

Amélioration de l'algorithme MPPT pour un système PV par
l'intégration des nouvelles techniques basées sur
l'intelligence artificielle

Par

Bacem GAIED CHORTANE

MÉMOIRE PRÉSENTÉ À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
COMME EXIGENCE PARTIELLE À L'OBTENTION DE LA MAÎTRISE
AVEC MÉMOIRE EN GÉNIE ÉNERGIES RENOUVELABLES ET
EFFICACITÉ ÉNERGÉTIQUE
M. SC. A.

MONTRÉAL, LE 4 JUILLET 2022

ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
UNIVERSITÉ DU QUÉBEC



Bacem Gaied Chortane, 2022



Cette licence [Creative Commons](#) signifie qu'il est permis de diffuser, d'imprimer ou de sauvegarder sur un autre support une partie ou la totalité de cette œuvre à condition de mentionner l'auteur, que ces utilisations soient faites à des fins non commerciales et que le contenu de l'œuvre n'ait pas été modifié.

PRÉSENTATION DU JURY

CE MÉMOIRE A ÉTÉ ÉVALUÉ

PAR UN JURY COMPOSÉ DE :

M. Ambrish Chandra, directeur de thèse
Département de génie électrique à l'École de technologie supérieure

M. Pierre Jean Lagacé, présidente du jury
Département de génie électrique à l'École de technologie supérieure

M. Qingsong Wang, membre du jury
Département de génie électrique à l'École de technologie supérieure

IL A FAIT L'OBJET D'UNE SOUTENANCE DEVANT JURY ET PUBLIC

LE 29 JUIN 2022

À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

REMERCIEMENTS

Avant tout, je voudrais exprimer ma sincère gratitude à mon directeur de recherche, le professeur Chandra Ambrish, pour le soutien continu de mes études de maitrise et de mes recherches, pour sa patience, sa motivation, son enthousiasme et ses immenses connaissances. Ses conseils m'ont aidé dans toutes les phases de recherche et de rédaction de cette thèse. Je n'aurais pas pu imaginer avoir un meilleur conseiller et mentor pour mes études de maitrise.

Je tiens à remercier mon superviseur, le docteur Mounir Benadja pour ses conseils et son encadrement pendant la période de la recherche. Je suis très reconnaissant pour son soutien, ses encouragements et son aide précieuse.

Je remercie ma mère et mon frère d'être à mes côtés comme une source de soins, d'amour, d'encouragement et de motivation, qui m'a rempli de patience et d'engagement.

Enfin, je dédie tout ce travail à mon père décédé récemment, tu étais toujours ma source d'inspiration, mon plus fort repère, merci pour ce que tu as été pour moi.

Amélioration de l'algorithme MPPT pour un système PV par l'intégration de nouvelles techniques basées sur l'intelligence artificielle

Bacem GAIED CHORTANE

RÉSUMÉ

Avec l'intégration croissante des énergies renouvelables dans les réseaux électriques, de nombreuses recherches sont menées pour améliorer l'efficacité des systèmes de conversion. Le défi mondial consiste à réduire le coût de production et à maximiser l'utilisation de ressources durables. À cet égard, l'énergie photovoltaïque est considérée comme une source très prometteuse en termes de coûts de mise en œuvre et du nombre d'applications utilisant des panneaux photovoltaïque (PV). Plusieurs techniques MPPT (Maximum Power Point Tracking) ont été développées pour suivre le point de puissance maximale (MPP). La technique Perturb and Observe (P&O) est l'une des techniques conventionnelles utilisées pour la poursuite du MPP, mais elle présente plusieurs inconvénients en termes de temps de réponse et de qualité du signal de sortie.

Dans notre recherche, une méthode basée sur un contrôleur à logique floue (FLC) qui corrige les limites des algorithmes conventionnels a été développé. Cette technique regroupe les avantages de la P&O-MPPT pour tenir compte des variations lentes et rapides de l'irradiation solaire, ainsi que la réduction du temps de traitement de la FLC-MPPT, pour résoudre des problèmes techniques complexes avec un nombre de règles des fonctions d'appartenance réduit. En conséquence, la technique proposée atteint des efficacités de suivi moyennes d'environ 99,6 % dans le cadre du test standard EN50530. Cette méthode offre un meilleur temps de réponse et des oscillations moins importantes que celles des méthodes conventionnelles.

Comme deuxième partie de notre étude, un modèle basé sur le système d'inférence adaptatif neuro-flou (ANFIS) a été développé. Cette technique combine un contrôleur de logique floue et des réseaux de neurones artificiels (ANN).

Les résultats des tests sont simulés sur Matlab/Simulink avec une comparaison des modèles proposés avec d'autres techniques MPPT telles que Perturb and Observ (P&O) et Incremental Conductance (INC).

Mots clés: Photovoltaïque, Convertisseur CC-CC Boost, MPPT, P&O, Intelligence artificielle, INC, FLC, ANFIS, EN50530, MATLAB/Simulink

Improvement of the MPPT algorithm for a PV system by integrating new techniques based on artificial intelligence

Bacem GAIED CHORTANE

ABSTRACT

With the increasing integration of renewable energies into power grids, much research is being conducted to improve the efficiency of conversion systems. The global challenge is to reduce the cost of production and maximize the use of sustainable resources. In this regard, photovoltaics is considered a very promising source in terms of implementation costs and the number of applications using PV panels. Several MPPT techniques have been developed to track the maximum power point. The Perturb and Observe (P&O) technique is one of the conventional techniques used for MPP tracking, but it has several drawbacks in terms of response time and output signal quality.

