الجمهورية الجزائرية الديمقراطية الشعبية
People's Democratic Republic OF Algeria
وزارة التعليم العالي و البحث العلمي
MINISTRY OF HIGHER EDUCATION AND SCIENTIFIC RESEARCH
جامعة الشهيد الشيخ العربي التبسي-تبسة
Echahid Cheikh Larbi Tebessi University-Tebessa
كلية العلوم و التكنولوجيا

DEPARTEMENT DE GENIE ELECTRIQUE

MEMOIRE

DE FIN D'ETUDES POUR L'OBTENTION DU DIPLOME DE MASTER EN

ELECTROTECHNIQUE INDUSTRIELLES

THEME

Optimisation du contrôle tertiaire d'un micro-réseau isolé basé sur les réseaux de neurones

Présenté par le binôme :

- Berrah youcef
- Latrech chames eddine

Devant le jury :

- Mr. Djebbar Mohamed Salah	MCA	**Président**
- Mr. Bendakir Abdelhakim	MCA	**Encadreur**
- Mr. Boukadoum Aziz	Pr	**Examinateur**

قسم الهندسة الكهربائية
كلية العلوم و التكنولوجيا

2025/2026


بسم الله الرحمن الرحيم

Abstract

This thesis addresses the improvement of tertiary control in isolated microgrids through the integration of Radial Basis Function (RBF) neural networks. Combined with a conventional PI controller within an adaptive framework, these networks enable online approximation of the system's nonlinear dynamics and real-time tuning of control parameters without requiring an exact mathematical model.

The obtained results on a hybrid solar–wind–battery microgrid demonstrate the superiority of the RBF-PI control strategy over the conventional PI controller. The proposed approach leads to an improvement in overall system performance, as well as enhanced management of active and reactive power. These findings confirm the effectiveness of artificial intelligence techniques for optimizing energy management in isolated microgrids.

Résumé

Ce mémoire traite de l'amélioration du contrôle tertiaire des micro-réseaux isolés par l'intégration des réseaux de neurones RBF (Radial Basis Function). Ces réseaux, associés à un régulateur PI conventionnel dans une architecture adaptative, permettent l'approximation en ligne du comportement dynamique du système et l'ajustement des paramètres de commande en temps réel, sans recourir à une modélisation mathématique exacte.

Les résultats obtenus sur un micro-réseau hybride solaire–éolien–batteries montrent la supériorité de la stratégie de commande RBF-PI par rapport au régulateur PI classique. Cette approche permet une amélioration des performances globales du système ainsi qu'une optimisation de la gestion des puissances active et réactive. Ces résultats confirment la pertinence de l'intelligence artificielle pour l'optimisation de la gestion énergétique des micro-réseaux isolés.

الملخص

يتناول هذا البحث تحسين التحكم الترتيبي (الثالث) في الشبكات الصغيرة المعزولة من خلال دمج شبكات العصب الاصطناعي . RBF (Radial Basis Function). حيث تُدمج هذه الشبكات مع منظم PI تقليدي ضمن بنية تكيفية، تسمح بتقريب السلوك الديناميكي للنظام بشكل آنٍ، مع ضبط معاملات التحكم في الزمن الحقيقي دون الاعتماد على نموذج رياضي دقيق.

أظهرت النتائج المحققة على شبكة هجينة تتكون من الطاقة الشمسية والرياح والبطاريات تفوق استراتيجية التحكم RBF-PI مقارنة بالتحكم التقليدي PI. حيث أدت هذه الاستراتيجية إلى تحسين الأداء العام للنظام، إضافة إلى تحسين إدارة القدرة الفعالة والتفاعلية. وتؤكد هذه النتائج فعالية تقنيات الذكاء الاصطناعي في تحسين إدارة الطاقة داخل الشبكات الصغيرة المعزولة.

Remercîments

Au terme de ce travail, notre première pensée va vers le Très-Haut. Nous rendons grâce à Allah, le Tout-Puissant, pour la force, la santé et la patience dont Il nous a comblés tout au long de ces années d'études.

Nous tenons à exprimer notre profonde et sincère reconnaissance à notre encadreur,

MCA. Bendakir Abdelhakim, dont l'exigence bienveillante, la disponibilité constante et la richesse de ses conseils ont été pour nous un guide précieux tout au long de l'élaboration de ce travail. Sa patience et sa générosité intellectuelle demeureront gravées dans notre mémoire.

Nous sommes particulièrement honorés de la bienveillance des membres du jury, **MCA. Djebbar Mohamed Salah** et **Pr. Boukadoum Aziz**, qui ont accepté de consacrer leur temps et leur expertise à l'examen attentif de ce mémoire. Leur contribution éclairée en enrichira indéniablement la portée.

Nous exprimons toute notre gratitude à notre famille et à nos amis pour leur amour, leur soutien et leur présence à nos côtés.

Enfin, nous adressons nos vifs remerciements à l'ensemble des enseignants du département ST pour la qualité de leur enseignement et leur dévouement à notre formation.

Dédicace

D'abord, merci à moi-même. Ce n'est pas de la vanité, c'est de la justice. C'est moi qui ai choisi ce chemin difficile, moi qui ai veillé seul devant l'écran des nuits entières, moi qui ai avalé le découragement et su revenir. Personne ne m'y a forcé, personne n'a achevé ce travail à ma place. Il commence par moi et finit par moi, et je mérite de le reconnaître.

Merci à mes parents. À mon père qui m'a appris qu'un homme se mesure à ce qu'il donne, pas à ce qu'il possède. À ma mère qui me demande encore « tu as mangé ? » comme si j'étais encore un enfant. Merci de ne pas s'être inquiétés quand j'ai échoué, et de ne pas avoir exagéré quand j'ai réussi. Merci de savoir la différence entre encourager et presser, et de ne jamais se tromper là-dessus.

Merci à mes frères et sœurs. Non pas parce qu'ils ont lu ce que j'écrivais, mais parce qu'ils ne l'ont pas fait, et ne m'ont pas harcelé de questions futiles. Parce qu'ils savaient quand m'entourer et quand me laisser tranquille. Parce qu'ils m'aiment sans conditions, et c'est rare de nos jours.

Merci à mon oncle. Cet homme qui me croit plus intelligent que je ne le suis, et qui le dit aux gens sans rougir. Merci de répondre à mon téléphone au milieu de la nuit quand j'ai besoin d'un conseil, sans se plaindre. Merci de m'aimer comme un fils, pas seulement comme le fils de son frère.

Merci à mon grand-père. Celui qui me répète chaque fois « j'ai vécu ma vie et j'apprends encore », me rappelant ainsi que toute la vie est une école. Merci de ne pas comprendre ce que j'écris, mais de comprendre ce que je ressens. Merci de prier pour moi sans que je le lui demande.

Enfin, merci à tous ceux qui sont passés dans ma vie et n'y sont pas restés, et à ceux qui y sont restés malgré tout. Ce travail n'est pas qu'un document académique, c'est la preuve que je n'ai jamais été seul, même quand je le croyais.

Latrech chames eddine

Dédicace

Tout d'abord, je tiens à remercier Dieu de m'avoir accordé la force, la patience et le courage nécessaires pour mener à bien ce modeste travail.

Je tiens à dédier cet humble travail à :

À mes très chers parents, en témoignage de ma profonde affection et de ma gratitude infinie pour leurs sacrifices et leur amour inconditionnel.

À mes chères sœurs et mes chers frères, pour leur soutien moral indéfectible et leur présence constante à mes côtés.

À mon cher neveu Arslan « Al-Doub », fils de ma chère sœur ce petit être qui occupe une place si grande dans mon cœur, mon bien-aimé et mon proche que Dieu le garde et le comble de bonheur.

À mon professeur, le Dr. Ayeb brahim, pour sa précieuse assistance, son soutien constant et sa bienveillance tout au long de l'élaboration de ce mémoire. Sa patience et ses conseils avisés ont été pour moi un moteur essentiel.

À tous ceux qui, de près ou de loin, ont contribué à la réalisation de ce travail, je vous adresse ma reconnaissance la plus sincère.

Berrah youcef

Liste des figures

Chapitre I : Fondements des micro-réseaux isolés et état de l'art du contrôle tertiaire

Figure I.1: schéma d'un micro-réseau 4

Figure I.2 Structure générale d'un micro-réseau 5

Figure I.3 : Architecture générale d'un micro-réseau en mode connecté au réseau 8

Figure I.4 : La structure de contrôle hiérarchique 11

Figure I.5: Système de gestion d'énergie dans un micro-réseau 14

Figure I.6: Architecture des réseaux de neurones 19

Figure I.7: Architecture générale du contrôle à logique floue (FLC) 20

Figure I.8: Structure générale de l'algorithme génétique 21

Figure I.9: Optimisation des essaims de particules 22

Figure I.10: Conventional and prospective AI-based control in the hierarchical control architecture 23

Chapitre II : Étude des réseaux de neurones artificiels et leur adaptation aux micro-réseaux isolés

Figure II.1 : Représentation d'un neurone biologique et analogie avec le neurone artificiel 27

Figure II.2 : Structure générale d'un neurone artificiel 28

Figure II.3: La fonction d'activation sigmoïde 30

Figure II.4: La fonction d'activation tangente hyperbolique 31

Figure II.5: Architecture d'un réseau neuronal multicouche 32

Figure II.6: Réseau de neurones récurrent (RNN) 35

Figure II.7: Architecture de LSTM 37

Figure II.8: Apprentissage d'un réseau de neurone artificiel 39

Figure II.9: Variation de l'erreur e(t) en fonction du temps t 42

Figure II.10 : Caractéristique non linéaire d'un système photovoltaïque en fonction de l'irradiation solaire .. 43

Figure II.11 : Variabilité de la production photovoltaïque et de la charge électrique dans un micro-réseau isolé 44

Figure II.12 : Complexité de la gestion énergétique dans un micro-réseau isolé (MGI) 45

Figure II.13 : Filtrage des fluctuations des données par un réseau de neurones artificiel 49

Chapitre III : Implémentation des réseaux de neurones pour le contrôle tertiaire des micro-réseaux isolés

Figure III.1 : Schéma fonctionnel du principe d'intégration des réseaux de neurones artificiels (RNA) dans le contrôle tertiaire d'un micro-réseau isolé 57

Figure III.2 : Modèle analogique d'un MLP 58

Figure III.3: Schéma général d'un régulateur PI 59

Figure III.4: Modélisation d'un système par la technique des réseaux de neurones 61

Figure III.5: La commande PI adaptative basée sur la technique des réseaux de neurones RBF 62

Figure III.6 : Structure d'un réseau de neurones RBF 63

Figure III.7 : Processus de préparation et de prétraitement des données avant l'apprentissage du réseau RNA 67

Figure III.8 : Évolution de la fonction de coût (MSE) en fonction du nombre d'epochs durant l'apprentissage du réseau de neurones 69

Figure III.9: Schéma de la propagation avant et de la rétropropagation du gradient 71

Figure III.10 : Structure d'un réseau de neurones avec trois neurones dans la couche cachée et deux neurones dans la couche de sortie 72

Figure III.11 : Principe de fonctionnement du contrôle tertiaire intelligent basé sur les réseaux de neurones artificiels 76

Chapitre IV : Simulation sous MATLAB/Simulink du contrôle tertiaire d'un micro-réseau isolé basé sur les réseaux de neurones RBF

Figure IV. 1 : Structure de Micro-réseau 80

Figure IV.2 : Modèle du micro-réseau isolé développé sous MATLAB/Simulink 81

Figure IV.3 : Regroupement des sources d'énergie du micro-réseau (PV, éolienne et batterie) 81

Figure IV.4 : Formes d'onde des tensions triphasées Vabc 84

Figure IV.5 : Formes d'onde des courants triphasés Iabc 84

Figure IV.6 : Évolution des puissances active P et réactive Q 85

Figure IV.7 : Réponse des composantes de tension Vd et Vq 85

Figure IV.8 : Évolution des composantes de courant Id et Iq 86

Figure IV.9: Erreur de suivi de la composante Vd 87

Figure IV.10 : Erreur de suivi de la composante Vq 87

Figure IV.11 : Erreur de suivi de la composante IdIq 88

Figure IV.12 : Contrôleur de tension basé sur RBF-PI 90

Figure IV.13 : Contrôleur de courant basé sur RBF-PI 90

Figure IV.14 : Évolution des puissances active P et réactive Q 91

Liste des tableaux

Chapitre I : Fondements des micro-réseaux isolés et état de l'art du contrôle tertiaire

Tableau II.1 Comparaison des Types d'Apprentissage en Intelligence Artificielle 40

Chapitre III : Implémentation des réseaux de neurones pour le contrôle tertiaire des micro-réseaux isolés

Tableau III.1: Variables du système 56

Chapitre IV : Simulation sous MATLAB/Simulink du contrôle tertiaire d'un micro-réseau isolé basé sur les réseaux de neurones RBF

Tableau IV.1 : Paramètres des régulateurs PI du micro-réseau étudié 83
Tableau IV.2 : Paramètres du réseau RBF utilisé dans le contrôleur RBF-PI 89

Liste d'abréviations

AC : Alternatif Courant (Courant Alternatif)

DC : Direct Courant (Courant Continu)

DER : Distributed Energy Resources (Sources d'Énergie Distribuées)

EMS : Energy Management System (Système de Gestion d'Énergie)

FLC : Fuzzy Logic Controller (Régulateur à Logique Floue)

MGI : Micro-réseau Isolé

MLP : Multi-Layer Perceptron (Perceptron Multicouche)

MSE : Mean Squared Error (Erreur Quadratique Moyenne)

PCC : Point de Couplage Commun

PI : Proportional-Integral (Proportionnel-Intégral)

PSO : Particle Swarm Optimization (Optimisation par Essaims de Particules)

PV : Photovoltaïque

RBF : Radial Basis Function (Fonction de Base Radiale)

RNA : Réseaux de Neurones Artificiels

RNN : Récurrent Neural Network (Réseau de Neurones Récurrent)

SOC : State of Charge (État de Charge)

LSTM : Long Short-Term Memory

Liste de matières

Abstract ……...…...I

Remerciements ……II

Dédicace ……..III

Liste des figures ……V

Liste des tableaux ……VIII

Liste des abréviations ……....IX

Liste de matières ……..…...XI

Introduction générale ……1

Chapitre I : Fondements des micro-réseaux isolés et état de l'art du contrôle tertiaire

I.1 Introduction 3

I.2 Généralités sur les micro-réseaux 3

I.2.1 Définition d'un micro-réseau 3

I.2.2 Structure générale d'un micro-réseau 4

I.2.3 Composants principaux d'un micro-réseau 6

I.3 Classification des micro-réseaux 8

I.3.1 Micro-réseaux connectés au réseau principal 8

I.3.2 Micro-réseaux isolés 9

I.4 Importance et applications des micro-réseaux isolés 9

I.4.1 Micro-projets de production d'énergie 9

I.4.2 Électrification des zones éloignées 10

I.4.3 Intégration des énergies renouvelables 10

I.5 Architecture de contrôle des micro-réseaux 11

I.5.1 Contrôle primaire 11

I.5.2 Contrôle secondaire 12

I.5.3 Contrôle tertiaire 13
I.6 Contrôle tertiaire dans les micro-réseaux isolés 13
I.6.1 Objectifs du contrôle tertiaire 14
I.6.2 Optimisation de la gestion énergétique 14
I.6.3 Coordination entre les sources d'énergie 14
I.7 État de l'art des méthodes de contrôle tertiaire 15
I.7.1 Méthodes classiques utilisées dans la littérature 15
I.7.2 Méthodes intelligentes utilisées dans la littérature 18
I.7.3 Limites des méthodes existantes 23
I.8 Conclusion 24

Chapitre II : Étude des réseaux de neurones artificiels et leur adaptation aux micro-réseaux isolés

II.1 Introduction 25
II.2 Généralités sur les réseaux de neurones artificiels 26
II.2.1 Définition des réseaux de neurones artificiels 26
II.2.2 Inspiration biologique 26
II.2.3 Structure générale d'un réseau de neurones 27
II.3 Modélisation mathématique d'un neurone artificiel 29
II.4 Fonctions d'activation 30
II.5 Types de réseaux de neurones artificiels 32
II.5.1 Réseau de neurones multicouche (MLP) 32
II.5.2 Réseaux de neurones récurrents (RNN) 34
II.5.3 Réseaux LSTM (Long Short-Term Memory) 36
II.5.4 Réseaux de neurones à fonctions de base radiale (RBF) 37
II.6 Apprentissage des réseaux de neurones 38

II.6.1 Principe d'apprentissage 38
II.6.2 Types d'apprentissage 39
II.6.3 Propagation avant 40
II.6.4 Fonction de coût 41
II.6.5 Fonction de coût dans les systèmes dynamiques 41
II.6.6 Rétropropagation du gradient 42
II.7 Problématique des micro-réseaux isolés (MGI) 43
II.7.1 Non-linéarité des systèmes énergétiques 43
II.7.2 Incertitudes liées aux énergies renouvelables 43
II.7.3 Complexité de la gestion énergétique 45
II.8 Applications des RNA dans les micro-réseaux isolés 46
II.8.1 Prévision de la charge 46
II.8.2 Prévision de la production renouvelable 46
II.8.3 Optimisation énergétique 47
II.8.4 Gestion du stockage 47
II.8.5 Décision du dispatching 47
II.9 Compatibilité des réseaux de neurones avec les MGI 48
II.9.1 Capacité de modélisation des systèmes non linéaires 48
II.9.2 Adaptation aux systèmes dynamiques 48
II.9.3 Apprentissage à partir des données 49
II.9.4 Robustesse face aux incertitudes 49
II.10 Avantages et limites des réseaux de neurones 50
II.10.1 Avantages des réseaux de neurones 50
II.10.2 Limites des réseaux de neurones 50
II.11 Conclusion 52

Chapitre III : Implémentation des réseaux de neurones pour le contrôle tertiaire des micro-réseaux isolés

III.1 Introduction 53

III.2 Formulation du problème du contrôle tertiaire 53

III.2.1 Objectif d'optimisation énergétique 54

III.2.2 Contraintes du système 54

III.3 Modélisation fonctionnelle du système de contrôle 55

III.3.1 Variables d'entrée du système 55

III.3.2 Variables de sortie (décision de contrôle) 56

III.4 Conception du contrôleur RNA 56

III.4.1 Principe d'intégration des RNA dans le contrôle tertiaire 57

III.4.2 Choix de l'architecture du réseau 57

III.4.3 Régulateur PI 58

III.4.4 La commande PI adaptative basée sur la technique des réseaux de neurones RBF 59

III.4.5 Approximation de l'expression $\frac{\partial y(k)}{\partial u(k)}$ par la technique des réseaux de neurones RBF 60

III.4.6 Structure du réseau proposé 62

III.4.7 Définition des entrées et sorties du réseau 64

III.4.8 Stratégie de décision du contrôleur 65

III.5 Processus d'apprentissage et d'entraînement 66

III.5.1 Préparation des données 66

III.5.2 Choix de la fonction de coût 68

III.5.3 Algorithme d'apprentissage utilisé 69

III.6 Algorithme global du contrôle tertiaire basé sur RNA 75

III.7 Analyse de la méthode proposée 76

III.7.1 Performances de l'approche proposée 76

III.7.2 Contraintes et limites de l'implémentation 77

III.8 Conclusion 78

Chapitre IV : Simulation et commande adaptative du contrôle tertiaire d'un micro-réseau isolé basée sur les réseaux de neurones RBF

IV.1 Introduction 79

IV.2 Présentation du micro-réseau étudié 79

IV.3 Modélisation du micro-réseau sous MATLAB/Simulink 80

IV.4 Implémentation du contrôle classique PI 82

IV.4.1 Structure du contrôleur PI 82

IV.4.2 Paramètres du régulateur PI 82

IV.4.3 Intégration du PI dans le système de contrôle 83

IV.4.4 Performances du micro-réseau sous contrôle PI 83

IV.5 Implémentation du contrôle intelligent RBF-PI 88

IV.5.1 Structure du contrôleur RBF-PI 88

IV.5.2 Paramètres du réseau RBF 89

IV.5.3 Intégration du contrôleur RBF-PI dans le micro-réseau 89

IV.5.4 Résultats de simulation du contrôle RBF-PI 91

IV.6 Conclusion 92

Conclusion général 93

Références Bibliographique 95

Introduction générale

Introduction Générale

L'électrification des zones isolées et l'intégration croissante des énergies renouvelables dans le mix énergétique mondial constituent aujourd'hui des enjeux majeurs pour les chercheurs et les ingénieurs du secteur électrique. Face aux limites des réseaux électriques traditionnels centralisés, peu flexibles et vulnérables aux perturbations de nouvelles architectures de production et de distribution de l'électricité ont vu le jour. Parmi elles, le concept de micro-réseau (microgrid) s'impose comme une solution prometteuse, capable d'intégrer de manière intelligente des sources d'énergie distribuées, des systèmes de stockage et des charges locales au sein d'une entité contrôlable et autonome.

Les micro-réseaux isolés, en particulier, représentent une catégorie spécifique de ces systèmes. Déconnectés du réseau électrique principal, ils doivent assurer seuls l'équilibre entre production et consommation, tout en maintenant la stabilité de la fréquence et de la tension. Ce fonctionnement autonome, bien qu'indispensable pour l'électrification des régions éloignées ou des îles, soulève des défis techniques considérables. La variabilité des sources renouvelables, la non-linéarité des comportements des convertisseurs de puissance et la complexité de la gestion énergétique rendent difficile l'application des méthodes de contrôle classiques, souvent conçues pour des systèmes linéaires et déterministes.

Le contrôle des micro-réseaux repose généralement sur une architecture hiérarchique à trois niveaux : le contrôle primaire, qui assure la stabilité rapide du système ; le contrôle secondaire, qui corrige les écarts de fréquence et de tension ; et le contrôle tertiaire, qui optimise la gestion globale de l'énergie sur le long terme. C'est ce dernier niveau qui fait l'objet de notre étude. Le contrôle tertiaire a pour mission de coordonner les différentes sources d'énergie, d'optimiser l'utilisation du stockage et de minimiser les coûts d'exploitation, tout en respectant les contraintes techniques du système.

Or, les approches conventionnelles du contrôle tertiaire fondées sur l'optimisation mathématique, la programmation linéaire ou la programmation stochastique présentent des limites face à la complexité et aux incertitudes des micro-réseaux isolés. Elles nécessitent souvent une modélisation précise du système, difficile à obtenir en pratique, et peinent à s'adapter aux variations rapides des conditions de fonctionnement. C'est dans ce contexte que les techniques d'intelligence artificielle, et plus particulièrement les réseaux de neurones artificiels, offrent des perspectives intéressantes. Leur capacité à apprendre à partir de données, à modéliser des relations non linéaires et à s'adapter aux environnements dynamiques les rend particulièrement adaptés aux problématiques des micro-réseaux isolés.

Parmi les différentes architectures de réseaux de neurones, les réseaux à fonctions de base radiale (RBF) retiennent notre attention. Leur structure relativement simple, leur vitesse d'apprentissage et leur bonne capacité d'approximation des systèmes non linéaires en font des candidats pertinents pour le contrôle en temps réel des systèmes énergétiques. L'association de ces réseaux avec des régulateurs classiques de type PI, dans une structure de commande adaptative, permet d'envisager une amélioration significative des performances du contrôle tertiaire.

C'est précisément l'objectif de ce mémoire : proposer et valider une stratégie de contrôle tertiaire pour micro-réseaux isolés, fondée sur l'utilisation des réseaux de neurones RBF. Ce travail s'articule autour de quatre chapitres. Le premier présente les fondements des micro-réseaux isolés et fait l'état de l'art des méthodes de contrôle tertiaire. Le second étudie les réseaux de neurones artificiels et analyse leur compatibilité avec les contraintes des micro-réseaux isolés. Le troisième décrit la conception et l'implémentation du contrôleur proposé. Enfin, le quatrième chapitre est consacré à la simulation sous MATLAB/Simulink et à la comparaison des performances entre le contrôle classique PI et la commande adaptative RBF-PI.

Chapitre I : Fondements des micro-réseaux isolés et état de l'art du contrôle tertiaire

I.1 Introduction

L'évolution rapide des systèmes énergétiques et l'augmentation de la demande en énergie ont conduit à la recherche de nouvelles architectures de production et de distribution de l'électricité. Les réseaux électriques traditionnels reposent principalement sur une production centralisée et un transport de l'énergie sur de longues distances. Cette structure entraîne souvent des pertes d'énergies importantes, une faible flexibilité dans l'intégration des énergies renouvelables et une vulnérabilité face aux perturbations.

Afin de répondre à ces défis, le concept de micro-réseau (Microgrid) a été introduit comme une solution innovante permettant d'intégrer des sources d'énergie distribuées et des systèmes de stockage au niveau local. Un micro-réseau est un système énergétique capable de fonctionner de manière autonome ou connecté au réseau principal, tout en assurant une gestion intelligente de la production et de la consommation d'énergie.

Les micro-réseaux isolés représentent une catégorie particulière de micro-réseaux, caractérisée par leur fonctionnement indépendant du réseau électrique principal. Ils jouent un rôle essentiel dans l'électrification des zones rurales ou éloignées et dans l'intégration des énergies renouvelables.

Dans ce chapitre, nous présentons les concepts fondamentaux liés aux micro-réseaux isolés, leurs composants, leurs classifications ainsi que les différentes stratégies de contrôle utilisées pour assurer leur fonctionnement stable et optimal.

I.2 Généralités sur les micro-réseaux

I.2.1 Définition d'un micro-réseau

Un micro-réseau peut être défini comme un système énergétique local comprenant des sources de production d'énergie distribuée, des dispositifs de stockage, des charges électriques et un système de contrôle capable de gérer les flux d'énergie entre ces différents éléments [1]. La structure générale d'un micro-réseau est illustrée dans la Figure I.1.

Plusieurs organismes scientifiques ont proposé différentes définitions du micro-réseau. D'une manière générale, un micro-réseau est défini comme :

« Un ensemble de charges et de ressources énergétiques distribuées interconnectées qui peuvent fonctionner comme une entité contrôlable unique par rapport au réseau électrique principal » [2].

Le micro-réseau est généralement connecté au réseau principal par un point appelé Point de Couplage Commun (PCC). Ce point permet l'échange d'énergie entre le micro-réseau et le réseau principal [3].

Un micro-réseau possède plusieurs caractéristiques importantes :

- Il peut fonctionner de manière connectée au réseau principal ;
- Il peut fonctionner de manière autonome en mode isolé ;
- Il dispose d'un système de contrôle intelligent ;
- Il permet l'intégration des énergies renouvelables.

Dans le mode connecté, le réseau principal impose généralement les valeurs de fréquence et de tension. En revanche, dans le mode isolé, le micro-réseau doit assurer lui-même la stabilité du système [4].

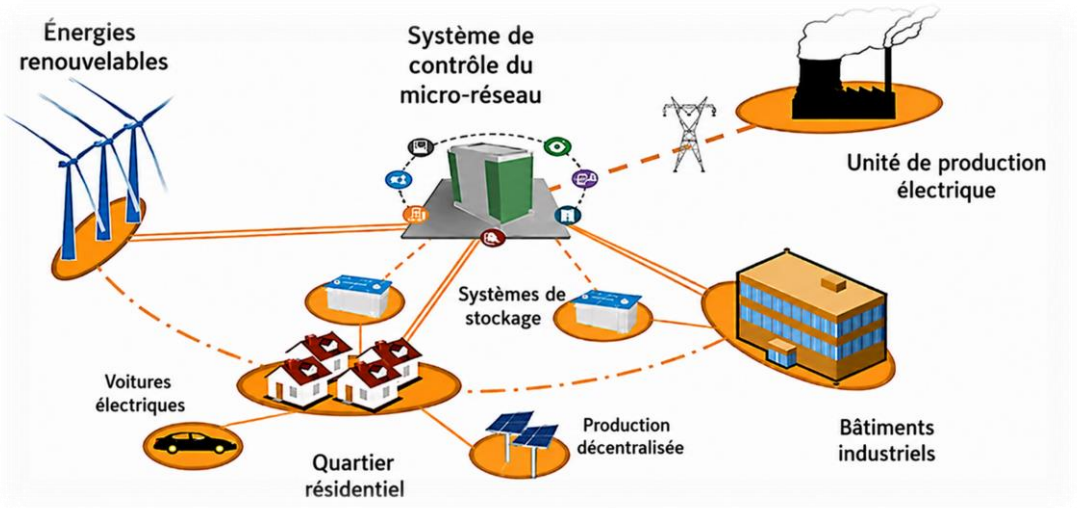


Figure I.1: schéma d'un micro-réseau [5]

I.2.2 Structure générale d'un micro-réseau

La structure d'un micro-réseau est constituée de plusieurs éléments interconnectés qui assurent la production, la conversion, le stockage et la distribution de l'énergie électrique.

En général, un micro-réseau comprend les composants suivants :

- Des sources d'énergie distribuées ;
- Des systèmes de stockage d'énergie ;

- Des charges électriques ;
- Des convertisseurs électroniques de puissance ;
- Un système de gestion d'énergie.

Ces différents éléments sont connectés à un bus électrique principal qui peut être de type AC ou DC. L'organisation de ces composants est illustrée dans la Figure I.2.

La structure générale d'un micro-réseau peut également inclure :

- Un système de communication.
- Un contrôleur central.
- Des contrôleurs locaux.

Ces dispositifs permettent d'assurer la coordination entre les différentes unités de production et de consommation [6].

Dans les micro-réseaux modernes, l'utilisation des systèmes de communication et des technologies de l'information joue un rôle essentiel dans la gestion intelligente de l'énergie [7].

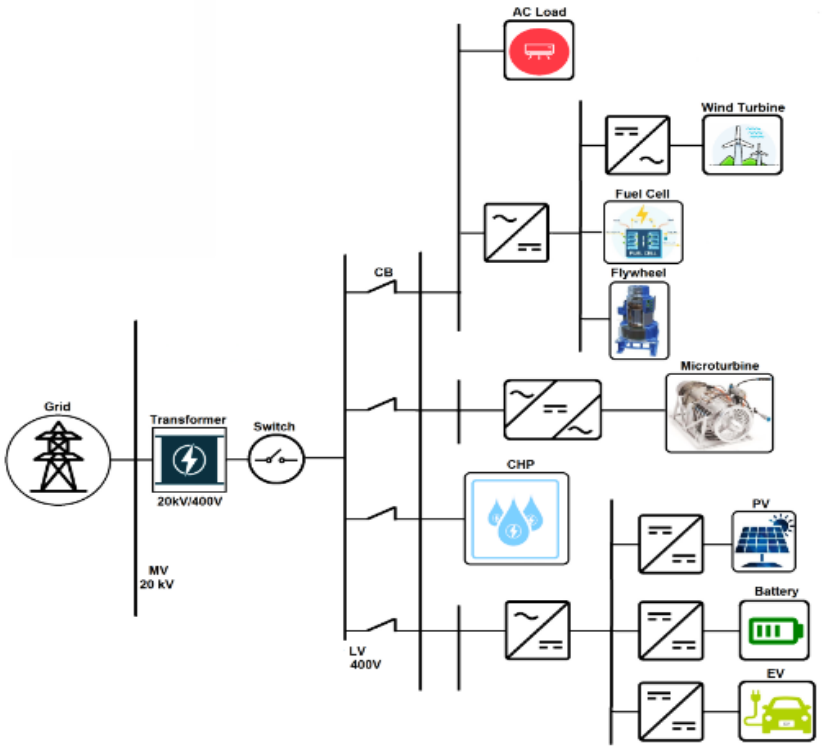


Figure I.2 Structure générale d'un micro-réseau

I.2.3 Composants principaux d'un micro-réseau

A. Sources d'énergie distribuées (DER)

Les sources d'énergie distribuées représentent les unités de production d'électricité situées à proximité des consommateurs. Contrairement aux centrales électriques traditionnelles qui produisent de grandes quantités d'énergie dans des installations centralisées, les DER produisent de l'électricité à petite échelle.

