d'inférence permettant un traitement numérique de ces inférences. En général, l'une des méthodes suivantes est utilisée [92] :

1. Méthode d'inférence Max-Min : Cette méthode utilise la conjonction (le "et" logique) pour agréger les règles. Elle prend la valeur minimale de l'appartenance de chaque prémisse dans chaque règle et utilise ensuite la valeur maximale pour la conclusion. Cette méthode est simple et facile à comprendre, mais elle peut sous-estimer les valeurs de sortie si une seule prémisse est fausse.
2. Méthode d'inférence Max-Prod : Cette méthode utilise également la conjonction pour agréger les règles, mais elle prend la valeur maximale de l'appartenance de chaque prémisse dans chaque règle et utilise ensuite le produit pour la conclusion. Cette méthode est plus sensible aux valeurs extrêmes et peut surévaluer les valeurs de sortie si une seule prémisse est vraie.
3. Méthode d'inférence Somme-Prod : Cette méthode utilise la disjonction (le "ou" logique) pour agréger les règles, en prenant la somme de l'appartenance de chaque prémisse dans chaque règle. Elle utilise ensuite le produit des fonctions d'appartenance pour la conclusion. Cette méthode est plus robuste que les deux premières, car elle prend en compte plusieurs règles pour déterminer la valeur de sortie.

3.2.1.6.4 Bloc de défuzzification

Ce bloc convertit la valeur linguistique floue de sortie en une sortie numérique. Cela implique l'utilisation de fonctions de défuzzification pour déterminer la valeur numérique appropriée, en utilisant les degrés d'appartenance de la valeur linguistique floue aux différents ensembles de sortie.

La défuzzification est le processus qui transforme une fonction d'appartenance floue, qui est un sous-ensemble flou, en une information précise pour l'organe de commande, qui nécessite un signal de commande précis. Cependant, il n'existe pas de stratégie systématique pour choisir parmi les nombreuses méthodes de défuzzification proposées dans la littérature. De plus, il est souvent nécessaire de prévoir un traitement du signal ainsi que la conversion digitale/analogique.

Les méthodes d'inférence floue fournissent une fonction d'appartenance pour la variable de sortie, qui est une information floue. Pour convertir cette information en grandeur physique, nous utilisons des méthodes de défuzzification. Il existe quatre méthodes couramment utilisées pour la défuzzification :

1. La méthode du maximum, qui consiste à choisir la valeur maximale de la fonction d'appartenance comme valeur de sortie.

2. La méthode de la moyenne des maxima, qui calcule la moyenne des valeurs maximales de la fonction d'appartenance et l'utilise comme valeur de sortie.
3. La méthode du centre de gravité, qui calcule le centre de gravité de la fonction d'appartenance et l'utilise comme valeur de sortie.
4. La méthode de la somme pondérée, qui pondère les valeurs de la fonction d'appartenance par leur degré d'appartenance et calcule la somme pondérée, qui est utilisée comme valeur de sortie.

3.2.1.7 Différentes classes de modèles flous

Les modèles flous peuvent être classés en deux grandes catégories principales [93-94] :

1. Les modèles linguistiques ou modèles de Mamdani, qui utilisent des variables linguistiques (par exemple, "faible", "moyen" et "élevé") pour représenter les entrées et les sorties. Ces modèles sont souvent utilisés pour modéliser des systèmes complexes où les relations entre les variables ne sont pas clairement définies. Le modèle de Mamdani fournit une sortie floue, qui est ensuite défuzzifiée pour obtenir une sortie précise.
2. Les modèles à conséquences fonctionnelles ou modèles de Takagi-Sugeno-Kang, qui utilisent des fonctions d'appartenance floues pour représenter les entrées et les sorties. Ces modèles sont souvent utilisés pour modéliser des systèmes où les relations entre les variables sont connues et peuvent être représentées par des fonctions mathématiques. Les modèles de Takagi-Sugeno-Kang fournissent une sortie précise, qui est une combinaison linéaire des entrées floues, pondérées par des fonctions linéaires.

3.2.1.8 Création du système flou

La création d'un système flou implique plusieurs étapes, qui peuvent varier en fonction du type de problème à résoudre et de la nature des données disponibles. Les étapes générales de la création d'un système flou comprennent :

➤ Définition du problème

La première étape consiste à définir le problème à résoudre et à identifier les variables d'entrée et de sortie. Il est également important de définir les objectifs du système flou et les critères d'évaluation de sa performance.

➤ Collecte de données

La collecte de données est une étape importante dans la création d'un système flou, car elle permet de définir les fonctions d'appartenance floues et les règles floues qui seront utilisées pour modéliser les relations entre les variables d'entrée et de sortie.

➤ **Modélisation des variables d'entrée et de sortie**

La modélisation des variables d'entrée et de sortie implique la définition des fonctions d'appartenance floues, qui représentent la manière dont les valeurs d'entrée et de sortie sont associées à des degrés d'appartenance à des ensembles flous.

➤ **Définition des règles floues**

Les règles floues définissent la logique du système flou en spécifiant comment les valeurs d'entrée sont combinées pour déterminer les valeurs de sortie. Les règles floues sont souvent formulées sous forme de "SI - ALORS", où les antécédents sont des propositions linguistiques floues et les conséquents sont des actions à entreprendre.

➤ **Implémentation du système flou**

Une fois que les fonctions d'appartenance et les règles floues ont été définies, il est possible d'implémenter le système flou en utilisant un langage de programmation dédié ou une bibliothèque logicielle.

➤ **Évaluation et ajustement**

Une fois que le système flou a été implémenté, il est important de l'évaluer pour mesurer sa performance et son efficacité. Si nécessaire, il est possible d'ajuster les paramètres du système flou pour améliorer ses performances.

3.2.2 Réseau Neuro--Flou Adaptatif (ANFIS)

Le réseau ANFIS (Adaptif Neural Fuzzy Inference System) est un système adaptatif hybride qui fusionne les avantages des réseaux de neurones artificiels et des systèmes de logique floue. Il a la capacité de modéliser des systèmes complexes et non-linéaires en utilisant des règles logiques floues et un apprentissage basé sur des réseaux de neurones [95]. Il est composé d'un ensemble de neurones connectés entre eux par des connexions directes. Chaque neurone modélise une fonction paramétrée, et toute modification des valeurs de ses paramètres entraîne une modification de la fonction et donc du comportement global du réseau adaptatif. Les paramètres d'un réseau adaptatif sont distribués sur l'ensemble des neurones qui le constituent. Cependant, chaque neurone possède également son propre ensemble de paramètres locaux : s'il est vide, le neurone est représenté par un cercle et sa fonction est fixe (on parle alors de neurone fixe), sinon, le neurone est représenté par un carré et la fonction associée dépend des valeurs de ses paramètres (on parle alors de neurone adaptatif) [96].

Les connexions entre les neurones d'un ANFIS sont exclusivement utilisées pour indiquer le sens de la propagation des stimulations en provenance des autres neurones.

La structure d'un ANFIS est basée sur une architecture en couches, avec une couche d'entrée pour recevoir les variables d'entrée, une couche de flou pour transformer les entrées en fonction d'appartenance floue à des ensembles flous, une couche de multiplication pour calculer le produit des fonctions d'appartenance floue, une couche de sommation pour additionner les produits des neurones de la couche de multiplication, et enfin une couche de sortie pour fournir la réponse finale, qui est une estimation de la variable de sortie [97-98].

3. 2.2.1 Principe de fonctionnement

Les réseaux neuro-flous hybrides utilisent un algorithme d'apprentissage supervisé pour apprendre des relations et des modèles à partir d'un ensemble de données d'apprentissage, composé d'exemples d'entrées et de leurs sorties correspondantes. Au cours de la phase d'apprentissage, la structure interne du réseau neuro-flou hybride est modifiée pour refléter la relation entre les entrées et les sorties dans la base de connaissances de l'ensemble d'apprentissage. Après la fin du cycle d'apprentissage, la précision du réseau neuro-flou est vérifiée en utilisant un ensemble de validation distinct, composé d'entrées et de sorties séparés de l'ensemble d'apprentissage [97].

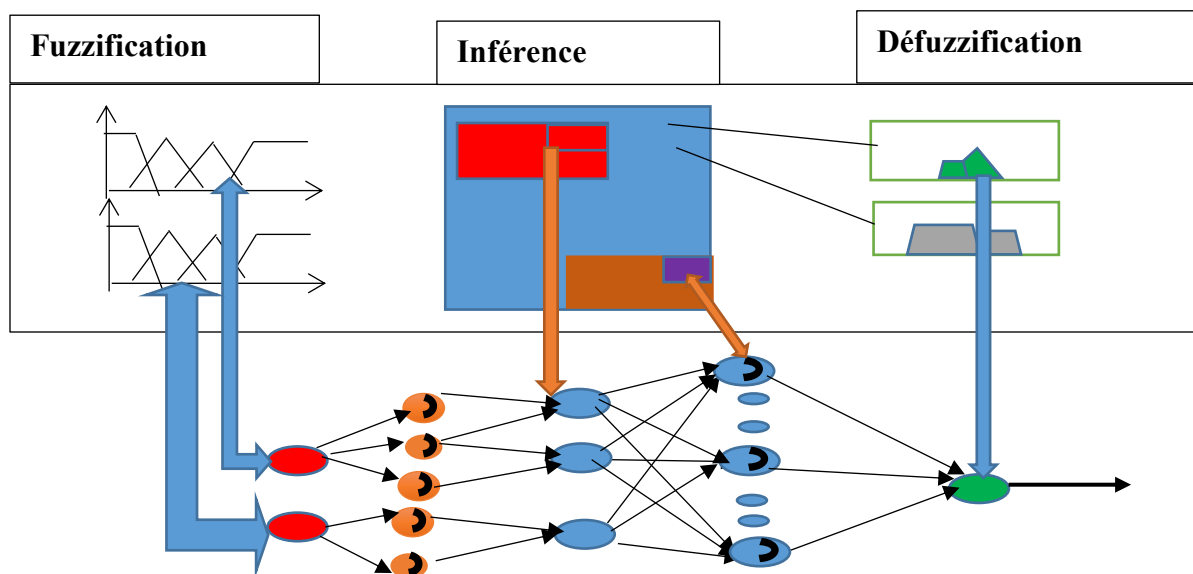


Figure 3.4: principe de neuro flou

ANFIS est effectivement basé sur un système d'inférence flou de type Takagi--Sugeno. Ce type de système utilise des règles logiques floues pour décrire des relations complexes entre des variables d'entrée et de sortie, et peut être utilisé pour modéliser des systèmes non-linéaires et complexes. Les règles logiques floues sont exprimées en termes de fonctions d'appartenance

flous, qui assignent des degrés d'appartenance flous à chaque valeur d'entrée dans un ensemble donné. Les règles logiques floues sont ensuite combinées en utilisant des opérateurs logiques flous pour générer une sortie floue. Le système Takagi-Sugeno (TSK) utilise ensuite cette sortie floue pour déterminer une fonction de sortie réelle pour l'ensemble des entrées. [99, 100].

Jang a utilisé une méthode d'apprentissage pour estimer les paramètres du modèle flou TSK à partir d'un ensemble de données d'entrée-sortie. Cette méthode, appelée méthode de descente de gradient hybride, combine la méthode de gradient stochastique et la méthode de gradient de Gauss-Newton pour atteindre une convergence plus rapide et plus stable. En utilisant cette méthode, les paramètres du modèle flou TSK sont ajustés pour minimiser l'erreur de prédiction entre les sorties du modèle et les sorties réelles correspondantes dans l'ensemble de données d'entraînement.

3.2.2.2 Structure d'ANFIS

La structure d'un ANFIS est basée sur une architecture en couches. Elle est constituée de cinq couches principales [100] :

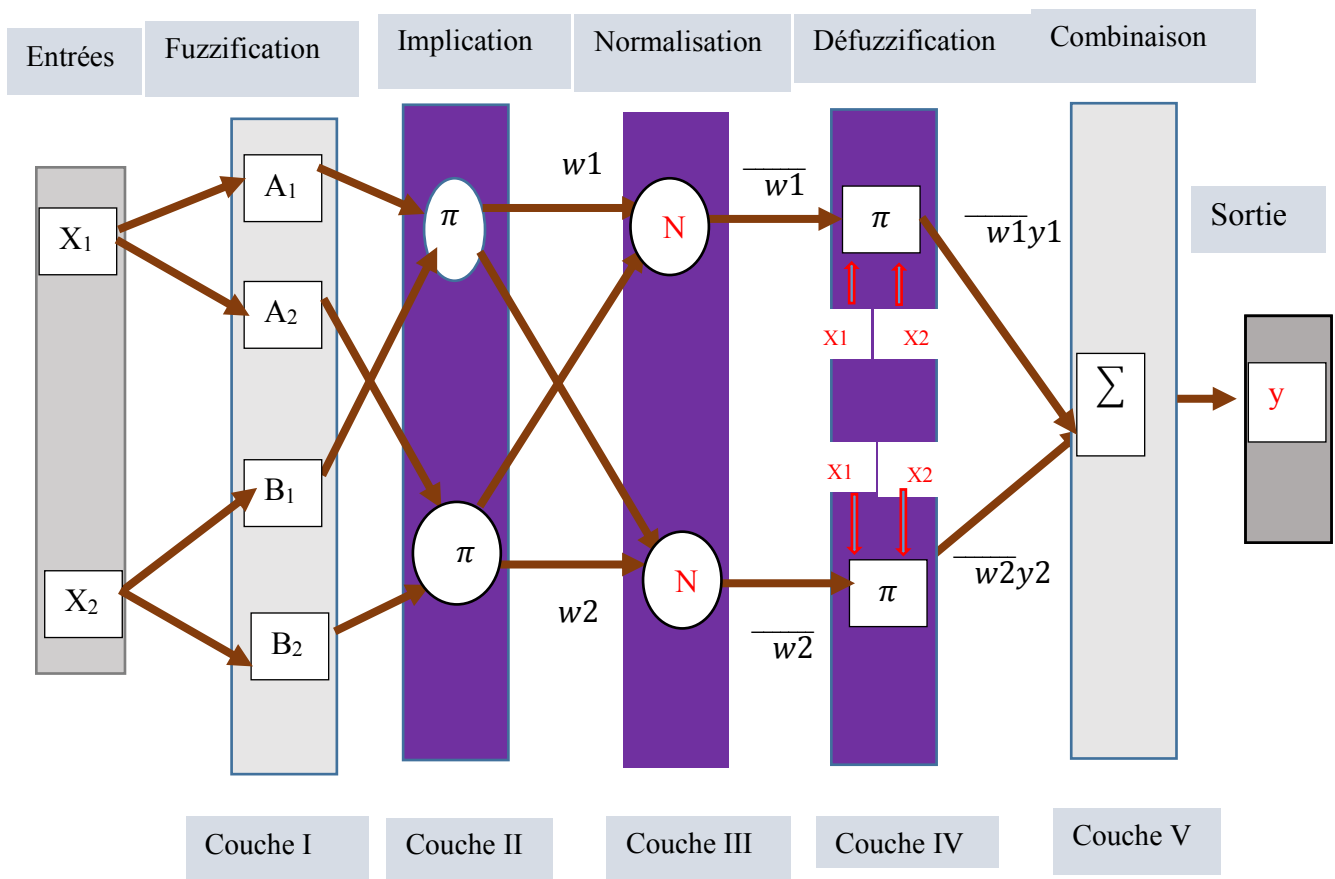


Figure.3.5: Structure d'ANFIS

Couche 1 : Fuzzification

Les neurones de cette couche sont responsables de la transformation des valeurs d'entrée en degré d'appartenance à des ensembles flous. Les fonctions d'appartenance utilisées dans le modèle de Jang sont des fonctions gaussiennes. Chaque neurone est caractérisé par un centre et une variance qui déterminent la forme et la largeur de la fonction d'appartenance gaussienne.

La fonction d'appartenance représente le degré d'appartenance d'une entrée donnée à un ensemble flou particulier, et la sortie de chaque neurone de cette couche est la valeur de degré d'appartenance de l'entrée à l'ensemble flou correspondant.

Chaque noeud i de cette couche est considéré comme un noeud adaptatif, où la sortie est définie comme suit [100] :

$$O_i^1 = \mu_{A_i}(x_1), \text{ for } i = 1,2 \quad (3.1)$$

$$O_i^1 = \mu_{B_{i-2}}(x_2), \text{ for } i = 3,4 \quad (3.2)$$

Où : x est l'entrée du noeud i

A_i est le terme linguistique associé à cette fonction

O_i^1 est le degré d'appartenance de x à A_i

Couche 2 : Couche d'implication

Les nœuds de cette couche sont des nœuds fixes qui agissent comme des multiplicateurs simples pour pondérer les règles floues. Chaque nœud de cette couche correspond à une règle floue, et son activation est déterminée par les fonctions d'appartenance floue de la première couche.

Le nœud de cette couche est représenté par le symbole " π ", et sa sortie représente la force de déclenchement de la règle floue. Cette force de déclenchement est déterminée par le produit des sorties des nœuds de la première couche qui correspondent aux antécédents de la règle [100]. Ainsi, la sortie de chaque nœud de la deuxième couche est une pondération de la règle floue correspondante, qui est utilisée dans la couche suivante pour générer la sortie finale du modèle.

La force de déclenchement (ou le degré d'activation) d'une règle est formée en fonction des signaux d'entrée comme suit :

$$O_i^2 = w_i = \mu_{A_i}(x_1)\mu_{B_i}(x_2), \text{ for } i = 1,2 \quad (3.3)$$

Couche 3 : Normalisation

Chaque neurone de la couche 3 calcule la contribution de la règle floue correspondante au résultat final en normalisant le degré d'activation de la règle. Cette couche est donc appelée couche de normalisation. Elle est importante pour s'assurer que les contributions de toutes les règles sont prises en compte de manière appropriée et ne favorisent pas une règle au détriment des autres. La normalisation est effectuée en divisant chaque degré d'activation de règle par la somme des degrés d'activation de toutes les règles [100].

Le signal de sortie \bar{w}_i du i -ème nœud est calculé en prenant le rapport de la force de déclenchement de la i -ème règle à la somme des forces de déclenchement de toutes les règles comme suit :

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \text{ for } i = 1, 2 \quad (3.4)$$

Couche 4 : Défuzzification

Cette couche joue un rôle essentiel dans la conversion des valeurs floues en valeurs numériques précises, en utilisant la méthode du centre de gravité. Comme dans un système de logique floue traditionnel, chaque neurone de la couche 04 est connecté à un neurone de normalisation correspondant dans la couche précédente, ainsi qu'aux entrées initiales du réseau.

Le neurone de la couche 04 calcule le conséquent pondéré de la règle en utilisant les valeurs floues des neurones de la couche précédente et les poids associés aux règles.

Cependant, contrairement à un système de logique floue traditionnel, les poids des règles dans ANFIS sont adaptés en fonction de l'erreur de prédiction. L'objectif est d'ajuster les poids pour minimiser l'erreur de prédiction entre la sortie du réseau et la valeur cible.

L'adaptation des poids est réalisée en utilisant un algorithme d'apprentissage supervisé, tel que la rétropropagation de l'erreur. Cela permet à ANFIS de s'adapter aux données d'entrée et d'améliorer ses performances au fil du temps.