In our research, a method based on a fuzzy logic controller (FLC) that corrects the limitations of conventional algorithms has been developed. This technique combines the advantages of P&O-MPPT to account for slow and fast variations in solar irradiance, as well as the reduced processing time of FLC-MPPT, to solve complex technical problems with a reduced number of membership function rules. As a result, the proposed technique achieves average tracking efficiencies of about 99.6% in the standard EN50530 test, and this method offers better response time and less oscillations than conventional methods.

As a second part of our study, a model based on the adaptive neuro-fuzzy inference system (ANFIS) was developed. This technique combines a fuzzy logic controller and artificial neural networks (ANN).

Test results are simulated on Matlab/Simulink with a comparison of the proposed models with other MPPT techniques such as Perturb and Observe (P&O) and Incremental Conductance (INC).

X

Keywords : Photovoltaic, DC-DC Boost Converter, MPPT, P&O, Artificial intelligence, INC, FLC, ANFIS, EN50530, MATLAB/Simulink

TABLE DES MATIÈRES

	Page
INTRODUCTION	1
CHAPITRE 1 REVUE DE LA LETERATURE.....	5
1.1 Introduction.....	5
1.2 Centrale photovoltaïque	6
1.3 Système photovoltaïque	7
1.4 Type des systèmes photovoltaïque.....	8
1.4.1 Système photovoltaïque autonome	8
1.4.2 Système photovoltaïque connecté au réseau.....	9
1.4.3 Système photovoltaïque hybride.....	10
1.5 Avantages et inconvénients des systèmes photovoltaïque.....	11
1.5.1 Avantages des systèmes photovoltaïques	11
1.5.2 Inconvénients des systèmes photovoltaïques.....	12
1.6 Module photovoltaïque	13
1.6.1 Modélisation d'une cellule photovoltaïque.....	13
1.6.2 Courbe caractéristique d'un module photovoltaïque	15
1.7 Convertisseur CC-CC Boost	19
1.7.1 Modélisation d'un convertisseur CC-CC Boost	19
1.7.2 Calcul des paramètres d'un convertisseur CC-CC Boost	22
1.8 Méthode d'extraction du point de puissance maximum (MPPT)	23
1.8.1 Méthode du courant de court-circuit (FCC).....	24
1.8.2 Méthode de la tension du circuit ouvert (FCO)	25
1.8.3 Méthode de la perturbation et observation (P&O).....	26
1.8.4 Méthode de la conductance incrémentale (INC)	28
1.9 Problématiques.....	30
1.9.1 Problématique de perte de puissance avec les algorithmes fractionnels...30	30
1.9.2 Problématique des conditions météorologiques avec les algorithmes P&O et INC.....	31
1.9.3 Problématique de robustesse et de fidélité des algorithmes MPPT basés sur l'intelligence artificielle	31
1.10 Objectifs de la recherche.....	31
1.11 Méthodologie	33
CHAPITRE 2 AMÉLIORATION DES ALGORITHMES P&O ET INC PAR L'INTEGRATION DES CONTROLEURS À LOGIQUE FLOUE	35
2.1 Introduction.....	35
2.1.1 Études antérieures sur les MPPT à base des FLC	35
2.2 La logique floue	37
2.2.1 Définition de la logique floue	37
2.2.2 La fuzzification	39
2.2.3 La fonction d'appartenance.....	39

2.2.4	Les règles floues	40
2.2.5	La défuzzification	41
2.3	Méthodologie	42
2.3.1	Système étudié	42
2.3.2	Structure du contrôleur à logique floue	43
2.3.3	Configuration du contrôleur logique floue	43
2.4	Résultat de simulation et discussions.....	47
2.5	Conclusion	53
 CHAPITRE 3 NOUVELLE METHODE DE SUIVI DU POINT DE PUISSANCE MAXIMALE D'UN SYSTÈME PHOTOVOLTAIQUE BASÉE SUR LE SYSTÈME D'INFERENCE NEURO-FLOUE ADAPTATIF		
3.1	Introduction.....	55
3.2	Études antérieures sur les MPPT basées sur L'ANFIS.....	55
3.3	Structure d'un contrôleur ANFIS.....	58
3.3.1	Réseau de neurones artificiels.....	58
3.3.1.1	Le neurone artificiel.....	59
3.3.1.2	Fonction d'activation	60
3.3.1.3	Composition d'un réseau de neurones	61
3.3.1.4	Apprentissage d'un réseau de neurones	61
3.3.1.5	Apprentissage supervisé.....	62
3.3.1.6	Fonction d'erreur (loss_function).....	63
3.3.2	Système d'inférence neuro-floue adaptative (ANFIS)	64
3.3.2.1	Réseau de neurones adaptatif.....	64
3.3.2.2	Algorithme d'apprentissage de rétropropagation	65
3.3.2.3	Architecture du l'ANFIS	66
3.3.2.4	Couches de l'ANFIS.....	69
3.3.2.5	Apprentissage de l'ANFIS.....	72
3.4	Modèle proposé.....	73
3.5	Apprentissage des deux modèles ANFIS.....	75
3.6	Résultat et discussions	78
3.7	Conclusion	82
 CONCLUSION		
	83
 RECOMMANDATION.....		
	85
 LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES.....		
	87