Ces sources peuvent être classées en deux catégories principales : les sources renouvelables et les sources conventionnelles.

Les sources renouvelables comprennent notamment l'énergie solaire photovoltaïque, l'énergie éolienne, l'énergie hydraulique et la biomasse. Ces sources présentent l'avantage d'être propres et renouvelables, mais leur production dépend fortement des conditions climatiques [8].

Les sources conventionnelles incluent les générateurs diesel, les micro-turbines à gaz et les piles à combustible. Elles sont généralement utilisées comme systèmes de secours afin d'assurer la continuité de l'alimentation électrique [4].

B. Systèmes de stockage d'énergie

Les systèmes de stockage d'énergie jouent un rôle fondamental dans les micro-réseaux, notamment dans les micro-réseaux isolés, car ils permettent de compenser l'intermittence des sources renouvelables [9].

Parmi les technologies de stockage les plus utilisées figurent :

- Batteries lithium-ion ;
- Batteries plomb-acide ;
- Supercondensateurs ;
- Volants d'inertie.

Ces systèmes permettent de stocker l'énergie excédentaire produite par les sources renouvelables et de la restituer lorsque la production est insuffisante.

Le stockage d'énergie permet également d'améliorer la stabilité du réseau et de réduire les fluctuations de puissance.

C. Charges

Les charges représentent les équipements qui consomment l'énergie électrique dans le micro-réseau. Elles peuvent être classées selon leur importance en charges critiques, charges prioritaires et charges non prioritaires [6].

La gestion des charges est particulièrement importante dans les micro-réseaux isolés afin de garantir la stabilité du système.

D. Convertisseurs de puissance

Les convertisseurs électroniques de puissance permettent de connecter les différentes sources d'énergie au réseau du micro-réseau.

Ils assurent plusieurs fonctions essentielles :

- Conversion AC/DC ;
- Conversion DC/AC ;
- Régulation de la tension ;
- Contrôle du flux de puissance.

Les convertisseurs les plus utilisés dans les micro-réseaux sont les onduleurs, les redresseurs et les convertisseurs DC/DC [3].

E. Système de gestion d'énergie

Le système de gestion d'énergie (Energy Management System – EMS) constitue le cerveau du micro-réseau. Il assure la coordination entre les sources d'énergie, les systèmes de stockage et les charges afin d'optimiser le fonctionnement global du système [7].

Ses principales fonctions sont :

- La gestion de la production d'énergie ;
- La planification énergétique ;
- L'optimisation économique ;
- La surveillance du système.

L'EMS utilise généralement des algorithmes avancés afin d'améliorer les performances du micro-réseau.

I.3 Classification des micro-réseaux

Les micro-réseaux peuvent être classés selon plusieurs critères, notamment le type de réseau électrique, les sources d'énergie utilisées ainsi que leur mode de fonctionnement. Toutefois, la classification la plus répandue repose principalement sur leur relation avec le réseau électrique principal.

I.3.1 Micro-réseaux connectés au réseau principal

Dans ce mode de fonctionnement, le micro-réseau est relié au réseau électrique principal à travers le Point de Couplage Commun (PCC). Dans cette configuration, le réseau principal joue un rôle déterminant puisqu'il impose généralement les paramètres essentiels du système, notamment la fréquence et la tension du réseau. L'architecture générale d'un micro-réseau en mode connecté au réseau principal est illustrée dans la Figure I.3.

Ainsi, le micro-réseau peut fonctionner de manière flexible en important de l'énergie lorsque la production locale est insuffisante, ou au contraire en exportant l'excédent d'énergie vers le réseau principal lorsque la production dépasse la consommation.

Ce mode de fonctionnement présente plusieurs avantages, parmi lesquels :

- Une meilleure stabilité du système électrique ;
- Une optimisation des coûts d'exploitation ;
- Une intégration facilitée des sources d'énergie renouvelables [3].

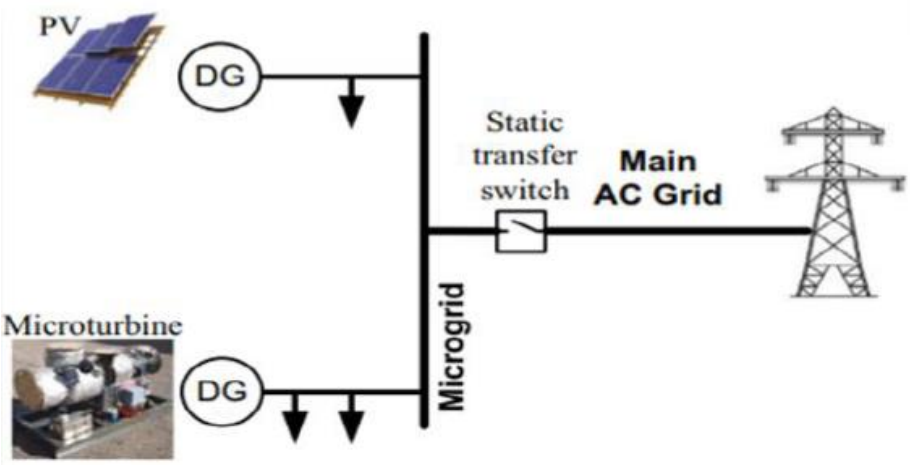


Figure I.3 : Architecture générale d'un micro-réseau en mode connecté au réseau [10]

I.3.2 Micro-réseaux isolés

Contrairement aux micro-réseaux connectés, les micro-réseaux isolés fonctionnent de manière totalement indépendante du réseau principal. Par conséquent, ils doivent assurer localement l'ensemble des fonctions de contrôle et de gestion du système électrique [6].

Dans ce cas, le micro-réseau est responsable de :

- La régulation de la fréquence ;
- La régulation de la tension ;
- Le partage de puissance entre les différentes sources de production.

Ce type de micro-réseau est généralement utilisé dans les zones éloignées ou difficiles d'accès, telles que les régions rurales isolées, les îles ou encore certaines installations industrielles situées loin du réseau électrique

I.4 Importance et applications des micro-réseaux isolés

Les micro-réseaux isolés occupent aujourd'hui une place importante dans les systèmes énergétiques modernes, notamment dans les régions éloignées où l'accès au réseau électrique principal reste limité ou difficile [1]. Grâce à leur capacité de fonctionner de manière autonome, ces systèmes permettent d'assurer une alimentation électrique fiable et continue pour les populations et les infrastructures locales.

Avec le développement rapide des énergies renouvelables et des technologies de stockage d'énergie, les micro-réseaux isolés représentent désormais une solution efficace pour répondre aux besoins énergétiques locaux tout en réduisant la dépendance aux combustibles fossiles et en limitant les impacts environnementaux [9].

I.4.1 Micro-projets de production d'énergie

Les micro-réseaux isolés facilitent la mise en place de micro-projets énergétiques destinés à produire et à distribuer de l'électricité à petite échelle. Ces projets sont particulièrement adaptés aux zones où l'extension du réseau électrique conventionnel n'est pas toujours possible.

Ils peuvent être déployés dans différents contextes tels que :

- Les villages ruraux ;
- Les communautés isolées ;
- Les sites industriels éloignés ;
- Les exploitations agricoles.

Dans la plupart des cas, ces micro-projets reposent sur des systèmes hybrides combinant plusieurs sources d'énergie, notamment des panneaux photovoltaïques, des éoliennes, des batteries de stockage ainsi que des générateurs diesel utilisés comme source de secours [8].

I.4.2 Électrification des zones éloignées

L'électrification des zones rurales ou isolées constitue l'une des applications les plus importantes des micro-réseaux isolés. Dans plusieurs régions du monde, l'extension du réseau électrique principal peut être techniquement complexe ou économiquement très coûteuse.

Dans ce contexte, les micro-réseaux isolés apparaissent comme une solution alternative efficace permettant de fournir de l'électricité aux populations locales et d'améliorer les conditions de vie ainsi que les activités économiques dans ces régions [11].

I.4.3 Intégration des énergies renouvelables

Les micro-réseaux isolés offrent également un cadre particulièrement adapté à l'intégration des sources d'énergies renouvelables telles que l'énergie solaire et l'énergie éolienne [8]. Toutefois, ces sources présentent une production intermittente, car elles dépendent fortement des conditions météorologiques.

Afin de garantir la stabilité et la continuité de l'alimentation électrique, différentes solutions peuvent être mises en œuvre, parmi lesquelles :

- L'utilisation de systèmes de stockage d'énergie ;
- L'intégration de générateurs de secours ;
- La mise en place de stratégies avancées de contrôle et de gestion énergétique [9].

I.5 Architecture de contrôle des micro-réseaux :

Le fonctionnement stable d'un micro-réseau dépend fortement du système de contrôle utilisé pour gérer les flux d'énergie entre les différentes unités du système. L'architecture hiérarchique de contrôle d'un micro-réseau est représentée dans la Figure I.4.

Le contrôle des micro-réseaux repose généralement sur une architecture hiérarchique composée de trois niveaux :

- Contrôle primaire ;
- Contrôle secondaire ;
- Contrôle tertiaire.

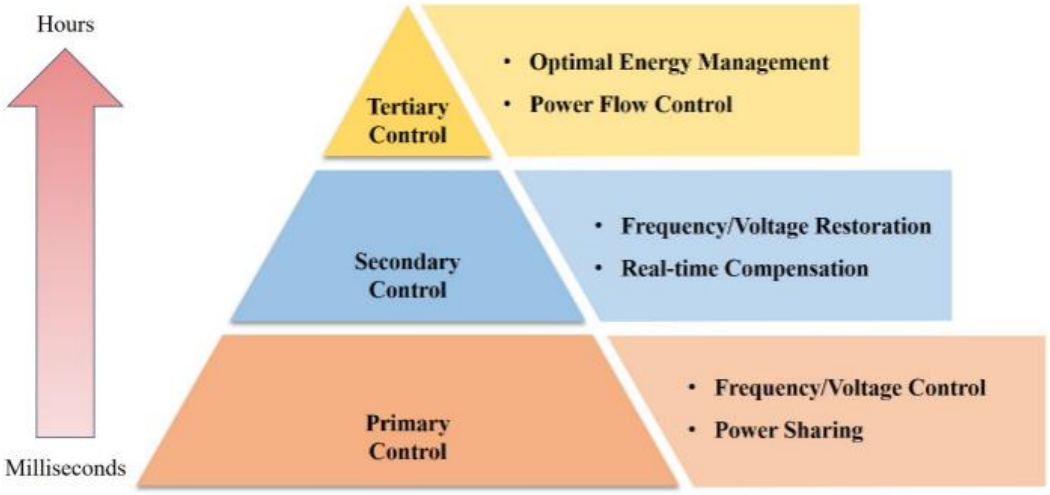


Figure I.4: La structure de contrôle hiérarchique.

I.5.1 Contrôle primaire :

Le contrôle primaire représente le premier niveau dans la hiérarchie de contrôle d'un micro-réseau. Il intervient directement au niveau des convertisseurs de puissance et assure une réaction rapide face aux variations de charge ou de production d'énergie. Ce niveau de contrôle joue un rôle essentiel dans la stabilité immédiate du système.

L'objectif principal du contrôle primaire est de maintenir l'équilibre du micro-réseau en régulant plusieurs paramètres importants, notamment la fréquence, la tension ainsi que le partage de la puissance entre les différentes sources d'énergie présentes dans le système.

Dans la majorité des micro-réseaux, le contrôle primaire repose sur la stratégie du Droop Control, également appelée contrôle de statisme. Le principe de cette méthode consiste à établir une relation entre la puissance active et la fréquence, ainsi qu'entre la puissance réactive et la tension. Grâce à ce principe, les différentes unités de production peuvent partager la puissance de manière automatique sans nécessiter une communication directe entre elles.

Cette approche présente plusieurs avantages importants. Elle permet tout d'abord une réponse très rapide aux perturbations du système. De plus, sa mise en œuvre reste relativement simple et elle favorise un fonctionnement décentralisé du micro-réseau, ce qui améliore la fiabilité globale du système.

Cependant, malgré ces avantages, le contrôle primaire peut provoquer certains écarts de tension et de fréquence par rapport aux valeurs nominales du système. Ces écarts doivent donc être corrigés par un niveau de contrôle supérieur, appelé contrôle secondaire [12].

I.5.2 Contrôle secondaire :

Le contrôle secondaire constitue le deuxième niveau de la hiérarchie de contrôle dans les micro-réseaux. Son rôle principal est de corriger les écarts de fréquence et de tension introduits par le contrôle primaire.

En effet, bien que le contrôle primaire permette de stabiliser rapidement le système après une perturbation, il ne garantit pas toujours le retour exact de la fréquence et de la tension à leurs valeurs nominales. Le contrôle secondaire intervient donc pour rétablir ces valeurs et assurer une meilleure qualité de l'énergie fournie aux consommateurs.

Les principales fonctions du contrôle secondaire consistent à restaurer la fréquence nominale du système, corriger la tension au niveau souhaité et améliorer la stabilité globale du micro-réseau. Ce niveau de contrôle peut être implémenté selon deux architectures principales : centralisée ou distribuée.

Dans une approche centralisée, un contrôleur principal collecte les informations provenant des différentes unités du micro-réseau, analyse l'état du système puis envoie les commandes nécessaires afin de corriger les écarts observés.

Dans une approche distribuée, les différentes unités du micro-réseau coopèrent entre elles pour atteindre les objectifs de régulation. Chaque unité participe au processus de contrôle sans dépendre

entièrement d'un contrôleur central, ce qui permet d'améliorer la flexibilité et la robustesse du système [12].

I.5.3 Contrôle tertiaire :

Le contrôle tertiaire représente le niveau le plus élevé dans l'architecture de contrôle des micro-réseaux. Contrairement aux niveaux primaire et secondaire qui se concentrent principalement sur la stabilité et la régulation du système, le contrôle tertiaire s'intéresse davantage à l'optimisation globale du fonctionnement énergétique et économique du micro-réseau.

L'objectif principal de ce niveau de contrôle est d'assurer une gestion optimale des ressources énergétiques disponibles. Il permet notamment d'optimiser la production d'énergie, de planifier l'utilisation des différentes sources et d'assurer une coordination efficace entre les unités de production, les systèmes de stockage et les charges.

Parmi les fonctions principales du contrôle tertiaire, on peut citer l'optimisation de la production d'énergie, la gestion économique du système, la planification énergétique ainsi que la coordination entre les différentes sources d'énergie présentes dans le micro-réseau.

Dans la plupart des cas, le contrôle tertiaire repose sur l'utilisation d'algorithmes d'optimisation permettant de déterminer la stratégie de fonctionnement la plus efficace. Ces algorithmes visent généralement à minimiser les coûts d'exploitation tout en respectant les contraintes techniques du système, telles que les limites de puissance des générateurs, l'état de charge des batteries ou encore la demande énergétique des consommateurs.

Ce niveau de contrôle joue donc un rôle essentiel dans l'amélioration de l'efficacité énergétique et dans la gestion intelligente des micro-réseaux, en particulier dans le cas des micro-réseaux isolés intégrant des sources d'énergie renouvelables [1].

I.6 Contrôle tertiaire dans les micro-réseaux isolés

Dans les micro-réseaux isolés, le contrôle tertiaire occupe une place essentielle dans la gestion globale du système énergétique. Contrairement aux micro-réseaux connectés au réseau principal, ces systèmes ne peuvent pas s'appuyer sur une infrastructure externe pour équilibrer la production et la consommation d'électricité. Par conséquent, ils doivent assurer localement une gestion efficace et optimale des ressources énergétiques disponibles afin de garantir la stabilité et la continuité de l'alimentation électrique.

I.6.1 Objectifs du contrôle tertiaire

Le contrôle tertiaire a pour objectif principal d'améliorer la gestion énergétique du micro-réseau sur le long terme. Il vise notamment à réduire les coûts de production de l'énergie tout en maximisant l'utilisation des sources d'énergie renouvelables disponibles. Il permet également d'optimiser l'utilisation des systèmes de stockage d'énergie, tels que les batteries, afin de mieux exploiter l'énergie produite. Par ailleurs, ce niveau de contrôle contribue à maintenir l'équilibre entre la production et la consommation d'électricité dans le micro-réseau.

I.6.2 Optimisation de la gestion énergétique

La gestion énergétique d'un micro-réseau consiste à déterminer la stratégie de fonctionnement la plus appropriée en fonction de plusieurs paramètres essentiels. Parmi ces paramètres figurent la production des sources d'énergie renouvelables, la demande énergétique des consommateurs, l'état de charge des batteries ainsi que les coûts associés aux différentes sources de production. Dans la plupart des cas, cette problématique est formulée comme un problème d'optimisation mathématique dont l'objectif principal est de minimiser les coûts de production tout en respectant les contraintes techniques et opérationnelles du système énergétique [7].

Ce principe est illustré par le schéma du système de gestion d'énergie présenté dans la Figure I.5.

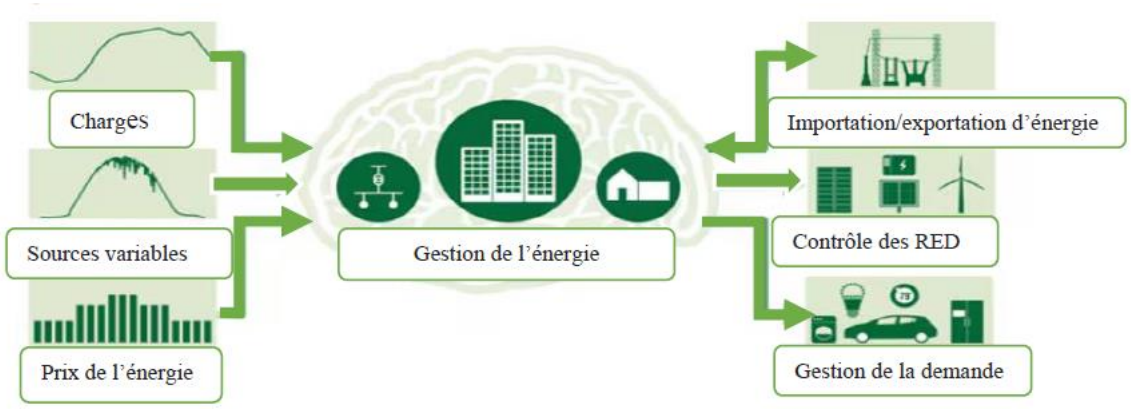


Figure I.5: Système de gestion d'énergie dans un micro-réseau [13].

I.6.3 Coordination entre les sources d'énergie

Dans un micro-réseau isolé, différentes sources d'énergie peuvent fonctionner simultanément, notamment les panneaux photovoltaïques, les éoliennes, les systèmes de stockage d'énergie et les générateurs conventionnels. Dans ce contexte, le contrôle tertiaire assure la coordination entre ces différentes sources afin d'optimiser la production globale d'énergie et de réduire les coûts

d'exploitation du système. Cette coordination contribue également à améliorer la stabilité et la fiabilité du micro-réseau. En outre, une gestion efficace des sources d'énergie permet de limiter l'utilisation des générateurs diesel et d'augmenter la part des énergies renouvelables dans le mix énergétique du système [9].

I.7 État de l'art des méthodes de contrôle tertiaire :

Le contrôle tertiaire constitue le niveau supérieur dans l'architecture hiérarchique de contrôle des micro-réseaux. Son objectif principal est d'assurer la gestion optimale de l'énergie, la coordination entre les différentes sources de production tout en minimisant les coûts d'exploitation du système [14].

Dans la littérature scientifique, plusieurs approches ont été proposées pour améliorer les performances du contrôle tertiaire. Ces approches peuvent être classées principalement en deux catégories : les méthodes classiques basées sur l'optimisation mathématique et les méthodes intelligentes basées sur les techniques d'intelligence artificielle [1].

I.7.1 Méthodes classiques utilisées dans la littérature

Les méthodes classiques reposent principalement sur des techniques d'optimisation mathématique pour résoudre les problèmes de gestion énergétique dans les micro-réseaux. Ces méthodes consistent à formuler le problème sous forme d'un modèle mathématique permettant de minimiser une fonction objective tout en respectant les contraintes techniques du système énergétique.

A. Optimisation mathématique

L'optimisation mathématique représente l'une des méthodes les plus utilisées pour résoudre les problèmes de gestion énergétique dans les micro-réseaux. Cette approche consiste à formuler le problème de fonctionnement du système sous la forme d'un problème d'optimisation comportant une fonction objective à minimiser ou à maximiser tout en respectant un ensemble de contraintes techniques. Dans la plupart des applications énergétiques, la fonction objective correspond généralement à la minimisation du coût total de production ou de l'utilisation des ressources énergétiques.

Dans les systèmes électriques, cette approche est largement utilisée pour résoudre le problème du dispatching économique qui consiste à déterminer la puissance optimale produite par chaque unité de génération afin de satisfaire la demande énergétique au coût minimal. Selon Wood et Wollenberg, les techniques d'optimisation constituent un outil fondamental dans la planification et l'exploitation

des systèmes de production d'énergie, car elles permettent d'améliorer l'efficacité globale du système tout en réduisant les coûts d'exploitation [15]. Dans le contexte des micro-réseaux isolés, cette méthode permet de coordonner le fonctionnement des générateurs conventionnels, des sources renouvelables et des systèmes de stockage afin d'assurer un fonctionnement optimal du système énergétique.

B. Programmation linéaire

La programmation linéaire est une technique d'optimisation largement utilisée lorsque les relations entre les variables du système peuvent être représentées sous forme d'équations linéaires. Le principe de cette méthode consiste à définir une fonction objectif linéaire ainsi qu'un ensemble de contraintes exprimées sous forme d'inégalités ou d'égalités linéaires. La solution optimale correspond alors au point de l'espace des solutions qui minimise ou maximise la fonction objective tout en respectant les contraintes imposées.

Dans les micro-réseaux, cette approche est souvent utilisée pour déterminer la répartition optimale de la production d'énergie entre les différentes sources disponibles. Elle permet notamment de planifier la production des générateurs et d'optimiser l'utilisation des ressources énergétiques tout en respectant les limites de fonctionnement des équipements. Bien que cette méthode soit relativement simple et efficace, son application reste limitée lorsque le système présente des comportements fortement non linéaires ou lorsque les incertitudes liées à la production renouvelable deviennent importantes [15].

C. Programmation non linéaire

Dans de nombreux cas réels, les relations entre les variables d'un système énergétique ne peuvent pas être décrites par des équations linéaires. Les caractéristiques de fonctionnement des générateurs, les pertes électriques ou encore les comportements des systèmes de stockage peuvent présenter des relations non linéaires. Pour modéliser ces phénomènes de manière plus réaliste, il est nécessaire d'utiliser des techniques d'optimisation plus avancées telles que la programmation non linéaire.

Le principe de cette méthode consiste à résoudre un problème d'optimisation dans lequel la fonction objective ou certaines contraintes présentent des relations non linéaires. Cette approche permet de modéliser avec plus de précision le comportement réel du système énergétique. Toutefois, la résolution de ces problèmes nécessite généralement des algorithmes de calcul plus complexes et

peut entraîner un temps de calcul plus élevé, surtout lorsque le nombre de variables de décision est important.

D. Programmation stochastique

La production d'énergie renouvelable dépend fortement des conditions météorologiques, ce qui introduit un certain niveau d'incertitude dans le fonctionnement des micro-réseaux. Afin de tenir compte de ces incertitudes, certains chercheurs ont proposé l'utilisation de la programmation stochastique dans la gestion énergétique des systèmes électriques.

Cette approche consiste à modéliser les variables incertaines, telles que la production photovoltaïque ou la demande énergétique, à l'aide de modèles probabilistes. L'objectif est d'optimiser le fonctionnement du système en tenant compte de plusieurs scénarios possibles représentant différentes conditions de fonctionnement. Selon Conejo et al., la programmation stochastique permet d'améliorer la robustesse des stratégies de gestion énergétique en intégrant explicitement les incertitudes dans le processus de décision [16].

E. Systèmes de gestion d'énergie (EMS)

Les systèmes de gestion d'énergie jouent un rôle essentiel dans l'implémentation du contrôle tertiaire dans les micro-réseaux. Ces systèmes sont responsables de la supervision globale du réseau et de la coordination entre les différentes unités de production, de stockage et de consommation.

Le fonctionnement d'un système EMS repose sur la collecte et l'analyse des données provenant des différents composants du micro-réseau. À partir de ces informations, des algorithmes de décision ou d'optimisation sont utilisés pour déterminer la stratégie de fonctionnement la plus appropriée. Selon Olivares et al., les systèmes de gestion d'énergie permettent d'améliorer l'efficacité énergétique des micro-réseaux et d'assurer une meilleure coordination entre les sources d'énergie distribuées [17].

I.7.2 Méthodes intelligentes utilisées dans la littérature

Avec l'augmentation de l'intégration des sources d'énergie renouvelables et la complexité croissante des micro-réseaux, plusieurs méthodes intelligentes ont été développées afin d'améliorer les performances du contrôle tertiaire.

A. Réseaux de neurones artificiels (RNA)

Les réseaux de neurones artificiels représentent l'une des techniques les plus utilisées dans le domaine de l'intelligence artificielle appliquée aux systèmes énergétiques. Inspirés du fonctionnement du cerveau humain, ces modèles sont constitués d'un ensemble de neurones artificiels interconnectés capables d'apprendre à partir de données d'apprentissage. L'objectif principal de cette approche est d'identifier les relations complexes entre différentes variables d'un système afin de prédire ou d'optimiser son comportement.

Le principe de fonctionnement des réseaux de neurones repose sur une phase d'apprentissage durant laquelle le modèle est entraîné à l'aide d'un ensemble de données d'entrée et de sortie. Pendant cette phase, les poids des connexions entre les neurones sont progressivement ajustés afin de réduire l'erreur entre les valeurs calculées et les valeurs réelles. Une fois l'apprentissage terminé, le réseau peut être utilisé pour effectuer des prédictions ou prendre des décisions dans de nouvelles situations. Selon Haykin, les réseaux de neurones sont particulièrement efficaces pour modéliser des systèmes non linéaires et dynamiques, ce qui les rend adaptés aux systèmes énergétiques complexes [18].

La structure typique des réseaux de neurones, incluant les architectures monocouche et multicouche ainsi que l'organisation des neurones en couches successives, est illustrée dans la Figure I.6.

Dans les micro-réseaux, les réseaux de neurones sont souvent utilisés pour la prévision de la production des sources d'énergie renouvelable, l'estimation de la demande énergétique et l'optimisation de la gestion de l'énergie. Grâce à leur capacité d'apprentissage et d'adaptation, ils permettent d'améliorer la précision des prévisions et d'optimiser le fonctionnement global du micro-réseau.

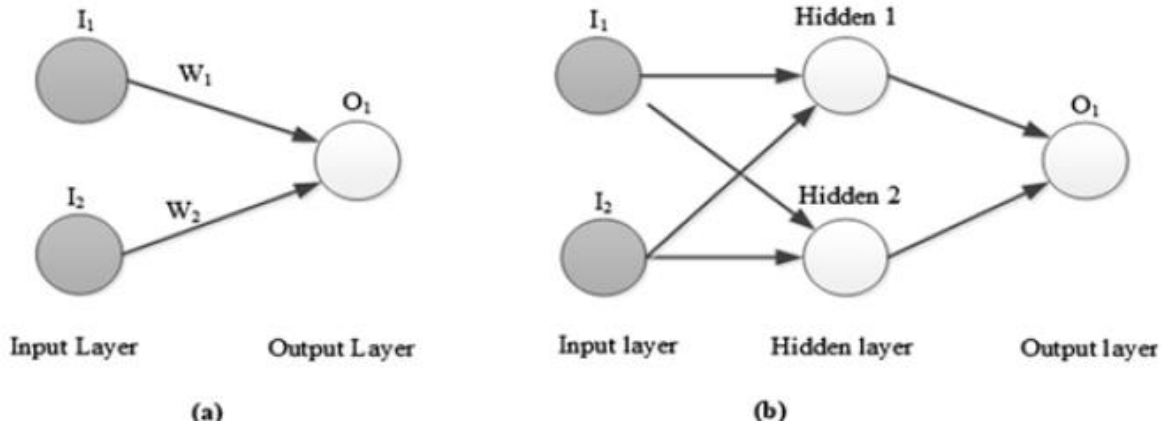


Figure I.6: Architecture des réseaux de neurones : (a) réseau de neurones monocouche ; (b) réseau neuronal multicouche.

B. Logique floue

La logique floue constitue une approche de contrôle particulièrement adaptée aux systèmes caractérisés par l'incertitude et l'imprécision. Cette méthode a été introduite par Zadeh en 1965 dans le but de représenter des informations imprécises à l'aide de variables linguistiques et d'ensembles flous [19].

Contrairement aux systèmes classiques basés sur une logique binaire stricte, la logique floue permet de représenter différents degrés d'appartenance à un ensemble. Le fonctionnement d'un contrôleur flou repose généralement sur trois étapes principales : la fuzzification des variables d'entrée, l'application d'un ensemble de règles logiques, puis la défuzzification qui permet de convertir les résultats obtenus en une valeur numérique exploitable par le système.

Dans le contexte des micro-réseaux, la logique floue est utilisée pour gérer la distribution de l'énergie entre les différentes sources disponibles en tenant compte de plusieurs paramètres tels que la demande énergétique, le niveau de charge des batteries ou la disponibilité des sources renouvelables. Cette méthode présente l'avantage de pouvoir intégrer l'expertise humaine dans le processus de décision et de s'adapter facilement aux systèmes complexes, comme le montre la Figure I.7.

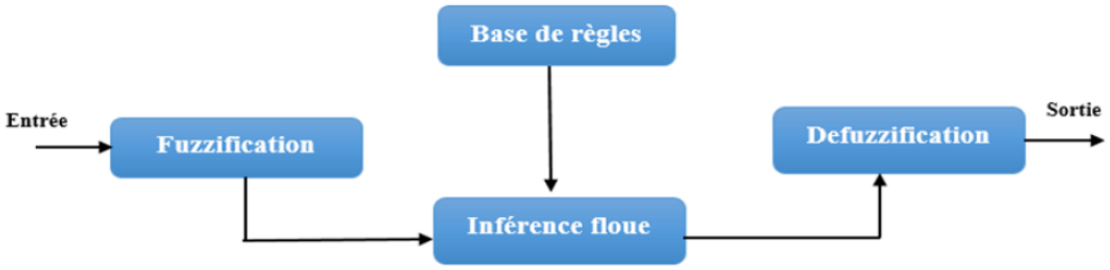


Figure I.7: Architecture générale du contrôle à logique floue (FLC).

C. Algorithmes génétiques

Les algorithmes génétiques constituent une technique d'optimisation inspirée des mécanismes de l'évolution biologique et de la sélection naturelle. Cette méthode repose sur l'idée de faire évoluer une population de solutions potentielles afin de trouver progressivement la meilleure solution possible à un problème donné.