Chaque nœud i dans cette couche est un nœud adaptatif avec une fonction de nœud contenant les paramètres résultants (p_i, q_i, r_i), et \bar{w}_i est une force de déclenchement normalisée provenant de la couche précédente, comme suit [100]:

$$O_i^4 = \bar{w}_i y_i = \bar{w}_i (p_i x + q_i y + r_i), \text{ for } i = 1, 2 \quad (3.5)$$

Couche 5 : Combinaison

La couche 5 dans un ANFIS est la couche de combinaison, également appelée couche de sommation. Cette couche calcule la sortie finale du réseau en combinant les sorties floues pondérées des neurones de la couche de défuzzification. Plus précisément, chaque neurone dans

la couche 5 est connecté aux neurones de la couche 4 via des poids de connexion, et calcule une somme pondérée de leurs sorties floues [100].

La sortie finale du réseau est alors obtenue en combinant les sorties des neurones de la couche 5, souvent par une simple sommation pondérée. Cette sortie représente la prédiction finale du modèle pour les entrées données.

Il convient de noter que les poids de connexion entre les neurones de la couche 4 et les neurones de la couche 5 ne sont généralement pas adaptatifs, mais sont définis à l'avance en fonction de la structure du réseau. En fin de compte, la couche 5 d'un ANFIS est responsable de combiner les sorties floues des neurones de la couche de défuzzification en une prédiction finale pour les entrées données.

3.2.2.3 Algorithme d'apprentissage de l'ANFIS

L'algorithme d'apprentissage ANFIS commence par construire un réseau initial, généralement en utilisant des fonctions d'appartenance floues pré-définies pour les variables d'entrée. Ensuite, nous appliquons une méthode d'apprentissage par rétropropagation de l'erreur afin d'ajuster les paramètres du réseau, en minimisant l'écart entre la sortie réelle et la sortie attendue pour chaque exemple d'entraînement [101]. Cependant, Jang a proposé une règle hybride d'apprentissage qui combine un algorithme de descente de gradient avec une estimation par moindres carrés, appelée la méthode d'apprentissage hybride ANFIS [102]. Cette méthode permet d'améliorer l'efficacité de l'apprentissage en utilisant l'estimation par moindres carrés pour ajuster les paramètres des couches de fuzzification et de règles, tandis que l'algorithme de descente de gradient est utilisé pour ajuster les paramètres des couches de normalisation et de défuzzification. En utilisant cette approche hybride, la méthode d'apprentissage ANFIS peut converger plus rapidement et avec une précision plus élevée que la simple rétro-propagation de l'erreur [04].

3.2.2.4 Algorithme de l'ANFIS

L'algorithme ANFIS combine les techniques de réseaux de neurones et de logique floue pour créer des modèles plus précis et plus fiables pour la prédiction et la classification [04]

Les étapes principales de l'algorithme ANFIS consistent en :

1. Initialisation des paramètres du réseau, y compris les centres et les variances des fonctions d'appartenance des ensembles flous, ainsi que les poids des connexions.
2. Entrée d'un exemple d'entraînement dans le réseau et propagation avant pour calculer la sortie.

3. Calcul de l'erreur entre la sortie calculée et la sortie attendue pour l'exemple d'entraînement.
4. Rétropropagation de l'erreur à travers le réseau pour ajuster les poids des connexions.
5. Mise à jour des paramètres des fonctions d'appartenance en utilisant une méthode de moindres carrés pour minimiser l'erreur globale.
6. Répéter les étapes 2 à 5 pour tous les exemples d'entraînement.
7. Vérification de la convergence de l'algorithme. Si la convergence est atteinte, le processus d'apprentissage est terminé. Sinon, retour à l'étape 2.

3.3 Prédiction de la tension de contournement par système d'inférence flou

Dans cette partie de notre étude, nous avons utilisé système d'inférence flou (SIF) pour prédire U_c d'un isolateur de HT soumis à diverses contraintes, telles que les niveaux de pollution et la conductivité.

Le système d'inférence flou se compose de trois étapes : la fuzzification, l'inférence et la défuzzification.

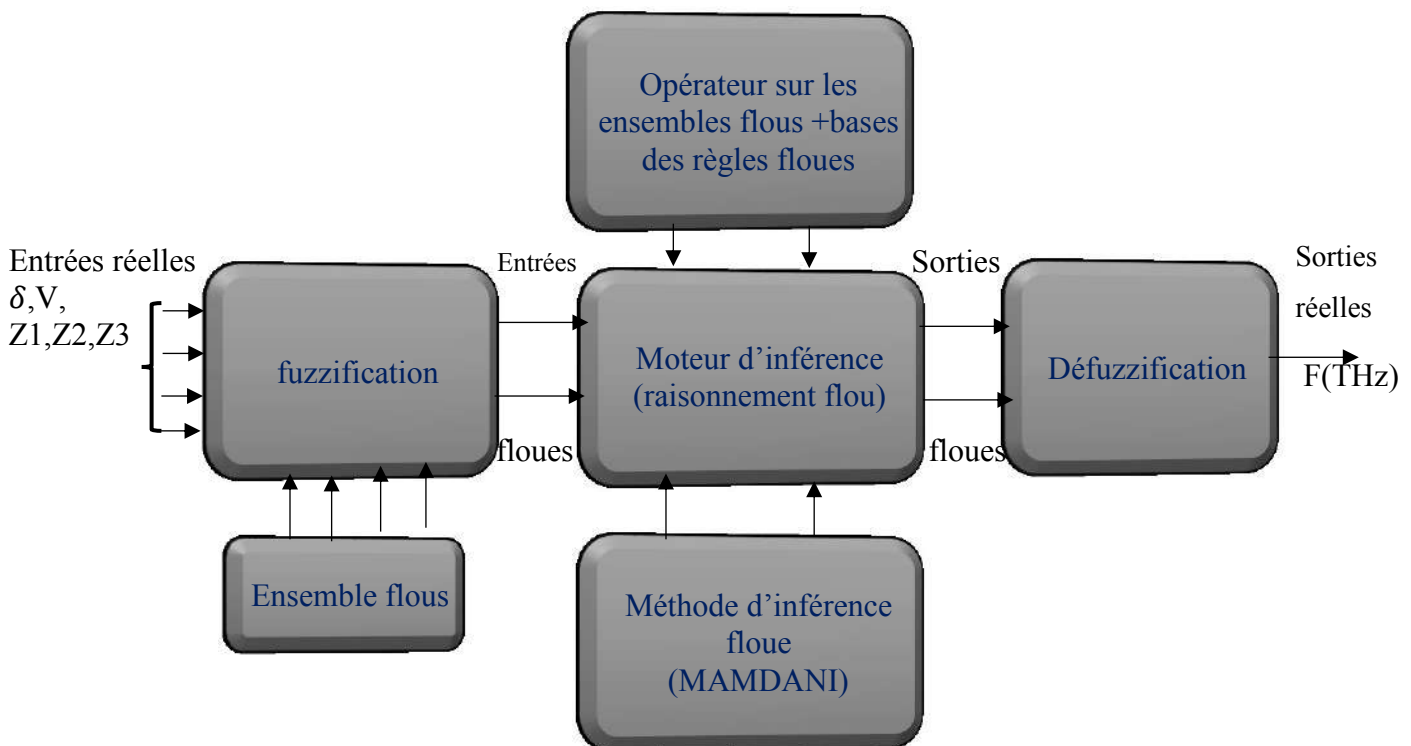


Figure 3.6 : Architecture de SIF

L'apparition de la couleur violette dans les étincelles électriques des isolateurs est due à l'émission de photons à haute énergie. Cette couleur caractéristique est le résultat d'une

puissance électromagnétique intense présente dans le phénomène de contournement. Elle peut être utilisée comme un indicateur précieux dans la détection et l'évaluation de ces phénomènes dans les isolateurs électriques. De plus, il convient de noter que d'autres couleurs sont également observées lors de ces événements. Au début du phénomène, les couleurs dominantes sont généralement le rouge, l'orange et le jaune. Cependant, à mesure que la puissance électromagnétique s'accroît, la couleur évolue progressivement vers le vert, le bleu et le violet. Cette évolution chromatique permet de mieux comprendre l'intensité et la nature du phénomène de contournement.

Il est important de noter que ces couleurs sont le résultat de réactions chimiques qui se produisent lors de l'amorçage de l'étincelle électrique.



Figure 3.7 : processus de contournement observé en laboratoire

Il est possible d'utiliser la différence de fréquence des couleurs pour représenter l'intensité du phénomène de contournement sur les isolateurs en associant différentes fréquences à différentes couleurs. Cette approche consiste à utiliser un spectre de couleurs où chaque couleur est correspondante à une plage de fréquences spécifique.

Couleur	Longueur d'onde (nm)	Fréquence (Hz)
Rouge	700	$4,29 \times 10^{14}$
Orange	620 – 590	$4,84 \times 10^{14} - 5,08 \times 10^{14}$
Jaune	580 – 570	$5,17 \times 10^{14} - 5,23 \times 10^{14}$
Vert	550 – 500	$5,45 \times 10^{14} - 6,00 \times 10^{14}$
Bleu	490 – 450	$6,12 \times 10^{14} - 6,67 \times 10^{14}$
Indigo	445 – 425	$6,72 \times 10^{14} - 7,08 \times 10^{14}$
Violet	400	$7,50 \times 10^{14}$

3.3.1. System d'inférence flou utilisé

Il est nécessaire de définir les éléments suivants pour formuler un problème en logique floue :

- Les entrées et sorties du SIF : Dans notre étude, nous avons choisi les entrées et sorties présentées dans la figure (3.8).
- Les univers de discours des variables d'entrée et de sortie, c'est-à-dire les intervalles de valeurs possibles pour ces variables, sont présentées dans le tableau (3.2).
- Les caractéristiques floues pour chaque variable, qui sont des valeurs de vérité telles que "petit", "grand", etc., sont présentées dans le tableau (3.3).
- Les fonctions d'appartenance des variables d'entrée et de sortie, qui décrivent la façon dont chaque valeur de chaque variable appartient à chaque caractéristique floue, sont présentées dans les figures (3.9-3.14).
- Les règles d'inférences floues, qui décrivent les actions à prendre en fonction des caractéristiques floues des variables d'entrée, sont données dans la figure (3.15).

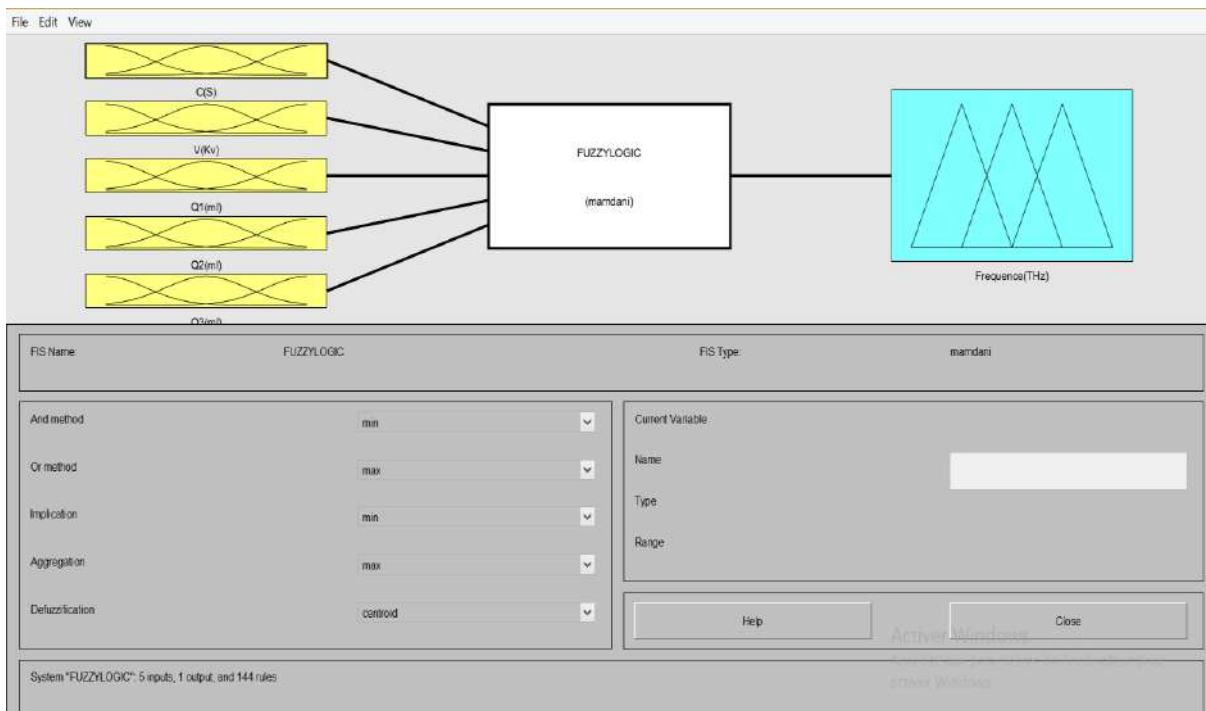


Figure 3.8 : Fenêtre principale de l'éditeur de système d'inférence flou sous MATLAB.

3.3.2 Entrées et sortie choisie

Nous avons utilisé la conductivité, le niveau de pollution et la tension d'alimentation comme entrées pour le système d'inférence flou, et la fréquence des couleurs comme variable de sortie. L'évolution des couleurs observées est généralement associée à l'augmentation de

l'énergie ou de la puissance impliquée dans le phénomène de contournement. Lorsque l'intensité est faible, les particules émises peuvent avoir une énergie relativement basse, ce qui se traduit par des couleurs plus proches du rouge, de l'orange et du jaune, qui sont associées à des longueurs d'onde plus longues. Cependant, à mesure que l'intensité augmente, les particules émises acquièrent plus d'énergie, entraînant des transitions vers des couleurs plus courtes, telles que le vert, le bleu et le violet, qui sont associées à des longueurs d'onde plus courtes.

Tableau 3.1 : Variables d'entrée et de sortie

Entrées		Sortie	
Symbole	Signification	Symbole	Signification
δ ('mS./cm')	Conductivité	F (terahertz 'THz') 1Hz = 10^{-12} THz	Fréquence
Qi (Q1, Q2, Q3) ('ml')	Quantité de pollution dans les zones d'isolateur HT		
V ('kV')	Tension d'alimentation		

3.3.3 Fonctions d'appartenances

Les univers de discours, c'est-à-dire les intervalles de valeurs possibles pour chaque variable, ainsi que les formes des fonctions d'appartenance de chaque variable, sont présentés dans les figures (3.9-3.14). Ces figures décrivent comment chaque valeur de chaque variable appartient à chaque caractéristique floue.

Il est important de souligner que le choix du type de fonction d'appartenance est basé sur nos analyses et nos hypothèses. Nous devons toujours garder à l'esprit que d'autres analyses peuvent conduire à d'autres formes de fonctions, et donc à d'autres résultats.

3.3.3.1 Fonctions d'appartenances des entrées

3.3.3.1.1 Conductivité




Figure 3.9 : Fonction d'appartenance de δ .

3.3.3.1.2. Tension d'alimentation

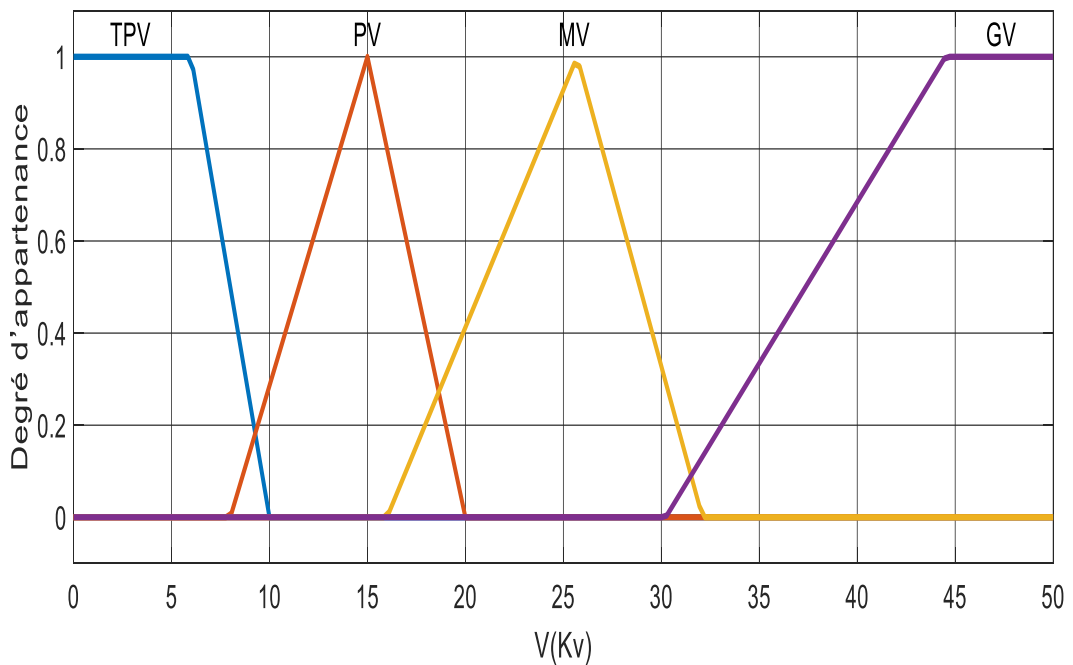


Figure 3.10 : Fonction d'appartenance de U.

3.3.3.1.3. Le niveau de pollution (Q1):




Figure 3.11 : Fonction d'appartenance de Q1.

3.3.3.1.4. Le niveau de pollution (Q2)




Figure 3.12 : Fonction d'appartenance de Q2.

3.3.3.1.5. Le niveau de pollution (Q3)




Figure 3.13 : Fonction d'appartenance de Q3.

3.3.3.2. Fonctions d'appartenances de la sortie




Figure 3.14 : Fonction d'appartenance de la fréquence des couleurs.

Tableau 3.2 : Les caractéristiques floues

Entrées										Sortie	
variables linguistiques T-L : Terme linguistique Si : Signification											
T-L		Si		T-L		Si		T-L		Si	
Conductivités δ (mS/cm) [0-120]		Tension d'alimentation (Kv) [0-50]		Q1 (ml) [0-35]		Q2 (ml) [0--40]		Q3 (ml) [0--70]		Fréquence (THz) [0-750]	
PC	<i>Petite Conductivité</i>	TPV	Très Petite Tension	PQ1	Petite Quantité	PQ2	Petite Quantité	PQ3	Petite quantité	PF	<i>Petite Fréquence</i>
MC	<i>Moyenne Conductivité</i>	PV	Petite Tension	MQ1	Moyenne Quantité	GQ2	Grande Quantité	GQ3	Grande quantité	MF	<i>Moyenne Fréquence</i>
GC	<i>Grande Conductivité</i>	MV	Moyenne Tension	GQ1	Grande Quantité					GF	<i>Grande Fréquence</i>
		GV	Grande Tension								

Il est important de noter que lorsqu'il s'agit de choisir le nombre de variables, le nombre d'intervalles et la forme des fonctions d'appartenance en logique floue, il n'existe pas de règles strictes à suivre.