LISTE DES TABLEAUX

	Page	
Tableau 2.1	Règles des fonctions d'appartenance du contrôleur floue	46
Tableau 2.2	Paramètres de simulation	50
Tableau 2.3	Efficacité et temps de réponse des différents algorithmes pour les deux tests du scénario 1	52
Tableau 2.4	Efficacité des trois algorithmes pour les 3 tests du scénario 3	53
Tableau 2.5	Efficacité de l'algorithme P&O et contrôleur logique floue pour différente configuration de champs photovoltaïque	53
Tableau 3.1	Différentes formes des fonctions d'activation d'un réseau de neurones ..	60
Tableau 3.2	Différentes fonctions d'erreur utilisés dans un réseau de neurones.....	63
Tableau 3.3	Les passes de l'algorithme d'apprentissage hybride	73
Tableau 3.4	Efficacité de l'algorithme pour des différentes configurations de champs PV	81
Tableau 3.5	Comparaison des propriétés des algorithmes conventionnels et l'algorithme ANFIS étudié	82

LISTE DES FIGURES

	Page	
Figure 0.1	Carte de l'irradiation solaire moyenne du monde	2
Figure 1.1	Centrale photovoltaïque installé à Tozeur en Tunisie d'une capacité de 10 MW	6
Figure 1.2	Schéma fonctionnel d'un système photovoltaïque	7
Figure 1.3	Différentes configurations d'un système photovoltaïque	8
Figure 1.4	Système photovoltaïque autonome	9
Figure 1.5	Système photovoltaïque connecté au réseau.....	10
Figure 1.6	Système photovoltaïque hybride.....	11
Figure 1.7	Passage d'une cellule photovoltaïque vers un champs de panneaux	13
Figure 1.8	Circuit équivalent d'une cellule photovoltaïque	14
Figure 1.9	Courbe caractéristique I-V d'un module PV pour 5 différentes valeurs d'irradiation et pour une température constante (25 degrés)	16
Figure 1.10	Courbe caractéristique I-V d'un module PV pour 5 différentes valeurs de température et pour une irradiation constante (1000 W/m ²)	17
Figure 1.11	Courbe caractéristique P-V d'un module PV pour 5 différentes valeurs d'irradiation et pour une température constante (25 degrés)	18
Figure 1.12	Courbe caractéristique P-V d'un module PV pour 5 différentes valeurs de température et pour une irradiation constante (1000 W/m ²).....	19
Figure 1.13	Circuit de base d'un convertisseur CC-CC Boost.....	20
Figure 1.14	Circuit du convertisseur CC-CC Boost lors de la transmission de la commutation	21
Figure 1.15	Circuit du convertisseur CC-CC Boost lors du basculement de la commutation	21
Figure 1.16	Schéma bloc de l'algorithme FCC	24

Figure 1.17	Schéma bloc de l'algorithme FCO.....	25
Figure 1.18	Principe de fonctionnement du point MPP pour une panneau PV.....	26
Figure 1.19	Schéma bloc de l'algorithme P&O	27
Figure 1.20	Schéma bloc de l'algorithme INC.....	29
Figure 2.1	Structure principale d'un contrôleur logique floue	38
Figure 2.2	Graphiques des différentes fonctions d'appartenance d'un contrôleur logique floue	40
Figure 2.3	Schéma fonctionnel du modèle proposé	42
Figure 2.4	Schéma fonctionnel de la commande MPPT basée sur la logique floue ..	43
Figure 2.5	Fonctions des ensembles flous de la première entrée du contrôleur.....	44
Figure 2.6	Fonctions des ensembles flous de la deuxième entrée du contrôleur	45
Figure 2.7	Fonctions des ensembles flous de la sortie du contrôleur.....	45
Figure 2.8	Courbe tridimensionnelle des relations entre les entrées et la sortie floue	46
Figure 2.9	Schéma Simulink du système étudié.....	48
Figure 2.10	Schéma Simulink pour le calcul du rendement des algorithmes MPPT ...	49
Figure 2.11	Courbe d'irradiation pour un changement chaque 0.1 secondes	50
Figure 2.12	Courbe d'irradiation pour un changement chaque 0.5 secondes	51
Figure 2.13	Courbe de puissance des trois algorithmes du premier test	51
Figure 2.14	Courbe de puissance des trois algorithmes du deuxième test	52
Figure 3.1	Architecture d'un réseau de neurones avec une seule couche cachée.....	59
Figure 3.2	Composition d'un réseau de neurones	61
Figure 3.3	Schéma bloc d'un réseau de neurones avec un apprentissage supervisé..	62
Figure 3.4	Architecture basique d'un ANFIS	68
Figure 3.5	Schéma bloc du système PV + contrôleur ANFIS étudié.....	75

Figure 3.6	Courbe d'apprentissage du modèle 1'ANFIS	77
Figure 3.7	Courbe d'apprentissage du modèle 1'ANFIS	77
Figure 3.8	Schéma Simulink du système étudié.....	78
Figure 3.9	Courbe de variation de l'irradiation.....	79
Figure 3.10	Courbe de variation de la température	79
Figure 3.11	Courbe de puissance à la borne du PV des trois algorithmes P&O, INC et MPPT-ANFIS	80

LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

MPP	Maximum Power Point
MPPT	Maximum Power Point Tracking
P&O	Perturbation & Observation
INC	Conductance Incrémentale
FLC	Contrôleur logique floue
IA	Intelligence Artificielle
ANN	Artificial Neural Network
ANFIS	Systèmes à inférence neuro-floue adaptatif
PV	Photovoltaïque
P-V	Puissance-Tension
I-V	Courant-Tension
FCO	Fraction de la tension du circuit ouvert
FCC	fraction du courant de court-circuit
CC-CC	Courant Continu-Courant Continu
RC	Resistance et capacité
AG	Algorithme génétique
COG	Centre de gravité
BOA	Bissectrice de surface
MOM	Moyenne du maximum
PSO	Particle Swarm Optimization
MSE	Erreur quadratique moyenne
MAE	Erreur moyenne absolue