Le principe de fonctionnement des algorithmes génétiques consiste à représenter chaque solution potentielle sous la forme d'un individu appartenant à une population. Au cours du processus d'optimisation, ces individus subissent plusieurs opérations inspirées de la génétique naturelle telles que la sélection, la reproduction et la mutation. À chaque génération, les solutions les plus performantes sont conservées et combinées afin de produire de nouvelles solutions potentiellement meilleures (voir Figure I.8).

Dans les micro-réseaux, les algorithmes génétiques sont utilisés pour résoudre des problèmes d'optimisation complexes liés à la gestion énergétique. Ils permettent notamment de déterminer la répartition optimale de la production d'énergie entre différentes sources tout en minimisant les coûts d'exploitation et en respectant les contraintes du système.

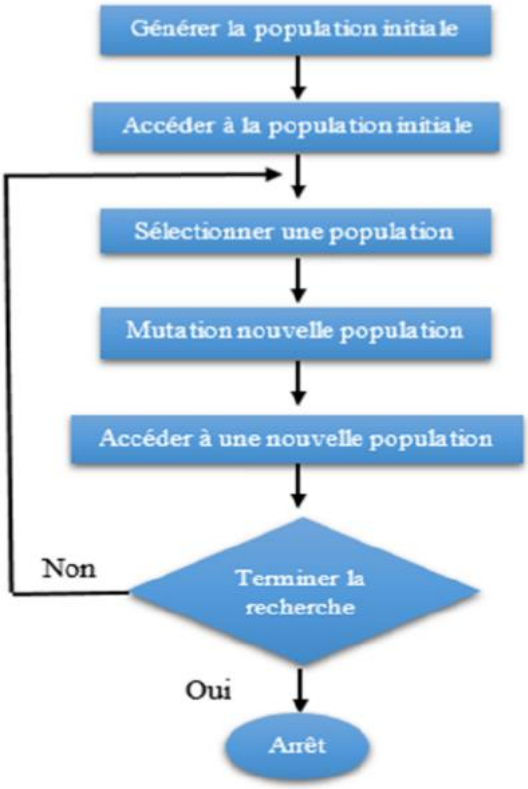


Figure I.8: Structure générale de l'algorithme génétique.

D. Optimisation par essaims de particules

L'algorithme optimisation par essaims de particules (PSO) est une méthode d'optimisation inspirée du comportement collectif observé dans les groupes d'animaux tels que les oiseaux ou les bancs de poissons. Cette méthode a été proposée par Kennedy et Eberhart en 1995 afin de résoudre des problèmes d'optimisation complexes dans différents domaines scientifiques [20].

Le fonctionnement de cet algorithme repose sur un ensemble de particules qui se déplacent dans l'espace de recherche afin de trouver la solution optimale. Chaque particule possède une position et une vitesse qui sont mises à jour à chaque itération en fonction de deux éléments principaux : la meilleure position trouvée par la particule elle-même et la meilleure position trouvée par l'ensemble du groupe. Ce mécanisme de coopération permet aux particules d'explorer efficacement l'espace de recherche et de converger progressivement vers la solution optimale, comme le montre la Figure I.9.

Dans les micro-réseaux, l'algorithme PSO est souvent utilisé pour optimiser la gestion énergétique et améliorer la répartition de la production entre les différentes sources d'énergie. Cette méthode permet également de minimiser les coûts d'exploitation et d'améliorer l'efficacité globale du système énergétique.

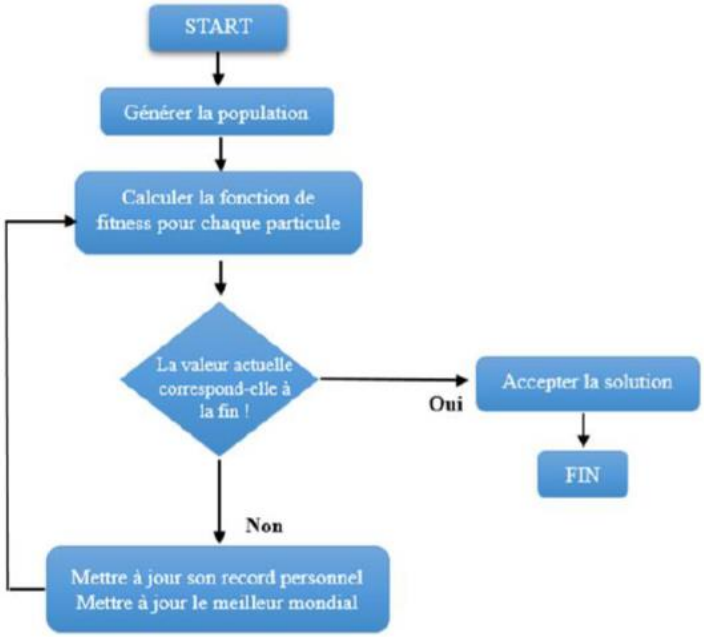


Figure I.9: Optimisation des essaims de particules.

E. Méthodes hybrides

Face à la complexité croissante des systèmes énergétiques modernes, plusieurs chercheurs ont proposé l'utilisation de méthodes hybrides combinant différentes techniques d'intelligence artificielle et d'optimisation. L'objectif de ces approches est de tirer parti des avantages de plusieurs méthodes afin d'améliorer les performances du système de contrôle.

Par exemple, certaines études combinent les réseaux de neurones avec des algorithmes d'optimisation tels que PSO afin d'améliorer la précision des prévisions et d'optimiser la gestion énergétique. D'autres travaux associent la logique floue à des algorithmes évolutifs afin d'obtenir des systèmes de contrôle plus robustes et plus adaptatifs.

Selon Mohammadi et al, l'utilisation de méthodes hybrides dans les systèmes de gestion d'énergie des micro-réseaux permet d'améliorer la performance globale du système et de mieux gérer les incertitudes liées aux sources d'énergie renouvelable [21], comme illustré dans la Figure I.10.

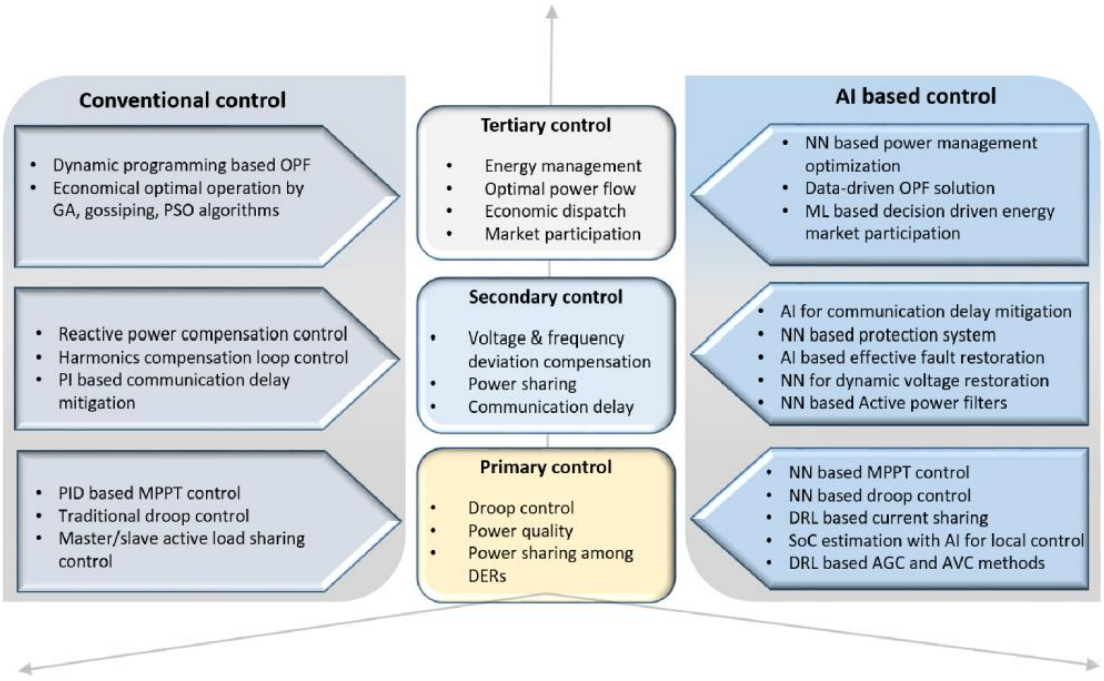


Figure I.10: Contrôle conventionnel et prospectif basé sur l'IA dans l'architecture de contrôle hiérarchique

I.7.3 Limites des méthodes existantes

Malgré les avancées significatives dans le domaine du contrôle tertiaire des micro-réseaux, les méthodes existantes présentent certaines limites. Les approches classiques, basées sur l'optimisation mathématique, nécessitent généralement une modélisation précise du système, ce qui devient difficile en présence de comportements non linéaires et d'incertitudes liées aux sources d'énergie renouvelables. De plus, leur performance peut être limitée lorsque le système devient complexe ou fortement dynamique.

Par ailleurs, bien que les méthodes intelligentes offrent une meilleure capacité d'adaptation et de gestion des incertitudes, elles restent dépendantes de la qualité et de la quantité des données d'apprentissage. Leur mise en œuvre peut également être plus complexe et nécessiter des ressources computationnelles importantes, notamment lors de la phase d'entraînement.

Ainsi, ces limites mettent en évidence la nécessité de développer des approches plus robustes et hybrides, capables de combiner la rigueur des méthodes classiques et la flexibilité des techniques intelligentes afin d'améliorer les performances du contrôle tertiaire dans les micro-réseaux isolés.

I.8 Conclusion

Dans ce chapitre, nous avons présenté les concepts fondamentaux liés aux micro-réseaux isolés ainsi que leurs principales caractéristiques. Nous avons également étudié les différentes architectures de contrôle utilisées pour assurer leur fonctionnement stable et efficace.

Une attention particulière a été portée au contrôle tertiaire, qui joue un rôle essentiel dans l'optimisation de la gestion énergétique et la coordination entre les différentes sources d'énergie.

L'analyse de l'état de l'art a montré que plusieurs méthodes ont été proposées dans la littérature pour améliorer les performances du contrôle tertiaire, notamment les méthodes classiques d'optimisation et les méthodes intelligentes basées sur l'intelligence artificielle.

Dans le chapitre suivant, nous présenterons les méthodes d'optimisation basées sur les réseaux de neurones artificiels, ainsi que leur application dans le contrôle tertiaire des micro-réseaux isolés

Chapitre II : Étude des réseaux de neurones artificiels et leur adaptation aux micro-réseaux isolés

II.1 Introduction

Les micro-réseaux isolés (MGI) constituent une solution pertinente pour l'intégration des sources d'énergie renouvelables et l'alimentation des zones éloignées du réseau électrique principal. Cependant, la gestion et le contrôle de ces systèmes représentent un défi majeur en raison de leur complexité, de leur comportement non linéaire et de la variabilité des ressources énergétiques disponibles.

Les méthodes classiques de contrôle tertiaire, bien qu'efficaces dans certains cas, présentent des limites face à la dynamique et à l'incertitude caractérisant les micro-réseaux isolés. Ces approches nécessitent généralement une modélisation mathématique précise du système, ce qui devient difficile dans un environnement réel marqué par la fluctuation des charges et des sources renouvelables.

Dans ce contexte, les réseaux de neurones artificiels (RNA) apparaissent comme une alternative prometteuse. Inspirés du fonctionnement du cerveau humain, ces modèles sont capables d'apprendre à partir de données et de représenter des relations complexes entre les variables d'un système sans recourir à une modélisation analytique explicite. Leur capacité à traiter des systèmes non linéaires et dynamiques les rend particulièrement adaptés aux problématiques liées aux micro-réseaux isolés.

Par ailleurs, les RNA ont été largement utilisés dans le domaine des systèmes énergétiques pour diverses applications, telles que la prévision de la demande, l'estimation de la production renouvelable et l'optimisation de la gestion énergétique. Leur utilisation dans le cadre du contrôle tertiaire permet d'améliorer la prise de décision et d'optimiser les performances globales du système.

Ainsi, ce chapitre a pour objectif de présenter les fondements des réseaux de neurones artificiels ainsi que d'analyser leur compatibilité avec les micro-réseaux isolés. Il s'articule autour de l'étude des principes de base des RNA, de leur fonctionnement mathématique, ainsi que de leur aptitude à répondre aux contraintes spécifiques des systèmes énergétiques modernes.

II.2 Généralités sur les réseaux de neurones artificiels

II.2.1 Définition des réseaux de neurones artificiels

Un réseau de neurones artificiels (RNA) est un système de calcul inspiré du fonctionnement du cerveau humain, constitué d'un ensemble de neurones artificiels interconnectés capables de traiter l'information et d'apprendre à partir des données. Les RNA appartiennent au domaine de l'intelligence

artificielle et de l'apprentissage automatique, et sont largement utilisés pour la résolution de problèmes complexes tels que la classification, la prédiction, l'optimisation et la reconnaissance de formes.

Selon la CNIL, « dans le domaine de l'intelligence artificielle, un réseau de neurones artificiels est un ensemble organisé de neurones interconnectés permettant la résolution de problèmes complexes tels que la vision par ordinateur ou le traitement du langage naturel ». Ainsi, les RNA reproduisent de manière simplifiée certains mécanismes du cerveau biologique à travers des opérations mathématiques et des processus d'apprentissage [22].

Chaque neurone artificiel reçoit un ou plusieurs signaux d'entrée, effectue un traitement basé sur une combinaison pondérée des données, puis produit une sortie à travers une fonction d'activation. Les connexions entre les neurones sont associées à des poids synaptiques qui sont ajustés progressivement durant la phase d'apprentissage afin d'améliorer les performances du réseau [18].

Il existe plusieurs architectures de réseaux de neurones artificiels, telles que les réseaux multicouches (MLP), les réseaux récurrents (RNN), les réseaux LSTM ainsi que les réseaux à fonctions de base radiale (RBF). Le choix de l'architecture dépend principalement de la nature du problème traité et des performances recherchées.

II.2.2 Inspiration biologique

Les RNA puisent leur inspiration dans la neurobiologie. La conception des réseaux artificiels est en effet « directement inspirée de notre compréhension du cerveau humain et de son incroyable capacité à apprendre et à s'adapter » [23]. Dans le cerveau, des milliards de neurones biologiques sont interconnectés par des synapses qui transmettent des signaux électrochimiques. De manière similaire, un RNA est constitué d'un grand nombre d'unités de calcul simples (« neurones artificiels ») reliées entre elles par des poids représentant des connexions synaptiques [24], comme illustré dans la Figure II.1.

L'histoire des réseaux de neurones remonte aux travaux de McCulloch et Pitts (1943), qui proposèrent le premier modèle mathématique de neurone formel capable de recevoir, traiter et décider de transmettre une information [25]. Ainsi, l'intuition de base est que, tout comme un cerveau apprenant par l'ajustement de ses synapses, un RNA peut apprendre à partir de données en ajustant ses connexions internes [18]. Cette inspiration biologique est à la fois conceptuelle (architecture en couches de neurones) et pragmatique (utilisation de fonctions d'activation rappelant un seuil de décharge neuronale).

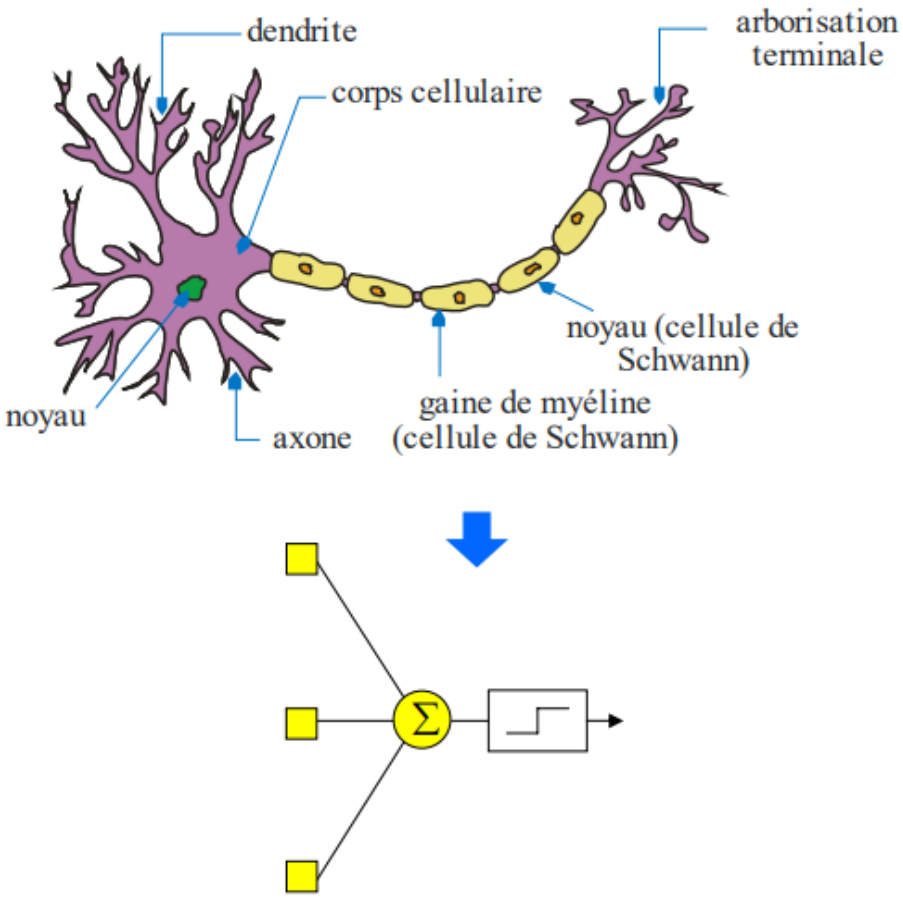


Figure II.1 : Représentation d'un neurone biologique et analogie avec le neurone artificiel

II.2.3 Structure générale d'un réseau de neurones

Un réseau de neurones artificiels typique est organisé en couches successives de neurones artificiels. Comme l'illustre la figure ci-dessous, un réseau classique comporte au minimum une couche d'entrée (input), une ou plusieurs couches cachées (hidden layers) et une couche de sortie (output).

• **Couche d'entrée :** reçoit les données brutes (par exemple, les mesures électriques d'un capteur).

• **Couches cachées :** chaque neurone de ces couches calcule une combinaison non linéaire des entrées reçues (via une fonction d'activation). Les couches cachées permettent de modéliser des relations complexes [24].

• **Couche de sortie :** fournit le résultat final du réseau (par exemple une prédiction ou une classification).

Chaque neurone dans ces couches est relié à tous les neurones de la couche précédente (dans un réseau neuronal à propagation directe standard). Chaque connexion est pondérée par un coefficient multiplicateur (le poids synaptique), qui quantifie l'influence du neurone en amont sur le neurone en aval. Ainsi, l'information circule depuis l'entrée jusqu'à la sortie, couche après couche. La CNIL souligne que les RNA sont « caractérisés par un grand nombre de couches de neurones, dont les coefficients de pondération sont ajustés au cours d'une phase d'entraînement (apprentissage profond) » [1].

On peut représenter schématiquement un réseau de neurones comme Figure II.2.

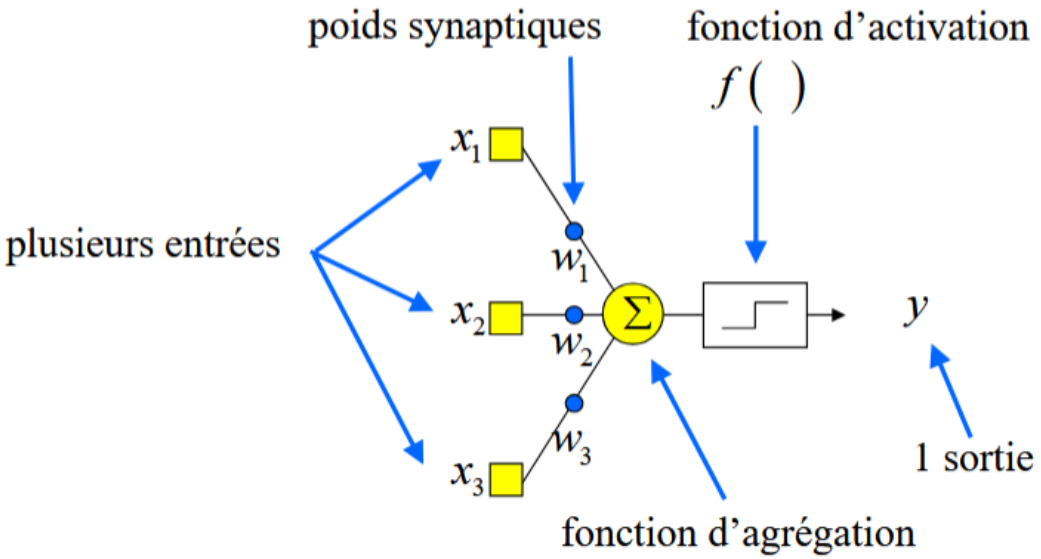


Figure II.2 : Structure générale d'un neurone artificiel (entrées, poids synaptiques et fonction d'activation)

Comme mentionné dans [24], « un signal est propagé à travers le réseau, de l'entrée jusqu'à la sortie. Chaque neurone artificiel effectue un calcul simple sur les données en entrée, puis transmet le résultat aux autres neurones connectés à lui ». Ces calculs sont des combinaisons linéaires suivies d'une non-linéarité (fonction d'activation).

II.3 Modélisation mathématique d'un neurone artificiel

Le neurone artificiel constitue l'unité de base des réseaux de neurones. Inspiré du neurone biologique, il permet de modéliser de manière simplifiée le traitement de l'information sous forme mathématique.

Mathématiquement, un neurone reçoit un vecteur d'entrée : **X= (x1, x2, ..., xn)**

Associé à un vecteur de poids : **W= (w1, w2, ..., wn)**

Le neurone calcule ensuite une combinaison linéaire des entrées, appelée somme pondérée, à laquelle s'ajoute un biais b :

$$z = \sum_{i=1}^{n} w_i x_i + b \quad \text{(II. 1)}$$

Où :

- w_i représente les poids synaptiques
- b désigne le biais du neurone

Cette valeur est ensuite transformée par une fonction d'activation f, afin de produire la sortie du neurone :

$$y = f(z) \quad \text{(II. 2)}$$

Ainsi, le modèle global d'un neurone peut s'écrire sous la forme :

$$y = f(\sum_{i=1}^{n} w_i x_i + b) \quad \text{(II. 3)}$$

Ce modèle simple permet néanmoins de représenter des relations aussi bien linéaires que non linéaires, en fonction du choix de la fonction d'activation. Le biais joue un rôle important, car il permet de décaler la fonction d'activation et d'augmenter la capacité du neurone à modéliser des phénomènes complexes [18].

II.4 Fonctions d'activation

Les fonctions d'activation jouent un rôle essentiel dans les réseaux de neurones, car elles introduisent la non-linéarité nécessaire pour modéliser des phénomènes complexes.

Parmi les fonctions les plus utilisées, on distingue :

A. La fonction sigmoïde :

$$f(z) = \frac{1}{(1 + e^{-z})} \quad \text{(II. 4)}$$

Elle permet de produire des valeurs comprises entre 0 et 1, ce qui la rend adaptée aux problèmes de classification binaire. Toutefois, elle présente un inconvénient lié au phénomène de gradient faible (vanishing gradient), qui peut ralentir l'apprentissage [24].

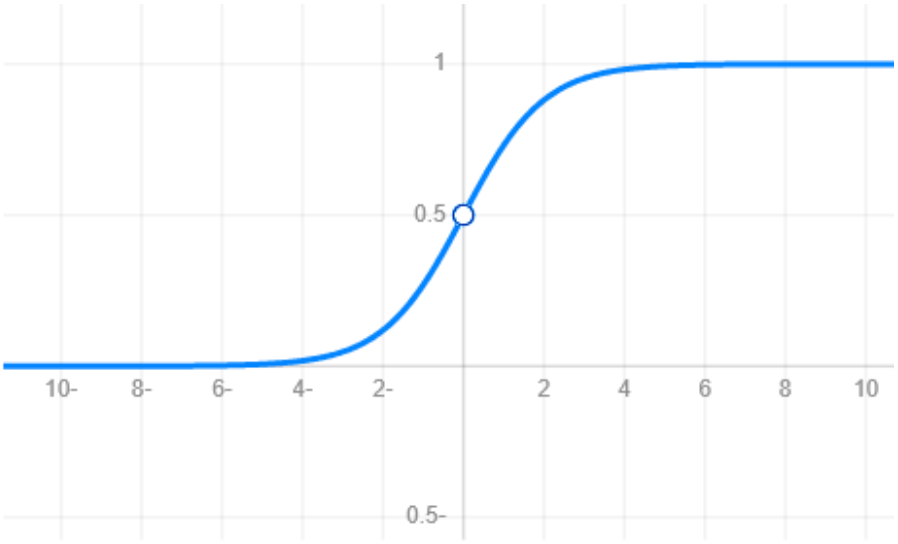


Figure II.3: La fonction d'activation sigmoïde

B. La fonction tangente hyperbolique (tanh) :

$$f(z) = \frac{e^{z}-e^{-z}}{e^{z}+e^{-z}} \qquad (II.5)$$

Cette fonction génère des valeurs comprises entre −1 et 1, ce qui permet une meilleure convergence dans certains cas par rapport à la fonction sigmoïde [18].

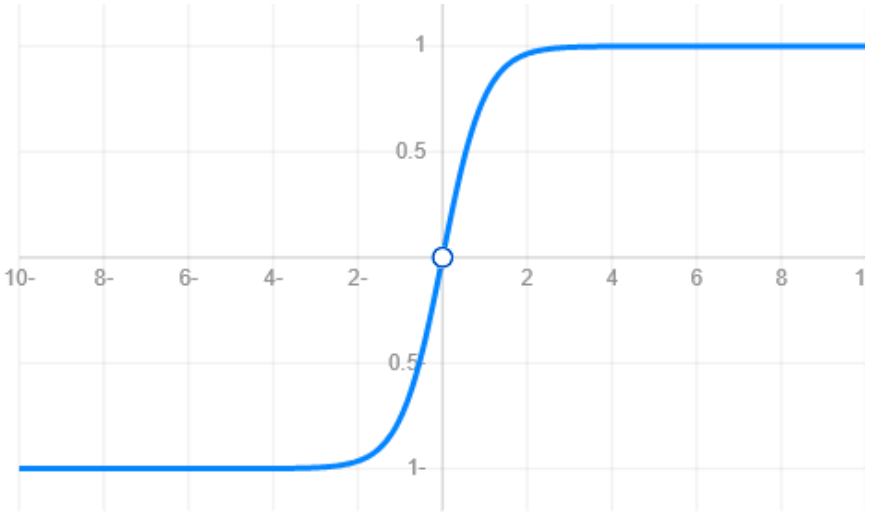


Figure II.4: La fonction d'activation tangente hyperbolique

- Dérivée de la fonction sigmoïde et tangente hyperbolique :

La dérivée de la fonction sigmoïde est donnée par :

$$f'(x) = a(1 - f(x))f(x) \quad (II.6)$$

La dérivée de la fonction tangente hyperbolique est donnée par :

$$f'(x) = a(1 - f(x)^2) \quad (II.7)$$

Ces dérivées sont utilisées dans l'algorithme de rétropropagation afin d'ajuster les poids du réseau de neurones.

C. La fonction ReLU (Unité linéaire rectifiée) :

$$f(z) = \max(0, z) \quad (II.8)$$

Très utilisée dans les réseaux profonds, la fonction ReLU est appréciée pour sa simplicité de calcul et sa capacité à limiter le problème de disparition du gradient.

Le choix de la fonction d'activation dépend fortement du type de problème traité ainsi que de l'architecture du réseau. En pratique, il influence directement la capacité du modèle à apprendre et à représenter des relations non linéaires, ce qui est particulièrement important dans le contexte des systèmes énergétiques complexes tels que les micro-réseaux isolés.

II.5 Types de réseaux de neurones artificiels

II.5.1 Réseaux de neurones multicouches (MLP)

Le perceptron multicouche (MLP – Multi Layer Perceptron) est un réseau de neurones artificiels constitué d'une couche d'entrée, d'une couche de sortie, ainsi que d'une ou plusieurs couches intermédiaires appelées couches cachées.

À titre d'exemple, la figure 5 illustre un réseau comportant n neurones dans la couche d'entrée, mmm neurones dans la couche cachée et r neurones dans la couche de sortie.

Le nombre de couches cachées ainsi que le nombre de neurones par couche varie en fonction de la complexité du problème à résoudre.

Cette architecture est largement utilisée notamment dans l'identification des systèmes et l'approximation des fonctions non linéaires.

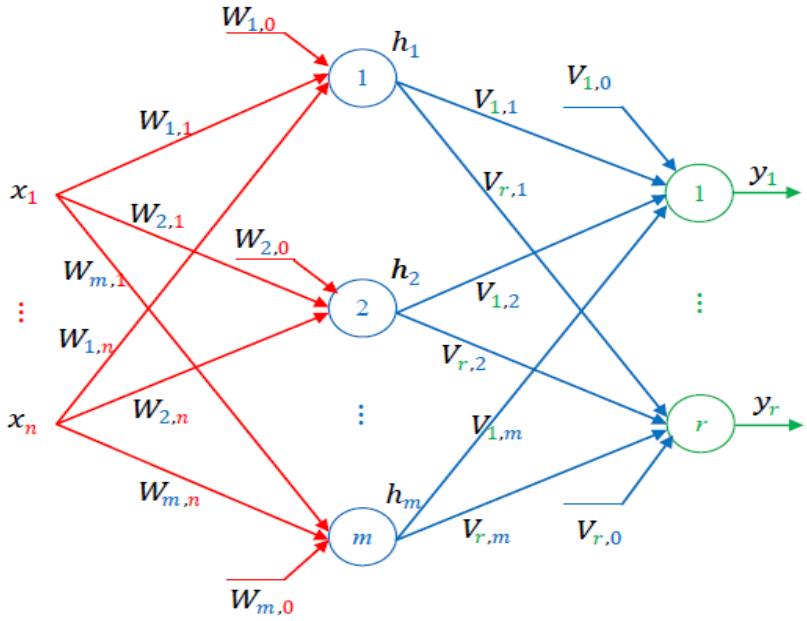


Figure II.5: Architecture d'un réseau neuronal multicouche

L'expression mathématique de la sortie du premier neurone dans la couche cachée est donnée par :

$$h_1 = f\left(W_{1,1}x_1 + W_{1,2}x_2 + \cdots + W_{1,n}x_n + W_{1,0}\right) = f\left(\sum_{i=0}^{n} W_{1,i}\, x_i\right) \quad \text{(II. 9)}$$

L'expression mathématique de la sortie du deuxième neurone dans la couche cachée est donnée par :

$$h_2 = f\left(W_{2,1}x_1 + W_{2,2}x_2 + \cdots + W_{2,n}x_n + W_{2,0}\right) = f\left(\sum_{i=0}^{n} W_{2,i}\, x_i\right) \quad \text{(II. 10)}$$

L'expression mathématique de la sortie du $j^{\text{ème}}$ neurone dans la couche cachée est donnée par :

$$h_m = f\left(W_{m,1}x_1 + W_{m,2}x_2 + \cdots + W_{m,n}x_n + W_{m,0}\right) = f\left(\sum_{i=0}^{n} W_{m,i}\, x_i\right) \quad \text{(II. 11)}$$

Le vecteur de sortie de la couche cachée peut être décrit comme suit :

$$h_J = f\left(\sum_{i=0}^{n} W_{J,i}\, x_i\right) \quad \text{(II. 12)}$$

L'expression de la sortie du premier neurone dans la couche de sortie est donnée par :

$$y_1 = g\left(V_{1,1}h_1 + V_{1,2}h_2 + \cdots + V_{1,m}h_m + V_{1,0}\right) = f\left(\sum_{j=0}^{m} V_{1,j}\, h_j\right) \quad \text{(II. 13)}$$

L'expression de la sortie du deuxième neurone dans la couche de sortie est donnée par :

$$y_2 = g\left(V_{2,1}h_1 + V_{2,2}h_2 + \cdots + V_{2,m}h_m + V_{2,0}\right) = f\left(\sum_{j=0}^{m} V_{2,j}\, h_j\right) \quad \text{(II. 14)}$$

L'expression de la sortie du $k^{ème}$ neurone dans la couche de sortie est donnée par :

$$y_r = g\,(V_{r,1}h_1 + V_{r,2}h_2 + \cdots + V_{r,m}\,h_m + V_{r,0}) = f\,(\sum_{j=0}^{m} V_{r,j}\,h_j) \qquad (\text{II.}15)$$

Le vecteur de sortie du réseau de neurones :

$$y_k = g\left(\sum_{j=0}^{m} V_{k,j}\,h_j\right) = g\,(\sum_{j=0}^{m} V_{k,j}\;f\,(\sum_{i=0}^{n} W_{j,i}\,x_i)) \qquad (\text{II.}16)$$

f : représente la fonction d'activation de la couche cachée.
g : représente la fonction d'activation de la couche de sortie.