Les entrées			PQ2		GQ2	
			PQ3	GQ3	PQ3	GQ3
PC	TPV	P Q1	PF	PF	PF	PF
		M Q1	PF	PF	PF	PF
		G Q1	PF	PF	PF	PF
	PV	P Q1	PF	PF	PF	PF
		M Q1	PF	MF	MF	MF
		G Q1	PF	MF	MF	GF
	MV	P Q1	PF	MF	MF	GF
		MQ1	PF	MF	MF	GF
		GQ1	PF	MF	MF	GF
	GV	PQ1	PF	MF	GF	GF
		MQ1	PF	MF	GF	GF
		GQ1	MF	GF	GF	GF
MC	TPV	PQ1	PF	PF	PF	PF
		MQ1	PF	PF	PF	PF
		GQ1	PF	PF	PF	PF
	PV	PQ1	PF	PF	PF	MF
		MQ1	PF	PF	PF	MF
		GQ1	PF	PF	PF	MF
	MV	PQ1	PF	PF	MF	MF
		MQ1	PF	MF	MF	GF
		GQ1	PF	MF	MF	GF
	GV	PQ1	MF	MF	MF	GF
		MQ1	MF	MF	MF	GF
		GQ1	MF	GF	GF	GF
GC	TPV	PQ1	PF	PF	PF	PF
		MQ1	PF	PF	PF	PF
		GQ1	PF	PF	PF	PF
	PV	PQ1	PF	PF	PF	MF
		MQ1	PF	PF	PF	MF
		GQ1	PF	MF	MF	GF
	MV	PQ1	PF	MF	MF	GF
		MQ1	PF	MF	MF	GF
		GQ1	MF	GF	GF	GF
	GV	PQ1	MF	GF	GF	GF
		MQ1	MF	GF	GF	GF
		GQ1	GF	GF	GF	GF

Tableau 3.3 : L'ensemble des règles floue.

3.3.4. Règles d'inférence

La figure (3.15) représente la fenêtre qui est utilisée dans MATLAB pour saisir les règles floues intégrées dans notre système d'inférence floue (SIF).

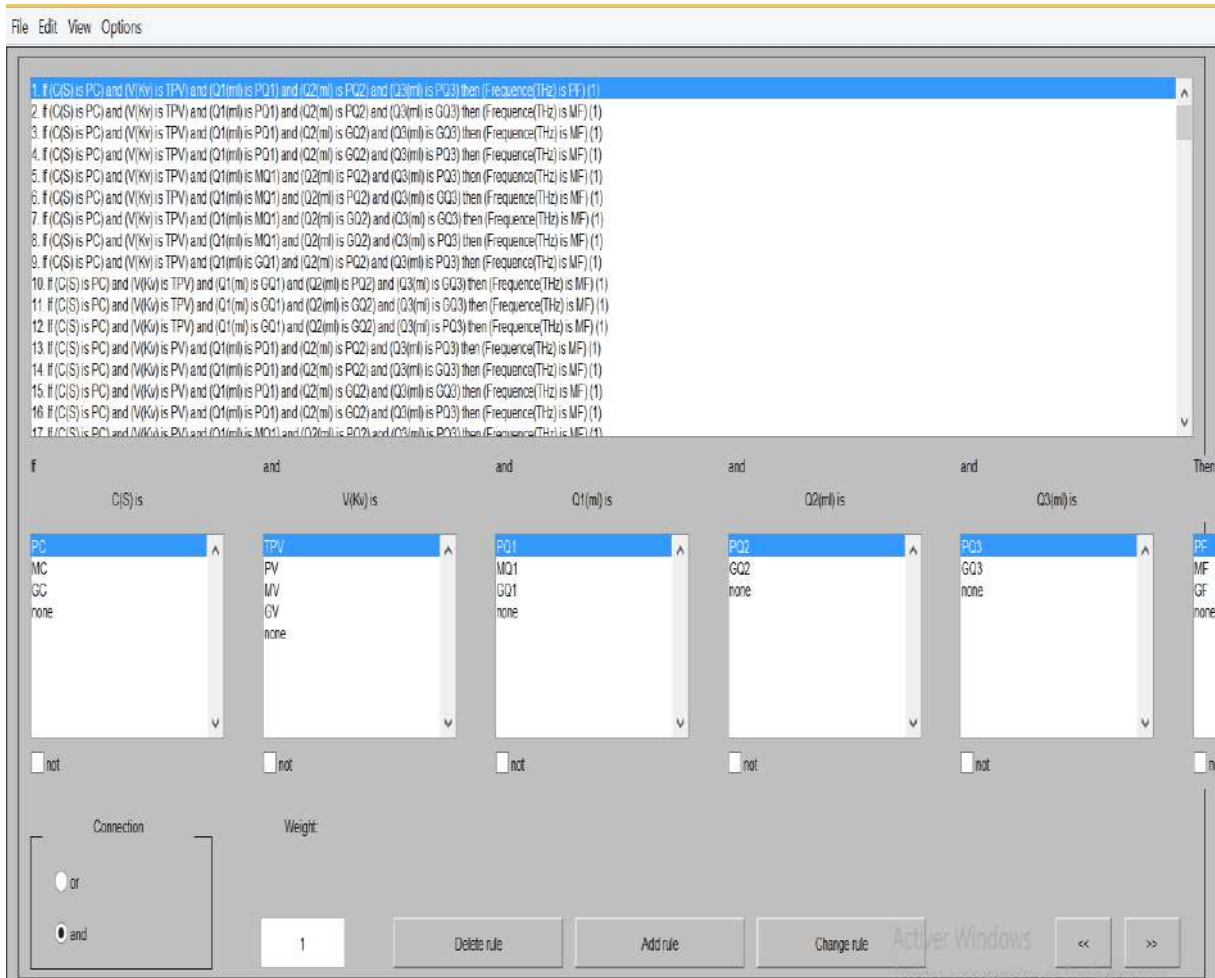


Figure 3 .15 : Les règles floues utilisées.

3.3.5. Fuzzification

La phase de fuzzification des variables d'entrée a généré respectivement quatre fonctions d'appartenance pour la tension d'alimentation, trois fonctions d'appartenance pour la conductivité, et deux fonctions d'appartenance pour la quantité de pollution de chaque zone. En conséquence, cela a ouvert la possibilité de générer un maximum de 144 règles d'inférence ($3 * 4 * 3 * 2 * 2 = 144$) en utilisant MATLAB.

La définition des règles se fait facilement en sélectionnant les fonctions d'appartenance associées aux entrées par leurs termes linguistiques, puis en définissant la sortie affectée par cette règle en utilisant également son terme linguistique associé. Le tableau (3.3) contient

l'ensemble des règles utilisées dans le système.

3.3.6 Défuzzification

Dans le cadre du système d'inférence en logique floue, l'évaluation des règles joue un rôle essentiel. Cette étape permet de déterminer la valeur de la variable de sortie floue en utilisant les entrées floues provenant de la phase de fuzzification, ainsi que l'ensemble des règles du système, grâce à une méthode d'inférence appropriée. Dans cette étude, Nous avons choisi d'appliquer l'opération max-min combinée à la loi de composition floue dans le cadre de la méthode d'inférence floue de Mamdani. Cela signifie que l'opérateur ET est implémenté en utilisant la fonction minimum, tandis que l'opérateur OU est réalisé en utilisant la fonction maximum.

3.3.7 Tests et validation



Figure 3.16 : La fenêtre de visualisation des règles d'inférence

La figure (3.16) montre la fenêtre de visualisation des règles d'inférence pour l'application des valeurs d'entrées (80mS/cm, 39.6 kV, 11.66ml, 13.33 ml, 23.33 ml)) en utilisant la méthode max-min (colorisation jaune). Elle illustre également la variable de sortie floue obtenue pour ces entrées (colorisation bleue). La valeur de la sortie calculée après la défuzzification par la méthode de centre de gravité représente la fréquence des couleurs, qui est égale à 668THz. Cette valeur appartient à l'intervalle flou [600-750], ce qui indique qu'il y a un contournement de l'isolateur.

Tableau 3.4 : Résultats de tests réalisés au laboratoire en utilisant SIF

$\delta=7.5$ mS/cm					
Tension appliqué	Q1(ml)	Q2(ml)	Q3 (ml)	Tests	
				pratiques	Simulation par (SIF)
45,80	11.6	13.3	23.3	Contournement	Contournement
39,70	23.3	26.6	46.6	Contournement	Contournement
34,80	34.9	39.9	69.9	Contournement	Contournement

$\delta=20$ mS/cm					
Tension appliqué	Q1(ml)	Q2(ml)	Q3 (ml)	Tests	
				pratiques	Simulation par (SIF)
34	11.6	13.3	23.3	Contournement	Contournement
26	23.3	26.6	46.6	Contournement	Contournement
23	34.9	39.9	69.9	Contournement	Contournement

$\delta=80$ mS/cm					
Tension appliqué	Q1 (ml)	Q2 (ml)	Q3 (ml)	Tests	
				pratiques	Simulation par (SIF)
39,50	11.6	13.3	23.3	Contournement	Contournement
36,20	23.3	26.6	46.6	Contournement	Contournement
33,70	34.9	39.9	69.9	Contournement	Contournement

$\delta=120$ mS/cm					
Tension appliqué	Q1 (ml)	Q2 (ml)	Q3 (ml)	Tests	
				pratiques	Simulation par (SIF)
38,50	11.6	13.3	23.3	Contournement	Contournement
35,40	23.3	26.6	46.6	Contournement	Contournement
33,60	34.9	39.9	69.9	Contournement	Contournement

Le tableau (3.4) présente les résultats de simulation obtenus à l'aide de système d'inférence floue pour prédire U_c de l'isolateur étudié, comparés aux résultats pratiques du tableau 1.2 du chapitre 1. Les 18 tests effectués n'ont montré aucune erreur, ce qui correspond

à un taux d'erreur de 0%. Nous avons donc conclu que le système flou est fiable pour prédire U_c de cet isolateur.

Notre système d'inférence floue présente l'avantage de pouvoir prédire de U_c pour des valeurs de paramètres difficiles ou impossibles à réaliser en laboratoire, ce qui permet d'économiser du temps et de l'argent. De plus, il peut modéliser des systèmes complexes et non-linéaires, ce qui est difficile avec des méthodes traditionnelles.

3.4 Architecture d'un système d'inférence neuro-flou adaptatif : (ANFIS)

La structure ANFIS est une architecture de réseau de neurones artificiels à cinq couches qui permet d'améliorer les règles floues existantes créées par des experts humains et d'ajuster le chevauchement entre les différents sous-ensembles flous, améliorant ainsi la précision et la fiabilité des modèles.

Dans cette étude, un modèle de base est construit avec quatre entrées et une sortie. Les quatre entrées sont la conductivité, la quantité de pollution dans la zone 1, 2 et 3. La sortie est la tension de contournement. Cette configuration est illustrée dans la figure 3.17.




Figure 3.17 : Correspondance entrée-sortie ANFIS

3.4.1 Résultats et discussions

Dans cette étude, le modèle ANFIS a été évalué en utilisant différentes fonctions d'appartenance (MF) telles que la fonction gaussienne (gaussmf), la fonction triangulaire (trimf), la fonction en forme de cloche (gbellmf) et la fonction trapézoïdale (trapmf). Chaque fonction d'appartenance a été testée avec deux (haut, bas) ou trois variables linguistiques (haut, moyen, bas) pour chaque entrée. Deux nombres d'époques différents, à savoir 50 et 300, ont été utilisés lors des tests.

Tableau 3.5 : Indices statistiques pour l'évaluation des performances des différents types de modèles ANFIS.

fonction d'appartenance d'entrée	No.of input MFs	No. d' époques	RMSE-train	RMSE-test	R ² -train	R ² -Test	MAPE-train	MAPE-test
Gaussienne	3333	50	0.13203	0.18262	0.99977	0.99947	0.12047	0.21177
	3333	300	0.12172	0.15862	0.99981	0.99960	0.12144	0.18252
	3322	50	0.13198	0.18196	0.99978	0.99947	0.12402	0.2051
	3322	300	0.12177	0.15826	0.99981	0.9996	0.12186	0.18306
Gaussienne à deux côtés (Tow-sided Gaussian)	3333	50	0.12179	0.16145	0.99981	0.99958	0.12474	0.19636
	3333	300	0.12179	0.16135	0.99981	0.99958	0.12491	0.19689
	3322	50	0.12234	0.16114	0.99980	0.99958	0.12669	0.19069
	3322	300	0.12182	0.16012	0.99981	0.99959	0.12573	0.18929
Triangulaire	3333	50	0.03365	0.013628	0.999985538	0.9999970	0.064612	0.027012
	3333	300	0.02291	0.012862	0.999993298	0.9999970	0.050033	0.027011
	3322	50	0.03361	0.013538	0.999985571	0.9999970	0.1705	0.28078
	3322	300	0.02292	0.013538	0.999993293	0.9999970	0.050223	0.02859
Trapezoidal	3333	50	0.14468	0.19648	0.99973	0.99938	0.16817	0.2902
	3333	300	0.14363	0.19573	0.99973	0.99939	0.16027	0.28252
	3322	50	0.14474	0.19592	0.99973	0.999390	0.1705	0.28078
	3322	300	0.14363	0.19571	0.99973	0.99939	0.16034	0.28255
Fonction d'appartenance Produit d'Intervalles (pimf)	3333	50	0.1447	0.19683	0.99973	0.99938	0.16995	0.29189
	3333	300	0.14363	0.19683	0.99973	0.99938	0.16011	0.29189
	3322	50	0.1447	0.19622	0.99973	0.99938	0.17002	0.28617
	3322	300	0.14365	0.19621	0.99973	0.99938	0.16141	0.2861
forme de cloche (Bell-shaped)	3333	50	0.12605	0.1705	0.99979	0.99953	0.12022	0.18767
	3333	300	0.1218	0.16007	0.99981	0.99959	0.12245	0.18838
	3322	50	0.12569	0.16879	0.99979	0.99954	0.12391	0.17981
	3322	300	0.12189	0.15974	0.99981	0.99959	0.12504	0.19161
Différence Sigmoidal	3333	50	0.12169	0.16041	0.99981	0.99959	0.12262	0.19094
	3333	300	0.12163	0.16023	0.99981	0.99959	0.1207	0.18531
	3322	50	0.12179	0.15969	0.99981	0.99959	0.12436	0.18614
	3322	300	0.12169	0.15922	0.99981	0.99959	0.12277	0.18273
Produit Sigmoidal	3333	50	0.12184	0.16073	0.99981	0.99958	0.12516	0.1983
	3333	300	0.12165	0.16036	0.99959	0.99981	0.12139	0.18758
	3322	50	0.12192	0.16014	0.99981	0.99959	0.12562	0.18963
	3322	300	0.12169	0.15931	0.99981	0.99959	0.12272	0.18194

Nous avons constaté que la fonction "Trimf" avec trois fonctions d'appartenance a donné les meilleurs résultats pendant la phase d'apprentissage ainsi que la phase de test. Elle a présenté la plus faible valeur de l'erreur RMSE (0,02291 et 0,012862) pendant les deux phases. Lors de la phase de test, on a pu constater que l'erreur MAPE atteignait son niveau le plus bas (0,027011), tandis que le coefficient de détermination R² atteignait son niveau le plus élevé (0,9999970).

Pour prédire U_c à l'aide de l'ANFIS, les paramètres que nous avons utilisés sont les suivants :

- nombre de MF = 3.
- type de MF = triangulaire (bas et haut).
- nombre maximum d'époques = 300 époques.
- type d'apprentissage : méthode hybride.
- type de MF de sortie : linéaire.

Tableau 3.6 : Différents paramètres de l'ANFIS




paramètres d'un ANFIS	Détails
type de MF	Trimf
nombre de MF	3
partie conséquente	linéaire

Le nombre de règles floues de ce système, utilisant la méthode de grid partitioning est de 81 règles ($3^4 = 81$ règles). Les variables linguistiques utilisées sont : [Haut, Moyen, Faible].

Au cours de l'étape d'inférence, des décisions sont prises en établissant des connexions logiques entre les variables d'entrée et la variable de sortie, tout en définissant les règles d'appartenance correspondantes

Les règles d'appartenance sont exprimées sous la forme de SI-ALORS, avec des conditions telles que "si l'entrée 1 est x" et "si l'entrée 2 est y", la sortie est calculée comme " $z = ax + by + c$ ".

Les fonctions d'appartenance des variables d'entrée sont obtenues en utilisant les instructions suivantes dans l'environnement MATLAB : $[x, mf] = \text{plotmf}(\text{fismat}, \text{'input'}, i)$, où fismat est la matrice de la logique floue et 'i' est l'indice de la variable d'entrée pour laquelle on veut tracer les fonctions d'appartenance. Les résultats sont ensuite tracés à l'aide de la commande $\text{plot}(x, mf)$ et sont représentés sur la figure 3.18.






Figure 3.18 : Formes des fonctions d'appartenance pour les variables d'entrée

3.4.2 Architecture d'ANFIS

La structure neuronale équivalente d'ANFIS, implémentée dans l'environnement MATLAB, est représentée sur la figure 3.19. Cette structure est une représentation graphique de la façon dont les différentes couches du modèle interagissent pour effectuer l'inférence floue.

La figure 3.19 montre comment les entrées sont propagées à travers les différentes couches de neurones, qui comprennent des neurones d'entrée, des neurones flous, des neurones de règle, des neurones de sommation et des neurones de sortie. En utilisant cette structure, ANFIS est capable d'apprendre et de modéliser des systèmes complexes en utilisant des règles logiques floues pour effectuer des tâches d'inférence.




Figure 3.19 : La structure du modèle ANFIS sélectionné sous MATLAB

Afin de valider l'efficacité de l'approche ANFIS, deux mesures d'erreur sont calculées : l'erreur quadratique moyenne (RMSE) et l'erreur absolue moyenne en pourcentage (MAPE). Les résultats de ces mesures sont présentés dans le tableau 3.7.

Tableau 3.7: Étude des critères de performance MSE et MAPE pour la méthode ANFIS

Tension appliquée (kV)	Tension de contournement prédite par ANFIS	Erreur absolue %	Erreur quadratique moyenne (MSE)
45,80	45,80	00	0
39,70	39.692	0.02	0.0000640
34,80	34.791	0.025	0.0000810
34	34.00	00	0
26	26.01	0.038	0.0001000
23	23.0017	0.0073	0.0000029
39,50	39.53	0.075	0.0009000
36,20	36.23	0.082	0.0009000
33,70	33.71	0.029	0.0001000
38,50	38.51	0.025	0.0001000
35,40	35.40	00	0
33,60	33.59	0.0297	0.0001000
19	19.023	0.1210	0.0005290
19.7	19.70	00	0
17.5	17.499	0.0057	0.0000010
39.4	39.40	00	0
38	38.00	00	0
35	35.01	0.0285	0.0001000
Erreur moyenne (MAPE)		0.027011	
Erreur moyenne (MSE)			0.0001654389
Root mean square error (RMSE= $\sqrt{\text{MSE}}$)			0.0128623054

Le tableau 3.7 montre comment l'erreur quadratique moyenne (RMSE) et l'erreur absolue moyenne en pourcentage (MAPE) sont déterminées. Pour chaque valeur, l'erreur absolue et l'erreur quadratique sont d'abord calculées, comme indiqué dans les colonnes 2 et 3.

L'erreur absolue mesure la différence entre la valeur prédite et la valeur réelle, tandis que l'erreur quadratique mesure cette différence au carré. Ensuite, la moyenne de ces erreurs est calculée pour obtenir le RMSE et le MAPE.

La figure 3.20 présente les résultats de la performance du modèle ANFIS pour la phase d'apprentissage.