LSM	Passe avant
GDM	Passe arrière
GD	Gradient descendant
LES	Estimateur des moindres carrés
MMC	Méthode des moindres carrés

LISTE DES SYMBOLES ET UNITÉS DE MESURE

MW	Méga Watt
I_d	Courant de jonction de la diode
I_{ph}	Photocourant d'une cellule photovoltaïque
Rsh	Résistance shunt d'une cellule photovoltaïque
Rs	Resistance série de la diode photovoltaïque
q	Charge d'un électron
I_s	Courant de saturation
V	Volt
K	Constante de Boltzmann
T	Température de jonction
N	Facteur d'idéalité d'une cellule photovoltaïque
f	Fréquence de commutation
D	Rapport Cyclique
ΔL_L	Courant d'ondulation estimé de l'inducteur
ΔV_0	Tension d'ondulation de sortie estimée
I_{mpp}	Courant au point de puissance maximale
I_{cc}	Courant de court-circuit
V_{mpp}	Tension au point de puissance maximale
V_{co}	Tension du circuit ouvert
P	Puissance
f	Fréquence de commutation
Ir	Irradiation solaire

A Ampère

Hz Hertz

H Henry

F Farad

W Watt

ms Milliseconde

Ω Ohm

INTRODUCTION

L'énergie solaire est propre et disponible en abondance. Les technologies solaires utilisent le soleil pour fournir de la lumière, de la chaleur, de l'électricité, etc. pour des applications domestiques et industrielles. Avec le taux alarmant d'épuisement des principales ressources énergétiques conventionnelles telles que le charbon, le pétrole et le gaz naturel, associé à la dégradation de l'environnement causée par le processus d'exploitation de ces sources d'énergie, il est devenu urgent d'investir dans des ressources énergétiques renouvelables qui permettraient de nous alimenter suffisamment à l'avenir sans dégrader l'environnement par l'émission de gaz à effet de serre. Le potentiel énergétique du soleil est immense, mais malgré cette ressource illimitée d'énergie solaire, sa récolte est un défi, principalement en raison de l'efficacité limitée des cellules photovoltaïques.

La demande de sources d'électricité renouvelables augmente rapidement en raison des efforts déployés au niveau mondial pour réduire les émissions de CO₂. L'énergie photovoltaïque, en particulier, joue un rôle prometteur tant pour les pays développés que pour les pays en développement, et elle est considérée comme la source d'énergie renouvelable la plus prometteuse en raison de ses avantages. Tout d'abord, l'énergie photovoltaïque est propre, puisqu'elle peut produire de l'électricité sans émettre de gaz à effet de serre et de gaz toxiques tels que le CO₂ et le NO_x. De plus, elle peut avoir des effets positifs d'un point de vue économique, non seulement parce qu'après l'investissement initial, elle réduit les factures d'électricité, mais aussi parce que le secteur des énergies renouvelables a le potentiel de créer de nouveaux emplois. En outre, les technologies exploitant l'énergie solaire sont relativement faciles à installer sur les toits et peuvent donc constituer un moyen de produire de l'électricité propre dans les zones rurales.

Le potentiel de production de l'électricité à partir des convertisseurs à effet photovoltaïque dépend essentiellement de la région où ces derniers sont installés. Plus précisément, le potentiel de production dépend de l'irradiation solaire moyenne comme le montre la figure 0.1.

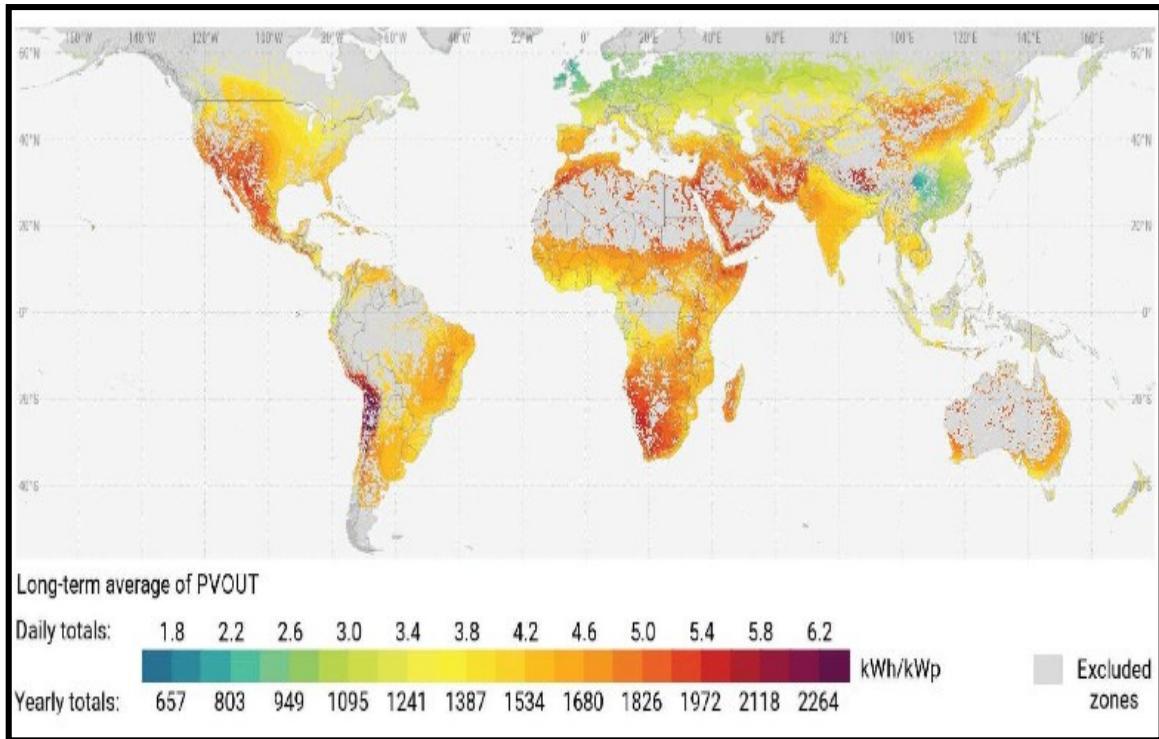


Figure 0.1 Carte de l'irradiation solaire moyenne du monde
Tirée de The Word Bank (2021)