Exemple 01 :

Soit le réseau de neurones montré dans la figure suivante, qui possède : trois entrées x_1, x_2, x_3 , deux neurones dans la couche cachée et un neurone dans la couche de sortie.

On donne :

$$\text{x1} = 0.5, \qquad \text{x2} = 0.1, \qquad \text{x3} = 0.4$$

La matrice des poids ainsi que les biais entre la couche d'entrée et la couche cachée sont :

$$W = \begin{pmatrix} W_{1,1} & W_{1,2} & W_{1,3} \\ W_{2;1} & W_{2,2} & W_{2,3} \end{pmatrix} = \begin{pmatrix} 1 & 0.5 & 1{,}5 \\ 2 & 1 & 0{,}5 \end{pmatrix}$$

$$\begin{pmatrix} W_{1.0} \\ W_{2.0} \end{pmatrix} = \begin{pmatrix} 0.2 \\ -0.3 \end{pmatrix}$$

La matrice des poids ainsi que les biais entre la couche cachée et la couche de sortie sont :

$$V = \begin{pmatrix} V_{1,1} & V_{1,2} \end{pmatrix} = (1.5 \quad 2)$$

$$\mathrm{V}_{1,0} = -1$$

La fonction d'activation pour la couche cachée et la couche de sortie est la fonction sigmoïde.

La sortie du premier neurone de la couche cachée :

$$\mathrm{h}_1 = \mathrm{f}(\mathrm{W}_{1,1}\mathrm{x}_1 + \mathrm{W}_{1,2}\mathrm{x}_2 + \mathrm{W}_{1,3}\mathrm{x}_3 + \mathrm{W}_{1,0})$$

$$\mathrm{h}_1 = \mathrm{f}(1 \times 0.5 + 0.5 \times 0.1 + 1.5 \times 0.4 + 0.2)$$

$$\mathrm{h}_1 = \mathrm{f}(1.35) = 0.7941$$

La sortie du deuxième neurone de la couche cachée :

$$h_2 = f(W_{2,1}x_1 + W_{2,2}x_2 + W_{2,3}x_3 + W_{2,0})$$

$$h_2 = f(2 \times 0.5 + 1 \times 0.1 + 0.5 \times 0.4 - 0.3)$$

$$h_2 = f(1) = 0.7311$$

Le vecteur de sortie de la couche cachée :

$$\begin{pmatrix} h_1 \\ h_2 \end{pmatrix} = \begin{pmatrix} 0.7941 \\ 0.7311 \end{pmatrix}$$

La sortie du réseau de neurones :

$$y_1 = g\left(V_{1,1}h_1 + V_{1,2}h_2 + V_{1,0}\right)$$

$$y1 = g(1.5 \times 0.7941 + 2 \times 0.7311 - 1)$$

$$y1 = g(1.6533) = 0.8393$$

II.5.2 Réseaux de neurones récurrents (RNN)

Les réseaux de neurones récurrents (RNN, Recurrent Neural Networks) constituent une classe de réseaux de neurones particulièrement adaptée au traitement des données séquentielles. Contrairement aux réseaux de neurones classiques à propagation directe (feed-forward), les RNN possèdent une mémoire interne permettant de prendre en compte les dépendances temporelles entre les données.

Dans un RNN, la sortie à un instant donné dépend non seulement de l'entrée actuelle, mais également des états précédents du réseau. Cette caractéristique est rendue possible grâce à des connexions récurrentes qui introduisent une boucle dans l'architecture du réseau, comme illustré dans la Figure II.6. Ainsi, l'information est propagée dans le temps, ce qui permet au modèle de mémoriser des informations passées et de les utiliser pour améliorer les prédictions futures.

Mathématiquement, l'état caché d'un RNN à l'instant t peut être défini comme suit :

$$h_t = f(W_h h_{t-1} + W_x x_t + b) \qquad (II.17)$$

Où :

- h_t représente l'état caché à l'instant t,
- x_t est l'entrée à l'instant t,

- W_h et W_x sont les matrices de poids,
- b est le biais,
- f est une fonction d'activation non linéaire.

Grâce à cette structure, les RNN sont particulièrement adaptés à l'analyse des séries temporelles, telles que la prévision de la charge ou de la production énergétique dans les micro-réseaux isolés [18].

Cependant, les RNN classiques présentent certaines limitations, notamment le problème de disparition ou d'explosion du gradient (vanishing/exploding gradient), ce qui rend leur apprentissage difficile sur des séquences longues. Cette limitation a conduit au développement de variantes plus avancées telles que les réseaux LSTM [26].

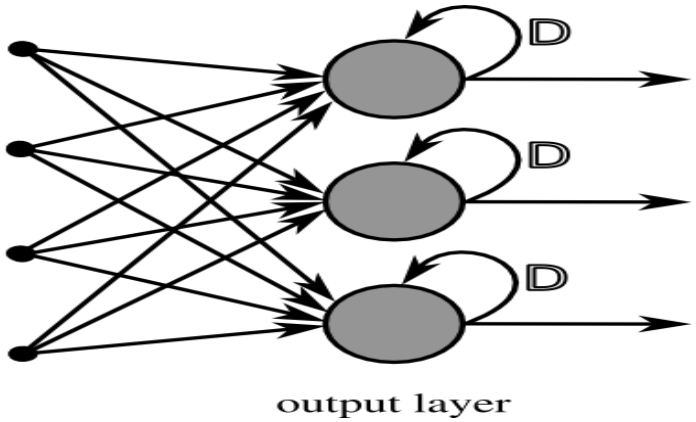


Figure II.6 : Réseau de neurones récurrent (RNN)

Exemple 02 :

Considérons un micro-réseau isolé dans lequel la puissance de charge varie au cours du temps. Les mesures enregistrées pendant plusieurs instants successifs sont données par :

Temps	Puissance de charge
t−2	4kw
t−1	5kw
t	6kw

Le réseau RNN exploite cette évolution temporelle afin de prédire la valeur future de la charge. En observant l'augmentation progressive de la consommation, le réseau peut anticiper la valeur suivante :

$$P_{charge(t+1)} \approx 7kW$$

Dans cet exemple, le réseau ne se contente pas d'analyser une seule valeur isolée, mais prend en compte la succession des états précédents afin d'améliorer la prédiction.

II.5.3 Réseaux LSTM (Long Short-Term Memory)

Les réseaux LSTM (Long Short-Term Memory) constituent une variante avancée des réseaux de neurones récurrents, conçue pour surmonter les limitations liées à la mémorisation à long terme dans les RNN classiques.

Introduits par Hochreiter et Schmidhuber [27], les LSTM intègrent une structure interne composée de plusieurs portes (gates) permettant de contrôler le flux d'information au sein du réseau, comme illustré dans la Figure II.7. Ces portes incluent généralement :

- La porte d'entrée (input gate),
- La porte d'oubli (forget gate),
- La porte de sortie (output gate).

Cette architecture permet au réseau de conserver ou d'oublier certaines informations de manière sélective, ce qui améliore considérablement sa capacité à modéliser des dépendances à long terme dans les données [27].

Le principe fondamental des LSTM repose sur l'introduction d'un état de cellule (cell state), qui agit comme une mémoire interne du réseau et permet le stockage des informations pertinentes sur de longues périodes.

Dans le contexte des micro-réseaux isolés, les LSTM sont particulièrement efficaces pour :

- La prévision de la charge électrique,
- La prédiction de la production des sources renouvelables,
- La modélisation des comportements dynamiques du système énergétique.

En raison de leur capacité à capturer les dépendances temporelles complexes, les LSTM sont largement utilisés dans les systèmes de contrôle avancé, notamment dans le cadre du contrôle tertiaire basé sur l'intelligence artificielle [24].

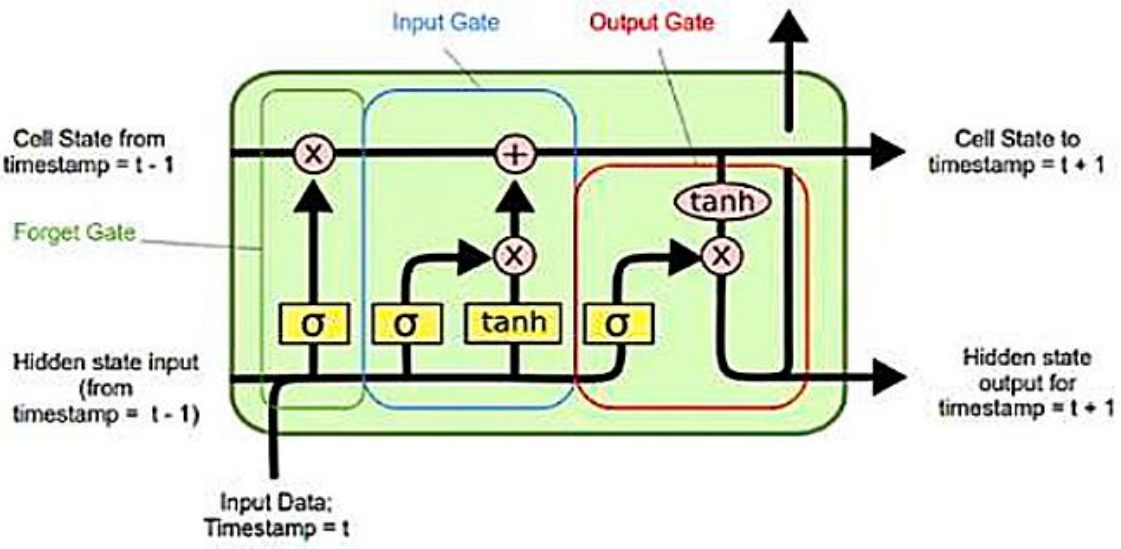


Figure II.7: Architecture de LSTM

II.5.4 Réseaux de neurones à fonctions de base radiale (RBF)

Les réseaux de neurones à fonctions de base radiale (RBF : Radial Basis Function) constituent une catégorie de réseaux de neurones artificiels utilisée dans les problèmes d'approximation, de prédiction et de contrôle des systèmes non linéaires. Un réseau RBF est généralement composé de trois couches : une couche d'entrée, une couche cachée utilisant des fonctions radiales (souvent gaussiennes) et une couche de sortie linéaire.

Contrairement aux réseaux multicouches classiques (MLP), les réseaux RBF réalisent une approximation locale des données, ce qui leur permet de traiter efficacement les systèmes dynamiques complexes [28].

La sortie d'un neurone caché est généralement donnée par la fonction gaussienne suivante :

$$h_j = exp\left(-\frac{\| X - C_{j,i} \|^2}{2b_j^2}\right) \quad \text{(II. 18)}$$

Où X représente le vecteur d'entrée, $C_{j,i}$ le centre du neurone et b_j la largeur de la fonction radiale.

La sortie globale du réseau RBF peut s'écrire :

$$y_k = \sum_{j=1}^{m} V_{k,j} h_j \qquad (II.19)$$

Les réseaux RBF présentent plusieurs avantages, notamment une vitesse d'apprentissage rapide, une structure simple et une bonne capacité de modélisation des phénomènes non linéaires. Pour cette raison, ils sont largement utilisés dans les applications de contrôle intelligent et de gestion énergétique des micro-réseaux isolés.

II.6 Apprentissage des réseaux de neurones

L'apprentissage constitue une étape essentielle dans le fonctionnement des réseaux de neurones artificiels. Il permet d'ajuster les paramètres du modèle, notamment les poids synaptiques et les biais, afin de minimiser l'écart entre les sorties prédites et les sorties réelles. L'objectif principal est donc d'améliorer progressivement les performances du réseau à partir des données disponibles.

II.6.1 Principe d'apprentissage

Le principe d'apprentissage repose sur l'optimisation d'une fonction de coût, qui mesure l'erreur entre la sortie produite par le réseau et la sortie attendue. Le réseau ajuste ses paramètres de manière itérative afin de réduire cette erreur, comme le schéma de la Figure II.8 l'illustre.

Ce mécanisme s'inspire de certaines approches biologiques, notamment la règle de Hebb, selon laquelle la connexion entre deux neurones est renforcée lorsque ceux-ci sont activés simultanément. Dans les réseaux modernes, cet ajustement est automatisé à l'aide d'algorithmes d'optimisation numérique [29].

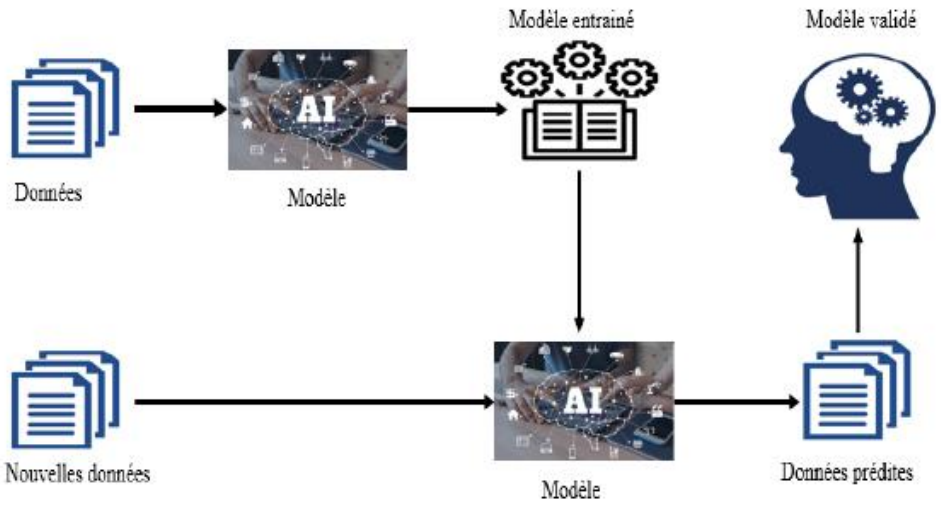


Figure II.8: Apprentissage d'un réseau de neurone artificiel

II.6.2 Types d'apprentissage

Selon la nature des données et la finalité de l'application, on distingue trois principaux types d'apprentissage :

- **Apprentissage supervisé :**
  basé sur des données d'entrée associées à des sorties connues. Le réseau apprend une relation directe entre les entrées et les sorties.
- **Apprentissage non supervisé :**
  basé uniquement sur les données d'entrée, sans étiquettes. Le réseau cherche à identifier des structures ou des regroupements dans les données.
- **Apprentissage par renforcement :**
  basé sur l'interaction avec un environnement. Le modèle apprend à prendre des décisions en fonction d'un système de récompense ou de pénalité [29].

Tableau II.1 Comparaison des Types d'Apprentissage en Intelligence Artificielle [30]

Critère	Apprentissage Supervisé	Apprentissage Non Supervisé	Apprentissage par Renforcement
Données d'entrée	Données étiquetées (entrées et sorties connues)	Données non étiquetées	Interactions avec l'environnement
Objectif	Apprendre à associer les entrées aux sorties correctes	Découvrir des schémas ou des motifs cachés dans les données	Maximiser une récompense cumulative
Exemples d'applications	Détection de spam, reconnaissance de la parole, prévision de séries temporelles	Analyse exploratoire des données, segmentation de clientèle, reconnaissance d'images	Jeux vidéo, robots autonomes, optimisation industrielle
Exemples d'algorithmes	Régression linéaire, réseaux de neurones artificiels, SVM	Algorithmes de clustering (K-means), DBSCAN, ACP (PCA)	Q-learning, Deep Q-Network (DQN), SARSA

II.6.3 Propagation avant

La propagation avant (forward propagation) correspond au passage des données à travers les différentes couches du réseau, depuis l'entrée jusqu'à la sortie.

Pour une couche l, la sortie est calculée selon l'expression suivante :

$$a^{(l)} = f\left(w^{(l)}a^{(l-1)} + b^{(l)}\right) \qquad \text{(II. 20)}$$

Où :

- $a^{(l-1)}$ représente les sorties de la couche précédente,
- $w^{(l)}$ est la matrice des poids,
- $b^{(l)}$ est le vecteur biais,
- f (·) est la fonction d'activation.

Ce processus permet de transformer progressivement les données d'entrée en une sortie finale en appliquant des transformations linéaires suivies de non-linéarités.

II.6.4 Fonction de coût

La fonction de coût permet de quantifier l'erreur entre la sortie prédite et la sortie réelle. Elle constitue la base de l'apprentissage.

Une des fonctions les plus utilisées est l'erreur quadratique moyenne :

$$\mathrm{E} = \frac{1}{2}\sum_{K=1}^{N}(\mathrm{Y_{réel}(k)} - \mathrm{Y_{prédit}(k)})^2 \qquad \text{(II. 21)}$$

L'objectif de l'apprentissage est de minimiser cette fonction afin d'améliorer la précision du modèle. Le choix de la fonction de coût dépend de la nature du problème traité (régression ou classification).

II.6.5 Fonction de coût dans les systèmes dynamiques

Dans les systèmes dynamiques, notamment les micro-réseaux isolés, le comportement du système évolue dans le temps en fonction des variations de la charge, de la production et des conditions environnementales. Pour cette raison, la fonction de coût ne peut pas être définie uniquement à un instant donné, mais doit prendre en compte l'évolution temporelle du système.

Ainsi, la fonction de coût est souvent définie comme une somme des erreurs sur plusieurs instants temporels, ce qui permet au modèle d'apprendre un comportement dynamique :

$$\mathrm{C} = \sum_{t=1}^{T}(\mathrm{v}(t)^* - \mathrm{v(t)})^2 \qquad \text{(II. 22)}$$

Où v^* représente la valeur de référence (ou consigne) et v la valeur obtenue par le système à un instant donné.

L'évolution temporelle de l'erreur e(t) associée à ce processus est présentée dans la Figure II.9.

Cette formulation permet au réseau de neurones d'intégrer l'information temporelle dans le processus d'apprentissage, ce qui améliore sa capacité à modéliser des systèmes dynamiques complexes et à anticiper leur évolution.

Par conséquent, cette approche permet d'améliorer les performances du modèle en termes de prédiction et d'adaptation, en particulier dans des environnements caractérisés par des variations rapides et des incertitudes, tels que les micro-réseaux isolés [31].

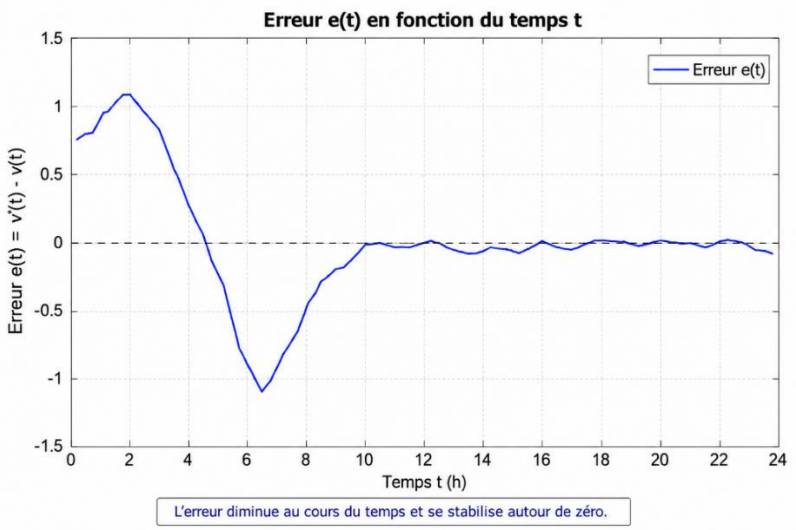


Figure II.9: Variation de l'erreur **e(t)** en fonction du temps **t**

II.6.6 Rétropropagation du gradient

La rétropropagation du gradient (back propagation) est l'algorithme principal utilisé pour entraîner les réseaux de neurones artificiels.

Elle consiste à calculer le gradient de la fonction de coût par rapport aux poids du réseau, en appliquant la règle de la chaîne. Ce gradient indique la direction dans laquelle les poids doivent être ajustés pour réduire l'erreur.

Les poids sont mis à jour selon la règle suivante :

$$w_{ij} = w_{ij} - \eta \frac{\partial E}{\partial w_{ij}} \qquad \text{(II. 23)}$$

Où :

- η est le taux d'apprentissage,
- E est la fonction de coût.

Le processus d'apprentissage se déroule en deux étapes principales :

- Une phase de propagation avant pour calculer la sortie,
- Une phase de propagation arrière pour ajuster les poids.

Ce mécanisme est répété de manière itérative jusqu'à convergence du modèle

II.7 Problématique des micro-réseaux isolés (MGI)

Les micro-réseaux isolés (MGI) représentent une solution efficace pour assurer l'alimentation électrique dans les zones éloignées ou non connectées au réseau principal. Toutefois, leur fonctionnement se caractérise par un ensemble de défis techniques complexes, liés principalement à la nature dynamique, non linéaire et incertaine de ces systèmes énergétiques.

II.7.1 Non-linéarité des systèmes énergétiques

Les MGI sont constitués de plusieurs éléments interconnectés, tels que les sources d'énergie renouvelable, les systèmes de stockage, les convertisseurs de puissance et les charges. Les interactions entre ces composants engendrent un comportement global fortement non linéaire.

En effet, la relation entre les variables d'entrée et de sortie du système ne peut pas être exprimée sous une forme linéaire simple. De manière générale, ce comportement peut être représenté comme suit :

$$y = f(x) \qquad (II.24)$$

Où f est une fonction non linéaire reliant les entrées x (production, charge, conditions climatiques) aux sorties y (tension, fréquence, puissance), Un exemple de ce comportement non linéaire est donné dans la Figure II.10.

Cette non-linéarité est notamment due aux caractéristiques intrinsèques des composants, comme les convertisseurs électroniques et les batteries, dont les modèles mathématiques sont complexes. Par conséquent, les méthodes classiques de modélisation et de contrôle deviennent limitées ou nécessitent des simplifications qui réduisent la précision des Résultats [32].

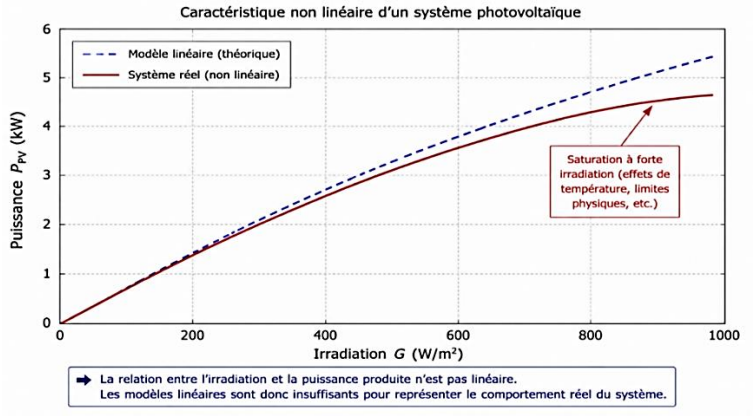


Figure II.10 : Caractéristique non linéaire d'un système photovoltaïque en fonction de l'irradiation solaire.

II.7.2 Incertitudes liées aux énergies renouvelables

L'intégration des énergies renouvelables dans les MGI introduit un niveau élevé d'incertitude. En effet, la production d'énergie solaire et éolienne dépend fortement des conditions météorologiques, qui sont variables et difficilement prévisibles.

Par exemple, la puissance produite par un générateur photovoltaïque dépend de l'irradiation solaire et de la température :

$$P_{PV} = f(G, T) \qquad (II.25)$$

Où G représente l'irradiation solaire et T la température ambiante.

Ces paramètres étant aléatoires, la production d'énergie devient fluctuante, ce qui peut provoquer un déséquilibre entre l'offre et la demande. Cela impacte directement la stabilité du micro-réseau, notamment au niveau de la fréquence et de la tension [33].

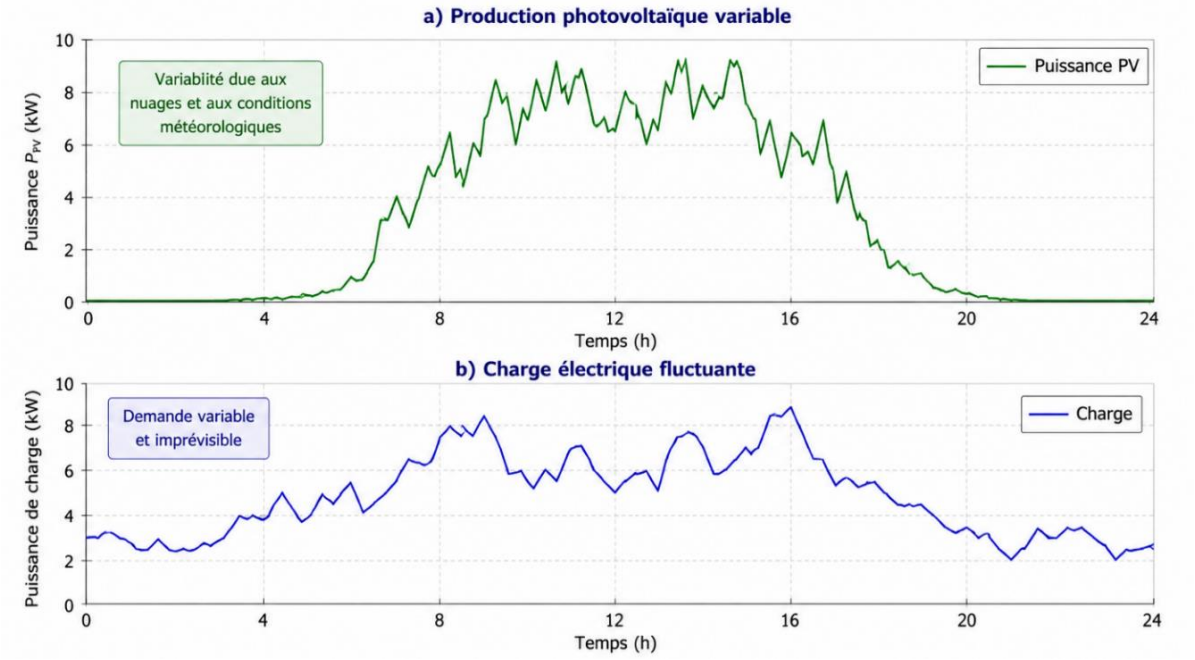


Figure II.11 : Variabilité de la production photovoltaïque et de la charge électrique dans un micro-réseau isolé

II.7.3 Complexité de la gestion énergétique

La gestion énergétique des MGI consiste à assurer un équilibre permanent entre la production et la consommation, tout en optimisant plusieurs objectifs tels que le coût, l'efficacité énergétique et la durée de vie des équipements.

Ce problème peut être formulé de manière générale comme un problème d'optimisation :

$$\min J = f(P_{production}, P_{stockage}, P_{charge}) \quad \text{(II. 26)}$$

Sous contraintes :

$$P_{production} + P_{stockage} = P_{charge} \quad \text{(II. 27)}$$

Cette optimisation est rendue complexe par :

- La variabilité des sources renouvelables ;
- Les contraintes techniques des systèmes ;
- La nature dynamique du réseau.

Ainsi, la gestion des MGI constitue un problème non linéaire, multi-variable et souvent multi-objectif, difficile à résoudre avec des approches classiques [34].

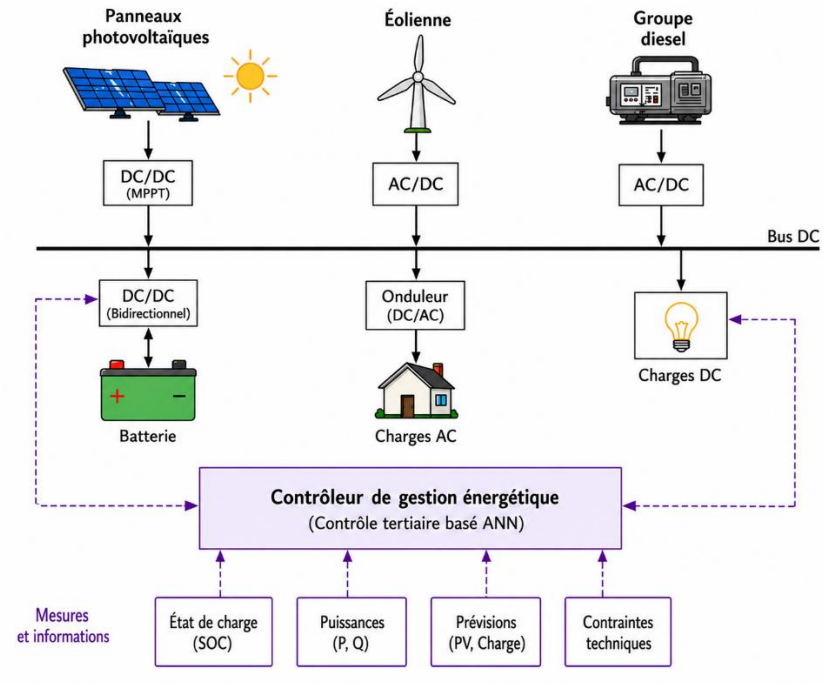


Figure II.12 : Complexité de la gestion énergétique dans un micro-réseau isolé (MGI).

II.8 Applications des RNA dans les micro-réseaux isolés

Les réseaux de neurones artificiels (RNA) ont été largement utilisés dans le domaine des micro-réseaux isolés en raison de leur capacité à modéliser des systèmes complexes, non linéaires et

dynamiques. Ils permettent d'améliorer la prise de décision et d'optimiser la gestion énergétique à différents niveaux.

II.8.1 Prévision de la charge

La prévision de la charge constitue un élément essentiel dans la gestion des micro-réseaux isolés. Elle permet d'anticiper la demande énergétique afin d'assurer un équilibre optimal entre production et consommation.