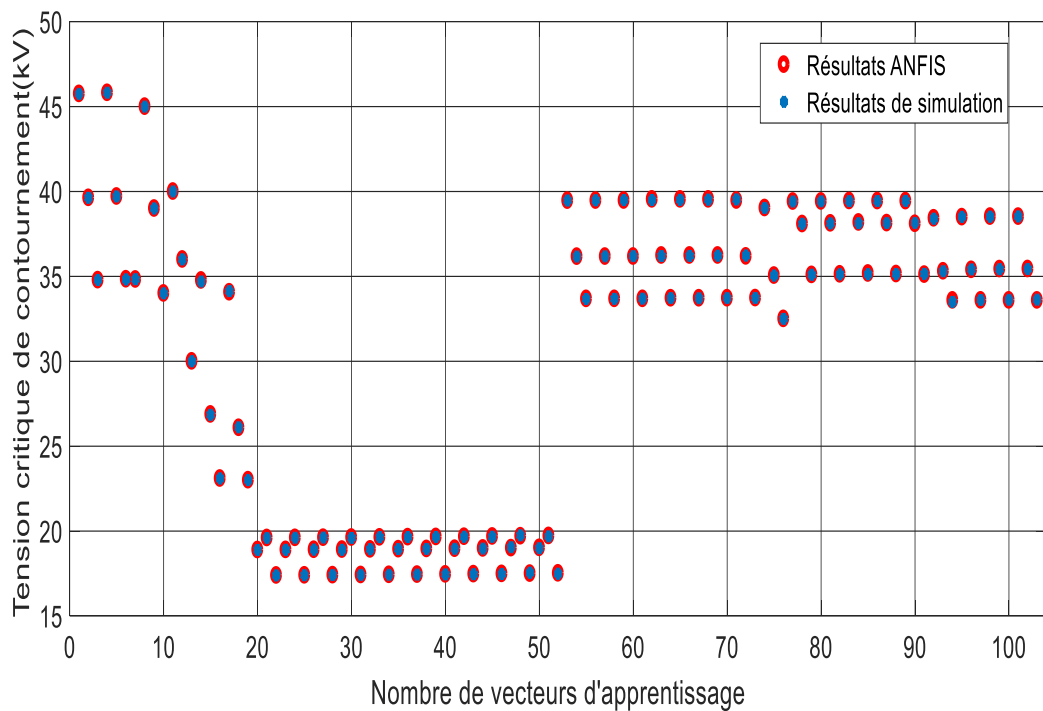


Figure. 3.20 : La performance du modèle ANFIS pour l'entraînement.

La performance de l'approche ANFIS est évaluée en comparant les valeurs prédites de U_c avec les valeurs de test. Cette comparaison est illustrée sur la figure 3.21. On peut observer que les prévisions du modèle ANFIS sont en bon accord avec les valeurs de test.




Figure 3.21 : Performance du modèle ANFIS pour les tests expérimentaux.

La figure 3.22 montre la corrélation entre les valeurs réelles et estimées de U_c pour toutes les données de test. La valeur de R^2 est proche de 0,99999, ce qui indique une forte corrélation entre les valeurs prédites et les valeurs réelles.




Figure 3.22 : Similitude entre les valeurs réelles et estimées de U_c pour l'ensemble de test.

Le tableau 3.8 présente les valeurs de l'erreur quadratique moyenne (RMSE), du coefficient de détermination (R^2) et de l'erreur moyenne absolue en pourcentage (MAPE) pour l'approche ANFIS appliquée à la prédiction de Uc.

Tableau 3.8: Statistiques de validation de la performance du modèle

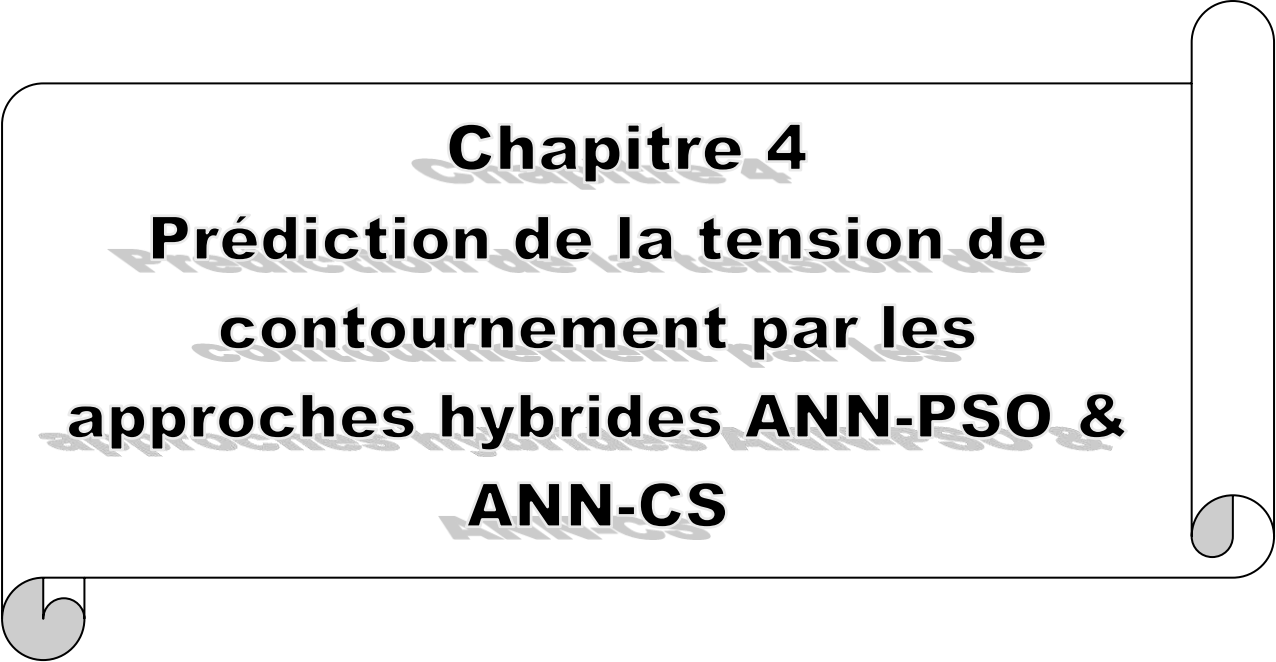
Coff.de corrélationr_ train	Coff.de corrélacion _test	Coff.de détermination (R_train) ²	Coff.de détermination (R_test) ²	MAPE_test	RMSE_test
0.999996	0.999998524	0.9999932988	0.999997049	0.027011	0.0128623

Les résultats montrent que l'erreur quadratique moyenne est de 0.0128623, ce qui indique une faible erreur de prédiction. Le coefficient de détermination (R^2) atteint une valeur élevée de 0.99999, ce qui indique une forte corrélation entre les valeurs prédites et les valeurs réelles. Enfin, l'erreur moyenne absolue en pourcentage (MAPE) est estimée à seulement 0.027%, ce qui montre que l'approche ANFIS a une bonne capacité de prédiction de Uc.

3.5 Conclusion

L'application du système d'inférence flou et de l'approche ANFIS pour la prédiction de Uc dans les réseaux électriques démontre l'efficacité de ces méthodes. Les résultats ont montré que l'approche ANFIS était capable de modéliser les relations complexes entre les variables d'entrée et la tension de contournement, ce qui a permis d'obtenir des prévisions précises et fiables. Les évaluations de performance basées sur l'erreur quadratique moyenne (RMSE), le coefficient de détermination (R^2) et l'erreur moyenne absolue en pourcentage (MAPE) ont confirmé l'efficacité de cette approche pour la prédiction de Uc.

Dans le prochain chapitre, les réseaux de neurones seront utilisés avec les méthodes d'optimisation par recherche du coucou (ANN--CS) et par essaim de particules (ANN--PSO) comme méthode de prédiction de Uc.



Chapitre 4
Prédiction de la tension de
contournement par les
approches hybrides ANN-PSO &
ANN-CS

4.1 Introduction

Essaim de particules (PSO) et la recherche de coucou (CS) sont deux algorithmes utilisés en intelligence artificielle pour résoudre des problèmes d'optimisation.

PSO est un algorithme d'optimisation stochastique inspiré du comportement de recherche de nourriture des oiseaux dans un essaim. Dans cet algorithme, un groupe d'individus appelés "particules" est utilisé pour explorer l'espace de recherche et rechercher la meilleure solution possible à un problème d'optimisation, en se basant sur une fonction objectif spécifiée.

D'un autre côté, l'optimisation par recherche de coucou est inspirée du comportement de reproduction parasitaire des coucous. Dans cet algorithme, chaque coucou représente une solution potentielle et cherche à améliorer sa propre performance en pondant ses œufs dans les nids d'autres coucous. Les coucous utilisent les meilleures performances trouvées par les autres coucous pour orienter leur propre recherche.

Dans ce chapitre, nous allons présenter deux méthodes pour estimer la tension de contournement. Ces approches combinent l'utilisation de réseaux de neurones avec deux techniques d'optimisation différentes : l'optimisation par recherche du coucou (CS) et l'optimisation par essaim de particules (PSO).

Tout d'abord, nous allons présenter les deux méthodes PSO et CS en expliquant leurs fonctionnements. Ensuite, nous détaillerons l'algorithme utilisé pour réaliser les deux approches hybrides (ANN-PSO et ANN-CS). Enfin, nous comparerons les performances de la méthode ANN-PSO avec celles de la méthode ANN-CS dans l'estimation de U_c .

4.2 Optimisation d'Essaim de Particules (Particle Swarm Optimization)

Particle Swarm Optimization (PSO), ou méthode d'optimisation par essaim particulaire (OEP) en français, est une méthode d'optimisation stochastique basée sur une population. Elle a été proposée en 1995 par Kennedy et Eberhart, qui ont puisé leur inspiration du comportement social des animaux évoluant en essaim tels que les bancs de poissons ou les vols groupés d'oiseaux [103].

L'algorithme de PSO simule une population de particules évoluant dans un espace de recherche multidimensionnel en se déplaçant lentement vers la solution optimale. Chaque particule est associée à une position qui correspond à une solution possible, et cette position est initialement assignée de manière aléatoire. Chaque particule a également son propre vecteur de vitesse unique qui est utilisé pour mettre à jour sa position à chaque itération [104]. L'ajustement de la vitesse de chaque particule est basé sur deux éléments de mémoire : la mémoire locale et la mémoire sociale. La mémoire locale de chaque particule correspond à sa meilleure position

connue jusqu'à présent. La mémoire sociale correspond à la meilleure position de toutes les particules de l'essaim. À chaque itération, la vitesse de chaque particule est modifiée pour s'orienter vers ces deux mémoires, ce qui permet aux particules de se déplacer vers les régions les plus favorables de l'espace de recherche [105].

Dans l'algorithme de PSO, chaque particule a uniquement connaissance de la position et de la vitesse de ses voisins les plus proches. Elle utilise sa propre mémoire ainsi que les informations locales sur ses voisins pour décider de son déplacement. En se basant sur ces informations, la particule met à jour sa position et sa vitesse actuelles. Des règles simples telles que "maintenir la même vitesse que les autres", "se déplacer dans la même direction" ou "rester à proximité de ses voisins" sont suffisantes pour Assurer la cohésion de l'essaim et faciliter l'apparition de comportements collectifs [106].

En d'autres termes, chaque particule a une connaissance limitée de son environnement. Cependant, en utilisant des règles simples pour interagir avec ses voisins, elles sont capables de coopérer pour atteindre l'objectif commun de trouver la solution optimale.

4.2.1 Principe de la Technique PSO

Le principe de l'algorithme est de trouver la solution optimale à un problème donné en orientant des particules à travers un espace de recherche. Pour ce faire, l'algorithme suit une série d'étapes logiques et mathématiques qui permettent d'ajuster la position et la vitesse de chaque particule, en fonction de l'expérience personnelle et collective de l'ensemble de l'essaim. Ce processus itératif permet d'améliorer progressivement la qualité de la solution trouvée, jusqu'à atteindre l'optimum global [107].

La technique PSO peut être appliquée dans divers domaines pour résoudre des problèmes d'optimisation complexes dans un délai raisonnable. Ce processus est caractérisé par sa capacité itérative, qui permet de répéter les étapes de recherche plusieurs fois pour améliorer progressivement la qualité de la solution [108-109-110].

La méthode PSO utilise de larges ensembles de particules fonctionnant comme des vecteurs se déplaçant dans l'espace de recherche. Chaque particule i est caractérisée par une position initiale x_i et une vitesse v_i , qui représente le vecteur de déplacement de la particule dans cet espace. Elle est représentée par $X_i = (x_{i1}, x_{i2}, \dots, x_{in})$.

L'objectif de la méthode PSO est de définir la vitesse v_i en considérant le comportement précédent de chaque particule ainsi que celui de ses voisins, afin de déterminer son propre mouvement dans l'espace de recherche [111-112].

Chaque particule se déplace en se basant sur les deux meilleures valeurs suivantes :

- La meilleure position passée de la particule, appelée pbest.
- La meilleure position obtenue parmi tous les voisins, appelée gbest.

la meilleure solution trouvée parmi les voisins d'une particule dans l'espace de recherche est appelée la meilleure position locale (lbest).

À chaque itération, les deux meilleures valeurs, à savoir pbest (meilleure position individuelle) et gbest/lbest (meilleure position locale ou globale), sont combinées pour ajuster la vitesse de chaque particule et calculer une mise à jour de sa position. En général, l'utilisation d'un voisinage social gbest (par exemple, lorsque l'individu x2 considère les individus x1 et x3 comme ses voisins, indépendamment de leur position spatiale), donne de meilleurs résultats que l'utilisation d'un voisinage spatial lbest qui se base sur la proximité des individus dans l'espace de recherche. [113-114].




Figure 4.1 Mouvement de chaque particule

La définition des voisinages est une étape importante dans l'algorithme PSO. Il existe deux types de voisinages [113] :

➤ **Voisinage géographique**

Également appelé voisinage topologique, est défini en fonction de la disposition spatiale des particules dans l'espace de recherche. Chaque particule considère comme voisines les autres qui sont situées à une distance définie autour d'elle. Cette distance est appelée le rayon de voisinage et peut être déterminée de différentes manières, comme par exemple en fonction de

la densité de particules dans l'espace ou en fonction d'un seuil prédéfini. Ce type de voisinage, qui permet aux particules de prendre en compte leur positionnement dans l'espace de recherche pour déterminer leurs mouvements, est souvent utilisé dans des problèmes de localisation ou d'optimisation de fonctions continues. Cependant, il peut être limité dans certaines situations où la distribution des particules n'est pas uniforme ou où les zones de recherche intéressantes sont éloignées les unes des autres, ce qui peut entraîner des difficultés de trouver les meilleures solutions pour les particules. C'est donc un voisinage dynamique, comme il a été illustré sur la Figure 4.2.

Dans cet exemple, nous supposons que le voisinage d'une particule est formé par les deux particules les plus proches.




Figure 4.2 : Voisinage géographique.

➤ **Voisinages sociaux :**

Ce type de voisinage est considéré comme statique. Cependant, il est couramment utilisé en PSO car il est facile à mettre en œuvre et donne généralement des résultats satisfaisants dans de nombreux cas. Il existe différentes structures de voisinages sociaux, que l'on peut représenter graphiquement (voir Figure 4-3). Les structures les plus couramment utilisées sont le voisinage en anneau, le voisinage en étoile et le voisinage en bloc [113].

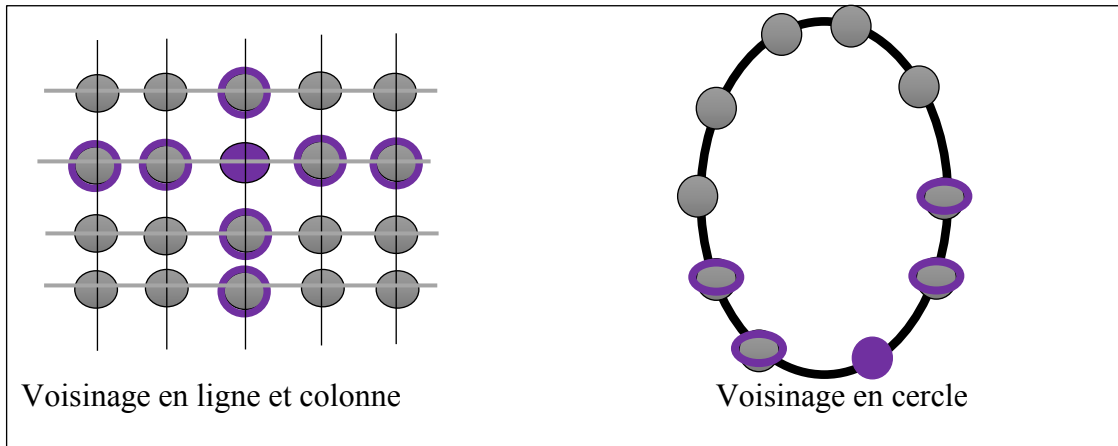


Figure 4-3: Deux cas de voisinage social

4.2.2 Formulation Mathématique de l'Algorithme PSO

Les équations pour mettre à jour la position sont les suivantes :

$$v_{ij}^{t+1} = wv_{ij}^t + c_1r_{1ij}[P_{bestij}^t - x_{ij}^t] + c_2r_{2ij}[G_{bestj}^t - x_{ij}^t], j \in \{1, 2, \dots, D\} \quad (4.1)$$

$$x_{ij}^{t+1} = x_{ij}^t + v_{ij}^{t+1} \quad (4.2)$$

P la meilleure position précédemment atteinte par la particule

G La meilleure position atteinte par les particules de l'essaim

Où w est une constante, appelée coefficient d'inertie ; c_1 et c_2 sont deux constantes, appelées coefficients d'accélération (habituellement, on prend $c_1 = c_2 = 2$) ; r_1 et r_2 sont deux nombres aléatoires tirés uniformément dans $[0, 1]$.

Les trois composantes mentionnées ci-dessus (i.e. d'inertie, cognitive et sociale) sont représentées dans l'équation (4.1) par les termes suivants :

- wv_{ij}^t correspond à la composante d'inertie du déplacement, où le paramètre w contrôle l'influence de la direction de déplacement sur le déplacement futur ;
- $c_1r_{1ij}[P_{bestij}^t - x_{ij}^t]$ correspond à la composante cognitive du déplacement, où le paramètre c_1 contrôle le comportement cognitif de la particule.
- $c_2r_{2ij}[G_{bestj}^t - x_{ij}^t]$ correspond à la composante sociale du déplacement, où le paramètre c_2 contrôle l'aptitude sociale de la particule.

Le coefficient d'inertie est donné par [115-116-117]:

$$w = w_{max} - \frac{w_{max} - w_{min}}{iter_{max}} \cdot iter \quad (4.3)$$

Où : w_{max} : Poids initial.

w_{min} : Poids final.

$iter_{max}$: Le nombre maximum d'itérations.

Le facteur de pondération (inertie) w permet de définir la capacité d'exploration de chaque particule en vue d'améliorer la convergence de l'algorithme. Une grande valeur de w ($w > 1$) se traduit par une grande amplitude de déplacement et donc une capacité d'exploration globale, tandis qu'une faible valeur de w ($w < 1$) se traduit par une amplitude de déplacement limitée, ce qui entraîne une capacité d'exploration locale réduite.

4.2.3 Algorithme de PSO

La mémoire de l'algorithme PSO est essentielle pour que les particules puissent mémoriser les positions les plus favorables qu'elles ont découvertes jusqu'à présent, leur permettant ainsi de se diriger vers les régions les plus propices de l'espace de recherche en se basant sur leurs expériences locales [117-118]. En outre, la mémoire permet également aux particules de communiquer entre elles et de partager leurs expériences sociales, ce qui facilite la convergence de l'essaim vers la solution optimale.

Dans l'algorithme [119], nous définissons la meilleure position connue de l'essaim comme G et utilisons une fonction $f(x)$ pour évaluer le critère de la position x .