Les chiffres de la carte présentés dans la figure 0.1 montrent que l'énergie solaire fournit un grand potentiel de production. Cependant, le meilleur rendement de conversion de la plupart des cellules solaires disponibles dans le commerce est de l'ordre de 10 à 20 %. Bien que les récentes percées dans la technologie des cellules solaires montrent une amélioration significative, le fait que l'efficacité maximale des cellules solaires se situe toujours dans la gamme des moins de 20 % montre qu'il y a une énorme marge d'amélioration.

Les systèmes photovoltaïques sont constitués de modules photovoltaïques, qui sont des dispositifs semi-conducteurs qui convertissent le rayonnement solaire incident en énergie électrique. En fonction des différents niveaux d'irradiation et de température, leur taux de production varie selon la situation géographique et les conditions climatiques.

La caractéristique électrique d'un module photovoltaïque est de nature non linéaire et présente un point particulier appelé le point de puissance maximale (MPP). Il s'agit du point de

fonctionnement optimal auquel le module fonctionne à sa puissance maximale. Pour extraire la puissance maximale, des algorithmes sont développés pour contrôler le convertisseur DC/DC, placé devant les panneaux PV, afin d'adapter dynamiquement le point de fonctionnement du système au point de puissance maximale.

De nombreux algorithmes d'extraction du point de puissance maximale (MPPT) ont été développés jusqu'à présent, et ces algorithmes MPPT varient en termes d'application, de complexité, de précision, de capteurs, de coût, de popularité, etc. Parmi eux, les méthodes perturbation et observation (P&O) et la conductance incrémentale (INC) ont attiré l'attention des chercheurs en raison de leur simplicité. Cependant, ces méthodes présentent un écart par rapport à la MPP en cas de changement rapide de l'irradiation solaire et des problèmes d'oscillations dans les états stables.

Dans ce contexte, et afin de remédier aux différentes limitations des algorithmes MPPT, dans cette recherche une nouvelle méthode basée sur les contrôleurs logique floue (FLC) est intégrée dans les algorithmes P&O et INC afin de corriger les problèmes de lenteur d'extraction et les oscillations présentes autour du MPP.

L'utilisation des techniques d'intelligence artificielle (IA) dans le domaine des énergies renouvelables a augmenté avec la reconnaissance de son potentiel. De nombreux problèmes liés aux énergies renouvelables correspondent exactement aux types de problèmes et aux questions pour lesquels l'approche de l'IA semble la plus adaptée. Dans ces modèles de calcul, on tente de simuler les fonctions cognitives et sensorielles du cerveau humain et d'utiliser cette capacité pour représenter et manipuler les connaissances sous forme de modèles. Sur la base de ces modèles, les ANN (Artificial neural network), par exemple, modélisent les relations fonctionnelles entrée-sortie et peuvent faire des prédictions sur d'autres combinaisons d'entrées invisibles. Les techniques d'IA ont le potentiel de faire de meilleures prédictions, plus rapides et plus pratiques que toutes les méthodes traditionnelles. D'autre part, les données issues des systèmes d'énergie photovoltaïque, étant intrinsèquement bruyantes, sont un bon candidat pour être traitées par des systèmes d'IA.

En effet, plusieurs recherches ont été menées afin d'exploiter les avantages de l'intelligence artificielle pour développer des algorithmes d'extraction du point de puissance maximale dans le but d'optimiser les systèmes photovoltaïques. Les systèmes à inférence neuro-floue adaptatif (ANFIS) ; qui sont des réseaux de neurones artificiels basés sur les systèmes d'inférence flous, ont été étudié pour l'extraction du MPP. Cependant, le principal inconvénient de ces systèmes est la nécessité d'un apprentissage et d'un paramétrage spécifiques pour chaque application et chaque configuration du système, ce qui entraîne une diminution de la fiabilité des modèles générés et de leur capacité à être adaptés à diverses situations et à différentes applications.

Dans le cadre de cette recherche de maîtrise, une nouvelle technique basée sur deux systèmes à inférence neuro-floue adaptatifs a été développé, pour améliorer les résultats des recherches précédentes sur les algorithmes d'extraction du point de puissance maximale en utilisant l'intelligence artificielle.

CHAPITRE 1

REVUE DE LA LETERATURE

1.1 Introduction

Le système photovoltaïque (PV) est l'une des technologies les plus importantes pour produire de l'énergie électrique. Cependant, il y a deux défauts majeurs, l'un est le faible rendement de conversion du système PV dû aux changements des conditions météorologiques, et l'autre est dû à la nature non linéaire des caractéristiques du réseau PV.

Les caractéristiques puissance-tension (P-V) et courant tension (I-V) changent généralement de manière non linéaire avec les changements de température et d'irradiation. Le suivi conventionnel du point de puissance maximale comprend des régulateurs de charge utilisés pour extraire la puissance maximale disponible du module PV en fonction de la variation de paramètres tels que la température et l'irradiation solaire. Le module PV produira une puissance maximale à une certaine tension, appelée point de puissance maximale. Les méthodes P&O et INC sont les plus utilisées dans les modules MPPT. D'autres techniques sont aussi utilisées, et qui sont dites fractionnelles, basées sur la mesure de la fraction de la tension du circuit ouvert (FCO), et la mesure de la fraction du courant de court-circuit (FCC).