Les réseaux de neurones artificiels sont capables d'exploiter les données historiques de consommation afin de prédire la charge future avec une bonne précision. Différentes architectures peuvent être utilisées, notamment les réseaux multicouches (MLP), les réseaux récurrents (RNN) ainsi que les réseaux à fonctions de base radiale (RBF). Ces modèles prennent en compte plusieurs variables telles que le temps, la température et les habitudes de consommation.

Grâce à leur capacité d'apprentissage et de généralisation, les RNA permettent d'améliorer la fiabilité des prévisions, ce qui contribue à une meilleure planification énergétique et à une réduction des coûts d'exploitation [24].

II.8.2 Prévision de la production renouvelable

Dans les micro-réseaux isolés, la production d'énergie renouvelable (solaire, éolienne) est fortement dépendante des conditions météorologiques, ce qui introduit une variabilité importante.

Les réseaux de neurones sont largement utilisés pour prédire la production énergétique à partir de variables telles que l'irradiation solaire, la vitesse du vent et la température. Différentes architectures neuronales peuvent être utilisées selon la nature du problème, notamment les réseaux MLP, RBF et les architectures récurrentes comme les LSTM. Ces dernières sont particulièrement adaptées à la modélisation des dépendances temporelles [20,35].

Une prévision précise de la production permet de réduire les incertitudes et d'améliorer la stabilité globale du micro-réseau.

II.8.3 Optimisation énergétique

L'optimisation énergétique vise à minimiser les coûts d'exploitation tout en respectant les contraintes techniques du système.

Les réseaux de neurones peuvent être utilisés pour approximer les fonctions de coût et proposer des stratégies de gestion optimales. Combinés avec des techniques d'optimisation, ils permettent de résoudre des problèmes complexes non linéaires et multi-objectifs.

Dans le cadre du contrôle tertiaire, les RNA jouent un rôle clé dans la prise de décision en temps réel, en tenant compte des prévisions et de l'état du système.

II.8.4 Gestion du stockage

Les systèmes de stockage (batteries) jouent un rôle crucial dans les micro-réseaux isolés en assurant l'équilibre entre production et consommation.

Les réseaux de neurones permettent d'optimiser les stratégies de charge et de décharge en fonction de plusieurs paramètres tels que l'état de charge (SOC), la demande énergétique et la production disponible [36].

Cette approche permet d'améliorer la durée de vie des batteries et d'augmenter l'efficacité globale du système énergétique.

II.8.5 Décision du dispatching

Le dispatching consiste à déterminer la répartition optimale de la puissance entre les différentes sources d'énergie disponibles.

Les réseaux de neurones peuvent être utilisés pour prendre des décisions de dispatching en temps réel en fonction de l'état du système, des prévisions et des contraintes opérationnelles. Ils permettent ainsi d'assurer une gestion efficace et flexible du micro-réseau [37].

Cette capacité est particulièrement importante dans le cadre du contrôle tertiaire, où l'objectif est d'optimiser le fonctionnement global du système.

II.9 Compatibilité des réseaux de neurones avec les MGI

Face aux défis présentés précédemment, les réseaux de neurones artificiels (RNA) apparaissent comme des outils particulièrement adaptés pour la modélisation et la gestion des micro-réseaux isolés. Leur capacité à apprendre à partir des données et à modéliser des relations complexes leur confère un avantage significatif.

II.9.1 Capacité de modélisation des systèmes non linéaires

Les réseaux de neurones sont capables d'approximer des fonctions non linéaires complexes avec une grande précision. Cette propriété est particulièrement utile dans le contexte des MGI, où les relations entre les variables sont difficiles à modéliser analytiquement.

Un neurone artificiel est généralement représenté par :

$$y = f(\sum_{i=1}^{n} w_i x_i + b) \quad \text{(II. 28)}$$

Cette formulation permet de construire des modèles capables d'approximer la fonction réelle du système :

$$\hat{y} = NN(x) \quad \text{(II. 29)}$$

Où NN représente le réseau de neurones.

Ainsi, les RNA offrent une alternative efficace aux modèles classiques pour représenter le comportement des systèmes énergétiques [18].

II.9.2 Adaptation aux systèmes dynamiques

Les MGI sont des systèmes dynamiques dont les conditions évoluent en permanence. Les réseaux de neurones possèdent une capacité d'adaptation grâce à leurs mécanismes d'apprentissage.

À chaque itération, les poids du réseau sont ajustés selon :

$$w_{new} = w_{old} - \eta \frac{\partial E}{\partial w} \quad \text{(II. 30)}$$

Où η est le taux d'apprentissage et E l'erreur.

Cette capacité permet aux RNA de suivre les variations du système et d'améliorer leurs performances en temps réel, ce qui est essentiel pour le contrôle des MGI [38].

II.9.3 Apprentissage à partir des données

Contrairement aux approches classiques, les réseaux de neurones ne nécessitent pas un modèle physique explicite. Ils apprennent directement à partir des données historiques.

Le processus d'apprentissage repose sur la minimisation de l'erreur :

$$E = \frac{1}{2}\sum(y_{réel} - y_{prédit})^2 \quad \text{(II. 31)}$$

Cette approche permet d'extraire des relations complexes entre les variables du système, ce qui améliore la précision des prédictions, notamment pour la production renouvelable et la demande énergétique [39].

II.9.4 Robustesse face aux incertitudes

Les réseaux de neurones sont capables de généraliser à partir des données d'apprentissage, ce qui leur permet de fonctionner efficacement même en présence de bruit ou d'incertitudes.

Dans le contexte des MGI, cette robustesse est essentielle pour faire face aux variations imprévisibles des sources renouvelables et aux erreurs de mesure, Le principe de réduction des fluctuations des données à l'aide d'un réseau de neurones est illustré dans la Figure II.13.

Ainsi, les RNA constituent une solution fiable pour la gestion des systèmes énergétiques dans des environnements incertains et dynamiques [40].

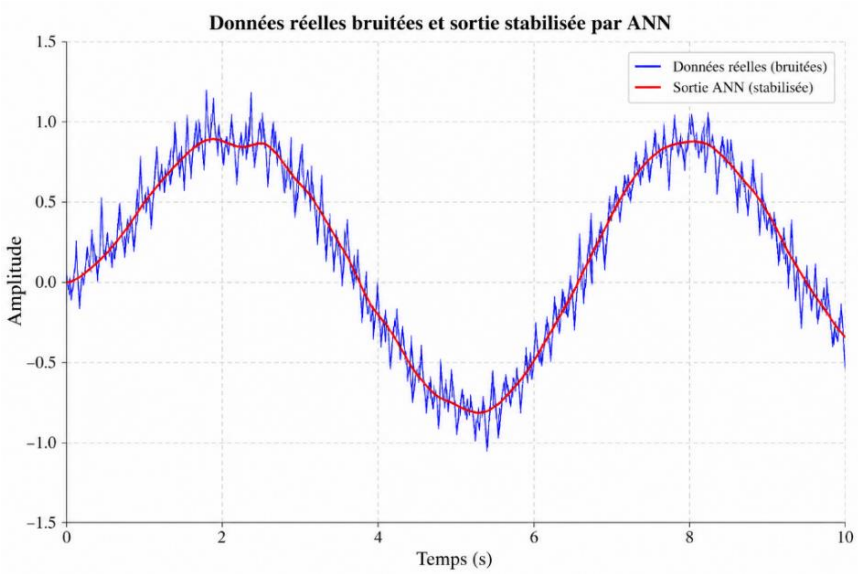


Figure II.13 : Filtrage des fluctuations des données par un réseau de neurones artificiel.

II.10 Avantages et limites des réseaux de neurones

II.10.1 Avantages des réseaux de neurones

Les réseaux de neurones offrent plusieurs avantages qui les rendent particulièrement adaptés à la modélisation et à la gestion des systèmes énergétiques complexes.

Tout d'abord, leur capacité à modéliser des systèmes non linéaires constitue un atout majeur. Contrairement aux méthodes classiques, les RNA peuvent approximer des relations complexes entre les variables d'entrée et de sortie sans nécessiter un modèle mathématique explicite. Cette propriété est particulièrement utile dans les micro-réseaux isolés, où les interactions entre les composants sont difficiles à formaliser [18].

Ensuite, les réseaux de neurones possèdent une grande capacité d'apprentissage à partir des données. En exploitant des données historiques, ils sont capables d'identifier des schémas cachés et d'améliorer progressivement leurs performances. Cette caractéristique est essentielle pour la prévision de la production des énergies renouvelables et de la demande énergétique [38].

Un autre avantage important réside dans leur adaptabilité aux systèmes dynamiques. Les RNA peuvent ajuster leurs paramètres en fonction de l'évolution du système, ce qui leur permet de fonctionner efficacement dans des environnements variables. Cette flexibilité est particulièrement pertinente dans les micro-réseaux isolés, où les conditions de fonctionnement changent en permanence.

Par ailleurs, les réseaux de neurones présentent une certaine robustesse face au bruit et aux incertitudes. Même en présence de données incomplètes ou perturbées, ils peuvent fournir des résultats acceptables grâce à leur capacité de généralisation [39].

Enfin, les RNA peuvent être intégrés dans des stratégies avancées de gestion énergétique, notamment pour améliorer la prise de décision et optimiser les performances globales du système.

II.10.2 Limites des réseaux de neurones

Malgré leurs nombreux avantages, les réseaux de neurones présentent également des limites qu'il est important de considérer.

Tout d'abord, leur performance dépend fortement de la qualité et de la quantité des données disponibles. Un manque de données ou des données mal représentatives peuvent entraîner un

apprentissage incorrect et dégrader les performances du modèle. Cette contrainte constitue un défi dans certaines applications énergétiques où les données sont limitées [40].

Ensuite, le processus d'apprentissage peut être long et nécessite des ressources de calcul importantes, en particulier pour les réseaux de grande taille. Cela peut limiter leur utilisation dans des applications nécessitant des réponses rapides ou des capacités de calcul réduites.

Un autre inconvénient majeur est le caractère « boîte noire » des réseaux de neurones. Contrairement aux modèles analytiques, il est souvent difficile d'interpréter les résultats fournis par un RNA ou de comprendre précisément le rôle de chaque paramètre dans la décision finale. Cela peut poser des problèmes de confiance et de validation dans certains contextes critiques.

De plus, le réglage des paramètres du réseau (nombre de couches, nombre de neurones, taux d'apprentissage, etc.) reste une tâche délicate qui influence fortement les performances du modèle. Ce processus nécessite souvent des essais multiples et une expertise spécifique.

Enfin, bien que les RNA soient robustes, ils ne garantissent pas toujours une solution optimale globale, notamment dans les problèmes d'optimisation complexes, ce qui peut nécessiter leur combinaison avec d'autres méthodes (algorithmes d'optimisation, approches hybrides).

II.11 Conclusion

Au terme de ce chapitre, nous avons présenté les fondements des réseaux de neurones artificiels ainsi que leur fonctionnement mathématique, en mettant en évidence leurs principales caractéristiques. L'étude a également permis d'analyser les problématiques majeures associées aux micro-réseaux isolés, notamment la non-linéarité des systèmes énergétiques, les incertitudes liées aux énergies renouvelables et la complexité de la gestion énergétique.

Face à ces défis, les réseaux de neurones artificiels se distinguent par leur capacité à modéliser des systèmes complexes, à s'adapter aux environnements dynamiques et à apprendre à partir des données. Ces propriétés les rendent particulièrement adaptés aux exigences des micro-réseaux isolés, en offrant une approche flexible et performante pour traiter des problèmes difficilement abordables par les méthodes classiques.

Cependant, malgré leurs nombreux avantages, certaines limites doivent être prises en considération, notamment la dépendance aux données, le coût computationnel et le manque d'interprétabilité. Cela souligne la nécessité d'une utilisation appropriée, voire combinée avec d'autres approches d'optimisation.

Dans ce contexte, l'intégration des réseaux de neurones dans les stratégies de contrôle avancées apparaît comme une solution prometteuse. En particulier, leur application à l'optimisation du contrôle tertiaire des micro-réseaux isolés constitue une voie de recherche pertinente, permettant d'améliorer la gestion énergétique et la performance globale du système.

Ainsi, le chapitre suivant sera consacré à l'étude et à la mise en œuvre d'une approche basée sur les réseaux de neurones pour l'optimisation du contrôle tertiaire dans les micro-réseaux isolés

Chapitre III : Implémentation des réseaux de neurones pour le contrôle tertiaire des micro-réseaux isolés

III.1 Introduction :

Les micro-réseaux isolés représentent une solution efficace pour assurer l'alimentation énergétique dans les zones non raccordées au réseau électrique principal. Toutefois, leur gestion optimale constitue un défi majeur en raison de la variabilité des sources d'énergie renouvelables, de la dynamique des charges et de la complexité du système global.

Dans ce contexte, le contrôle tertiaire joue un rôle essentiel en assurant l'optimisation de la gestion énergétique et la coordination entre les différentes sources d'énergie. Néanmoins, les méthodes classiques de contrôle présentent certaines limitations face aux caractéristiques non linéaires et incertaines des micro-réseaux isolés.

Afin de surmonter ces limitations, les réseaux de neurones artificiels apparaissent comme une solution prometteuse, grâce à leur capacité à modéliser des systèmes complexes et à apprendre à partir des données. Comme présenté dans le chapitre précédent, ces approches offrent des performances intéressantes pour la prédiction, l'optimisation et la prise de décision dans les systèmes énergétiques.

Dans cette perspective, ce chapitre est consacré à l'implémentation des réseaux de neurones dans le cadre du contrôle tertiaire des micro-réseaux isolés. L'objectif principal est de proposer une approche basée sur les RNA permettant d'améliorer la gestion énergétique et d'optimiser la répartition des puissances au sein du système.

Pour ce faire, une modélisation fonctionnelle du système est d'abord présentée, suivie par la conception du contrôleur basé sur les réseaux de neurones. Ensuite, la stratégie de contrôle ainsi que le processus d'apprentissage sont détaillées, avant de présenter une analyse de la méthode proposée.

III.2 Formulation du problème du contrôle tertiaire

Le contrôle tertiaire dans les micro-réseaux isolés vise principalement à assurer une gestion optimale de l'énergie en garantissant l'équilibre entre la production et la consommation, tout en respectant les contraintes opérationnelles du système. Dans ce cadre, le problème peut être formulé comme un problème d'optimisation visant à améliorer les performances globales du micro-réseau.

III.2.1 Objectif d'optimisation énergétique

L'objectif principal du contrôle tertiaire consiste à minimiser une fonction de coût représentant les performances du système. Cette fonction peut intégrer plusieurs critères tels que le coût de production, l'utilisation du stockage ou encore les pertes énergétiques.

De manière générale, le problème peut être exprimé comme suit :

$$\min J = f(Pprod, Pstock, Pcharge) \quad \text{(III. 1)}$$

Où :

- P prod représente la puissance produite,
- P stock la puissance liée au stockage (charge/décharge),
- P charge la puissance demandée par les charges.

Dans une formulation plus simple, l'objectif peut être de minimiser l'écart entre la production et la consommation :

$$J = (Pprod + Pstock - Pcharge)^2 \quad \text{(III. 2)}$$

Cette formulation permet d'assurer l'équilibre énergétique du système, ce qui constitue une condition essentielle pour le bon fonctionnement du micro-réseau isolé.

III.2.2 Contraintes du système

Le problème d'optimisation est soumis à un ensemble de contraintes techniques liées au fonctionnement du micro-réseau. La contrainte principale correspond à l'équilibre instantané entre la production et la consommation :

$$Pprod + Pstock = Pcharge \quad \text{(III. 3)}$$

Par ailleurs, le système de stockage est soumis à des limites physiques, notamment en termes d'état de charge (State of Charge, SOC), qui doit rester dans un intervalle admissible :

$$SOCmin \leq SOC \leq SOCmax \quad \text{(III. 4)}$$

De plus, les puissances générées ou échangées doivent respecter les limites des équipements :

$$Pmin \leq P \leq Pmax \quad \text{(III. 5)}$$

Ces contraintes rendent le problème d'optimisation non linéaire et dépendant du temps, ce qui complique sa résolution à l'aide des méthodes classiques.

Dans ce contexte, l'utilisation des réseaux de neurones artificiels apparaît comme une approche pertinente permettant d'approximer la solution optimale et de faciliter la prise de décision au niveau du contrôle tertiaire.

III.3 Modélisation fonctionnelle du système de contrôle

Dans le cadre de la mise en œuvre d'un contrôle tertiaire basé sur les réseaux de neurones, il est nécessaire de simplifier la représentation du micro-réseau isolé afin de faciliter le processus de décision.

En effet, une modélisation détaillée du système peut devenir complexe et difficile à exploiter dans un contexte de contrôle. Pour cette raison, on adopte une approche fonctionnelle consistant à représenter le système sous forme d'une relation entre des variables d'entrée et des variables de sortie.

Ainsi, le micro-réseau est considéré comme une « boîte noire », dans laquelle les informations disponibles permettent de déterminer les actions de contrôle appropriées. Cette simplification permet notamment d'intégrer plus facilement un modèle basé sur les réseaux de neurones.

III.3.1 Variables d'entrée du système

Les variables d'entrée correspondent aux grandeurs qui décrivent l'état du micro-réseau à un instant donné. Elles constituent les informations nécessaires au contrôleur pour prendre une décision adaptée.

Dans cette étude, trois variables principales ont été retenues :

- La puissance de charge P charge, qui représente la demande énergétique du système ;
- La puissance de production P prod, issue des sources renouvelables ;
- L'état de charge de la batterie (SOC), qui indique le niveau d'énergie disponible dans le système de stockage.

Le choix de ces variables permet de prendre en compte les éléments essentiels du fonctionnement du micro-réseau, à savoir la production, la consommation et le stockage.

III.3.2 Variables de sortie (décision de contrôle)

Les variables de sortie représentent les actions générées par le système de contrôle afin d'assurer un fonctionnement équilibré du micro-réseau.

Dans ce cadre, les sorties considérées sont :

- La puissance de stockage P stock, correspondant à la charge ou à la décharge de la batterie ;
- La puissance de dispatching P dispatch, qui permet de répartir l'énergie entre les différentes sources disponibles.

Ces variables traduisent directement la décision du contrôle tertiaire.

On peut ainsi représenter le fonctionnement global du système par la relation suivante :

$$(\text{Pstock}, \text{Pdispatch}) = \text{f}(\text{Pcharge}, \text{Pprod}, \text{SOC}) \qquad \text{(III. 6)}$$

Où la fonction f (·) sera déterminée à l'aide d'un réseau de neurones artificiels.

Tableau III.1: Variables du système

Type	Variable	Symbole	Description
Entrée	Puissance de charge	Pcharge	Demande énergétique
Entrée	Puissance de production	Pprod	Production renouvelable
Entrée	État de charge	SOC	Niveau de la batterie
Sortie	Puissance de stockage	Pstock	Charge/Décharge
Sortie	Dispatching	Pdispatch	Répartition énergétique

III.4 Conception du contrôleur RNA

Dans cette partie, il s'agit de définir l'architecture du contrôleur basé sur les réseaux de neurones artificiels, ainsi que les principaux choix techniques permettant d'assurer une gestion efficace du micro-réseau isolé au niveau du contrôle tertiaire.

L'objectif est de construire un modèle capable d'apprendre la relation entre les variables d'entrée du système et les actions de contrôle à appliquer. Cette approche permet de remplacer partiellement les méthodes classiques par une stratégie basée sur l'apprentissage à partir des données.

III.4.1 Principe d'intégration des RNA dans le contrôle tertiaire

L'intégration des réseaux de neurones dans le contrôle tertiaire repose sur l'utilisation d'un modèle capable de reproduire le comportement du système à partir des données disponibles.

Concrètement, le réseau de neurones reçoit en entrée les informations relatives à l'état du micro-réseau, telles que la puissance de charge, la production et l'état de charge du stockage. Il fournit en sortie les décisions de contrôle correspondantes.

Cette approche permet d'améliorer la capacité du système à s'adapter aux variations et aux incertitudes, ce qui constitue un avantage important dans le cas des micro-réseaux isolés [29].

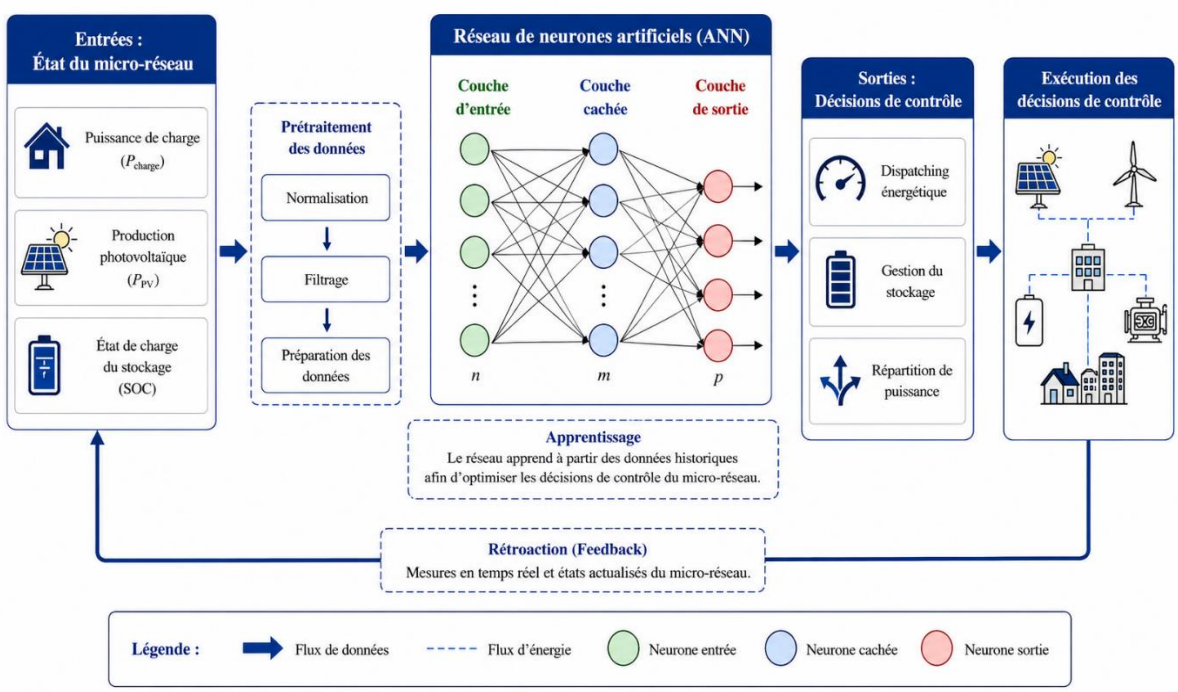


Figure III.1 : Schéma fonctionnel du principe d'intégration des réseaux de neurones artificiels (ANN) dans le contrôle tertiaire d'un micro-réseau isolé

III.4.2 Choix de l'architecture du réseau

Plusieurs architectures de réseaux de neurones artificiels peuvent être utilisées dans les applications de contrôle et de gestion énergétique des micro-réseaux isolés. Parmi les plus connues figurent les réseaux multicouches (MLP), les réseaux récurrents (RNN), les réseaux LSTM ainsi que les réseaux à fonctions de base radiale (RBF).

Les réseaux MLP sont largement utilisés pour l'approximation des fonctions non linéaires et les problèmes de prédiction grâce à leur bonne capacité de généralisation [18]. Les réseaux récurrents et les architectures LSTM sont particulièrement adaptés aux systèmes dynamiques temporels, puisqu'ils permettent de prendre en compte les dépendances temporelles des données [24].

Dans ce travail, le choix s'est porté sur le réseau de neurones à fonctions de base radiale (RBF) pour la conception du contrôleur tertiaire proposé. Ce choix est motivé par plusieurs avantages liés aux caractéristiques des micro-réseaux isolés.

Le réseau RBF présente une structure relativement simple composée d'une couche d'entrée, d'une couche cachée utilisant des fonctions d'activation radiales et d'une couche de sortie linéaire. Contrairement aux réseaux MLP classiques, les réseaux RBF réalisent une approximation locale des données, ce qui améliore leur capacité à représenter efficacement les relations non linéaires du système énergétique [28].

Par ailleurs, les réseaux RBF possèdent une vitesse d'apprentissage élevée ainsi qu'une bonne stabilité numérique, ce qui les rend particulièrement adaptés aux applications de contrôle en temps réel. Leur rapidité de convergence constitue également un avantage important dans le cadre du contrôle tertiaire, où les décisions énergétiques doivent être prises rapidement afin d'assurer l'équilibre entre la production, le stockage et la consommation d'énergie.

Ainsi, le réseau RBF représente une solution pertinente pour la gestion intelligente des micro-réseaux isolés, notamment dans les situations caractérisées par des variations importantes de charge et de production renouvelable.

III.4.3 Régulateur PI

L'expression mathématique d'un régulateur PI (Proportional Integral) est donnée par l'équation suivante :

$$u(k) = u(k-1) + k_p\big(e(k) - e(k-1)\big) + k_i e(k) \qquad (III.6)$$

Où u(k) représente la sortie du régulateur PI (le signal de commande appliqué au système) et e(k) représente l'erreur entre la référence r(k) et la sortie du système y(k).

L'erreur est définie par :

$$e(k+1) = r(k+1) - y(k+1) \quad \text{(III. 7)}$$

Le schéma général du régulateur PI appliqué au micro-réseau isolé est présenté dans la figure suivante.

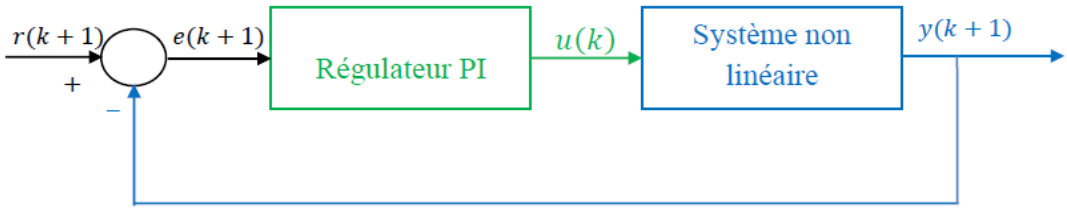


Figure III.3: Schéma général d'un régulateur PI

Les performances du régulateur PI dépendent directement des valeurs des paramètres k_p et k_i. Un choix approprié de ces paramètres permet d'obtenir de bonnes performances du système, tandis qu'un mauvais réglage peut dégrader la qualité de la réponse du contrôle.

Afin d'améliorer les performances du régulateur PI dans le contrôle tertiaire du micro-réseau isolé, les paramètres k_p et k_i. peuvent être ajustés automatiquement à l'aide des réseaux de neurones RBF.

III.4.4 La commande PI adaptative basée sur la technique des réseaux de neurones RBF

L'expression mathématique du régulateur PI adaptatif est donné par l'équation suivante :

$$u(k) = u(k-1) + k_p(k)\big(e(k) - e(k-1)\big) + k_i(k)e(k) \quad \text{(III. 8)}$$

Les paramètres k_p et k_i peuvent être ajustés automatiquement en utilisant la méthode de descente du gradient afin de minimiser la fonction de performance E(k), définie comme la somme de l'erreur quadratique entre la référence r(k) et la sortie du système y(k).

La fonction de performance est donnée par :

$$E(k) = \frac{1}{2}\sum_{k=1}^{N} e^2(k) = \frac{1}{2}\sum_{k=1}^{N}\big(r(k) - y(k)\big)^2 \quad \text{(III. 9)}$$

La mise à jour des paramètres du régulateur PI kp et ki sont ajustés en utilisant la méthode du gradient :

$$k_p(k) = k_p(k-1) + \Delta k_p(k) \quad \text{(III. 10)}$$

$$k_i(k) = k_i(k-1) + \Delta k_i(k) \quad \text{(III. 11)}$$

Avec :

$$\Delta k_p(k) = -\eta \frac{\partial E(k)}{\partial k_p(k)} = -\eta \frac{\partial E(k)}{\partial y(k)} \frac{\partial y(k)}{\partial u(k)} \frac{\partial u(k)}{\partial k_p(k)} \quad \text{(III. 12)}$$

$$\Delta k_p(k) = \eta e(k) \frac{\partial y(k)}{\partial u(k)} \big(e(k) - e(k-1)\big) \quad \text{(III. 13)}$$

Et :

$$\Delta k_i(k) = -\eta \frac{\partial E(k)}{\partial k_i(k)} = -\eta \frac{\partial E(k)}{\partial y(k)} \frac{\partial y(k)}{\partial u(k)} \frac{\partial u(k)}{\partial k_i(k)} \quad \text{(III. 14)}$$

$$\Delta k_i(k) = \eta e(k) \frac{\partial y(k)}{\partial u(k)} e(k) \quad \text{(III. 15)}$$

Où η représente le taux d'apprentissage utilisé dans l'algorithme de descente du gradient.

Dans le cas général, il est difficile de déterminer directement l'expression du terme : $\frac{\partial y(k)}{\partial u(k)}$

En raison du comportement non linéaire du micro-réseau isolé. Cependant, il est bien connu que les réseaux de neurones artificiels possèdent une grande capacité d'approximation des fonctions non linéaires. Ainsi, les réseaux de neurones RBF peuvent être utilisés afin d'approximer le terme : $\frac{\partial y(k)}{\partial u(k)}$ et d'améliorer les performances du régulateur PI adaptatif ainsi que la stabilité du système de contrôle tertiaire du micro-réseau isolé.

III.4.5 Approximation de l'expression $\frac{\partial y(k)}{\partial u(k)}$ par la technique des réseaux de neurones RBF

Le réseau de neurones RBF est utilisé afin d'approximer l'expression de la dérivée de la sortie du système par rapport à son entrée :$\frac{\partial y(k)}{\partial u(k)}$.

Le principe consiste à utiliser un modèle neuronal RBF capable de reproduire le comportement non linéaire du micro-réseau isolé. La figure suivante présente le principe de modélisation du système par les réseaux de neurones RBF.

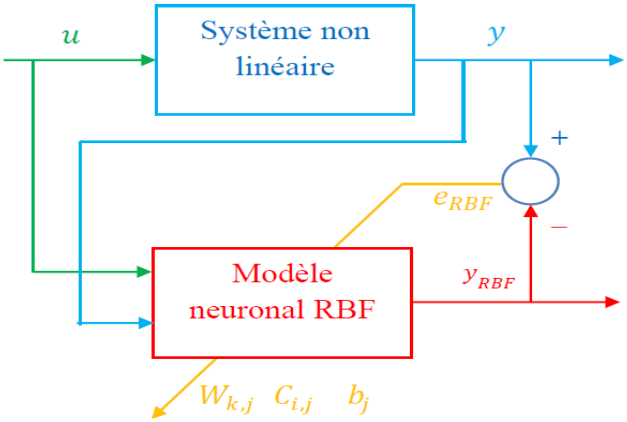


Figure III.4: Modélisation d'un système par la technique des réseaux de neurones

La sortie du réseau RBF est donnée par :

$$y_{RBF} = \sum_{j=1}^{m} W_{1j}\, h_j \qquad \text{(III. 16)}$$

Où :

- W_{1j} représente les poids du réseau ;
- h_j représente la fonction gaussienne du neurone caché ;
- m représente le nombre de neurones de la couche cachée.

La fonction gaussienne utilisée dans le réseau RBF est exprimée par :

$$h_j = \exp\left(-\frac{\|X - C_{i,j}\|^2}{2b_j^2}\right) \qquad \text{(III. 17)}$$

Avec :

- X le vecteur d'entrée ;
- $\boldsymbol{C_{i,j}}$ le centre du neurone ;
- b_j la largeur de la fonction gaussienne.