Pour chaque particule, les étapes suivantes sont suivies :

- ✚ Initialisation de la position : Chaque particule est positionnée de manière aléatoire dans l'espace de recherche.
- ✚ Initialisation de la meilleure position personnelle : Au départ, la meilleure position connue de la particule (p) est définie comme sa position initiale.
- ✚ Comparaison avec la meilleure position globale : La valeur de la fonction (f) est calculée pour la meilleure position de la particule (p) et pour la meilleure position de l'essaim (g). Si la valeur de $f(p)$ est inférieure à la valeur de $f(g)$, cela signifie que la particule a trouvé une meilleure position que l'essaim jusqu'à présent. Dans ce cas, la meilleure position de l'essaim est mise à jour pour être égale à la meilleure position de la particule ($g = p$).
- ✚ Initialisation de la vitesse : Chaque particule a une vitesse initiale attribuée. Cette vitesse peut être définie de manière aléatoire ou avec une certaine heuristique basée sur la connaissance du problème.
- ✚ Tant que l'on n'a pas atteint le nombre maximal d'itérations ou une certaine valeur du critère :

- Pour chaque particule i :

- Générer deux nombres aléatoires c_1 et c_2 : Ces nombres sont utilisés comme coefficients pour ajuster la vitesse de la particule.
- Mettre à jour la vitesse de la particule : La vitesse de la particule est mise à jour en utilisant la formule (4.1).
- Mettre à jour la position de la particule : La position de la particule est mise à jour en utilisant la formule (4.2).
- Mettre à jour la meilleure position connue de la particule : Si la valeur de la fonction pour la nouvelle position de la particule ($f(x_{i(t+1)})$) est inférieure à la valeur de la fonction pour sa meilleure position connue ($f(p_i)$), alors la meilleure position connue de la particule est mise à jour : $p_i = x_i(t+1)$
- Mettre à jour la meilleure position de l'essaim : Si la valeur de la fonction pour la meilleure position de la particule ($f(p_i)$) est inférieure à la valeur de la fonction pour la meilleure position de l'essaim ($f(g)$), alors la meilleure position de l'essaim est mise à jour : $g = p_i$

Dans cette formulation, g représente l'optimum recherché, c'est-à-dire la meilleure solution trouvée parmi toutes les particules de l'essaim jusqu'à présent.

La figure (4.4) représente le principe de l'algorithme

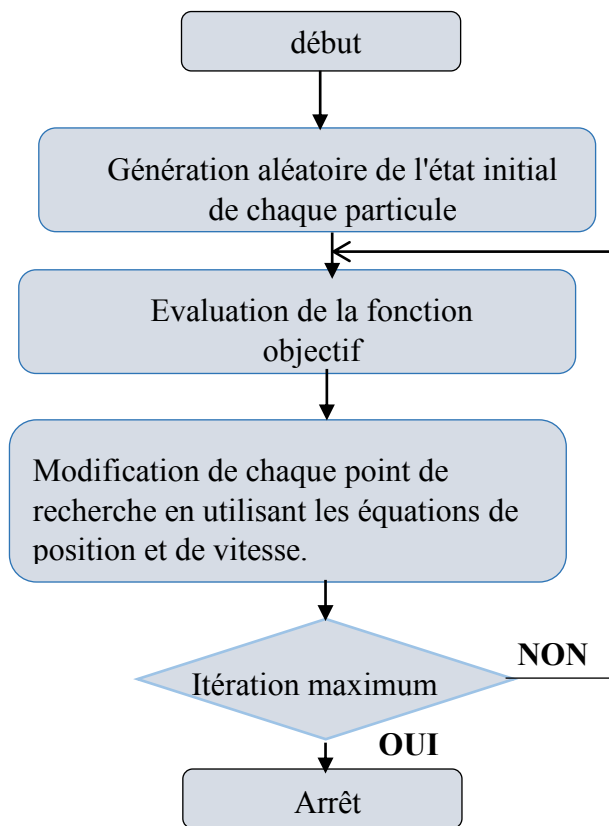


Figure 4.4: Organigramme de l'algorithme de PSO

4.3. Recherche de Coucou (CS)

La recherche sur le coucou s'inspire de la nature, en particulier du parasitisme de couvée interspécifique observé chez certaines espèces de coucous qui pondent leurs œufs dans les nids d'autres espèces d'oiseaux pour éviter d'assumer les responsabilités parentales. Cette stratégie est également utile pour minimiser le risque de perte d'œufs, car les coucous peuvent distribuer leurs œufs parmi un grand nombre de nids différents [120-121].

L'algorithme métaheuristique proposé par Yang et Deb en 2009 pour résoudre les problèmes d'optimisation est basé sur cette stratégie [122-123], en distribuant les solutions potentielles sur un grand nombre de domaines de recherche.

4.3.1. Oiseau de coucou

"Oiseau de coucou" est une expression française qui se traduit en anglais par "cuckoo bird". Le coucou pond ses œufs dans les nids d'autres oiseaux, un comportement appelé le parasitisme de couvée, qui lui permet d'assurer la transmission de sa descendance en utilisant l'instinct naturel des oiseaux hôtes pour élever leurs jeunes. Pour augmenter la probabilité de succès, la femelle coucou élimine souvent un œuf de l'hôte avant de pondre le sien. Cependant, certains oiseaux hôtes peuvent être en conflit avec le coucou intrus, et ont développé des stratégies pour reconnaître et éviter ce comportement [124].

Effectivement, certains oiseaux hôtes ont développé la capacité de reconnaître les œufs de coucou dans leur nid, notamment grâce à une aire de peau sensible et dénudée sous leur ventre qui leur permet de détecter les différences de température et de texture. Dans certains cas, ils peuvent rejeter ou abandonner le nid en réponse à la présence d'un œuf de coucou.

Cependant, certains types de coucous, tels que le Tapera, ont évolué pour imiter les œufs de leurs hôtes en termes de couleur et de forme. Cela rend plus difficile pour l'oiseau hôte de détecter la présence de l'œuf de coucou, augmentant ainsi les chances de succès de la stratégie de parasitisme de couvée du coucou. Cette capacité d'imitation peut varier en fonction des espèces de coucous et des espèces hôtes impliquées [125].



Figure 4.5: Oiseau de coucou

4.3.2 Principaux composants de recherche coucou

Dans la recherche coucou, le nid et l'oeuf sont deux composants importants de l'algorithme méta-heuristique [125].

4.3.2.1 Nid

Les caractéristiques principales des nids sont les suivantes :

- Le nombre de nids est fixé et égal à la taille de la population.
- Chaque nid représente une solution possible du problème d'optimisation.
- Les nids sont considérés comme des individus dans une population.
- Les nids peuvent être remplacés par de nouvelles solutions générées aléatoirement.
- Chaque oeuf dans un nid représente une solution améliorée à partir de la solution précédente, obtenue par l'application de la méta-heuristique de recherche coucou.

4.3.2.2 Œufs

L'œuf est l'un des principaux composants de la recherche de coucou. Dans cette méthode d'optimisation, chaque œuf dans un nid représente une solution possible à un problème d'optimisation. Les coucous les déposent dans les nids d'autres oiseaux afin d'éviter d'élever leur propre progéniture et minimiser les risques de perte.

Dans la recherche de coucou, les œufs déposés dans les nids représentent différentes solutions possibles. De nouvelles solutions sont créées en remplaçant les œufs existants par de nouveaux (œufs de coucou) qui résultent de modifications apportées aux solutions précédentes.

4.3.2.3 Fonction objectif

La fonction objectif (ou fonction de fitness) évalue la qualité d'une solution dans l'espace de recherche en lui attribuant une valeur numérique. Dans le cas de la recherche coucou, la qualité d'un nid est mesurée en fonction de l'oeuf qu'il contient, car c'est celui-ci qui détermine la capacité d'un coucou à se reproduire et à se propager dans les générations futures [125]. Ainsi, la qualité de l'oeuf de coucou est directement liée à sa capacité à engendrer une nouvelle génération de coucous.

4.3.3. Vol de Lévy

Le vol de Lévy est une distribution de probabilité utilisée en théorie des probabilités et en statistiques, et qui est souvent utilisée en recherche coucou. Elle tire son nom du mathématicien français Paul Lévy, qui l'a introduite en 1925 [126-127].

Le vol de Lévy est caractérisé par des sauts aléatoires de longueur variable, qui permettent à l'algorithme de couvrir de grandes distances dans l'espace de recherche de manière efficace. Elle est souvent utilisée pour simuler les mouvements des animaux lorsqu'ils cherchent de la nourriture, et elle est considérée comme une alternative à la marche aléatoire classique, qui est plus limitée dans sa portée [128-129].

En recherche coucou, le vol de Lévy est souvent utilisé pour modéliser les mouvements des coucous lorsqu'ils cherchent des nids pour pondre leurs œufs [130]. Elle permet de diversifier les solutions proposées et d'explorer de manière plus efficace l'espace de recherche.




Figure 4.6: Exploration stochastique avec le Vol de Lévy (a), Marche aléatoire simple (b)

4.3.4 Principe de la Technique CS (Cuckoo Search)

Le principe de CS (Cuckoo Search) est de simuler le comportement de recherche de nourriture et de reproduction des coucous dans la nature pour résoudre des problèmes d'optimisation. Le comportement de reproduction des coucous consiste à déposer un œuf dans un nid appartenant à une autre espèce d'oiseau, puis à quitter le nid parental. Les œufs sont ensuite couvés et nourris par les parents adoptifs jusqu'à l'éclosion [131].

Dans l'algorithme CS, Chaque solution possible est considérée comme un nid de coucou. Une population initiale est générée aléatoirement, et la qualité de chaque solution est évaluée en utilisant une fonction objective à optimiser. Les nids de haute qualité sont conservés, tandis que ceux de qualité inférieure sont remplacés par de nouveaux nids générés aléatoirement ou en utilisant des opérateurs de croisement ou de mutation.

Le processus de reproduction des coucous est simulé en sélectionnant un nid au hasard dans la population et en y déposant un nouvel œuf (c'est-à-dire en créant une nouvelle solution possible) [131]. Si l'œuf du coucou est de meilleure qualité que ceux présents dans le nid, le coucou abandonne son œuf et le remplace par le sien. Sinon, le coucou conserve son œuf dans son nid.

L'étape de remplacement et de reproduction est répétée plusieurs fois pour permettre aux coucous d'explorer de nouveaux nids dans l'espace de recherche et d'améliorer la qualité de leurs solutions. La méthode de sélection permet de maintenir la diversité de la population et d'éviter une convergence trop rapide vers un optimum local [131-132].

En résumé, le principe de CS est de combiner la recherche aléatoire et la sélection pour explorer de manière efficace l'espace de recherche et trouver des solutions optimales pour les problèmes d'optimisation.

4.3.5 Algorithme de la recherche Coucou (Cuckoo Search)

L'algorithme CS utilise un ensemble de nids (solutions) pour effectuer la recherche. Chaque nid est représenté par un vecteur x_i de n dimensions, où i est l'indice du nid. Le nombre total de nids est fixé à N , ce qui correspond à la taille de la population.

L'algorithme CS fonctionne selon les étapes suivantes :

1. Générer une population initiale de n nids d'hôtes aléatoires.
2. Évaluer la qualité/fitness de chaque nid en utilisant la fonction objectif $f(x)$.
3. Initialiser la meilleure solution comme étant la solution du premier nid.
4. Tant que la génération actuelle est inférieure ou égale à MaxGeneration :
 - Pour chaque nid :
 1. Sélectionner un nid voisin aléatoire.
 2. Générer un nouvel œuf (nouvelle solution) en effectuant des Vols de Lévy.
 3. Évaluer la qualité/fitness de l'œuf du coucou en utilisant la fonction objectif $f(x)$.
 4. Comparer la qualité/fitness de l'œuf du coucou avec celle de la solution actuelle dans le nid.
 5. Si la qualité/fitness de l'œuf du coucou est meilleure, remplacer la solution dans le nid par l'œuf du coucou.

6. Abandonner une fraction p_a (probabilité de découverte de l'œuf par l'oiseau hôte) des pires nids (solutions) et construire de nouveaux nids aléatoires.
7. Sélectionner la meilleure solution parmi tous les nids.
8. Mettre à jour la meilleure solution si la qualité/fitness de la meilleure solution actuelle est améliorée.
9. Retourner la meilleure solution trouvée.

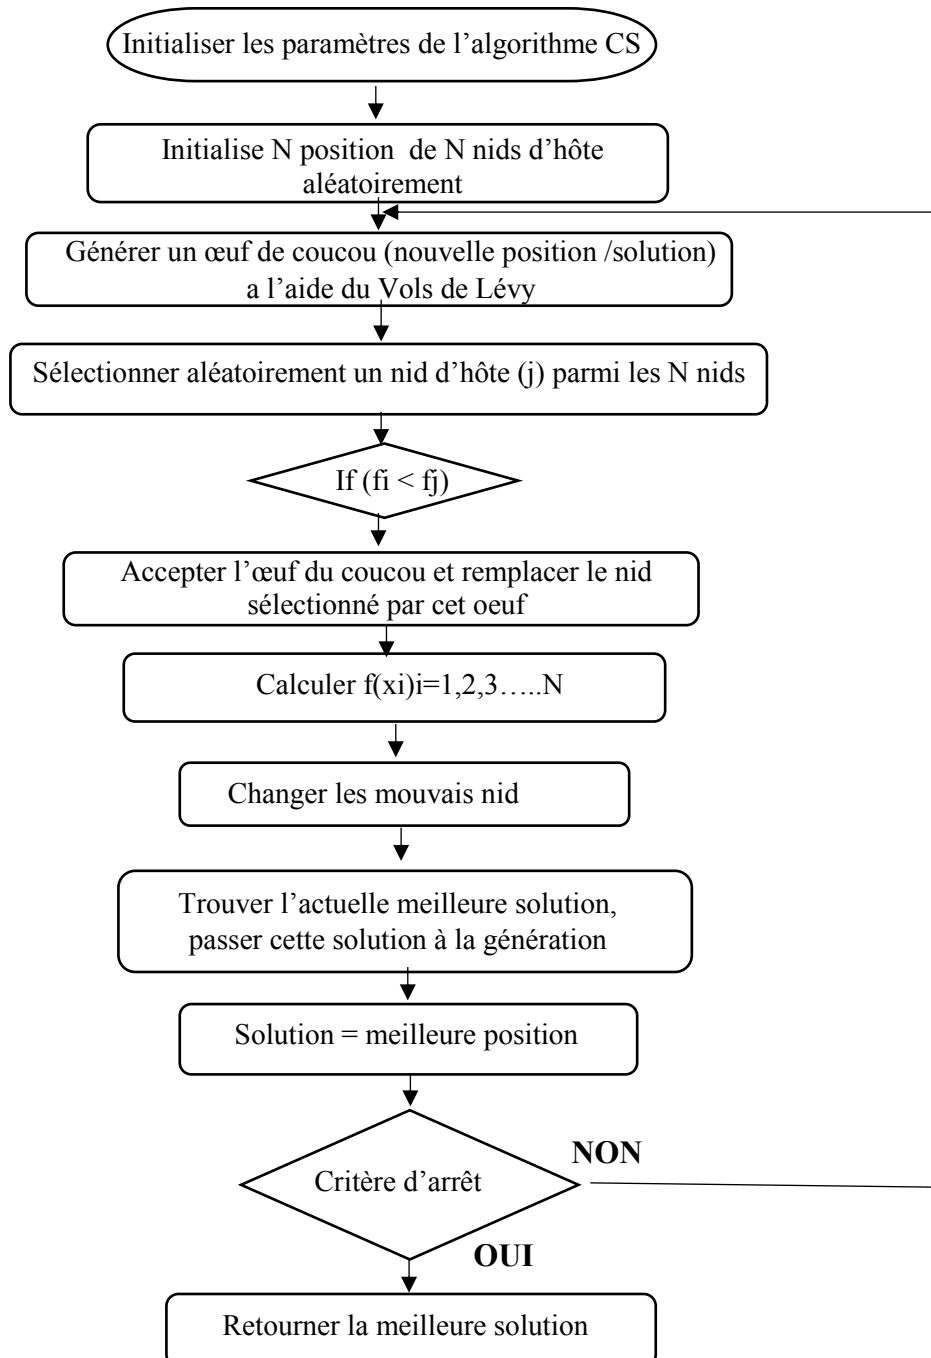


Figure 4.7: Organigramme de l'algorithme de la recherche coucou

4.4 Combinaison d'un réseau de neurones et des méthodes CS et PSO

L'optimisation par essaim de particules (PSO) et par l'algorithme de la recherche de coucou (Cuckoo Search) peuvent être utilisées dans l'entraînement des réseaux de neurones [133]. Voici une comparaison entre les deux méthodes :

1. **Convergence** : L'un des avantages de PSO est sa capacité à converger rapidement vers la solution optimale, même pour des problèmes complexes. Cependant, la convergence de PSO peut être influencée par des paramètres tels que la taille de l'essaim et les coefficients de poids, ce qui peut rendre la méthode plus sensible aux hyperparamètres que la recherche de coucou (Cuckoo Search).
2. **Exploration** : L'algorithme de recherche de coucou (CS) est connu pour sa capacité à explorer efficacement l'espace de recherche, même pour des problèmes à plusieurs dimensions. Cela est dû à l'utilisation d'une heuristique de recherche basée sur des stratégies d'évolution et de parasitisme inspirées du comportement de nidification des oiseaux coucous. Ces stratégies permettent à l'algorithme de s'adapter à différentes topologies de la fonction objectif et d'explorer de manière plus globale l'espace de recherche, le PSO est généralement efficace pour trouver des solutions locales de haute qualité, mais peut être moins efficace dans la recherche de solutions globales pour des problèmes complexes.
3. **Stabilité** : le PSO est généralement considéré comme plus stable en raison de son mécanisme de mouvement progressif des particules, tandis que la recherche de coucou peut être plus sensible à des fluctuations et à une convergence moins régulière en raison de ses processus de perturbation aléatoire. Cependant, la stabilité peut varier en fonction des paramètres et de la mise en œuvre spécifiques.
4. **Performance** : Les performances des deux méthodes dépendent du problème spécifique et des données d'entrée. Cependant, plusieurs études ont montré que l'approche CS peut être plus efficace pour des problèmes de classification, tandis que PSO peut être plus adapté pour des problèmes de régression.

Le choix entre ANN-CS et ANN-PSO dépend des besoins spécifiques de l'application et de la complexité du problème.

4.5 Prédiction de la tension de contournement par ANN--PSO et ANN--CS

Dans cette partie, deux approches hybrides sont présentées pour estimer U_c . Les deux approches combinent l'utilisation de réseaux de neurones avec l'algorithme de recherche de coucou (CS) et l'optimisation par essaim de particules (PSO).

Pour évaluer les performances de ces méthodes hybrides, l'outil proposé utilise les données expérimentales et l'ensemble de données mentionnés dans le chapitre 1 pour entraîner le réseau de neurones artificiels (ANN) et évaluer ses performances.

Une fois que le système a été entraîné avec les données d'apprentissage, il est important de tester sa performance avec des données de test qui n'ont pas été utilisées pour l'apprentissage. Si le système réussit à estimer U_c à partir des données de test, cela démontre sa capacité à généraliser et à prédire avec précision cette valeur pour de nouvelles situations où il n'a pas été préalablement entraîné.

4.5.1 Algorithme de l'approche hybride ANN -PSO

L'approche hybride ANN -PSO est une méthode qui combine l'utilisation d'un réseau neuronal artificiel (ANN) et d'un algorithme d'optimisation par essaim de particules (PSO) pour résoudre des problèmes complexes.