Dans ce chapitre, une revue de la littérature est présenté sur les différents systèmes photovoltaïques et leurs topologies de connexion, leurs avantages et inconvénients. Puis une présentation des différentes configurations du convertisseur CC-CC boost et enfin les différentes techniques d'extraction du point de puissance maximale.

1.2 Centrale photovoltaïque

Les centrales photovoltaïques utilisent les rayons du soleil, qui est abondante, disponible, intermittente et facile à capturer. Cette énergie est ensuite transformée en énergie électrique à l'aide des panneaux photovoltaïques. Il s'agit d'un type de centrales solaires. En effet, un grand nombre de panneaux sont installés dans une configuration optimale et récoltent l'énergie lumineuse du soleil pour la convertir en énergie électrique qui alimente le réseau.

La figure 1.1 tirée de (<https://www.afrik21.africa>) montre une central photovoltaïque installé à Tozeur en Tunisie d'une capacité de 10 MW et qui sera raccordé au réseau. Ce projet évitera l'émission de 8.7 millions de tonnes de CO₂ par année.



Figure 1.1 Centrale photovoltaïque installée à Tozeur en Tunisie d'une capacité de 10 MW
Tirée de <https://www.afrik21.africa>

1.3 Système photovoltaïque

Les systèmes photovoltaïques offrent la possibilité de produire de l'électricité de manière propre, silencieuse et fiable. Les systèmes photovoltaïques sont composés de cellules et de dispositifs photovoltaïques qui convertissent directement l'énergie lumineuse en électricité. Comme la source de lumière est généralement le soleil, on les appelle souvent des cellules solaires. Les principaux éléments qui peuvent être inclus dans un système photovoltaïque sont les panneaux solaires, les batteries, les régulateurs/contrôleurs, les onduleurs et la charge, comme le résume le schéma fonctionnel de la figure 1.2. Pour un système de production fiable qui peut fonctionner indépendamment du réseau électrique, les batteries peuvent être un composant viable du système total. Des générateurs de secours peuvent être inclus dans un système pour fournir de l'énergie lorsque le système PV ne fonctionne pas, et sont généralement inclus lorsque les systèmes ne sont pas connectés au réseau.

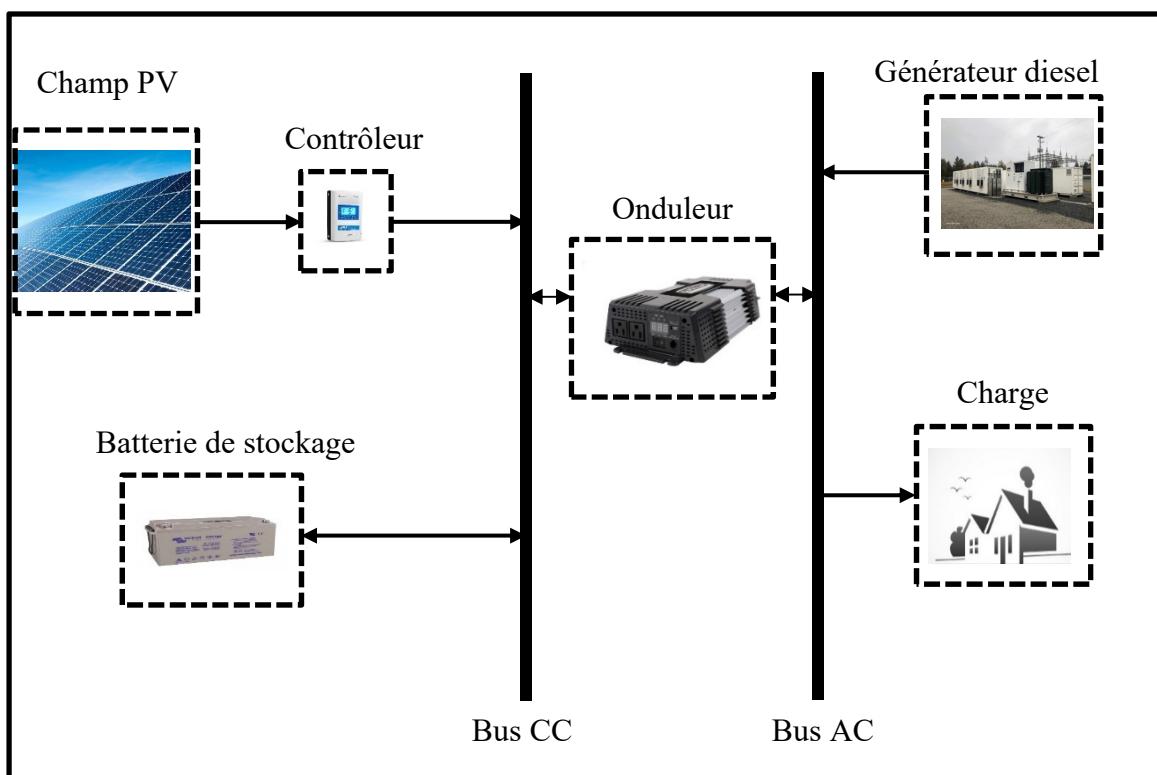


Figure 1.2 Schéma fonctionnel d'un système photovoltaïque

1.4 Type des systèmes photovoltaïque

Il existe essentiellement trois types de systèmes photovoltaïques. Il s'agit du système PV connecté au réseau, du système autonome et du système hybride. La figure 1.3 montre les différentes configurations d'un système photovoltaïque.