Ainsi, la dérivée de la sortie du système par rapport à l'entrée peut être approximée par :

$$\frac{\partial y(k)}{\partial u(k)} = \sum_{j=1}^{m} W_{1j}\left(-\frac{\boldsymbol{C_{1j} - u}}{\boldsymbol{b_j^2}}\right) h_j \qquad \text{(III. 18)}$$

La figure suivante montre la structure du régulateur PI adaptatif basé sur les réseaux de neurones RBF.

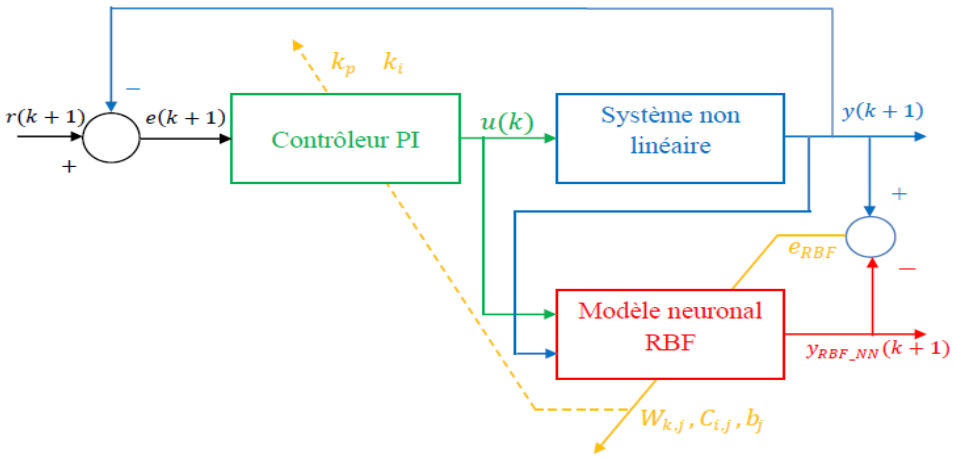


Figure III.5: La commande PI adaptative basée sur la technique des réseaux de neurones RBF

Cette combinaison entre le régulateur PI et les réseaux de neurones RBF permet d'améliorer les performances du système de contrôle tertiaire du micro-réseau isolé, notamment en termes de stabilité, d'adaptabilité et de robustesse face aux perturbations et aux variations des sources d'énergie renouvelables.

III.4.6 Structure du réseau proposé

Le réseau de neurones RBF (Radial Basis Function) est une architecture de réseau neuronal introduite pour résoudre des problèmes d'approximation de fonctions non linéaires, de classification et de commande des systèmes dynamiques. Il est constitué de trois couches : une couche d'entrée, une couche cachée utilisant des fonctions gaussiennes comme fonctions d'activation et une couche de sortie à activation linéaire.

Les réseaux RBF présentent plusieurs avantages, notamment une vitesse d'apprentissage rapide, une structure simple ainsi qu'une bonne capacité d'approximation des systèmes non linéaires

La structure générale du réseau RBF est représentée par la figure correspondante.

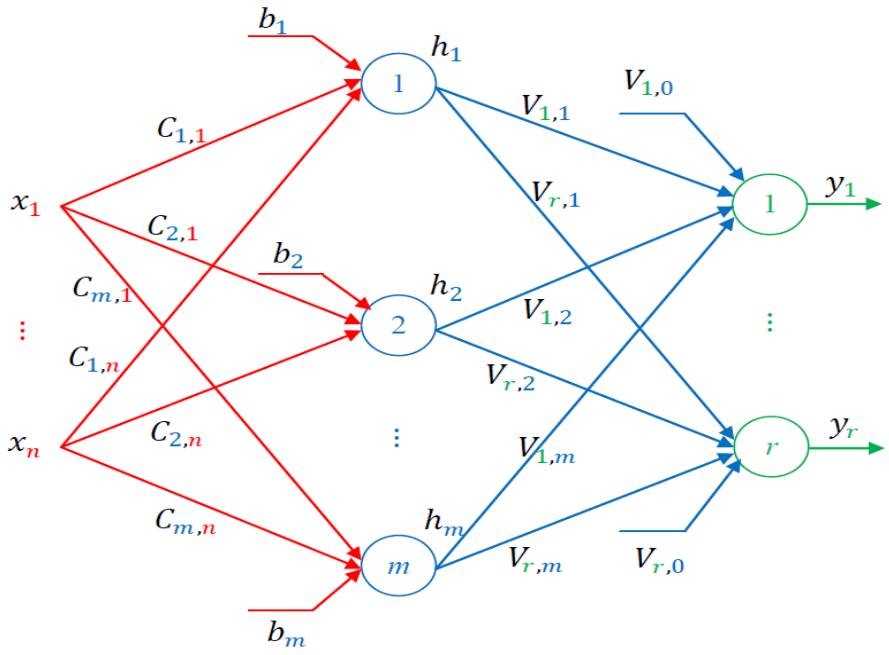


Figure III.6 : Structure d'un réseau de neurones RBF

Le vecteur d'entrée du réseau est défini par : $X = [x_1, x_2, \dots, x_n]^T$

La sortie des neurones cachés, associée au centre $\mathbf{C_{j,i}}$ et au paramètre de largeur b_j, est donnée par :

$$h_j = \exp\left(-\frac{\|X - C_{j,i}\|^2}{2b_j^2}\right) \qquad \text{(III. 19)}$$

Où :

- $\mathbf{C_{j,i}}$ représente le centre de la fonction radiale ;
- b_j désigne le paramètre de largeur de la fonction gaussienne ;
- $\| \mathbf{X} - \mathbf{C_{j,i}} \|$ représente la distance euclidienne entre l'entrée et le centre du neurone.

La sortie du réseau RBF peut être exprimée par :

$$y_k(k) = \sum_{j=1}^{m} V_{kj} h_j = \sum_{j=1}^{m} V_{kj} \exp\left(-\frac{\|X - C_{j,i}\|^2}{2b_j^2}\right) \qquad \text{(III. 20)}$$

Où V_{kj} représente le poids synaptique reliant la couche cachée à la couche de sortie.

Les paramètres du réseau, à savoir les centres $C_{j,i}$, les largeurs b_j et les poids V_{kj}, sont ajustés à l'aide de l'algorithme de descente du gradient afin de minimiser l'erreur quadratique entre la sortie désirée y(k) et la sortie du réseau neuronal $y_{RBF}(k)$.

L'expression de l'erreur quadratique du réseau RBF est donnée par :

$$E_{RBF}(k) = \frac{1}{2}\sum_{k=1}^{r} \left(y(k) - y_{RBF(k)}\right)^2 \quad \text{(III. 21)}$$

Les paramètres du réseau sont mis à jour selon les relations suivantes :

$$C_j(k+1) = C_j(k) + \Delta C_j + \alpha\left(C_j(k) - C_j(k-1)\right) \quad \text{(III. 22)}$$

$$b_j(k+1) = b_j(k) + \Delta b_j + \alpha\left(b_j(k) - b_j(k-1)\right) \quad \text{(III. 23)}$$

Où :

- α est le facteur de momentum ;
- η représente le taux d'apprentissage.

$$V_j(k+1) = V_j(k) + \Delta V_j + \alpha\left(V_j(k) - V_j(k-1)\right) \quad \text{(III. 24)}$$

Les variations des paramètres sont calculées par :

$$\Delta C_j = \eta e_{RBF}(k) V_{kj} h_j \frac{X - Cj}{b_j^2} \quad \text{(III. 25)}$$

$$\Delta b_j = \eta e_{RBF}(k) V_{kj} h_j \frac{\|X - C_j\|^2}{b_j^3} \quad (III. 26)$$

$$\Delta V_{kj} = \eta e_{RBF}(k) h_j \quad \text{(III. 27)}$$

Grâce à cette structure, le réseau RBF offre une bonne précision d'approximation, une convergence rapide et une efficacité importante dans les applications de contrôle intelligent des micro-réseaux isolés.

III.4.7 Définition des entrées et sorties du réseau

Les variables d'entrée et de sortie du réseau de neurones sont définies sur la base de la modélisation fonctionnelle présentée précédemment (section III.3).

Cependant, dans le cadre de l'implémentation du modèle, ces variables doivent être adaptées afin d'être compatibles avec le processus d'apprentissage du réseau de neurones.

Ainsi, les entrées du réseau sont constituées de :

- La puissance de charge P charge,
- La puissance de production P prod,
- L'état de charge du stockage SOC.

Avant leur utilisation, ces données peuvent être normalisées afin d'améliorer la stabilité et la performance de l'apprentissage.

Les sorties du réseau correspondent quant à elles à :

- La puissance de stockage P stock,
- La puissance de dispatching P dispatch.

Ces sorties sont généralement exprimées sous forme de valeurs continues, ce qui permet au réseau de neurones de traiter le problème comme un problème de régression.

Ainsi, le réseau de neurones établit une correspondance entre un vecteur d'entrée et un vecteur de sortie :

$$Y = f(X) \qquad \text{(III. 28)}$$

Avec : X= [P charge, P prod, SOC] Y= [P stock, P dispatch]

III.4.8 Stratégie de décision du contrôleur

La stratégie de décision du contrôleur basé sur les réseaux de neurones repose sur un processus structuré permettant de transformer les informations issues du micro-réseau en actions de commande adaptées. Contrairement aux approches classiques, cette stratégie ne repose pas sur des règles fixes, mais sur un modèle appris capable de s'adapter aux différentes conditions de fonctionnement.

Dans un premier temps, les données décrivant l'état du micro-réseau sont acquises en temps réel. Ces données incluent notamment la puissance de charge, la puissance de production ainsi que l'état de charge du système de stockage. Elles représentent l'ensemble des informations nécessaires à la prise de décision.

Ensuite, ces informations sont introduites dans le réseau de neurones, qui joue le rôle d'un modèle décisionnel. À travers les différentes couches du réseau, les données subissent une série de transformations non linéaires, permettant d'extraire les relations complexes existant entre les variables

d'entrée et les actions de contrôle. Cette phase correspond à la propagation avant, au cours de laquelle le réseau génère une estimation des décisions optimales.

À partir de ce traitement, le contrôleur fournit en sortie les signaux de commande associés au stockage et au dispatching. Ces signaux traduisent directement la stratégie de gestion énergétique adoptée par le système, en tenant compte à la fois de la demande, de la production et de l'état du stockage.

Enfin, les décisions générées sont appliquées au micro-réseau, ce qui permet d'ajuster le fonctionnement global du système. Cette boucle de décision peut être répétée de manière continue, assurant ainsi une adaptation dynamique aux variations du système.

L'un des principaux avantages de cette stratégie réside dans sa capacité à réagir rapidement aux fluctuations, notamment celles liées aux énergies renouvelables. Grâce à son mécanisme d'apprentissage, le réseau de neurones est capable d'anticiper certaines variations et d'améliorer progressivement la qualité des décisions prises, ce qui contribue à optimiser la gestion énergétique du micro-réseau [41].

III.5 Processus d'apprentissage et d'entraînement

Le processus d'apprentissage représente une étape déterminante dans la mise en œuvre du contrôleur basé sur les réseaux de neurones. Il permet au modèle d'établir une relation cohérente entre les variables d'entrée décrivant l'état du micro-réseau et les variables de sortie correspondant aux décisions de contrôle.

Dans ce contexte, l'apprentissage ne consiste pas uniquement à ajuster des paramètres mathématiques, mais à reproduire un comportement de gestion énergétique capable de s'adapter aux différentes conditions de fonctionnement du système. Cette capacité dépend fortement de la qualité des données utilisées, du choix de la fonction de coût et de l'algorithme d'apprentissage adopté.

III.5.1 Préparation des données

La préparation des données constitue une étape essentielle, car elle conditionne directement la qualité de l'apprentissage et la capacité de généralisation du modèle.

Dans cette étude, les données sont organisées sous forme d'un ensemble d'échantillons, chacun représentant un état du micro-réseau. Chaque échantillon est constitué :

- D'un vecteur d'entrée X= [P charge, P prod, SOC],
- D'un vecteur de sortie Y= [P stock, P dispatch].

Afin de garantir la pertinence de l'apprentissage, la base de données doit couvrir un large éventail de situations, notamment :

- Des variations de la charge,
- Des fluctuations de la production renouvelable,
- Différents niveaux de charge du système de stockage.

Une étape importante consiste également à effectuer un prétraitement des données. Celui-ci inclut généralement :

- La normalisation des variables afin de les ramener dans un intervalle homogène,
- L'élimination des valeurs aberrantes,
- Et éventuellement la séparation des données en ensembles d'apprentissage et de validation [18].

La Figure III.7 illustre les principales étapes de préparation et de prétraitement des données avant l'apprentissage du réseau de neurones artificiels

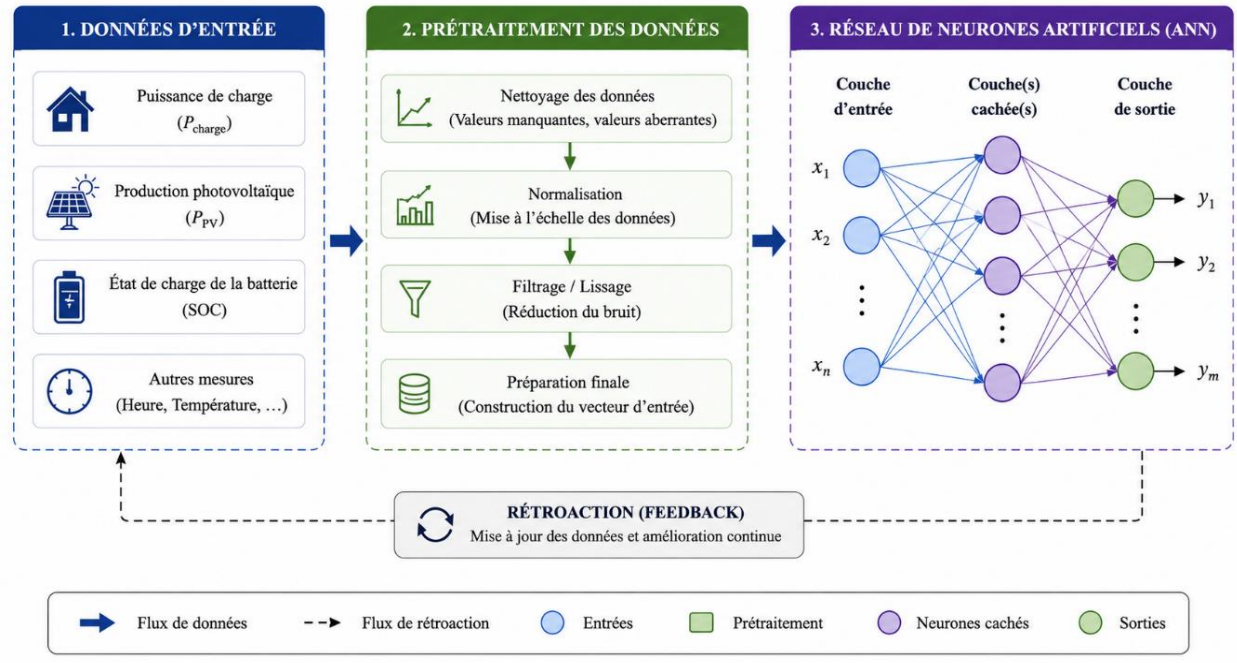


Figure III.7 : Processus de préparation et de prétraitement des données avant l'apprentissage du réseau ANN.

III.5.2 Choix de la fonction de coût

La fonction de coût joue un rôle essentiel dans l'apprentissage du réseau de neurones, puisqu'elle permet de mesurer l'écart entre les sorties calculées par le réseau et les valeurs de référence.

Dans cette étude, le problème traité correspond à une estimation continue des décisions de contrôle énergétique. Pour cette raison, la fonction d'erreur quadratique moyenne (Mean Squared Error – MSE) a été retenue.

La fonction de coût est définie par :

$$E = \frac{1}{2}\sum_{K=1}^{N}(Y_{réel}(k) - Y_{prédit}(k))^2 \quad \text{(III. 29)}$$

Où :

- $Y_{réel}(k)$ représente la valeur de référence,
- $Y_{prédit}(k)$ représente la sortie du réseau,
- N correspond au nombre d'échantillons.

L'erreur associée à chaque échantillon peut également être exprimée par :

$$e(k) = Y_{réel}(k) - Y_{prédit}(k) \quad \text{(III. 30)}$$

Ainsi, la fonction de coût devient :

$$E = \frac{1}{2}\sum_{K=1}^{N} e(k)^2 \quad \text{(III. 31)}$$

L'évolution de cette erreur au cours des différentes itérations d'apprentissage est représentée dans la Figure III.8.

Le choix de la fonction MSE se justifie par plusieurs avantages :

- Elle pénalise fortement les erreurs importantes,
- Elle est continue et dérivable,
- Elle facilite l'application de l'algorithme de rétropropagation du gradient.

Dans le cas des micro-réseaux isolés, cette fonction permet d'évaluer la qualité des décisions produites par le contrôleur neuronal concernant la gestion de l'énergie, le dispatching et le stockage.

Pour les systèmes dynamiques, la fonction de coût peut être évaluée sur plusieurs instants temporels afin de tenir compte de l'évolution du système énergétique et des variations de charge et de production renouvelable.

Ainsi, le choix de la fonction de coût influence directement la précision du modèle neuronal ainsi que la stabilité globale du contrôle tertiaire proposé [18].

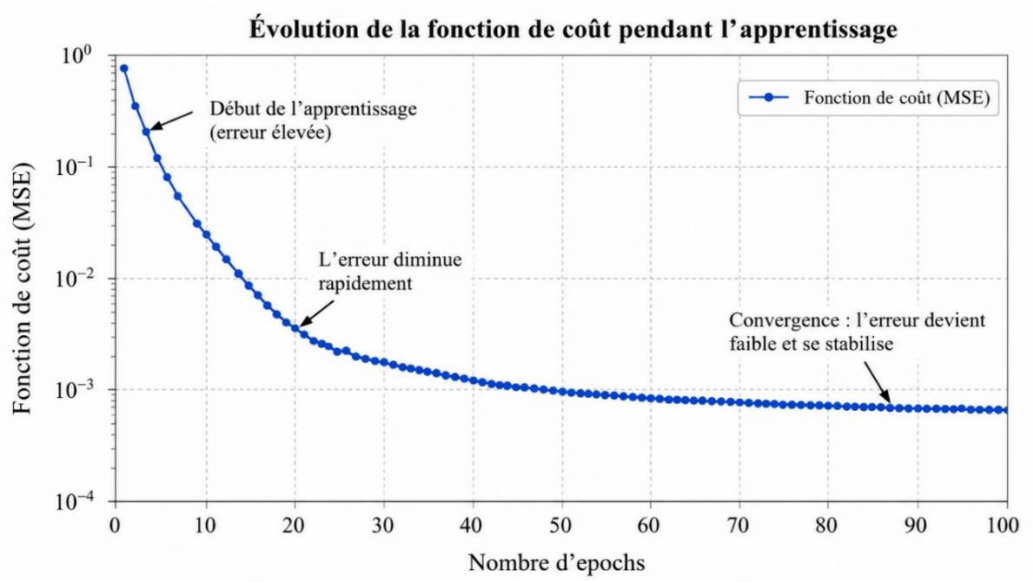


Figure III.8 : Évolution de la fonction de coût (MSE) en fonction du nombre d'epochs durant l'apprentissage du réseau de neurones.

III.5.3 Algorithme d'apprentissage utilisé

Le principe de la rétropropagation du gradient repose sur la minimisation d'une fonction d'erreur représentant l'écart entre les sorties du réseau et les valeurs désirées. Cette méthode permet de propager l'erreur depuis la couche de sortie vers les couches internes du réseau afin d'ajuster progressivement les paramètres du modèle.

Dans un premier temps, l'erreur est calculée au niveau des neurones de sortie à partir de la différence entre la sortie désirée et la sortie obtenue par le réseau de neurones. Pour les neurones des couches cachées, l'erreur ne peut pas être déterminée directement ; elle est alors estimée à partir de la somme pondérée des erreurs propagées depuis la couche suivante. Le mécanisme général de propagation avant et de rétropropagation du gradient est illustré dans la Figure III.9.

La fonction à minimiser est la somme de l'erreur carrée entre la sortie désirée et la sortie du réseau de neurones, son expression s'écrite comme suit :

$$E = \frac{1}{2}\sum_{K=1}^{N}\left(Y_d(k) - Y_{nn}(k)\right)^2 \quad \text{(III. 32)}$$

Où :

- $Y_d(k)$ représente la sortie désirée,
- $Y_{nn}(k)$ représente la sortie du réseau de neurones.

L'ajustement des paramètres du réseau est réalisé selon la méthode de descente du gradient :

$$X(k+1) = X(k) - \eta\frac{\partial E(k)}{\partial X(k)} \quad \text{(III. 33)}$$

Avec :

- η : taux d'apprentissage,
- X : vecteur des paramètres du réseau.

Mise à jour des poids entre la couche cachée et la couche de sortie :

Les poids reliant la couche cachée à la couche de sortie sont ajustés selon :

$$V_{k,j}(k+1) = V_{k,j}(k) + \eta\delta_k h_j \quad \text{(III. 34)}$$

Où :

- $V_{k,j}$ représente le poids entre le neurone caché j et le neurone de sortie k,
- h_j représente la sortie du neurone caché,
- δ_k représente le signal d'erreur de la couche de sortie.

La sortie du réseau est donnée par :

$$y_{nn,k} = g\left(\sum_{j=0}^{m} V_{k,j}h_j\right) \quad \text{(III. 35)}$$

Dans le cas d'une fonction d'activation sigmoïde, le terme d'erreur devient :

$$\delta_k = e_k\left(1 - y_{nn,k}\right)y_{nn,k} \quad \text{(III. 36)}$$

Pour une fonction tangente hyperbolique :

$$\delta_k = e_k\left(1 - y_{nn,k}^2\right) \quad \text{(III. 37)}$$

Mise à jour des poids entre la couche d'entrée et la couche cachée :

Les poids reliant la couche d'entrée à la couche cachée sont ajustés selon :

$$W_{j,i}(k+1) = W_{j,i}(k) + \eta\delta_j x_i \quad \text{(III. 38)}$$

Où :

- $W_{j,i}$ représente le poids entre l'entrée i et le neurone caché j,
- x_i représente l'entrée du réseau,
- δ_j représente l'erreur de la couche cachée.

La sortie du neurone caché est donnée par :

$$h_j = f\left(\sum_{i=0}^{n} w_{j,i}x_i\right) \quad \text{(III. 39)}$$

Dans le cas d'une fonction sigmoïde :

$$\delta_j = (1 - h_j)h_j \sum_{k=1}^{r} \delta_k V_{k,j} \quad \text{(III. 40)}$$

Pour une fonction tangente hyperbolique :

$$\delta_j = \left(1 - h_j^2\right) \sum_{k=1}^{r} \delta_k V_{k,j} \quad \text{(III. 41)}$$

Ainsi, l'algorithme de rétropropagation permet de corriger progressivement les poids synaptiques afin de réduire l'erreur globale du réseau et d'améliorer les performances du contrôleur neuronal utilisé dans le contrôle tertiaire des micro-réseaux isolés [18].

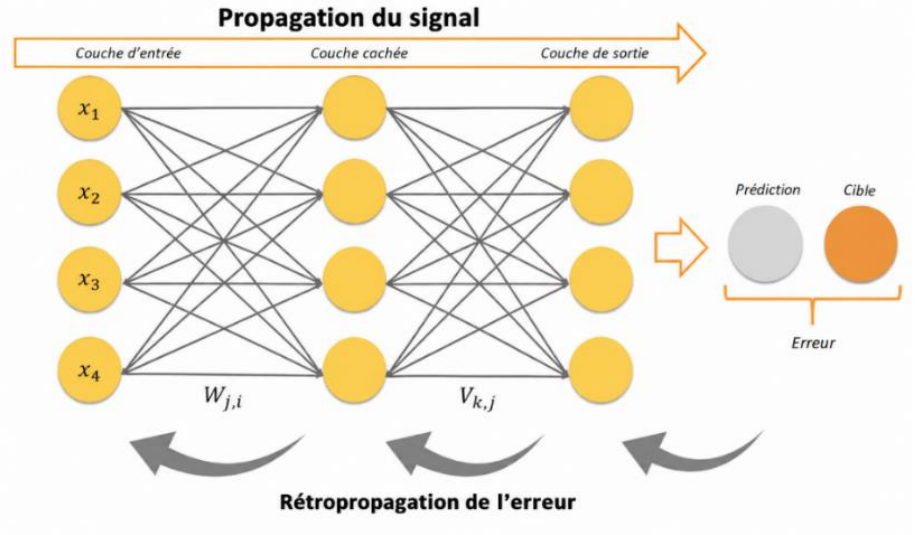


Figure III.9: Schéma de la propagation avant et de la rétropropagation du gradient

Exemple :

Soit le réseau de neurones montré dans la figure précédente qui possède :

- Deux entrées $x_1 et\ x_2$,
- Trois neurones dans la couche cachée,
- Deux neurones dans la couche de sortie.

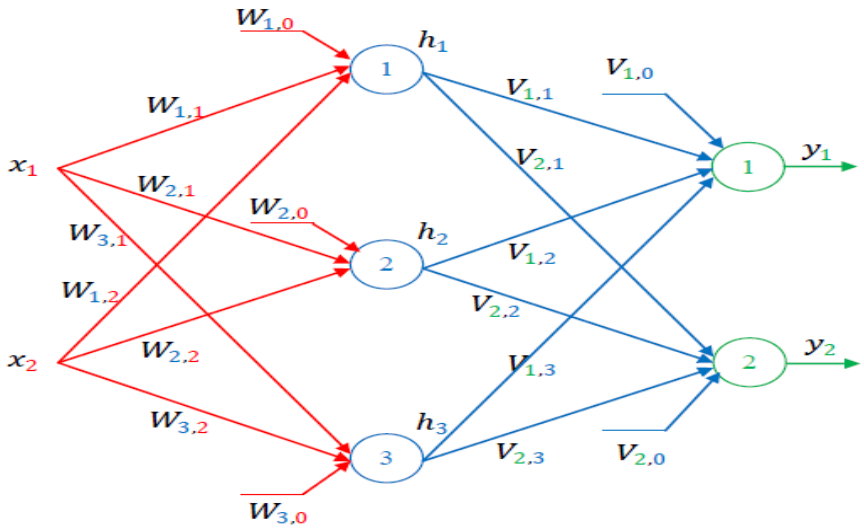


Figure III.10 : Structure d'un réseau de neurones avec trois neurones dans la couche cachée et deux neurones dans la couche de sortie

On donne :

$$x_1 = 0.4 \qquad x_2 = 0.7$$

La matrice des poids ainsi que les biais entre la couche d'entrée et la couche cachée sont :

$$W = \begin{pmatrix} 1 & 2 \\ 2 & 1 \\ 3 & 2 \end{pmatrix} \qquad \begin{pmatrix} W_{1,0} \\ W_{2,0} \\ W_{3,0} \end{pmatrix} = \begin{pmatrix} 1 \\ -1 \\ 2 \end{pmatrix}$$

La matrice des poids ainsi que les biais entre la couche cachée et la couche de sortie sont :

$$V = \begin{pmatrix} 2 & -1 & 3 \\ 1 & 2 & -2 \end{pmatrix} \qquad \begin{pmatrix} V_{1,0} \\ V_{2,0} \end{pmatrix} = \begin{pmatrix} 2 \\ -2 \end{pmatrix}$$

Les fonctions d'activation pour la couche cachée et la couche de sortie sont respectivement la fonction sigmoïde et la fonction linéaire.

On veut que les sorties du réseau de neurones y_1 et y_2 soient égales aux sorties désirées :

$$y_{d1} = 1.5 \quad y_{d2} = 2.5$$

On donne le taux d'apprentissage :

$$\eta=0.4$$

Les sorties y_1 et y_2

Sortie du premier neurone de la couche cachée

$$h_1 = f\left(W_{1,1}x_1 + W_{1,2}x_2 + W_{1,0}\right)$$
$$h_1 = f(1 \times 0.4 + 2 \times 0.7 + 1)$$
$$h_1 = f(2.8)$$
$$h_1 = 0.9427$$

Sortie du deuxième neurone de la couche cachée

$$h_2 = f\left(W_{2,1}x_1 + W_{2,2}x_2 + W_{2,0}\right)$$
$$h_2 = f(2 \times 0.4 + 1 \times 0.7 - 1)$$
$$h_2 = f(0.5)$$
$$h_2 = 0.6225$$

Sortie du troisième neurone de la couche cachée

$$h_3 = f\left(W_{3,1}x_1 + W_{3,2}x_2 + W_{3,0}\right)$$
$$h_2 = f(3 \times 0.4 + 2 \times 0.7 + 2)$$
$$h_2 = f(4.6)$$
$$h_2 = 0.9900$$

Le vecteur de sortie de la couche cachée est :

$$\begin{pmatrix} h_1 \\ h_2 \\ h_3 \end{pmatrix} = \begin{pmatrix} 0.9427 \\ 0.6225 \\ 0.9900 \end{pmatrix}$$

Sortie de la couche de sortie

Première sortie

$$y_1 = g\left(V_{1,1}h_1 + V_{1,2}h_2 + V_{1,3}h_3 + V_{1,0}\right)$$
$$y_1 = g(2 \times 0.9427 - 1 \times 0.6225 + 3 \times 0.9900 + 2)$$
$$y_1 = g(6.2329)$$
$$y_1 = 6.2329$$

Deuxième sortie

$$y_2 = g\left(V_{2,1}h_1 + V_{2,2}h_2 + V_{2,3}h_3 + V_{2,0}\right)$$
$$y_2 = g(1 \times 0.9427 + 2 \times 0.6225 - 2 \times 0.9900 - 2)y$$
$$y_2 = g(-1.7923)$$
$$y_2 = -1.7923$$

Le vecteur de sortie est :

$$\begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = \begin{pmatrix} 6.2329 \\ -1.7923 \end{pmatrix}$$

Mise à jour des poids entre la couche cachée et la couche de sortie

$$V_{k,j}(k+1) = V_{k,j}(k) + \eta \delta_k h_j$$

Avec :

$$\delta_1 = e_1 = (y_{d1} - y_1)$$
$$\delta_1 = 1.5 - 6.2329 = -4.7329$$
$$\delta_2 = e_2 = (y_{d2} - y_2)$$
$$\delta_2 = 2.5 - (-1.7923) = 4.2923$$

Nouveaux poids de la première sortie

$$V_{1,1} = 2 + 0.4 \times (-4.7329) \times 0.9427 = 0.2152$$
$$V_{1,2} = -1 + 0.4 \times (-4.7329) \times 0.6225 = -2.1786$$
$$V_{1,3} = 3 + 0.4 \times (-4.7329) \times 0.9900 = 1.1260$$
$$V_{1,0} = 2 + 0.4 \times (-4.7329) = 0.1068$$

Nouveaux poids de la deuxième sortie

$$V_{2,1} = 1 + 0.4 \times 4.2923 \times 0.9427 = 2.6185$$
$$V_{2,2} = 2 + 0.4 \times 4.2923 \times 0.6225 = 3.0686$$
$$V_{2,3} = -2 + 0.4 \times 4.2923 \times 0.9900 = -0.3001$$
$$V_{2,0} = -2 + 0.4 \times 4.2923 = -0.2831$$

Mise à jour des poids entre la couche d'entrée et la couche cachée

Calcul des erreurs de la couche cachée

$$\delta_1 = (1 - h_1)h_1\left(\delta_1 V_{1,1} + \delta_2 V_{2,1}\right)$$
$$\delta_1 = (1 - 0.9427)(0.9427)\left((-4.7329) \times 0.2152 + 4.2923 \times 2.6185\right)$$
$$\delta_1 = 0.5481$$

$$\delta_2 = (1 - h_2)h_2\left(\delta_1 V_{1,2} + \delta_2 V_{2,2}\right)$$
$$\delta_2 = (1 - 0.6225)(0.6225)\left((-4.7329) \times (-2.1786) + 4.2923 \times 3.0686\right)$$
$$\delta_2 = 5.5112$$

$$\delta_3 = (1 - h_3)h_3\left(\delta_1 V_{1,3} + \delta_2 V_{2,3}\right)$$
$$\delta_3 = (1 - 0.9900)(0.9900)\left((-4.7329) \times 1.1260 + 4.2923 \times (-0.3001)\right)$$
$$\delta_3 = -0.0655$$

Nouveaux poids entre la couche d'entrée et la couche cachée

$$W_{1,1} = 1 + 0.4 \times 0.5481 \times 0.4 = 1.0877$$
$$W_{1,2} = 2 + 0.4 \times 0.5481 \times 0.7 = 2.1535$$
$$W_{1,0} = 1 + 0.4 \times 0.5481 = 1.2192$$

$$W_{2,1} = 2 + 0.4 \times 5.5112 \times 0.4 = 2.8818$$
$$W_{2,2} = 1 + 0.4 \times 5.5112 \times 0.7 = 2.5431$$
$$W_{2,0} = -1 + 0.4 \times 5.5112 = 1.2045$$

$$W_{3,1} = 3 + 0.4 \times (-0.0655) \times 0.4 = 2.9895$$
$$W_{3,2} = 2 + 0.4 \times (-0.0655) \times 0.7 = 1.9817$$
$$W_{3,0} = 2 + 0.4 \times (-0.0655) = 1.9738$$

Donc, les nouveaux poids du réseau sont ajustés afin de réduire progressivement l'erreur entre les sorties prédites et les sorties désirées.