La procédure suivie pour établir cette approche hybride est:

1. **Collecte des données** : La première étape consiste à collecter des données pertinentes pour le problème à résoudre. Ces données peuvent être des données historiques, des données de simulation ou des données expérimentales
2. **Définition de l'architecture du ANN** : L'étape suivante consiste à définir l'architecture du ANN. Cela implique de déterminer le nombre de couches, le nombre de neurones par couche et les fonctions d'activation à utiliser.
3. **Entraînement du ANN** : Une fois que l'architecture du ANN est définie, le ANN est entraîné en utilisant les données prétraitées. L'objectif est de minimiser l'erreur de prédiction en ajustant les poids et les biais du ANN.
4. **Définition de la fonction d'objectif** : La fonction d'objectif joue un rôle fondamental en évaluant la qualité de la solution proposée par le processus d'optimisation. Dans ce cas, la fonction d'objectif est définie pour minimiser l'erreur de prédiction.
5. **Définition des paramètres PSO** : Les paramètres PSO tels que le nombre de particules, la vitesse maximale et la constante d'accélération sont définis.
6. **Initialisation des particules** : Les particules sont initialisées avec des positions et des vitesses aléatoires.

7. **Évaluation des particules** : Les particules sont évaluées en utilisant la fonction d'objectif définie précédemment.
8. **Mise à jour des positions et des vitesses** : Les positions et les vitesses des particules sont mises à jour en utilisant les équations de PSO.
9. **Vérification de la condition d'arrêt** : La condition d'arrêt est vérifiée pour déterminer si les particules ont convergé vers une solution optimale.
10. **Continuez à répéter les étapes 8 à 10** jusqu'à ce que la condition d'arrêt soit satisfaite.
11. **Validation du modèle** : Le modèle est validé en utilisant des données indépendantes pour évaluer sa performance.

En résumé, l'approche hybride ANN -PSO combine les avantages d'un ANN pour la modélisation et la prédiction avec les avantages d'un algorithme d'optimisation par essaim de particules pour trouver la solution optimale.

4.5.1.1 Paramètres de l'algorithme ANN -PSO

Les valeurs adoptées pour les paramètres de l'approche ANN -PSO sont :

- Nombre de neurones cachés : $n=10$
- Le nombre Maximal d'itérations $I_{max}=6000$
- Le nombre de particules (la taille d'essaim) $pop=100$
- Constantes d'accélération $c1=1$ et $c2 = 2$.

Afin de prédire U_c , un réseau de neurones à trois couches est configuré avec quatre neurones d'entrée (trois niveaux de pollution et conductivité de la pollution), dix neurones dans la couche cachée et un neurone de sortie, comme illustré dans la figure 4.9.

Pour déterminer la meilleure architecture, une série de tests a été effectuée en fixant les valeurs de $c1$ et $c2$ ($c1=1$ et $c2=2$).et l'erreur quadratique moyenne (RMSE) a été calculée. La procédure de recherche a été arrêtée après 6000 itérations.

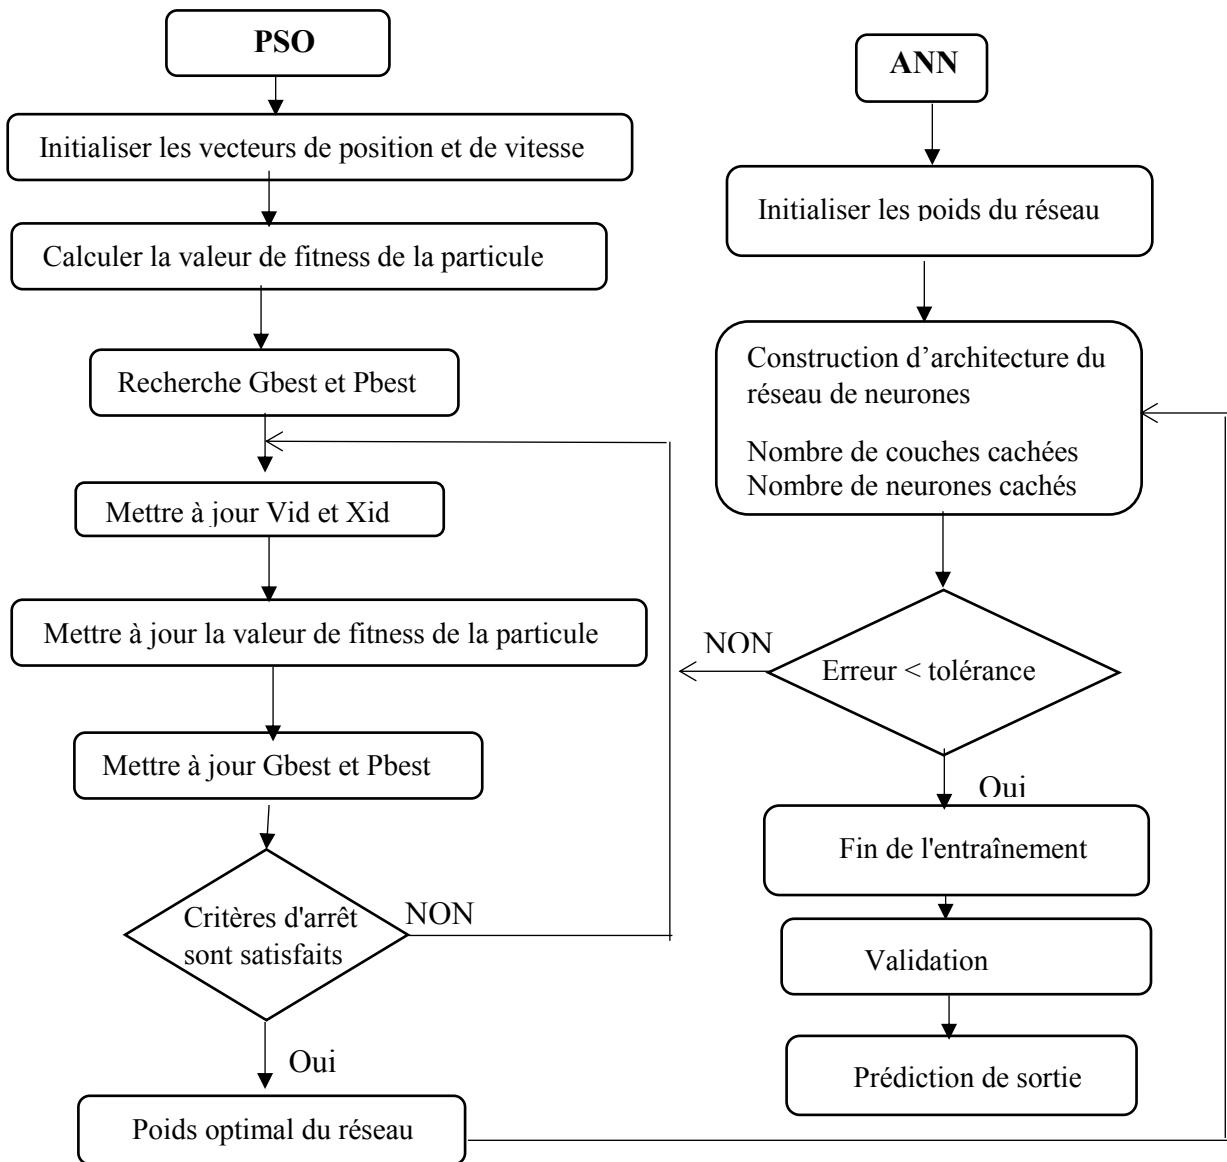


Figure 4.8 : Organigramme de ANN -PSO




Figure 4.9 : Implémentation de l'architecture de ANN -PSO avec MATLAB

4.5.1.2 Résultats et discussion

La technique ANN-PSO utilise une base de données pour entraîner le réseau de neurones à déterminer U_c . Cette technique utilise des entrées/sorties telles que la conductivité δ , la quantité de pollution dans les trois zones de l'isolateur (Q1, Q2, Q3) et la tension de contournement. Une fois la tâche d'apprentissage de l'approche terminée, il est essentiel de vérifier les performances du modèle en utilisant des données de test générées à partir du tableau 1.2 du chapitre 1.

La figure 4.10 montre les résultats de l'entraînement de l'approche ANN-PSO sur une base de données d'apprentissage contenant 103 vecteurs. Après l'apprentissage, nous évaluons l'efficacité de l'approche en utilisant des données de test contenant 18 vecteurs.




Figure 4.10 : Performance de ANN -PSO en phase d'apprentissage

La figure 4.11 illustre la comparaison entre les prédictions de U_c obtenues par l'approche ANN-PSO et les valeurs réelles obtenues lors du test, afin d'évaluer l'efficacité de l'approche proposée.

Nous pouvons constater une certaine adéquation entre l'approche et les données mesurées, ce qui indique que la méthode ANN-PSO est capable de prédire avec précision la tension de contournement.






Figure 4.11 : Performance de ANN -PSO en phase de test

L'évaluation de la corrélation entre les valeurs prédites de U_c par l'approche hybride ANN-PSO et les valeurs réelles mesurées est un critère essentiel pour évaluer la précision de la méthode proposée.



a. Phase d'apprentissage



b. Phase de test

Figure 4.12 Courbe de régression pour l'estimation de U_c

Un coefficient de corrélation R^2 proche de 1 indique une forte corrélation entre les valeurs estimées et mesurées, ce qui démontre une grande précision de l'approche. Dans notre étude, la valeur de R^2 égale à 0,99821 confirme la performance de l'approche proposée.

4.5.2 Approche hybride réseaux de neurones – recherche coucou (ANN -CS)

La méthode ANN-CS consiste à utiliser l'algorithme de Cuckoo Search pour optimiser les poids et les biais des neurones d'un réseau de neurones artificiels. Ces paramètres sont les déterminants de la fonction de transfert des neurones et influencent ainsi les performances du réseau.

L'approche CS est utilisée pour explorer efficacement l'espace des paramètres et trouver les valeurs qui minimisent la fonction de fitness. Une fois les paramètres optimisés, la méthode ANN peut être utilisée pour prédire U_c .

Comme mentionné précédemment, les variables considérées comme des entrées sont la conductivité, la quantité de pollution dans les zones d'isolateur (Q1, Q2, Q3), tandis que la variable de sortie est la tension de contournement. Une fois que la phase d'apprentissage de l'approche est terminée, leur performance est évaluée à l'aide d'une phase de tests.

4.5.2.1 Algorithme de l'approche hybride ANN -CS

Par la suite, nous présentons la procédure suivie pour développer l'approche hybride ANN-CS :

1. Collecte des données : La première étape consiste à collecter les données nécessaires pour résoudre le problème. Les données peuvent être sous forme d'images, de fichiers audio, de séries temporelles, etc

2. Prétraitement des données : Les données collectées doivent être prétraitées pour éliminer les bruits et les erreurs. Cette étape peut inclure la normalisation, la réduction de dimension. etc

3. Formation du réseau de neurones : Dans cette étape, un réseau de neurones est formé en utilisant les données prétraitées. Le choix du type de réseau de neurones dépend du type de problème à résoudre.

4. Recherche coucou : La recherche coucou est utilisée pour optimiser les paramètres du réseau de neurones. Cette étape consiste à générer une population de solutions aléatoires et à les évaluer en utilisant une fonction d'évaluation. Les meilleures solutions sont sélectionnées pour la prochaine génération et le processus est répété jusqu'à ce qu'une solution optimale soit trouvée.

5. Validation et test : Une fois la formation et l'optimisation du réseau de neurones terminées, Le modèle est évalué en utilisant des données de test pour mesurer sa précision et sa performance.

4.5.2.2 Organigramme de l'approche hybride ANN -CS

Dans la première étape, l'algorithme charge toutes les données d'entraînement. Le système de recherche de coucou (CS) utilise ces données pour rechercher et identifier les meilleurs paramètres et initialiser les préférences lors de la première génération. Ensuite, ces paramètres sont transmis au réseau de neurones artificiels (ANN) où une analyse est effectuée pour trouver la meilleure configuration. Le CS met à jour les paramètres avec la meilleure solution possible à chaque itération jusqu'à ce que la dernière époque ou cycle soit atteint. La figure 4.13 présente l'organigramme de l'approche hybride ANN -CS.

Le processus commence par l'entrée des données dans le réseau de neurones artificiels (ANN) et l'initialisation des valeurs des poids et des biais dans la structure de l'ANN. Ensuite, l'ANN génère une sortie correspondante, qui est comparée aux valeurs réelles des données. L'évaluation de la sortie de l'ANN et des données réelles est effectuée en calculant l'erreur entre ces deux valeurs. Une mesure couramment utilisée est l'erreur quadratique moyenne (RMSE) qui représente la différence moyenne entre la sortie de l'ANN et les valeurs réelles des données.

Si l'erreur quadratique moyenne est supérieure à l'objectif de performance global requis, le réseau de neurones est optimisé en adaptant les valeurs des poids et des biais. L'algorithme de recherche de coucou est utilisé pour optimiser ces paramètres. Le processus d'optimisation du réseau de neurones implique généralement la mise à jour des poids et des biais en utilisant des techniques d'optimisation telles que la rétropropagation du gradient ou d'autres algorithmes d'optimisation plus avancés.

Ce processus d'ajustement des poids et des biais est répété de manière itérative jusqu'à ce que l'objectif de performance global soit atteint ou qu'un critère d'arrêt soit satisfait.

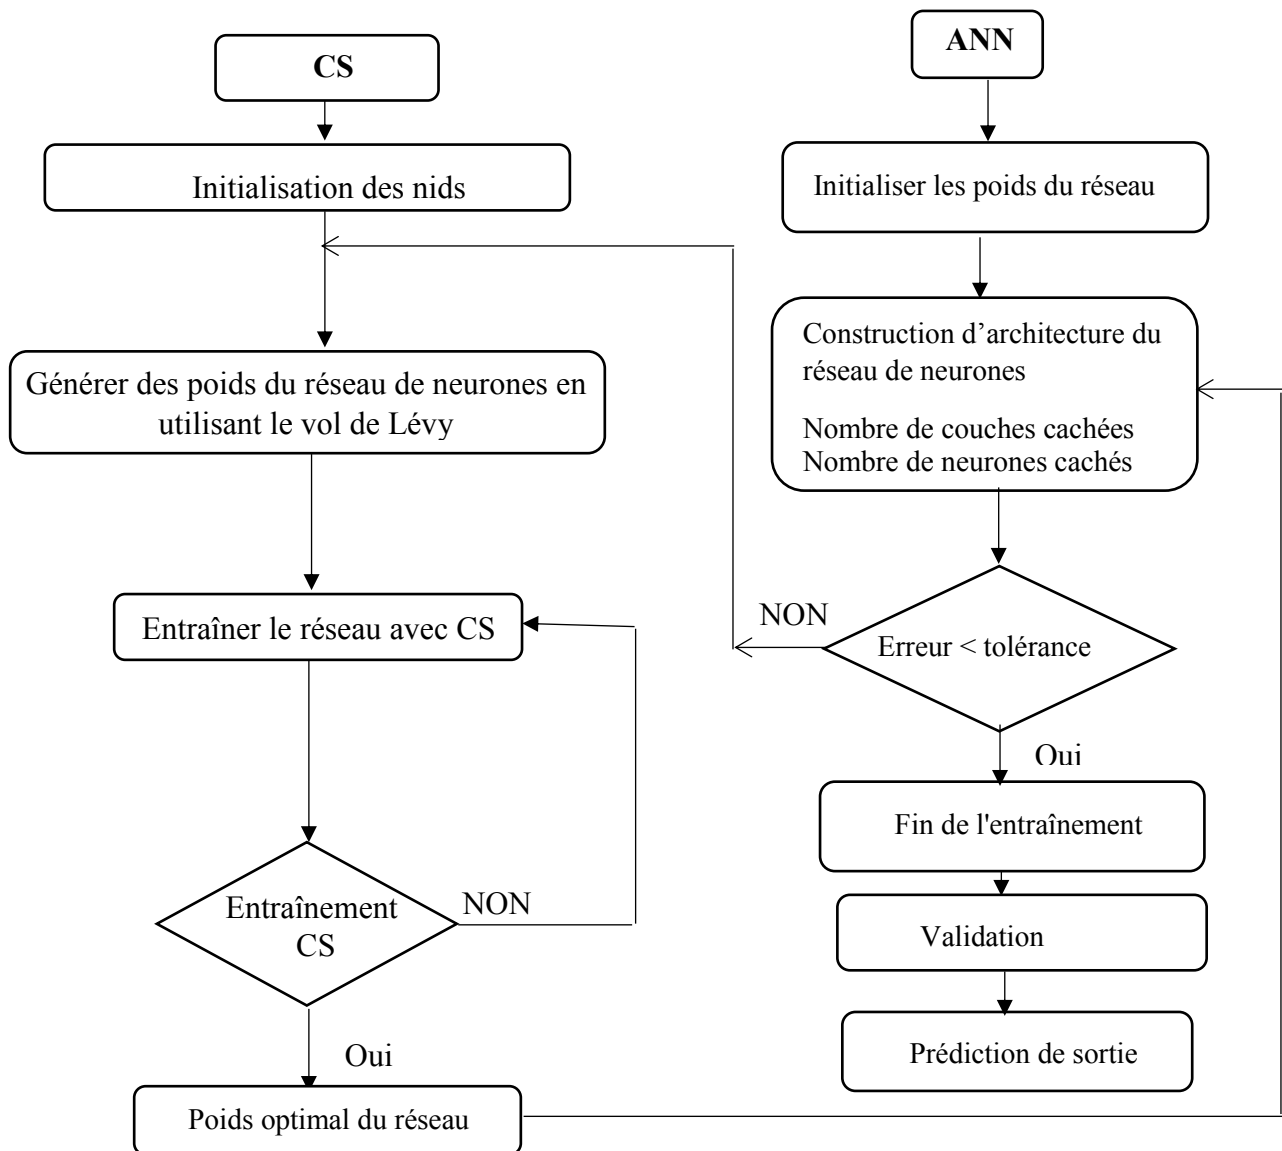


Figure 4.13 : Organigramme de l'approche hybride ANN –CS

4.5.2.3 Paramètres de l’algorithme ANN -CS

Les paramètres de l'approche ANN -CS peuvent être définis en utilisant les valeurs suivantes :

Tableau 4.1 : Paramètres de l’algorithme ANN –CS

Paramètres	Valeur
Pa : probabilité de découvert d’œuf de coucou	0.25
P : nombre de nids	20
Nombre d’itération	100
Nombre de neurones cachés	n=10

4.5.2.4 Résultats et discussion

La figure 4.14 montre une corrélation entre les valeurs estimées et les valeurs réelles de U_c , ce qui confirme l'efficacité de la méthode ANN-CS dans la prédiction de cette tension.






Figure 4.14 : Performance de ANN -PSO en phase de test



a. Phase d'apprentissage



b. Phase de test

Figure 4.15 Courbe de régression pour la prédiction de U_c

La performance de l'approche proposée a été prouvée par la valeur de R^2 qui s'élève à 0,9868. Cette valeur indique une corrélation très forte entre les valeurs observées et les valeurs prédites.

4.6 Performances de ANN -PSO et ANN -CS

Pour évaluer les deux approches ANN-PSO et ANN-CS, des corrélations ont été effectuées sur les résultats générés par ces méthodes. Les valeurs correspondantes sont présentées dans le tableau 4.

De plus, l'évaluation des résultats obtenue par les deux approches a été effectuée en utilisant l'erreur moyenne de pourcentage absolu (MAPE). Cette mesure a permis de quantifier la précision des prédictions en comparant les valeurs prédites avec les valeurs réelles de test.