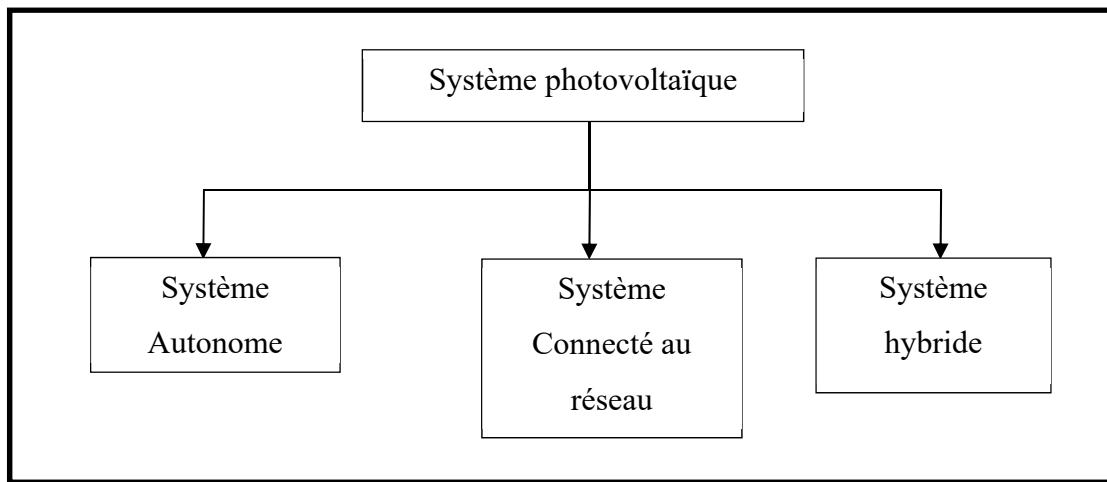


Figure 1.3 Différentes configurations d'un système photovoltaïque

1.4.1 Système photovoltaïque autonome

Les systèmes PV qui ne sont pas connectés au réseau électrique sont connus sous le nom de systèmes PV hors réseau et également appelés systèmes autonomes. Les systèmes directs utilisent l'énergie PV dès qu'elle est produite, tandis que les systèmes de stockage sur batterie peuvent stocker l'énergie pour l'utiliser plus tard, la nuit ou par temps nuageux. Ces systèmes sont utilisés en dehors des réseaux électriques, et peuvent servir à alimenter des stations de répéteurs radio, des cabines téléphoniques et l'éclairage public. La figure 1.4 montre un système photovoltaïque autonome typique.

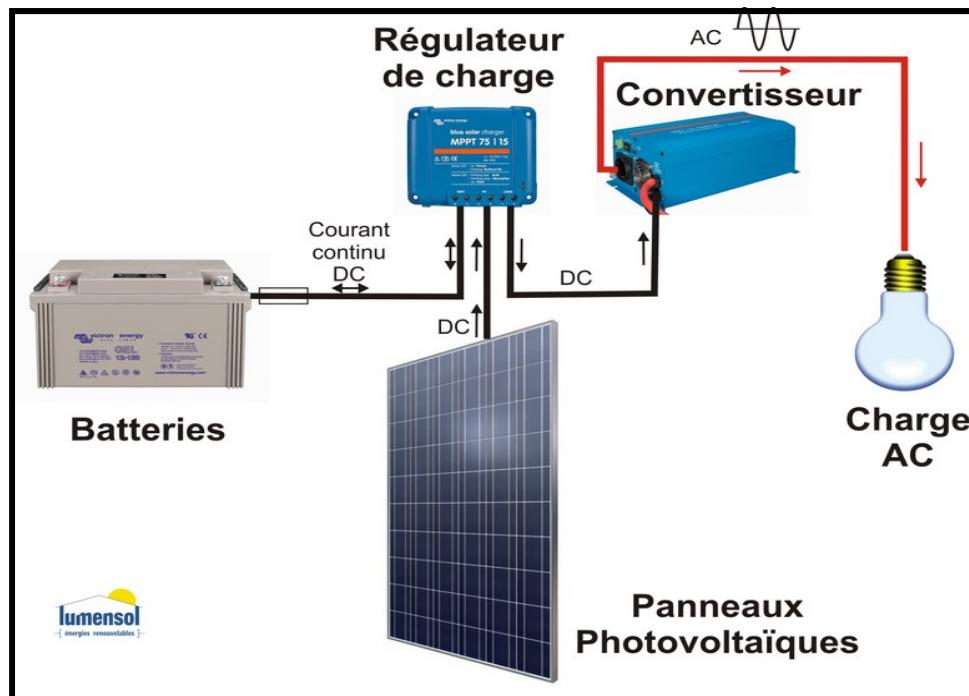


Figure 1.4 Système photovoltaïque autonome
Tirée de lumensol.fr

1.4.2 Système photovoltaïque connecté au réseau

Ces systèmes sont connectés à un réseau électrique plus large. Le système PV est connecté au réseau électrique à l'aide d'un onduleur de haute qualité, qui convertit le courant continu du champ PV en courant alternatif conforme aux normes du réseau. Pendant la journée, l'électricité produite par le système est soit utilisée immédiatement, soit revendue à des sociétés de distribution d'électricité. Le soir, lorsque le système n'est pas en mesure de fournir de l'électricité immédiatement, l'électricité peut être rachetée du réseau, comme le montre la figure 1.5.