III.6 Algorithme global du contrôle tertiaire basé sur RNA

L'algorithme global du contrôle tertiaire proposé repose sur l'exploitation des données du micro-réseau afin de générer des décisions de gestion énergétique adaptées aux conditions de fonctionnement du système.

Le processus commence par l'acquisition des variables principales du micro-réseau, notamment la puissance produite, la puissance demandée ainsi que l'état de charge de la batterie. Ces données sont ensuite normalisées puis appliquées au réseau de neurones RBF.

Dans la couche cachée, les fonctions radiales permettent d'évaluer la similarité entre les données d'entrée et les centres des neurones. Les activations obtenues sont ensuite combinées dans la couche de sortie afin de produire les décisions de contrôle énergétique. Le principe général de ce fonctionnement est présenté dans la Figure III.11.

Le contrôleur neuronal détermine alors les actions nécessaires pour assurer :

- L'équilibre entre production et consommation,
- La gestion du stockage énergétique,
- Et l'optimisation du dispatching des sources disponibles.

Les paramètres du réseau sont ajustés progressivement au cours de l'apprentissage afin de réduire l'erreur entre les sorties calculées et les valeurs de référence.

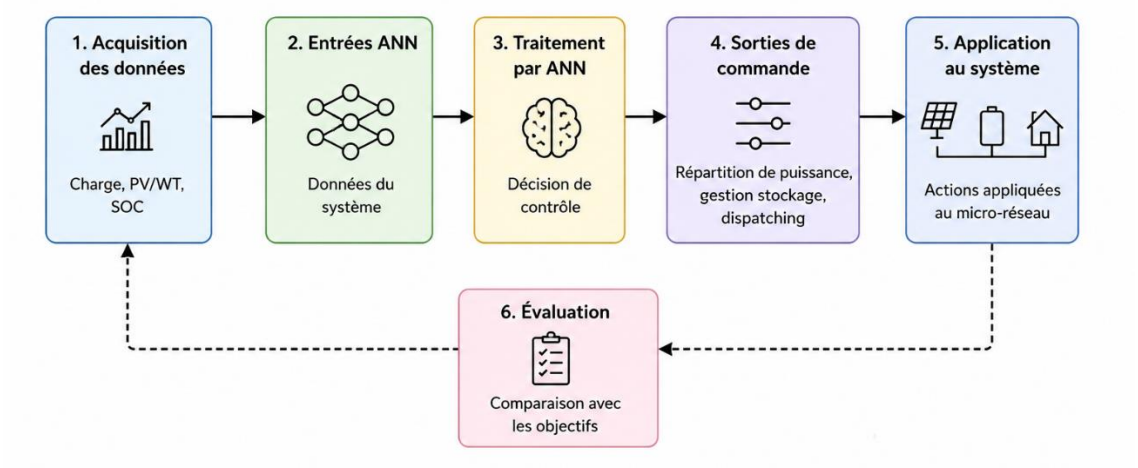


Figure III.11 : Principe de fonctionnement du contrôle tertiaire intelligent basé sur les réseaux de neurones artificiels

III.7 Analyse de la méthode proposée

L'approche proposée repose sur l'utilisation d'un réseau de neurones à fonctions de base radiale (RBF) pour assurer le contrôle tertiaire d'un micro-réseau isolé. Le contrôleur développé exploite les données énergétiques du système afin de générer des décisions adaptées aux différentes conditions de fonctionnement du micro-réseau.

Le principe du contrôle consiste à analyser en temps réel les variables principales du système, notamment la puissance produite, la puissance demandée et l'état de charge de la batterie, puis à déterminer les actions nécessaires pour maintenir l'équilibre énergétique du micro-réseau.

III.7.1 Performances de l'approche proposée

Le réseau RBF possède une capacité importante d'approximation des relations non linéaires entre les variables d'entrée et les variables de sortie du système. Cette propriété permet au contrôleur neuronal de représenter efficacement les comportements dynamiques du micro-réseau isolé.

L'architecture proposée permet également de traiter simultanément plusieurs paramètres énergétiques du système. Le contrôleur peut ainsi adapter les décisions de stockage et de dispatching en fonction des variations de la charge et de la production renouvelable.

La structure locale des fonctions radiales améliore la rapidité de réponse du réseau face aux variations du système énergétique. Après la phase d'apprentissage, le contrôleur génère rapidement les consignes nécessaires à la gestion énergétique du micro-réseau.

La rapidité de convergence du réseau RBF constitue également un avantage important pour les applications de contrôle en temps réel. Le temps de calcul reste relativement faible après l'apprentissage, ce qui facilite l'intégration du contrôleur dans un environnement dynamique.

L'approche proposée améliore aussi la stabilité énergétique du micro-réseau en assurant une meilleure coordination entre la production, le stockage et la consommation d'énergie. Le contrôleur contribue ainsi à réduire les déséquilibres de puissance et à optimiser l'exploitation des ressources disponibles.

Le réseau RBF présente enfin l'avantage de ne pas nécessiter un modèle mathématique détaillé du micro-réseau. Le comportement du système est appris directement à partir des données utilisées durant la phase d'apprentissage.

III.7.2 Contraintes et limites de l'implémentation

Les performances du réseau RBF dépendent fortement de la qualité des données utilisées pendant l'apprentissage. Une base de données insuffisante ou peu représentative peut réduire la capacité du réseau à généraliser correctement le comportement du micro-réseau.

Le choix des paramètres du réseau influence également les performances globales du contrôleur. Le nombre de neurones cachés, les centres des fonctions radiales ainsi que les largeurs des fonctions gaussiennes doivent être correctement ajustés afin d'obtenir une configuration efficace.

La phase d'apprentissage peut nécessiter un temps de calcul relativement important selon la taille du réseau et la quantité de données utilisées. Cette étape reste particulièrement sensible lors du réglage des paramètres du modèle.

Le fonctionnement interne du réseau demeure également difficile à interpréter de manière analytique. Comme pour plusieurs approches basées sur les réseaux de neurones, il reste complexe d'expliquer précisément l'influence de chaque paramètre sur les décisions générées par le contrôleur.

Les performances du réseau peuvent enfin diminuer lorsque le système rencontre des situations très différentes de celles utilisées durant l'apprentissage. Dans ce cas, une nouvelle phase d'entraînement peut être nécessaire afin d'améliorer la précision des décisions de contrôle.

III.8 Conclusion

Dans ce chapitre, une méthode de contrôle tertiaire basée sur les réseaux de neurones artificiels a été développée pour la gestion énergétique des micro-réseaux isolés. L'étude a permis de définir les différentes étapes de conception du contrôleur neuronal, depuis la formulation du problème jusqu'à l'élaboration de l'algorithme global de contrôle.

L'architecture du réseau RBF adoptée dans ce travail a été présentée ainsi que le choix des variables d'entrée et de sortie utilisées pour la prise de décision énergétique. Le processus d'apprentissage du réseau, fondé sur la minimisation de l'erreur et l'ajustement des paramètres du modèle, a également été étudié afin d'assurer des performances de contrôle adaptées aux conditions de fonctionnement du micro-réseau.

L'analyse de la méthode proposée a montré que l'utilisation des réseaux de neurones permet de traiter efficacement les comportements non linéaires et les variations dynamiques caractérisant les micro-réseaux isolés. Cette approche contribue à améliorer la gestion du stockage, la répartition de puissance et l'équilibre énergétique global du système.

Malgré certaines contraintes liées à la qualité des données et au paramétrage du réseau, le contrôleur neuronal proposé constitue une solution flexible et performante pour le contrôle tertiaire des micro-réseaux isolés.

Chapitre IV : Simulation et commande adaptative du contrôle tertiaire d'un micro-réseau isolé basée sur les réseaux de neurones RBF

IV.1 Introduction

Dans les micro-réseaux isolés, le contrôle tertiaire joue un rôle essentiel dans la gestion optimale de l'énergie ainsi que dans la coordination entre les différentes sources de production et de stockage. Toutefois, l'intégration des énergies renouvelables, notamment les systèmes photovoltaïques et éoliens, introduit des comportements non linéaires et des variations dynamiques qui limitent les performances des méthodes classiques de commande.

Afin d'améliorer les performances du système, les techniques intelligentes basées sur les réseaux de neurones artificiels représentent une solution efficace grâce à leurs capacités d'apprentissage et d'adaptation aux systèmes dynamiques. Parmi ces techniques, les réseaux de neurones à fonctions de base radiale (RBF) sont largement utilisés pour l'approximation des systèmes non linéaires et l'amélioration des stratégies de commande adaptative.

Dans ce chapitre, une commande adaptative du contrôle tertiaire basée sur les réseaux de neurones RBF est appliquée à un micro-réseau isolé sous l'environnement MATLAB/Simulink. Une comparaison entre un régulateur PI classique et une commande adaptative RBF-PI sera réalisée afin d'évaluer les performances du système en termes de stabilité, de rapidité de réponse et de robustesse face aux perturbations.

IV.2 Présentation du micro-réseau étudié

Le micro-réseau étudié dans ce travail a été développé sous MATLAB/Simulink afin d'évaluer les performances du contrôle tertiaire proposé. Le système est constitué de plusieurs sources d'énergie renouvelable connectées à un bus commun PCC, d'un système de stockage, d'une charge électrique triphasée ainsi que de convertisseurs électroniques assurant l'interface entre les différentes unités du micro-réseau.

La production énergétique est assurée par un générateur photovoltaïque (PV) d'une puissance de 500 kW et une génératrice éolienne de 300 kW. Le micro-réseau intègre également un système de stockage par batteries de 200 kW permettant d'améliorer l'équilibre énergétique du système.

Les convertisseurs électroniques jouent un rôle important dans le contrôle des échanges de puissance active et réactive ainsi que dans la régulation des tensions du micro-réseau.

Le modèle réalisé sous Simulink permet d'étudier le comportement dynamique du système et d'analyser les performances des stratégies de contrôle appliquées dans différentes conditions de fonctionnement.

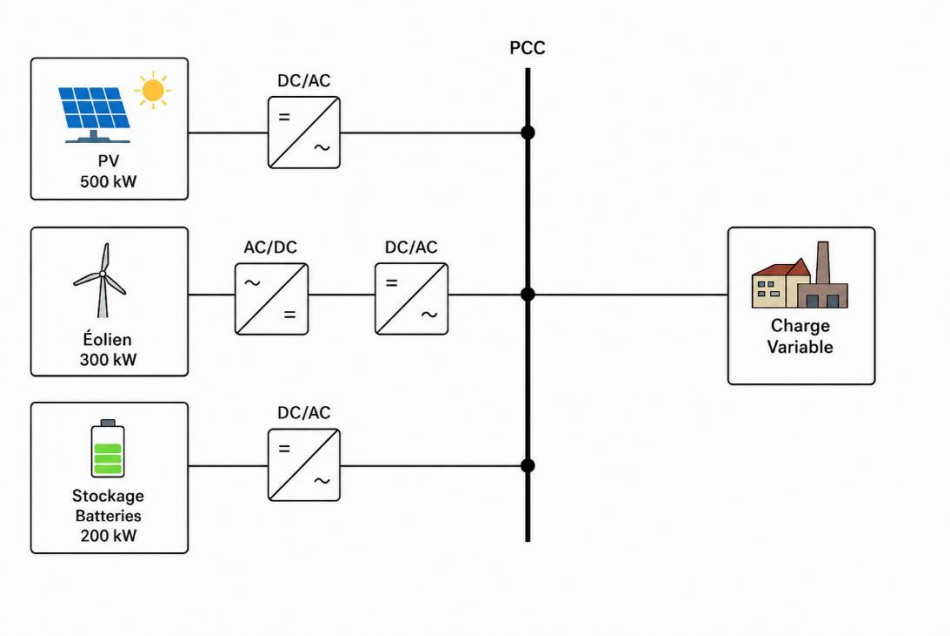


Figure IV. 1 : Structure de Micro-réseau

IV.3 Modélisation du micro-réseau sous MATLAB/Simulink

Afin d'évaluer les performances du contrôleur proposé, un modèle du micro-réseau isolé a été développé sous l'environnement MATLAB/Simulink. Cette modélisation permet de représenter le comportement dynamique des différentes unités du système ainsi que leurs interactions avec la stratégie de contrôle appliquée.

Le micro-réseau étudié comprend un générateur photovoltaïque, une génératrice éolienne, un système de stockage par batteries, des convertisseurs électroniques ainsi qu'une charge électrique connectée au bus AC principal.

L'objectif principal de cette modélisation est d'assurer l'équilibre entre la production et la consommation d'énergie tout en maintenant la stabilité du système face aux variations de charge et aux perturbations de fonctionnement.

L'environnement Simulink permet également d'analyser les échanges de puissance active et réactive, le comportement des tensions du système ainsi que les performances dynamiques des différentes stratégies de contrôle utilisées dans cette étude.

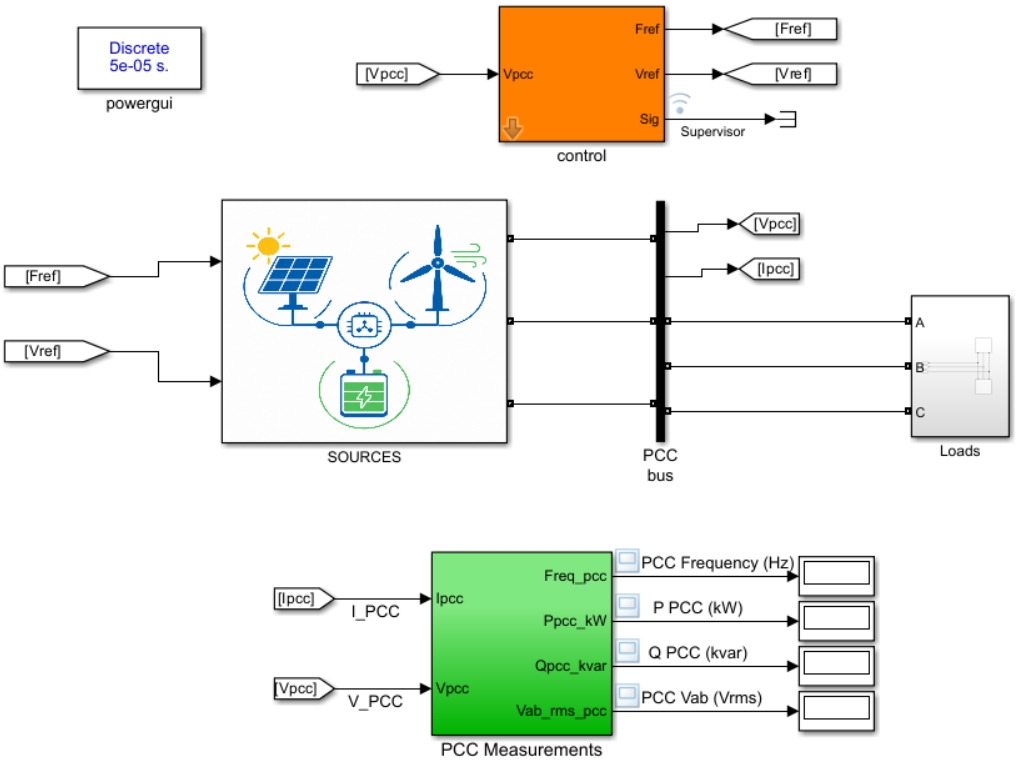


Figure IV.2 : Modèle du micro-réseau isolé développé sous MATLAB/Simulink

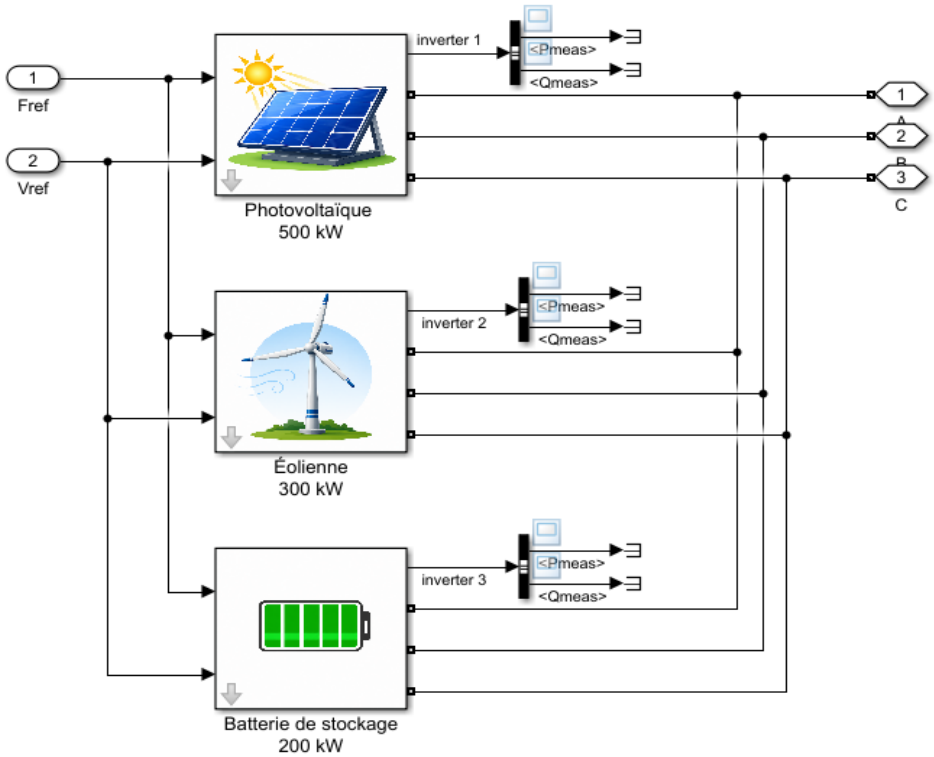


Figure IV.3 : Regroupement des sources d'énergie du micro-réseau (PV, éolienne et batterie)

IV.4 Implémentation du contrôle classique PI

Afin d'évaluer les performances de la stratégie de contrôle proposée, un régulateur classique de type PI a été implémenté sous l'environnement MATLAB/Simulink. Cette commande constitue une méthode de référence permettant d'analyser le comportement du micro-réseau avant l'intégration du contrôleur intelligent basé sur les réseaux de neurones RBF.

Le contrôle PI est largement utilisé dans les systèmes de commande des micro-réseaux grâce à sa simplicité de mise en œuvre et à sa capacité à assurer une réponse dynamique acceptable dans différentes conditions de fonctionnement.

IV.4.1 Structure du contrôleur PI

Le contrôleur utilisé dans cette étude est un régulateur PI implémenté dans les boucles de régulation de tension et de courant du micro-réseau. La structure du régulateur repose principalement sur deux actions fondamentales : l'action proportionnelle Kp et l'action intégrale Ki.

L'action proportionnelle permet d'améliorer la rapidité de réponse du système en réagissant instantanément à l'erreur, tandis que l'action intégrale assure l'élimination de l'erreur statique afin d'améliorer la précision du contrôle.

Le régulateur reçoit comme entrée l'erreur entre la valeur de référence et la valeur mesurée, puis génère un signal de commande appliqué aux convertisseurs électroniques du micro-réseau.

Dans le modèle Simulink, les régulateurs PI sont implémentés dans les blocs régulateurs de tension (voltage regulators) et régulateurs de courant (current regulators) afin d'assurer le contrôle des tensions Vd et Vq, ainsi que le suivi des courants de référence du système.

IV.4.2 Paramétrage du régulateur PI

Les paramètres du régulateur PI ont été réglés sous l'environnement MATLAB/Simulink afin d'assurer une réponse stable et rapide du micro-réseau étudié. Le choix des gains proportionnel Kp et intégral Ki influence directement les performances dynamiques du système, notamment la rapidité de réponse, la stabilité et la réduction de l'erreur de suivi.

Les paramètres des régulateurs de tension et de courant ont été ajustés de manière à garantir un bon suivi des valeurs de référence ainsi qu'une gestion efficace des échanges de puissance dans le micro-réseau isolé.

Tableau IV.1 : Paramètres des régulateurs PI du micro-réseau étudié

Paramètre	PI-(Vd)	PI-(Vq)	PI-(IdIq)
Gain proportionnel (Kp)	2	2	0.3
Gain intégral (Ki)	14	14	20
Limites de sortie [Supérieure ; Inférieure]	[1.25 ; -1.25]	[1.25 ; -1.25]	[1.25 ; -1.25]
Temps d'échantillonnage (Ts)	5e-05	5e-05	5e-05

IV.4.3 Intégration du PI dans le système de contrôle

Dans le modèle Simulink du micro-réseau étudié, les régulateurs PI sont intégrés dans les boucles de commande des convertisseurs électroniques afin d'assurer la régulation des tensions et le contrôle des courants du système. Les contrôleurs sont implémentés au niveau des blocs régulateurs de tension (voltage regulators) et régulateurs de courant (current regulators) associés aux différents onduleurs du micro-réseau.

Les régulateurs de tension permettent de générer les courants de référence à partir des erreurs entre les tensions mesurées et les tensions de référence ($V_d ref, V_q ref$) Ces références sont ensuite utilisées par les régulateurs de courant afin d'assurer le suivi des courants et la commande des convertisseurs électroniques.

Cette structure de commande permet d'améliorer la stabilité du micro-réseau ainsi que le contrôle des échanges de puissance active et réactive entre les différentes unités du système. Elle contribue également à assurer une gestion énergétique stable face aux variations de charge et aux perturbations de fonctionnement.

IV.4.4 Performances du micro-réseau sous contrôle PI

Dans le système étudié, les trois onduleurs utilisent la même structure de commande PI et fonctionnent sous des conditions similaires. Par conséquent, les résultats de simulation obtenus présentent des comportements presque identiques pour les différents onduleurs. Ainsi, les figures suivantes illustrent principalement la réponse globale du micro-réseau sous contrôle PI.

- **Analyse des tensions et courants de réseau triphasé**

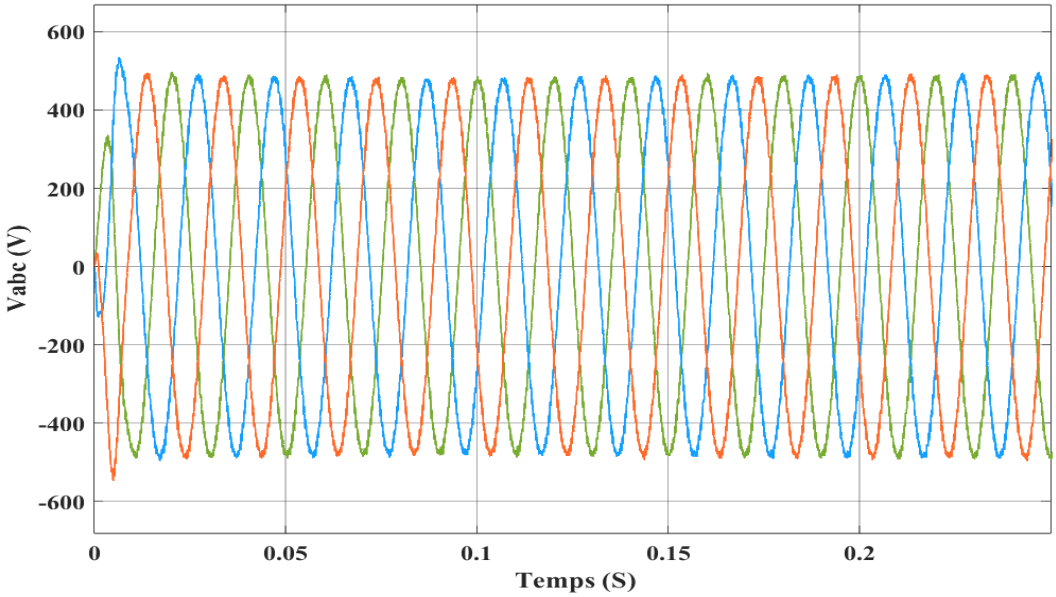


Figure IV.4 : Formes d'onde des tensions triphasées Vabc

Les tensions triphasées présentent des formes sinusoïdales équilibrées avec une amplitude stable après le régime transitoire. Cela montre que le contrôleur PI assure une régulation correcte de la tension et un fonctionnement stable du micro-réseau.

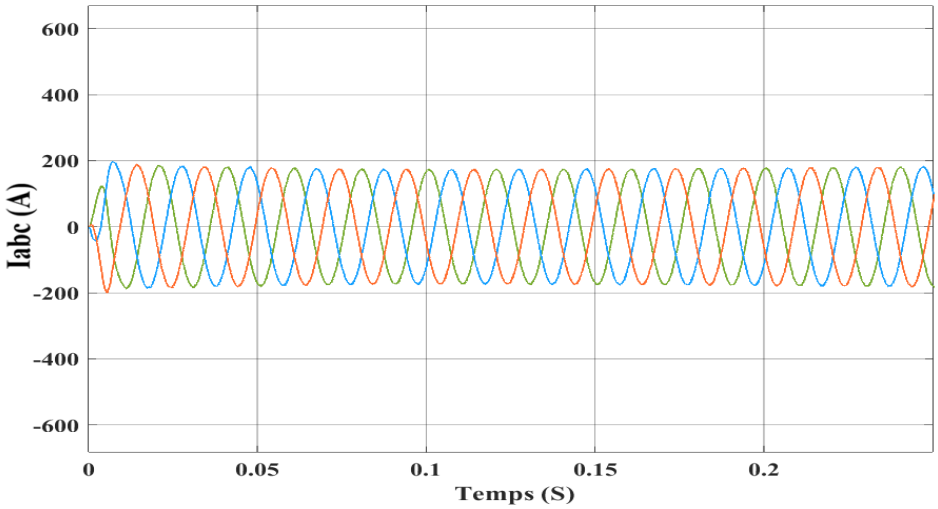


Figure IV.5 : Formes d'onde des courants triphasés Iabc

Les courants triphasés présentent des formes sinusoïdales équilibrées avec un déphasage de 120° entre les phases. Après une courte phase transitoire, les amplitudes deviennent stables, ce qui montre l'efficacité du contrôleur PI dans la régulation du courant et la stabilité du micro-réseau isolé.

- **Analyse des puissances active et réactive**

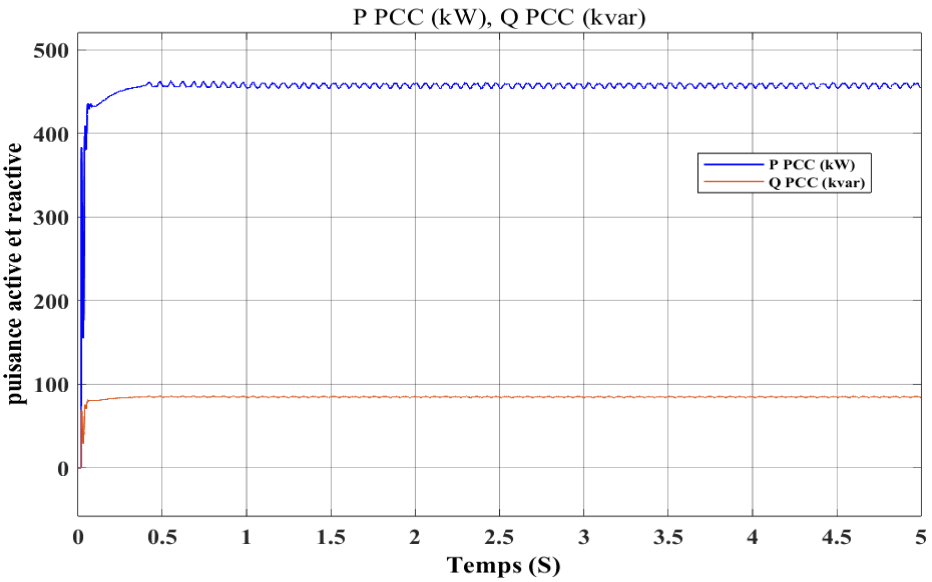


Figure IV.6 : Évolution des puissances active P et réactive Q

La puissance active atteint rapidement une valeur stable après une courte phase transitoire, ce qui montre la capacité du contrôleur PI à assurer le transfert de puissance demandé. La puissance réactive reste limitée et relativement stable, indiquant une bonne régulation énergétique du micro-réseau.