Tableau 4.2 : Comparaison des performances de ANN -PSO et ANN -CS à l'aide de MAPE

Mesure de la tension à l'aide de tests (kV)	Prédiction de la tension à l'aide de ANN -PSO (kV)	Erreur de pourcentage absolu (APE) à l'aide de ANN -PSO	Prédiction de la tension à l'aide de ANN -CS (kV)	Erreur de pourcentage absolu (APE) à l'aide de ANN -CS
45,80	45.548	0.5502	43.8377	4.2845
39,70	40.2675	1.4295	38.7866	2.3008
34,80	33.7680	2.9655	33.8215	2.8118
34	33.9191	0.2379	35.7357	5.1050
26	25.97348	0.1020	29.7702	14.5008
23	23.3734	1.6235	24.5747	6.8465
39,50	39.3851	0.2909	39.3077	0.4868
36,20	36.4044	0.5646	36.4044	0.5646
33,70	33.5889	0.3297	35.6748	5.8599
38,50	38.4607	0.1021	37.7631	1.9140
35,40	35.6385	0.6737	35.8964	1.4023
33,60	33.9764	1.1202	32.6201	2.9164
19	18.5767	2.2279	19.7037	3.7037
19.7	20.1335	2.2005	21.7802	10.5594
17.5	18.0057	2.8897	17.6828	1.0446
39.4	39.3369	0.1602	39.7716	0.9431
38	36.9664	2.7200	37.5129	1.2818
35	35.4751	1.3574	36.8668	5.3337
	MAPE=1.1970		MAPE=3.9922	

Les résultats obtenus confirment que les deux approches proposées sont efficaces pour la prédiction de U_c .

4.7 Comparaison entre ANN -PSO et ANN -CS

En comparant les résultats de l'approche hybride ANN -CS avec l'approche ANN - PSO, il a été constaté que l'approche ANN -PSO est plus performante en termes de coefficient de détermination R^2 . En effet, l'approche ANN -PSO a une valeur de R^2 de l'ordre de 0.99821, ce qui est supérieure à celle trouvée pour l'approche hybride ANN -CS. Cela indique que l'approche RNA-PSO est plus précise et plus fiable pour prédire U_c .

Tableau 4.3 : Validation des approches ANN -PSO et ANN-CS proposées à l'aide d'indicateurs statistiques

Modèle	Coff. de correlation (r_train)	Coff. de correlation r_test	Coff. de determination (R_train) ²	Coff. de determination (R_test) ²	MAPE_test	RMS_test
RN-PSO	0.99814	0.99821	0.99628	0.99642	1.1969	0.5406
RN-CS	0.98574	0.9868	0.97168	0.97377	3.9923	1.4869

4.8 Conclusion

Dans cette étude, deux approches hybrides, ANN-PSO et ANN-CS, ont été utilisées afin d'estimer la tension de contournement des isolateurs.

Les résultats ont montré que les deux méthodes ont obtenu des valeurs de R^2 proche de 1, ce qui confirme leur performance satisfaisante. Cependant, il convient de noter que l'approche ANN-PSO a présenté des résultats légèrement supérieurs à ceux de l'approche ANN-CS en termes de précision.

Conclusion générale

Travail effectué

Ce travail nous a permis d'étudier le phénomène de contournement des isolateurs pollués sur les lignes de haute tension. Notre objectif principal est de prédire la tension de contournement de l'isolateur de haute tension de type 175CTV en utilisant des techniques d'intelligence artificielle. Pour cela, nous avons étudié différentes architectures de réseaux de neurones artificiels, notamment le réseau de neurones à régression généralisée (GRNN), le réseau de neurones en cascade avant (CFNN) et le réseau de neurones à propagation avant (FFNN). En complément, nous avons également utilisé des systèmes flous et la méthode neuro-floue d'inférence adaptative (ANFIS). Enfin, nous avons développé une approche hybride en combinant les réseaux de neurones artificiels (ANN) avec des techniques d'optimisation par recherche du coucou (CS) et essaim de particules (PSO).

En utilisant des données expérimentales et en ajustant des paramètres spécifiques, nous avons entraîné le réseau de neurones à généraliser et à estimer la tension de contournement en se basant sur la quantité de pollution et la conductivité δ . De plus, nous avons utilisé des systèmes flous pour représenter les relations complexes entre les différentes variables et effectuer des prédictions basées sur des règles floues dérivées de l'expertise humaine. Nous avons également étudié la méthode du système adaptatif d'inférence neuro-floue (ANFIS), qui combine les avantages des réseaux de neurones et des systèmes flous. Cette approche nous a permis d'ajuster automatiquement les paramètres du modèle flou en utilisant des techniques d'apprentissage et d'optimisation, conduisant ainsi à des prédictions plus précises et robustes de la tension de contournement. Finalement, nous avons exploité une approche hybride en combinant les réseaux de neurones artificiels (ANN) avec les techniques d'optimisation par recherche du coucou (CS) et essaim de particules (PSO) pour ajuster les paramètres du réseau de neurones.

Pour évaluer la performance des techniques d'intelligence artificielle proposées, nous avons utilisé plusieurs paramètres d'évaluation : l'erreur absolue moyenne en pourcentage (MAPE), l'erreur quadratique moyenne (RMSE) et le coefficient de détermination (R^2).

Des tests expérimentaux ont été effectués pour rassembler des données sur le comportement de l'isolateur lorsqu'il est soumis à différentes conditions de pollution et de tension. Dans ces tests, une tension alternative a été appliquée progressivement sur l'isolateur pollué de type 175CTV dans le but d'obtenir la tension de contournement. Le processus consistait à augmenter graduellement la tension appliquée jusqu'à ce que l'isolateur se décharge et qu'un arc électrique se produit. Ces mesures nous ont fourni des données précieuses sur le comportement de l'isolateur pollué et nous ont permis de déterminer la tension de contournement spécifique à

l'isolateur étudié. Ensuite, les données expérimentales ont été utilisées pour valider les modèles d'intelligence artificielle que nous avons créés.

À partir de cette étude, nous avons conclu les points suivants :

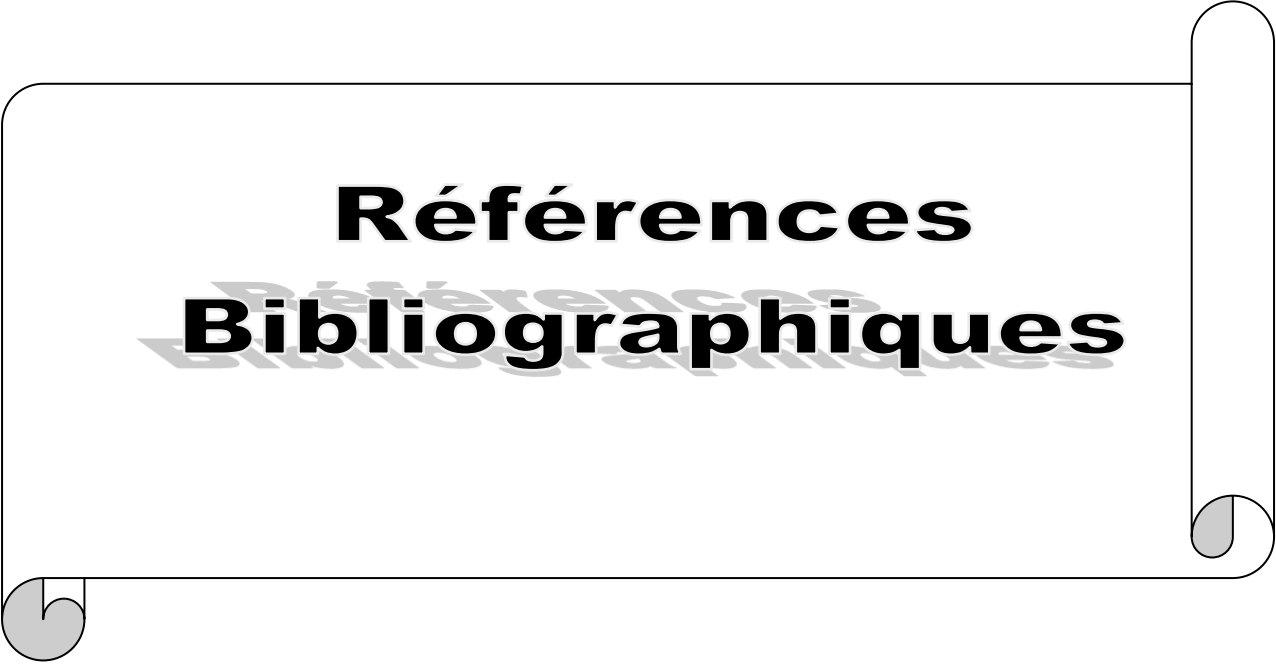
- ✓ La pollution peut modifier les caractéristiques des isolateurs, compromettant ainsi la sécurité et la fiabilité des systèmes d'alimentation électrique.
- ✓ Il est essentiel de comprendre l'impact de la pollution sur les lignes électriques afin de garantir leur bon fonctionnement et leur durabilité, ainsi que d'assurer la sécurité des opérations électriques.
- ✓ Le contournement de l'isolateur est influencé par divers paramètres. Dans notre étude, nous avons pris en compte la conductivité, la quantité de pollution artificielle ainsi que l'amplitude de la tension appliquée afin d'analyser leur impact sur ce phénomène.
- ✓ Le risque de contournement de l'isolateur augmente en effet lors du dépôt de pollution sur celui-ci, ainsi qu'avec l'augmentation de la conductivité de la pollution.
- ✓ la manière d'éviter le contournement est de retirer la couche de pollution déposée par un lavage direct.
- ✓ le réseau de neurones de type GRNN a montré une performance supérieure par rapport aux FFANN et CFANN, avec un coefficient de détermination (R^2) de 0,99960 lors de la phase de test, tandis que celui du CFANN était d'environ 0,983925.
- ✓ Les résultats démontrent que l'approche ANN-PSO est plus efficace que l'approche ANN-CS dans la prédiction de la tension de contournement.
- ✓ Les méthodes d'intelligence artificielle ont joué un rôle essentiel dans la prédiction de la tension critique de contournement des isolateurs. les perceptrons multicouches, les systèmes flous (FIS), l'approche ANFIS, ainsi que les approches hybrides ANN-PSO et ANN-CS ont été utilisés avec succès dans cette tâche. Ces méthodes ont démontré leur capacité à capturer les relations complexes entre les variables d'entrée et la tension de contournement, offrant ainsi des prévisions précises et fiables.

Perspectives

Afin de poursuivre ce travail de manière continue, nous proposons :

- ✓ L'application d'arduino pour prédire la tension de contournement représente une perspective prometteuse. Cela permet aux utilisateurs de surveiller et de mesurer avec précision la tension de contournement de manière efficace, contribuant ainsi à améliorer la sécurité des structures et des installations soumises à des tensions élevées.

- ✓ L'utilisation des logiciels de simulation par éléments finis pour prédire la tension de contournement offre de grandes opportunités. Ces outils permettent de modéliser la géométrie complexe d'une structure et de prendre en considération les multiples facteurs qui influencent la tension de contournement, tels que les conditions de chargement, les propriétés du matériau et les interactions entre les différentes parties de la structure. Ainsi, ces simulations peuvent fournir des prévisions précises et aider à optimiser la conception et la performance des structures soumises à des contraintes de tension.

A decorative border resembling a scroll, with a vertical strip on the right side and rounded corners at the bottom left and bottom right.

Références

Bibliographiques

Références Bibliographiques

- [01] V. M. Rutsky. "Prediction of discharge characteristics of external high-voltage insulation near industrial enterprises, polluting the atmosphere". 9^{ème} international symposium on high voltage engineering, rapport 3247, Autriche, 28 Aout - 1er September 1995.
- [02] G. Houlgate, P.J. Lambeth, W.J. Roberts. "Performances des isolateurs en milieu maritime en très haute et ultra haute tension". CIGRE, Rapport 33-01, 1982.
- [03] Keller-Jacobsen, Aa. Pederson, J.K. Rasmussen, A. Henriksen, C. Lindqvist, S. Smedsfelt. "Essais au laboratoire et en plein air pour dimensionner correctement les isolateurs exposés à la pollution saline". CIGRE, rapport 33-11, 1978.
- [04] S. A. Bessedik, "Contournement des isolateurs pollués", Thèse de doctorat, Université Mohamed Boudiaf d'Oran, 2015.
- [05] O. Guenounou. "Méthodologie de conception de contrôleurs intelligents par l'approche génétique: application à un bioprocédé". Université de Toulouse III-Paul Sabatier, 2009.
- [06] H. Benguesmia, "Modeling an Insulator Under Pollution Conditions under Alternative Voltage 50 Hz". Thèse de doctorat, Université de Biskra, 2018.
- [07] D. Mokeddem. "Contrôle flou des processus biotechnologiques à base d'algorithmes génétiques". Thèse de doctorat. Université de Sétif 2014.
- [08] E.B. Huerta. "Logique floue et algorithmes génétiques pour le pré-traitement de données de biopuces et la sélection de gènes". Thèse de doctorat, Université d'Angers 2008.
- [09] J.-S. Jang. "ANFIS: adaptive-network-based fuzzy inference system". IEEE transactions on systems, man, and cybernetics. 23 (1993) 665-685.
- [10] W. Wu. "Synthèse d'un contrôleur flou par algorithme génétique: application au réglage dynamique des paramètres d'un système", thèse de doctorat, Université de Lille 1 1998.
- [11] B. Mohammed. "Sûreté de fonctionnement d'un système d'inférence floue avec une architecture redondante un parmi deux avec diagnostic (1oo2D) à base de FPGA", thèse de doctorat, Université abdelmalek essaadi, Tanger, (2013).
- [12] G. Asimakopoulou, V. Kontargyri, G. Tsekouras, F. Asimakopoulou, I. Gonos, I. Stathopoulos. "Artificial neural network optimisation methodology for the estimation of the critical flashover voltage on insulators". IET Science, Measurement & Technology. (2009) 90-104.
- [13] V. Kontargyri, A. Gialketsi, G. Tsekouras, I. Gonos, I. Stathopoulos. "Design of an artificial neural network for the estimation of the flashover voltage on insulators". Electric Power Systems Research. 77 (2007) 1532-1540.
- [14] M. Gençoğlu, M. Cebeci. "Investigation of pollution flashover on high voltage insulators using artificial neural network". Expert Systems with Applications, pp 7338-7345, 2009.
- [15] M. Cirstea, A. Dinu, M. McCormick, J.G. Khor. "Neural and fuzzy logic control of drives and power systems". Livre elseiver, 2002.
- [16] Y. Bourek, L. Mokhnache, S. Nait, R. Kattan. "Study of discharge in Point-Plane air interval using fuzzy logic". Journal of Electrical Engineering and Technology. No. 4, pp 410-417, 2009.

- [17] G. Asimakopoulou, V. Kontargyri, G. Tsekouras, C.N. Elias, F. Asimakopoulou, I. Stathopoulos. "A fuzzy logic optimization methodology for the estimation of the critical flashover voltage on insulators". *Electric Power Systems Research*. 81 (2011) 580-588.
- [18] M. Bouhamama, "Modélisation du contournement sur isolateur réel pollué", thèse de doctorat en Sciences, Université Djillali Liabes de Sidi-Bel-Abbes, 2018.
- [19] M. Farzaneh et W A .Chisholm, "Insulators for icing and polluted environments", Piseataway, N.J.; IEEE Press; Hoboken N J: Witey, p. 680, 2009.
- [20] N. Mhaguen, "Développement de modèles dynamiques de prédiction de la tension critique de contournement des isolateurs recouverts de glace basés sur la méthode des éléments finis", thèse de maitrise, UQAC, janvier 2011
- [21] A. Mekhaldi et H. Boudjelthia, "Contribution à l'étude de la pollution des isolateurs de haute tension dans la région électrique de Annaba". P.F.E, ingéniorat - ENP - Juin 1984.
- [22] A .kara, "Contribution à l'étude d'un modèle dynamique de contournement d'un isolateur pollué", mémoire de magister, Université Ferhat ABBAS - Sétif 1, 2013.
- [23] El. Azzag, " Problèmes de contournement et perforation des isolateurs de haute tension", thèse doctorat d'état, Université Badji Mokhtar, Annaba, 2007
- [24] M. Ben alia, "amélioration des performances des chaines d'isolateur de de haute tension", thèse de doctorat en sciences, ENP, Alger, 2016.
- [25] G. Riquel, E. Span genberg, "De la céramique au synthétique", *EDE-Epure*, N° 58, Avril 1998.
- [26] X. Ducouret, " Lignes aériennes : matériels. Isolateurs ", *Technique de l'ingénieur D4423-2006*
- [27] Y. Porcheron, " Lignes aériennes : Matériels entrant dans la constitution d'une ligne aérienne", *Technique de l'ingénieur D4425*.
- [28] M.Teguar, A.Boubakeur, " Pollution des Isolateurs de Haute Tension ", Laboratoire de Haute Tension, Département de Génie Electrique, Ecole Nationale Polytechnique d'Alger (E.N.P.) janvier 2004.
- [29] J.Y. Saison, " Etude du phénomène d'humidification des dépôts naturels et artificiels de pollution sur des isolateurs électriques ", Thèse de doctorat en Sciences, Université de Strasbourg, France, 1992.
- [30] S. Gopal and Y. Narayana Rao, "On the Flashover Mechanisms of Polluted Insulators", *ISPPISD, IIT-, MADRAS, Inde*, pp. 1-6- 1983.
- [31] M.Teguar, A.Boubakeur, " Pollution des Isolateurs de Haute Tension ", Laboratoire de Haute Tension, Département de Génie Electrique, Ecole Nationale Polytechnique d'Alger (E.N.P.) janvier 2004.
- [32] P. Claverie, Y.Porcheron, " Les phénomènes de pollution des isolateurs et l'isolement des ouvrages en régions polluées", *RGE*, Tome 82, No. 3, pp. 166-194, Mars 1973, Paris, France.
- [33] A. El- Sulaiman and M. I. Qureshi, "Effect of contamination on the leakage current of inland desert insulators", *IEEE. Trans. On E.I*, Vol. E.I-19, no 4, August, 1984.

- [34] C. E.I-60, " Technique des essais à haute tension, Définition et prescription générales aux essais", Première édition, 1973.
- [35] W. Heise, G.F. luxa, G.Revrery, M. P. Verma, "Estimation de la méthode d'essais sous pollution artificielle par couche solide" .CIGRE, rapport 33-09 -1982, Paris, France.
- [36] A. Cimador, M. Cojan, P. Hautefeuille, M. Moreau, "Méthodes de dimensionnement des isolateurs de Lignes Aériennes en régions polluées", CIGRE, Rapport 33-04, 1978, Paris, France.
- [37] M. MARICH, " Validation de nouvelles méthodes de modélisation du contournement des isolateurs pollués ", thèse doctorat, Université des sciences et de la technologie d'Oran- Mohamed Boudiaf (USTO-MB), 2018.
- [38] S. Flazi, "Etude du Contournement Electrique des Isolateurs Haute Tension Pollués Critère d'Elongation de la Décharge et Dynamique du Phénomène", thèse de doctorat d'état, Université Paul Sabatier, Toulouse, 1987.
- [39] H. STREUBEL, "The influence of non-uniform contamination on the flashover voltage of insulators", 4th International Symposium on High Voltage Engineering, Rapport 46-10, Athens, Greece, 5-9 September 1983.
- [40] T. Braunsbeger, M. Kurrat, "Cyclic Water Dop Corona on Silicone Rubber Samples" 15th International Symposium on High Voltage Engineering, University of Ljubljana, Elektointstitut Milan Widmar, Ljubljana, Slovenia, August 27 - 31, T4 - 280, pp. 1- 5, 2007.
- [41] R. Boudissa, T. Belhoul, K.D. Haim, S. Kornhuber, "Effet of Inclination Angle Of Hydrophobic Silicone Insulation Covered By Water Drops on its Dc Performance", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 24, Issue 5, pp. 2890-2900, October 2017.
- [42] R. Boudissa, A. Bayadi, R. Baersch, "Effect of Pollution Distribution Class on Insulators Flashover under AC Voltage", Electric Power Systems Research 104, pp.176 – 182, 2013.
- [43] R. Matsuoka, S. Ito K. Sakanishi and K. Naito, "Flashover on Contaminated Insulators with different diameters", IEEE Trans. Dielectr. Electr. Insul. Vol.26 No. 6, December 1991.
- [44] R. Sundararajan and R.S.Gorur, "Effect on Insulator profiles on DC flashover Voltage under Polluted conditions", IEEE Trans. Dielectr. Electr. Insul. Vol.1 No. 1, Février 1994.
- [45] T.C Chen and H.I.M. Nour, "A study on Profile of HVDC Insulators", IEEE Trans.on Elect.Insul, Vol.24, No. 1, pp.113-117, Februray1989.
- [46] Y. Bourek, N. M'Ziou, H. Benguesmia, "Prediction of Flashover Voltage of High-Voltage Polluted Insulator Using Artificial Intelligence". Transactions on Electrical and Electronic. Materials.2018; 19; 59-68.
- [47] Y. Hen Hu, J. Neng Hwang, "Handbook of neural network signal processing ", CRC Press LLC, United States of America, 2001.

- [48] W. Mc Culloch and W. Pitts., "A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics", Vol.7. pp. 115-133, 1943.
- [49] R. Zemouri, "Contribution à la surveillance des systèmes de production à l'aide des réseaux de neurones dynamiques : Application à la e-maintenance", Thèse de Doctorat, Université Franche-Comté, 2003.
- [50] L. Mokhnache, "Application des réseaux de neurones dans le diagnostic et la prédiction des isolations de haute tension ", Thèse de Doctorat, ENP, Décembre 2003.
- [51] M. Nezar. "Diagnostic des associations convertisseurs statiques–machine asynchrone en utilisant les techniques de l'intelligence artificielle". Thèse de doctorat, Université de Batna, 2006.
- [52] J. Sarangapani, "Neural network control of nonlinear discrete-time systems", Vol. 21. CRC press, 2006.
- [53] L. Baghli, "Contribution à la commande de la machine asynchrone, utilisation de la logique floue, des réseaux de neurones et des algorithmes génétiques", Thèse de doctorat, Université Henri Poincaré, Nancy-I, France, 1999.
- [54] S. Narad, and P. Chavan, "Cascade Forward Back-propagation Neural Network Based Group Authentication Using (n, n) Secret Sharing Scheme", *Procedia Computer Science*, vol.78, pp.185 – 191, 2016.
- [55] K. Hornik, M. Stinchcombe and H. White, "Multilayer feedforward networks are universal approximators", *Neural Networks* Vol.2, No. 5, pp. 359-366, 1989.
- [56] G. Cybenko, "Approximation by superpositions of a sigmoidal function. Mathematics of Control", *Signals and Systems* Vol.2, pp. 303-314, 1989.
- [57] P.S. Sastry, G. Santharam and K.P. Unnikrishnan, "Memory neuron networks for identification and control of dynamical systems", *IEEE Trans. on Neural Networks* Vol.5, No.2, pp. 306-319, 1994.
- [58] T. Norbert, "Treillis de Galois et réseaux de neurones : une approche constructive d'architecture des réseaux de neurones", thèse de doctorat, Université d'Artois - Faculté des Sciences Jean Perrin.
- [59] O. Guenounou, "Méthodologie de conception de contrôleurs intelligents par l'approche génétique : application à un bioprocédé", Thèse de doctorat, Université Toulouse III - Paul Sabatier, 2009.
- [60] C. Bishop, "Neural networks for pattern recognition", Oxford University Press, 1995.
- [61] M.Y .Ammar, "Mise en œuvre de réseaux de neurones pour la modélisation de cinétiques réactionnelles en vue de la transposition Batch/Continu", Thèse de Doctorat, I.N.P. Toulouse, 17 juillet 2007.
- [62] Y .Najjar, H.Ali, "On the Use of BPNN in Liquefaction Potential Assessment Tasks", *Artificial Intelligence and Mathematical Methods in Pavement and Geomechanical Systems*, Attoh-Okine (Editor). Vol. 75. (1998a). pp. 55-63.
- [63] Y .Najjar Y, H .Ali, "CPT-Based Liquefaction Potential Assessment: A Neuronet Approach". *ASCE Geotechnical Special Publication No.75*, Dakoulas, P. et. Al. (Editors), (1): (1998b). pp. 542-553.

- [64] Y .Najjar, X.Zhang, “Characterizing the 3D Stress-Strain Behavior of sandy Soils: A Neuro-Mechanistic Approach”. ASCE Geotechnical Special Publication. Filz, G. and Griffiths, D. (Editors) vol. 96. (2000). pp. 43-57.
- [65] S. Riad, J. Mania J, L. Bouchaou, Y. Najjar, “Modélisation de la relation pluie-débit par les réseaux de neurones artificiels (RNA ou ANN) : Application à un bassin versant en zone semi-aride (Maroc) ”. Colloque international sur l’Hydrologie des régions méditerranéennes et semi-arides. Montpellier, France 2003.
- [66] Z. Yao-ming, M. Zhi-jun, C. Xu-zhi, W .Zhe, W. “Helicopter engine performance prediction based on cascade-forward process neural network”. In 2012 IEEE
- [67] M. Riedmiller, “Advanced supervised learning in multi-layer perceptrons—from backpropagation to adaptive learning algorithms”. *Computer Standards & Interfaces*. 1994.16(3): 265-278.
- [68] R. Battiti, A. Villani and T. L. Nhat, “Neural Network Models for Intelligent Networks: Deriving the Location from Signal Patterns”, *Autonomous Intelligent Networks and Systems*, UCLA, Los Angeles, May 2002
- [69] S. Haykin, “Neural Networks: A comprehensive Foundation”, Pearson Education Inc, 1999
- [70] D.S. Broomhead, D. Lowe, "Multivariate functional interpolation and adaptive networks," *Complex Systems*, vol. 2, pp.321-355, 1988.
- [71] J. Moody, C.J Darken., "Fast Learning in Network for Locally Tuned Processing Units," *Neural Computation*, vol. 1, pp.281-294, 1989.
- [72] T. Poggio, F. Girosi, "Network for approximation and learning," *Proc. IEEE*, vol. 78, pp. 1481 -1497, 1990.
- [73] D. Johari, T. Khawa, "Artificial neural network based technique for lightning prediction," 5th Stud. Conf. Res. Dev.,Malaysia, 2007.
- [74] D. Samek, D. Manas, "Artificial neural networks in artificial time series prediction benchmark," *Int. J. Math. Models Methods in Appl. Sci*, vol. 5, pp. 1085-1093, 2011.
- [75] Bessedik SA, Hadi H. Prediction of flashover voltage of insulators using least squares support vector machine with particle swarm optimization. *Electric Power Systems Research*. 2013;104: 87-92.
- [76] Clodoaldo Ap. M. Lima, Andr C L. V. Coelho, Fernando J. Von Zuben , “Fuzzy Systems Design via Ensembles of ANFIS“, Department of Computer Engineering and Industrial Automation (DCA) School of Electrical and Computer Engineering (FEEC) State University of Campinas – Unicamp , 2002.
- [77] Dinie Bin Muhammad, “Fault detection using neural network“,University Malaysia Pahang, thesis, Sesi Pengajian: 2007/2008.
- [78] F. J Uppal & R. J Patton, “Fault Diagnosis of an Electro-pneumatic Valve Actuator Using Neural Networks with Fuzzy Capabilities“, 24-26 April 2002.
- [79] M. A. Shoorehdeli & M.Teshnehlab & A.Khaki Sedigh, "Identification using ANFIS with intelligent hybrid stable learning algorithm approaches", Springer-Verlag London Limited 2008.

- [80] L.A Zadeh, "fuzzy sets", *Informatique and Control*, Vol.8, pp. 338-353, 1965
- [81] J.-S.R Jang, "ANFIS: Adaptive-Network-based Fuzzy Inference System", *IEEE Transaction on Systems, Man, and Cybernetics*, vol. 23, pp.665-685, 1993.
- [82] J. Godjevac, "Idées Nettes sur la Logique Floue", *Collection Informatique*, Presses Polytechniques et Universitaires Romandes, Lausanne, 1999.
- [83] E. Bonilla Huerta, " Logique floue et algorithmes génétique Biopuces et la sélection de gènes ", thèse de doctorat, Ecole Doctorale STIM. Angers, 2008.
- [84] E.H. Mamdani, S. Assilian. "An experiment in linguistic synthesis with a fuzzy logic controller". *International journal of man-machine studies*. 7 (1975) 1-13.
- [85] M. Sahraoui , "Contrôle robuste des systèmes non linéaires par les approches de l'intelligence artificielle", thèse de doctorat, Université d'Oran 1 A.Ben Bella, 2016.
- [86] E.H. Mamdani, and S. Assilian, "An experiment in linguistic synthesis with a fuzzy logic controller". *International Journal of Man-Machine Studies* Vol.7, No. 1, pp. 1-15, 1975
- [87] E.Kim, M. Park, S. Ji and M. Park, "A new approach to fuzzy modeling", *IEEE Transactions on Fuzzy Systems* Vol.5, No. 3, pp. 328-337, 1997
- [88] L. Wang et R. Langari, "Complex systems modeling via fuzzy logic". *IEEE Trans. On Systems, Man, And Cybernetics-Part B: Cybernetics* Vol.26, No. 1, pp.100-106, 1996
- [89] W. Pedrycz, and L.A. Zadeh, "Fuzzy Set Engineering", CRC Press. Boca Raton, USA, 1995
- [90] G.J. Klir and B. Yuan, "Fuzzy sets and fuzzy logic: theory and applications". Prentice-Hall. Inc. Upper Saddle River, NJ, USA, 1994
- [91] H. R. Berenji, P. Khedkar, "Learning and Tuning Fuzzy Logic Controllers Through Reinforcements", *IEEE Transactions on Neural Networks*, vol. 3, no. 5, pp. 724-740, 1992.
- [92] L. Jouffe, "Fuzzy Inference System Learning by Reinforcement Methods", *IEEE Transactions on Systems, Man, and Cybernetics*, vol.28, no.3, pp. 338-355, 1998.
- [93] F. Herrera, M. Lozano, J. L. Verdegay, "Tuning Fuzzy Controllers by Genetic Algorithms",*International Journal of Approximate Reasoning*, vol. 12, pp. 299-315, 1995.
- [94] F. Abdessemed, K. Benmahammed and E. Monacelli, "A Fuzzy-based Reactive Controller for Non holonomic Mobile Robot", *Robotics and Autonomous Systems*, vol. 47, pp. 31-46, 2004.
- [95] A.Bahramifar, R. Shirkhani, M .Mohammadi, "An ANFIS based approach for predicting the Manning roughness coefficient in alluvial channels at the bank-full stage", *International Journal of Engineering*, Vol.26, No. 2, pp. 177-186, 2013.
- [96] C. I .Ejiofor & U.A .Okengwu, "Adaptive Neuro Fuzzy Inference System (ANFIS): MATLAB Simulation of Breast Cancer Experimental Data", *IOSR Journal of Computer Engineering (IOSR-JCE)* e-ISSN: 2278-0661, p-ISSN: 2278-8727, Volume 19, Issue 4, Ver. V. (Jul.-Aug. 2017), PP 53-60.

- [97] Sh. Chopra, G. Dhiman , A. Sharma , M. Shabaz ,P.Shukla , and M. Arora , "Taxonomy of Adaptive Neuro-Fuzzy Inference System in Modern Engineering Sciences", Computational Intelligence and Neuroscience Volume ,2021.
- [98] B.A. Bensaber, G.P.Diaz, Y. Lahrouni, "Design and modeling an Adaptive Neuro-Fuzzy Inference System (ANFIS) for the prediction of a security index in VANET". J. Comput. Sci. 2020, 47, 101234.
- [99] B. Haznedar; A. Kalinli, "Training ANFIS structure using simulated annealing algorithm for dynamic systems identification". Neuro computing, 302, 66–74, 2018.
- [100] JSR. Jang, "ANFIS Adaptive network based fuzzy inference system". IEEE transactions on systems. Man Cybern. 23.3.665–683. 1993.
- [101] U. Caydas, A. Hascalik & S. Ekici "An adaptive neuro-fuzzy inference system (ANFIS) model for wire-EDM" Expert Systems with Applications. Vol. 36, pp. 6135-6139, 2009.
- [102] B. Sidda Reddy, J. Suresh Kumar & K. Vijaya Kumar Reddy "Prediction of Surface Roughness in Turning Using Adaptive Neuro-Fuzzy Inference System" Jordan Journal of Mechanical and Industrial Engineering. Vol. 3, pp. 252-259, 2009.
- [103] J. Kennedy and R. C. Eberhart. "Particle Swarm Optimization". IEEE International Conference on Neural Networks, vol. IV, pp. 1942–1948, November 1995.
- [104] J. Eberhart Kennedy, "A new optimizer using particle swarm theory". In Proceedings of the Sixth International Symposium on Micro Machine and Human Science (MHS'95), Nagoya, Japan, pp. 39–43, 4–6 October 1995.
- [105] H .Nguyen, H.Moayedi, L.K.Foong, H.A.H. AlNajjar, W.A.W .Jusoh, A.S.A. Rashid, J.Jamali, "Optimizing ANN models with PSO for predicting short building seismic response". Eng. Comput, 1–15, 2019.
- [106] D.J.Armaghani, M. Hajihassani, E.T. Mohamad, A.Marto, S.A .Noorani, "Blasting-induced flyrock and ground vibration prediction through an expert artificial neural network based on particle swarm optimization". Arab. J. Geosci. 7, 5383–5396, 2014.
- [107] B.Gordan, D.J. Armaghani, M.Hajihassani, M.Monjezi . "Prediction of seismic slope stability through combination of particle swarm optimization and neural network". Eng. Comput. 32, 85–97, 2016.
- [108] X.Yang, Y. Zhang, Y.Yang, W. Lv, "Deterministic and Probabilistic Wind Power Forecasting Based on Bi-Level Convolutional Neural Network and Particle Swarm Optimization". Appl. Sci. 9, 1794, 2019.
- [109] L.T. Le, H.Nguyen, J.Dou and J. Zhou, "A Comparative Study of PSO-ANN, GA-ANN, ICA-ANN, and ABC-ANN in Estimating the Heating Load of Buildings' Energy Efficiency for Smart City Planning" Appl. Sci, 9, 2630, 2019.
- [110] J. Han, X. Sun, Y. Zhou, "Duration effect of spectrally matched ground motion records on collapse resistance capacity evaluation of RC frame structures", Struct. Des. Tall Spec. Build. 26 (2017) 1–12.
- [111] R.C. Eberhart, Y. Shi. "Comparing inertia weights and constriction factors in particle swarm optimization". Proceedings of the 6th IEEE Congress on Evolutionary Computation, IEEE Press. pp. 84-88, 2000.

- [112] Gourgand et Kemmoe, "Particle Swarm Optimization :A study of particle displacement for solving continuous and combinatorial optimization problems", 2009.
- [113] Y. Bekakra, "Contribution à l'Etude et à la Commande Robuste d'un Aérogénérateur Asynchrone à Double Alimentation", thèse de doctorat, Université de Biskra, 2014.
- [114] R. Eberhart, Y. Shi, "Comparing inertial weights and constriction factor in particle swarm optimization", Proceeding of the International Congress on Evaluating Computation, San Diego, California, IEEE Service Center, Piscataway, NJ, pp. 84- 88, 2000.
- [115] M. Padma Lalitha, V. C. Veera Reddy, V. Usha, "Optimal DG placement for minimum real power loss in radial distribution systems using PSO", Journal of Theoretical and Applied Information Technology, pp. 107- 116, 2010.
- [116] M. Alizamir, S .Sobhanardakani , "An Artificial Neural Network-Particle Swarm Optimization (ANN-PSO) Approach to Predict Heavy Metals Contamination in Groundwater Resources", Jundishapur J. Health Sci., 10(2), 2018.
- [117] O. Kisi, M. Alizamir, M. Zounemat-Kermani, "Modeling groundwater fluctuations by three different evolutionary neural network techniques using hydroclimatic data". Nat Hazards;87(1):367–81, 2017.
- [118] KW. Chau, "Application of a PSO-based neural network in analysis of outcomes of construction claims". Automat Construct;16(5):642–6, 2007.
- [119] A.Belkebir,Y.Bourek,H.Benguesmia."Particle swarm optimization of a neural network model for predicting the flashover voltage on polluted cap and pin insulator". Diagnostyka, Vol. 23, No. 4, 2022 .
- [120] Tein et Ramli, 2010] L.H. Tein, R. Ramli. "Recent advancements of nurse scheduling models and a potential path". In Proc. 6th IMT-GT Conference on Mathematics, Statistics and its Applications (ICMSA 2010). pp. 395-409, 2010.
- [121] A.Gherboudj, A. Layeb, S. Chikhi. "Solving 0-1 knapsack problems by a discrete binary version of cuckoo search algorithm". International Journal of Bio-Inspired Computation. Vol. 4, N°4, pp 229-236, 2012
- [122] X-S Yang, S. Deb. "Cuckoo search via Lévy flights". World Congress on Nature and Biologically Inspired Computing (NaBIC 2009). pp. 210-2014, 2010.
- [123] X-S Yang, S. Deb. "Engineering optimisation by cuckoo search". Int. J.Mathematical Modeling and Numerical Optimisation.Vol.1, N°4, pp.330-343, 2010.
- [124] A. Layeb. "A novel quantum inspired cuckoo search for knapsack problems". Int. J. Bio-Inspired Computation. Vol. 3, N°. 5, pp 297-305, 2011.
- [125] A. Ouaarab, "Résolution de Problèmes d'Optimisation Combinatoire par des Métaheuristiques Inspirées de la Nature : Recherche du Coucou via les Vols de Lévy", 2015.
- [126] C. Brown, L. S. Liebovitch, R. Glendon. "Lévy flights in Dobe Ju/'hoansi foraging patterns". Human Ecol. Vol. 35, pp 129-138, 2007.
- [127] A. M. Reynolds, M. A. Frye. "Free-flight odor tracking in Drosophila is consistent with an optimal intermittent scale-free search". PLoS One, 2, e354. 2007.

- [128] I. Pavlyukevich. Lévy flights, “non-local search and simulated annealing”. *J. Computational Physics*. Vol. 226, N° 2, pp. 1830-1844, 2007.
- [129] M. F. Shlesinger, G. M. Zaslavsky, U. Frisch. “Lévy Flights and Related Topics in Physics”. Springer, Berlin, 1995.
- [130] D. Ben-Avraham et S. Havlin. “Diffusion and Reactions in Fractals and Disordered Systems”, Univ. Press, Cambridge, 2000.
- [131] A. Gherboudj, “Méthodes de résolution de problèmes difficiles académiques”, thèse de doctorat, Université de Constantine2, 2013.
- [132] R. Rajabioun. “Cuckoo Optimization Algorithm. *Applied Soft Computing*”. Vol. 11, N° 8, pp. 5508-5518, 2011.
- [133] E. Valian, S. Mohanna and S. Tavakoli, “Improved Cuckoo Search Algorithm for Feed forward Neural Network Training”, *International Journal of Artificial Intelligence & Applications*, vol. 2, no. 3, pp. 36-43, 2011.