- **Analyse des composantes Vd, Vq, Id et Iq**

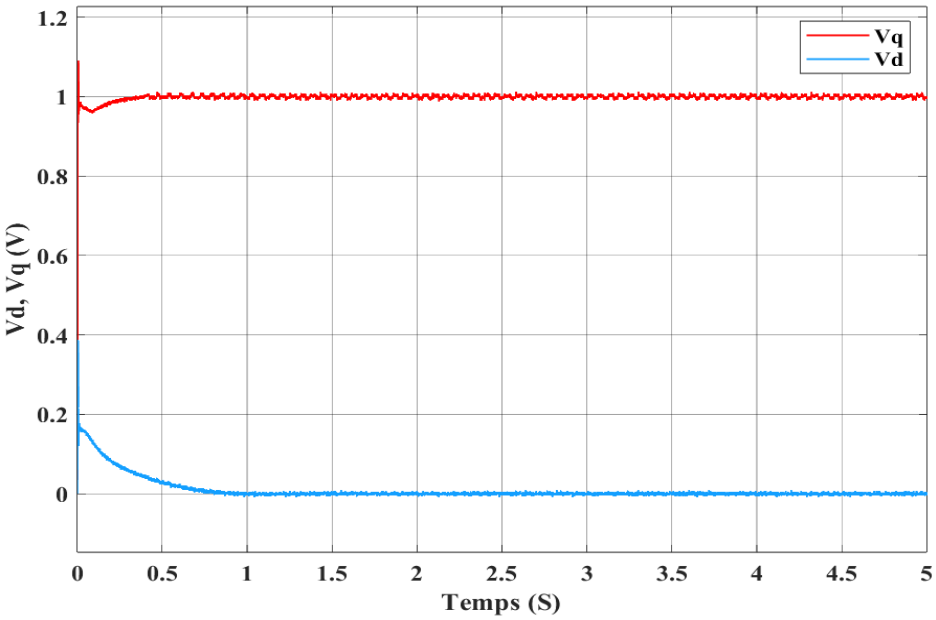


Figure IV.7 : Réponse des composantes de tension Vd et Vq

La composante Vd suit correctement sa valeur de référence avec une bonne stabilité en régime permanent. La composante Vq converge vers une valeur proche de zéro, traduisant un bon découplage dans le repère synchrone dq.

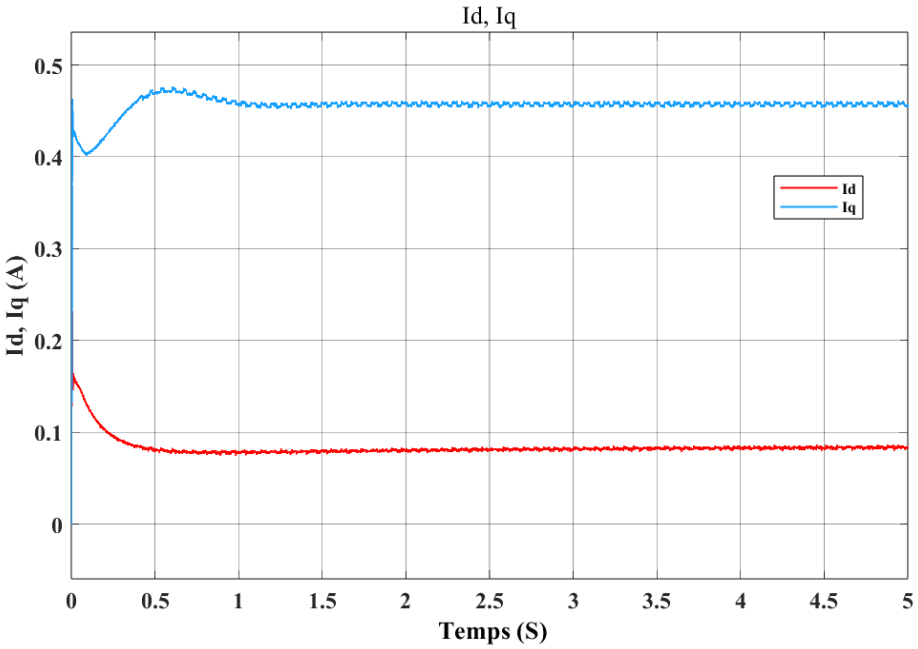


Figure IV8 : Évolution des composantes de courant Id et Iq

Les courants Id et Iq présentent une réponse stable après le régime transitoire. La composante Id assure principalement le transfert de puissance active tandis que Iq reste faible, ce qui indique une bonne maîtrise de la puissance réactive.

- **Analyse des erreurs de suivi**

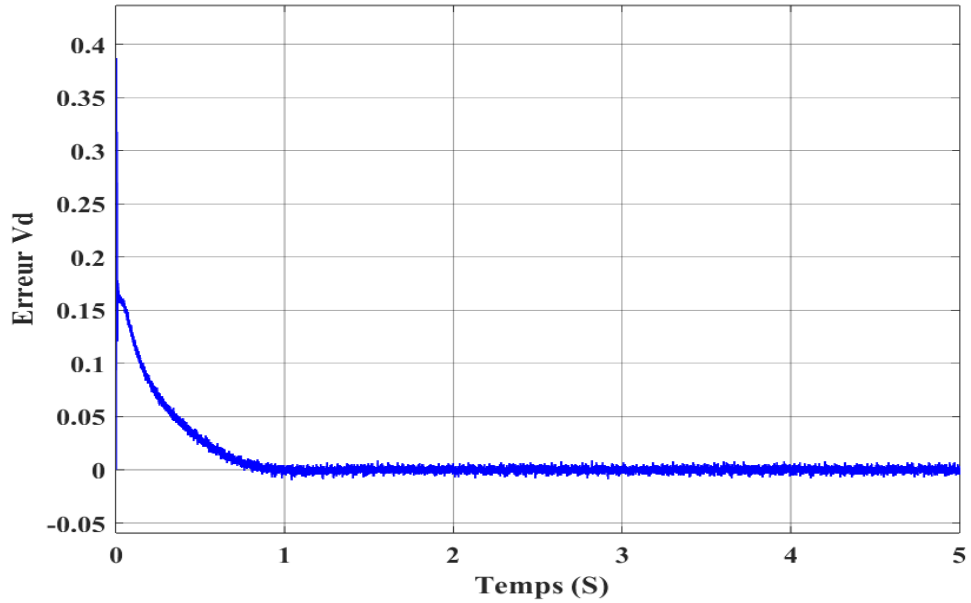


Figure IV.9 : Erreur de suivi de la composante Vd

L'erreur de suivi diminue progressivement après le démarrage et se stabilise autour de zéro avec de faibles oscillations. Cela montre que le régulateur PI assure une correction acceptable de l'erreur de commande.

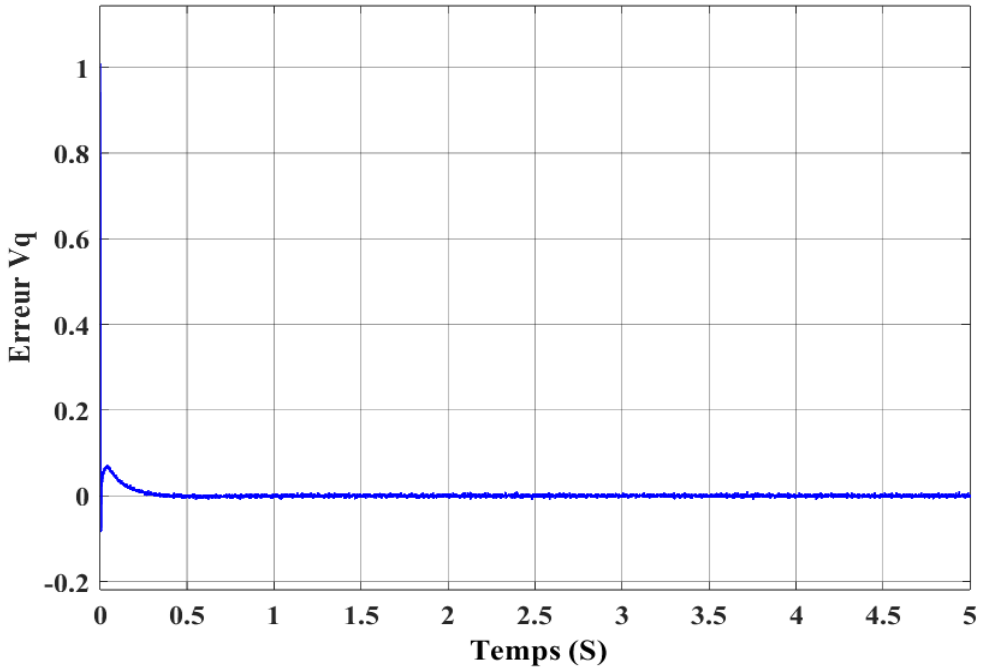


Figure IV.10 : Erreur de suivi de la composante Vq

L'erreur associée à la composante Vq converge rapidement vers zéro après la phase transitoire. Les faibles variations observées en régime permanent traduisent une stabilité satisfaisante du système sous contrôle PI.

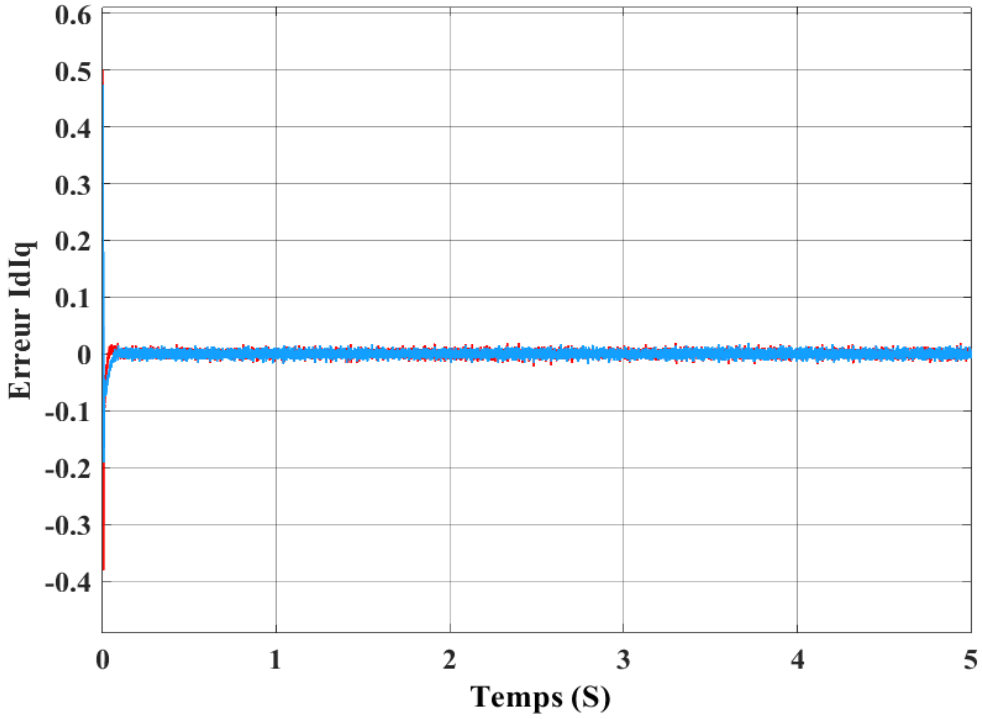


Figure IV.11 : Erreur de suivi de la composante IdIq

L'erreur relative aux composantes Id et Iq diminue rapidement et tend vers zéro après la phase transitoire. Les faibles oscillations observées en régime permanent indiquent que le système contrôlé par PI présente une stabilité satisfaisante et un bon suivi des consignes

IV.5 Implémentation du contrôle intelligent RBF-PI

IV.5.1 Structure du contrôleur RBF-PI

Le contrôleur RBF-PI utilisé dans cette étude combine un réseau de neurones à fonctions de base radiale (RBF) et un régulateur PI afin d'améliorer les performances de commande du micro-réseau.

La structure du réseau RBF est composée de trois couches : une couche d'entrée recevant l'erreur de régulation e et sa variation Δe, une couche cachée constituée de neurones à fonctions radiales gaussiennes, et une couche de sortie générant les signaux nécessaires au contrôleur PI.

Le réseau neuronal est implémenté sous MATLAB/Simulink à l'aide d'une S-Function, permettant l'exécution des calculs en temps réel et l'adaptation du contrôleur aux variations dynamiques du système. Grâce à ses capacités d'approximation des systèmes non linéaires, le contrôleur RBF-PI contribue à améliorer la précision de régulation, la rapidité de réponse et la robustesse du micro-réseau.

IV.5.2 Paramètres du réseau RBF

Tableau IV.2 : Paramètres du réseau RBF utilisé dans le contrôleur RBF-PI.

Paramètre	Valeur
Fonction d'activation	Gaussienne
Gain proportionnel Kp	[0.3 ; 3]
Gain intégral Ki	[20 ; 50]
Période d'échantillonnage Ts	5e-05 s
Limites de sortie	[-1.25 ; 1.25]

IV.5.3 Intégration du contrôleur RBF-PI dans le micro-réseau

Le contrôleur RBF-PI a été intégré dans le modèle Simulink du micro-réseau isolé afin d'assurer une gestion optimale des grandeurs électriques au niveau des convertisseurs.

Dans cette structure, le système est organisé sous forme de deux niveaux de régulation en cascade. Le premier niveau traite l'erreur entre les tensions de référence et les tensions mesurées (Voltage control) afin de générer des courants de référence adaptés au fonctionnement du système.

Le deuxième niveau assure le suivi de ces courants de référence en les comparant aux courants mesurés (Current control). À partir de cette comparaison, le contrôleur RBF-PI génère les signaux de commande nécessaires pour piloter les onduleurs du micro-réseau.

L'ensemble du contrôleur est implémenté sous forme de S-Function MATLAB, ce qui permet une exécution en temps réel et une intégration directe dans l'environnement Simulink.

Cette structure permet d'améliorer la précision de la régulation ainsi que la robustesse du micro-réseau face aux variations de charge et aux perturbations externes.

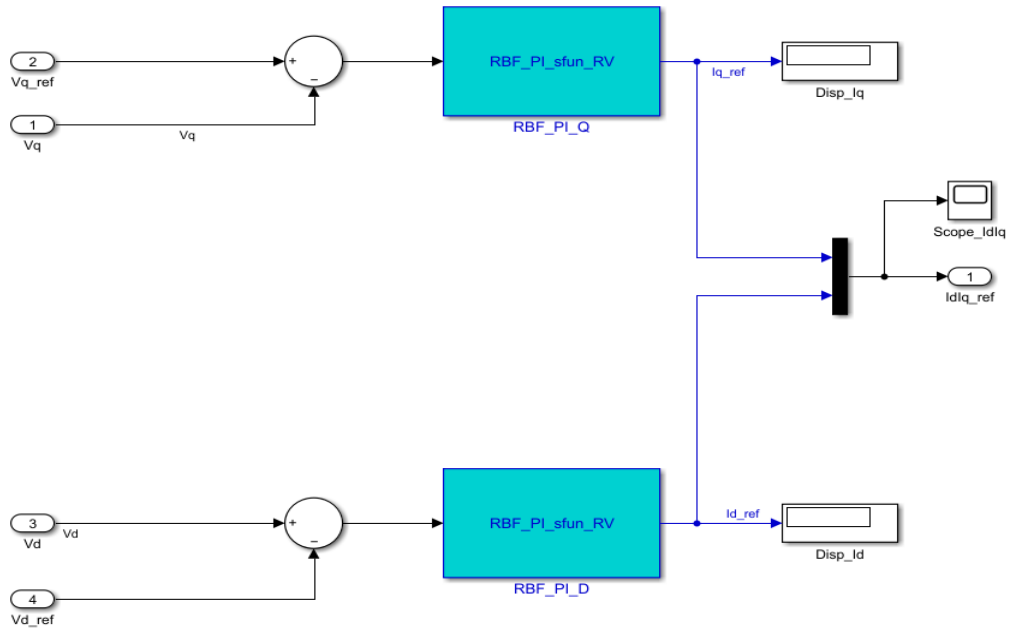


Figure IV.12 : Contrôleur de tension basé sur RBF-PI

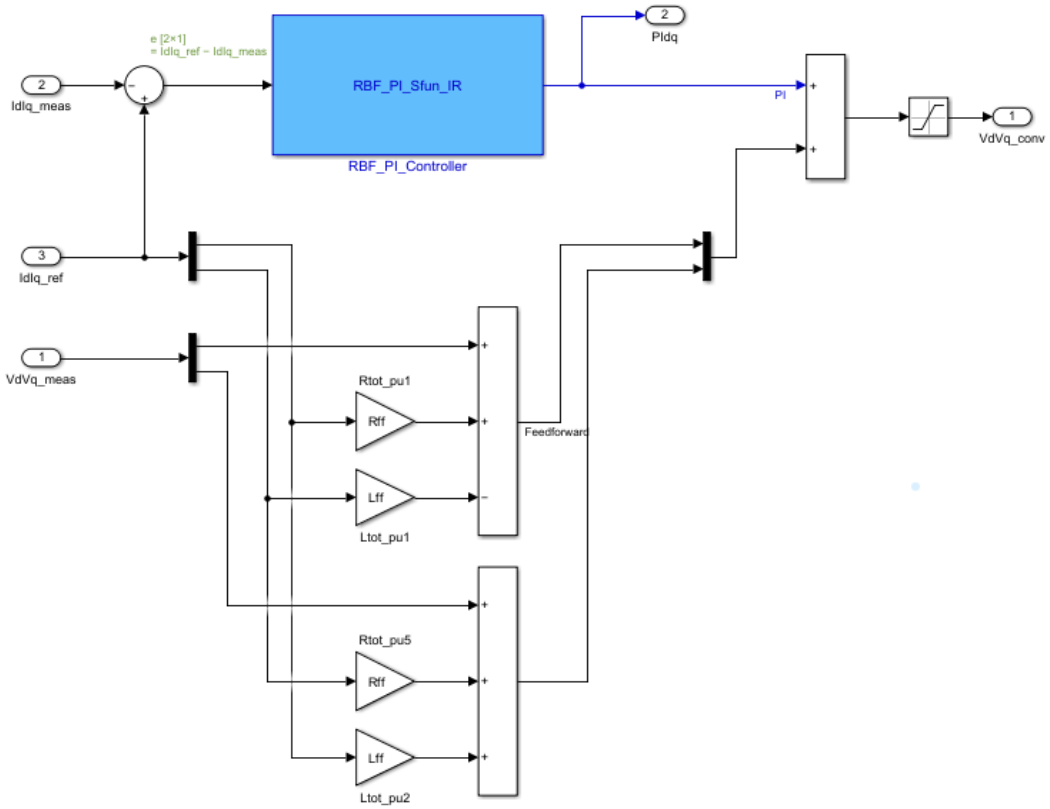


Figure IV.13 : Contrôleur de courant basé sur RBF-PI

IV.5.4 Résultats de simulation du contrôle RBF-PI

Les résultats de simulation obtenus avec le contrôleur intelligent RBF-PI montrent un comportement dynamique satisfaisant du micro-réseau dans le repère synchrone dq. On observe une amélioration globale des performances du système au niveau des grandeurs électriques principales.

Les composantes Vd, Vq, Id et Iq présentent une évolution plus stable et mieux amortie, avec une réduction significative des oscillations durant le régime transitoire. L'erreur de suivi associée aux variables de commande E_d et E_q diminue rapidement et tend vers des valeurs très proches de zéro, ce qui traduit une bonne capacité du contrôleur à suivre les consignes imposées.

Par ailleurs, les résultats montrent une amélioration du comportement énergétique du système. La puissance active augmente de manière plus efficace, tandis que la puissance réactive est mieux compensée et réduite, ce qui reflète une meilleure gestion de l'énergie au niveau du micro-réseau.

Dans l'ensemble, le contrôleur RBF-PI assure une réponse plus rapide, une meilleure précision et une stabilité renforcée du système par rapport aux conditions de fonctionnement classiques, ce qui confirme son efficacité pour les applications de commande des micro-réseaux isolés

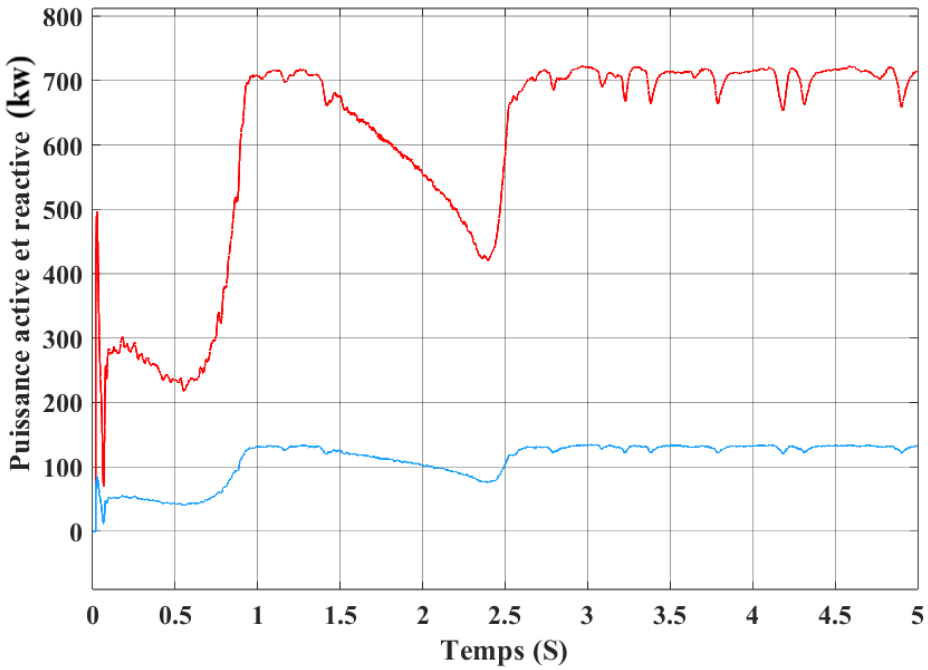


Figure IV.14 : Évolution des puissances active P et réactive Q

IV.6 Conclusion

Dans ce chapitre, les performances du micro-réseau isolé ont été évaluées à travers des simulations réalisées sous MATLAB/Simulink. Une première étude a été consacrée au fonctionnement du système sous contrôle PI classique afin d'analyser son comportement et de disposer d'une référence de comparaison.

Par la suite, une stratégie de commande intelligente basée sur un réseau de neurones à fonctions de base radiale (RBF) associée à un régulateur PI a été mise en œuvre dans le système de contrôle. Les résultats obtenus ont permis de mettre en évidence l'efficacité de cette approche pour la gestion énergétique du micro-réseau.

L'analyse des puissances active et réactive a montré un fonctionnement plus performant du système, caractérisé par une meilleure exploitation de la puissance active et une réduction de la puissance réactive. Ces améliorations traduisent une gestion plus efficace des flux d'énergie ainsi qu'une meilleure adaptation du système aux conditions de fonctionnement du micro-réseau.

Les résultats de simulation confirment ainsi la capacité du contrôleur RBF-PI à améliorer les performances globales du système et à renforcer l'efficacité de la stratégie de gestion énergétique proposée. Par conséquent, l'intégration du réseau de neurones RBF constitue une solution pertinente pour la mise en œuvre du contrôle tertiaire, en permettant une optimisation de la gestion de l'énergie et une utilisation plus efficace des ressources disponibles au sein du micro-réseau isolé.

Conclusion Générale

Conclusion Générale

Ce mémoire a porté sur une problématique concrète : comment gérer au mieux l'énergie dans un micro-réseau isolé, là où le réseau électrique national n'est pas là pour compenser les déséquilibres entre production et consommation. Nous avons vu que cette tâche de contrôle tertiaire, bien que fondamentale, devient particulièrement ardue lorsqu'on intègre massivement des énergies renouvelables intermittentes et des systèmes de stockage dont le comportement est difficile à prévoir.

Face aux limites des méthodes classiques — qui demandent souvent de simplifier à l'extrême le problème pour pouvoir le résoudre — nous avons exploré une piste différente : faire appel aux réseaux de neurones, et plus précisément aux réseaux à fonctions de base radiale (RBF), pour améliorer le contrôle du système. L'idée était de combiner l'expérience et la simplicité du régulateur PI avec la capacité d'adaptation d'un réseau de neurones capable d'apprendre le comportement réel du micro-réseau à partir des données.

Les résultats que nous avons obtenus sous MATLAB/Simulink sont encourageants. La commande adaptative RBF-PI a montré qu'elle pouvait réduire les oscillations lors des transitions, suivre plus fidèlement les consignes imposées, et gérer de manière plus fine les échanges de puissance active et réactive. En pratique, cela se traduit par un micro-réseau plus stable, plus réactif aux variations de charge ou de production solaire, et globalement plus performant.

Un aspect intéressant de notre approche est qu'elle ne nécessite pas de connaître parfaitement le modèle mathématique du système. Le réseau RBF apprend à estimer la sensibilité du micro-réseau en temps réel, ce qui évite d'avoir à recourir à des équations complexes souvent impraticables dans des conditions réelles. Cette propriété d'adaptation constitue sans doute le principal atout de la méthode proposée.

Cela dit, notre travail ne résout pas tout. Les performances obtenues dépendent largement de la qualité des données utilisées pour entraîner le réseau. Si ces données ne couvrent pas suffisamment de situations variées, le contrôleur risque de se montrer déconcerté face à des événements imprévus. De plus, le choix du nombre de neurones, des centres et des largeurs des fonctions gaussiennes reste une étape sensible qui demande du temps et plusieurs essais. Enfin, il faut être honnête : un réseau de neurones reste un système complexe dont le fonctionnement interne n'est pas toujours évident à expliquer. Dans un contexte industriel où on aime comprendre le pourquoi de chaque décision, cette opacité peut poser problème et mérite d'être prise en compte.

Sur le plan des perspectives, plusieurs directions mériteraient d'être explorées. On pourrait imaginer d'optimiser les paramètres du réseau RBF à l'aide d'algorithmes évolutifs comme les algorithmes génétiques ou l'optimisation par essaims de particules. On pourrait aussi tester des architectures hybrides, par exemple en couplant le réseau RBF avec des systèmes à logique floue pour mieux intégrer l'expertise humaine, ou avec des réseaux LSTM pour anticiper les variations temporelles de la charge et de la production. Et surtout, il serait indispensable de valider expérimentalement ces résultats sur un banc d'essai physique, car la simulation, aussi utile soit-elle, ne remplace jamais l'épreuve du réel.

En définitive, ce travail confirme que les techniques d'intelligence artificielle, loin d'être des gadgets théoriques, peuvent apporter une réponse sérieuse et efficace aux défis concrets du contrôle des micro-réseaux isolés. À l'heure où l'électrification des zones rurales et l'intégration des énergies propres deviennent des priorités mondiales, développer des outils de contrôle intelligents, capables de s'adapter en permanence à un environnement changeant, apparaît comme une nécessité. Nous espérons que les éléments présentés ici pourront éclairer les travaux futurs et contribuer, modestement, à cette évolution.

Références bibliographique

[1] N. Hatziargyriou, Microgrids: Architectures and Control, Wiley-IEEE Press, 2014.

[2] R. H. Lasseter, “Microgrids,” IEEE Power Engineering Society Winter Meeting, 2002.

[3] J. M. Guerrero et al, “Hierarchical control of droop-controlled AC and DC microgrids,” IEEE Transactions on Industrial Electronics, 2011.

[4] H. Bevrani, B. Francois, T. Ise, Microgrid Dynamics and Control, Wiley-IEEE Press, 2017.

[5] : Guerassimoff, G. (2017). Microgrids: pourquoi, pour qui? (pp. 252-pages). Presses des Mines.

[6] S. Chowdhury, S. P. Chowdhury, Microgrids and Active Distribution Networks, IET Press, 2009.

[7] A. Mohamed, O. Mohammed, “Real-time energy management algorithm for microgrids,” IEEE Transactions on Smart Grid, 2013.

[8] T. Ackermann, Wind Power in Power Systems, Wiley, 2012.

[9] H. Ibrahim et al., “Energy storage systems characteristics and comparisons,” Renewable and Sustainable Energy Reviews, 2008.

[10]: Tayab, U. B., Roslan, M. A. B., Hwai, L. J., & Kashif, M. (2017). A review of droop control techniques for microgrid. Renewable and Sustainable Energy Reviews, 76, 717-727.

[11] A. Keyhani, Design of Smart Power Grid Renewable Energy Systems, Wiley, 2011.

[12] J. M. Guerrero et al., “Advanced control architectures for intelligent microgrids,” IEEE Transactions on Industrial Electronics, 2013.

[13] Shi, W. (2023). Gestion efficace des énergies renouvelables dans les micro-réseaux.

Articles - Vidéos - Événements. Université de Californie, Los Angeles.

[14] Guerrero J.M., Vasquez J.C., Matas J., de Vicuña L.G., Castilla M. Hierarchical control of droop-controlled AC and DC microgrids. IEEE Transactions on Industrial Electronics, 2011.

[15] Wood A.J., Wollenberg B.F. Power Generation, Operation and Control. Wiley, 2013.

[16] Conejo A.J., Carrion M., Morales J.M. Decision Making Under Uncertainty in Electricity Markets. Springer, 2010.

[17] Olivares D.E. et al. Trends in microgrid control. IEEE Transactions on Smart Grid, 2014.

[18] Haykin S. Neural Networks and Learning Machines. Pearson, 2009.

[19] Zadeh L.A. Fuzzy Sets. Information and Control, 1965.

[20] Kennedy J., Eberhart R. Particle Swarm Optimization. IEEE International Conference on Neural Networks, 1995.

[21] Mohammadi M. et al., Energy management in microgrids, Renewable and Sustainable Energy Reviews, 2017.

[22] CNIL, “Intelligence artificielle et réseaux de neurones,” 2023. [Online]. Available: https://www.cnil.fr. [Accessed: Mar. 27, 2026].

[23] IBM, “What are neural networks,” 2023. [Online]. Available: https://www.ibm.com. [Accessed: Mar. 27, 2026].

[24] I. Goodfellow, Y. Bengio and A. Courville, Deep Learning. Cambridge: MIT Press, 2016

[25] W. McCulloch and W. Pitts, “A logical calculus of the ideas immanent in nervous activity,” Bulletin of Mathematical Biophysics, vol. 5, pp. 115–133, 1943.

[26] Y. Bengio, P. Simard, and P. Frasconi, “Learning long-term dependencies with gradient descent is difficult,” IEEE Transactions on Neural Networks, 1994.

[27] S. Hochreiter and J. Schmidhuber, “Long short-term memory,” Neural Computation, 1997.

[28] J. Moody and C. J. Darken, “Fast Learning in Networks of Locally-Tuned Processing Units,” Neural Computation, vol. 1, no. 2, pp. 281–294, 1989.

[29] C. Touzet.Seconde éditionles réseaux de neurones artificiels introduction au connexionisme. Rapport, 2016.

[30] Mifdal, R. (2019). Mémoire présenté à l’école de technologie supérieure comme exigence

partielle à l’obtention de la maîtrise avec mémoire en génie, concentration personnalisée. Écolede technologie supérieure, Université du Québec, Montréal, Canada.

[31] T. Alwar and P. K. Shanmugam, “Artificial Intelligence Driven Smart Hierarchical Control for Microgrids—A Comprehensive Review,” AI Journal, 2026

[32] H. Bevrani, Robust Power System Frequency Control, Springer, 2014.

[33] J. A. Pecas Lopes et al, “Microgrids operation and control,” IEEE Trans., 2006.

[34] N. Hatziargyriou, Microgrids : Architectures and Control, Wiley, 2014.

[35] A. Graves, Supervised Sequence Labelling with Recurrent Neural Networks, Springer, 2012.

[36] M. E. Glavin et al., “Battery management systems for microgrids,” IEEE Trans., 2013.

[37] A. Bidram and A. Davoudi, “Hierarchical Structure of Microgrids Control System,” IEEE Trans. Smart Grid, 2012.

[38] Y. LeCun et al., “Deep learning,” Nature, 2015.

[39] K. Hornik, “Approximation capabilities of multilayer feedforward networks,” 1991.

[40] M. H. Ali, “Neural network-based control of microgrids,” 2014.

[41] H. K. Khalil, Nonlinear Systems, 3rd ed. Upper Saddle River, NJ, USA: Prentice Hall, 2002.