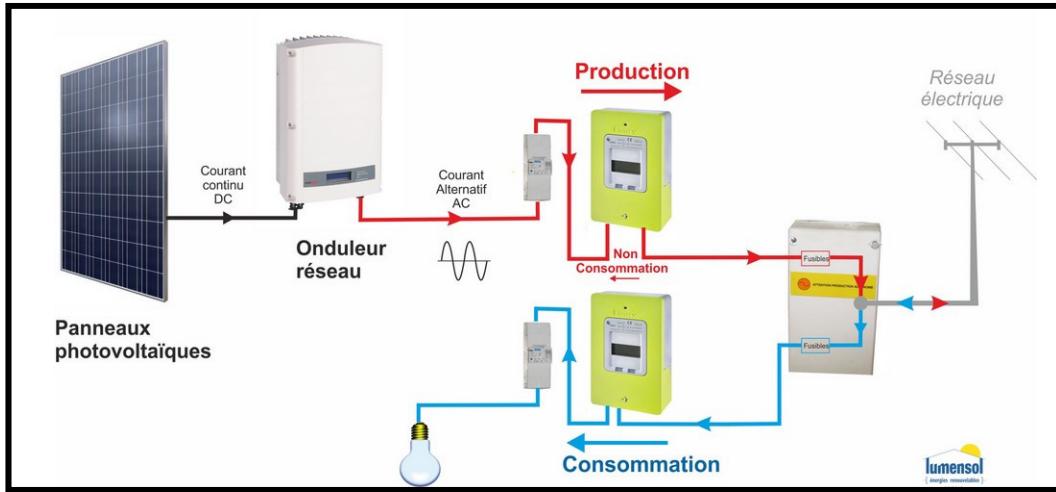


Figure 1.5 Système photovoltaïque connecté au réseau
Tirée de lumensol.fr

1.4.3 Système photovoltaïque hybride

Un système hybride combine le PV avec d'autres formes de production d'énergie, généralement un générateur diesel. Le biogaz peut également être utilisé. L'autre forme de production d'énergie est généralement un type de générateur capable de moduler la puissance de sortie en fonction de la demande. Cependant, plus d'une forme d'énergie renouvelable peut être utilisée, par exemple l'éolien et le solaire. Un système hybride éolien-PV typique se compose d'une petite éolienne, d'un générateur photovoltaïque, d'un système de stockage approprié et de l'équipement électronique. La production d'énergie photovoltaïque permet de réduire la consommation du combustible non renouvelable. La figure 1.6 montre un système hybride typique.

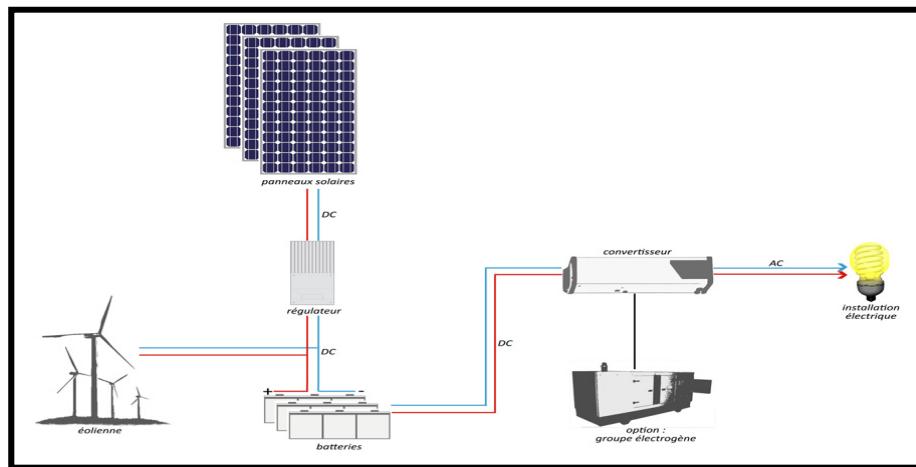


Figure 1.6 Système photovoltaïque hybride
Tirée de fmsolenergy.com

1.5 Avantages et inconvénients des systèmes photovoltaïque

Le passage à l'énergie photovoltaïque a été une solution durable et moins coûteuse pour des dizaines de comtés. Si les cellules photovoltaïques présentent de nombreux avantages pour la communauté, elles ont aussi quelques inconvénients. Et les mauvais côtés du passage au photovoltaïque sont surtout ressentis par les vieilles structures qui ne sont pas adaptées aux installations PV. Dans les deux prochaines sections les avantages ainsi que les inconvénients des systèmes photovoltaïques seront listés.

1.5.1 Avantages des systèmes photovoltaïques

Les systèmes photovoltaïques présentent plusieurs avantages et parmi eux on site :

- L'électricité produite par les cellules photovoltaïque est non polluante et silencieuse. Parce qu'ils n'utilisent pas d'autres ressources que le soleil, les systèmes photovoltaïques n'émettent pas de pollution nocive pour eau ou l'aire dans l'environnement, et n'épuisent pas les ressources naturelles.
- Les systèmes photovoltaïques sont silencieux et visuellement discrets.

- L'énergie solaire est une ressource renouvelable disponible localement. Il n'est pas nécessaire de l'importer d'autres régions ou pays. Cela permet de réduire les impacts environnementaux liés au transport et de réduire notre dépendance vis-à-vis des importations de pétrole. Contrairement aux combustibles qui sont extraits et récoltés, lorsque nous utilisons l'énergie solaire pour produire de l'électricité, nous n'épuisons ni n'altérons la ressource.
- Un système PV peut être construit à n'importe quelle taille en fonction des besoins énergétiques. En outre, le propriétaire d'un système PV peut l agrandir ou le déplacer si ses besoins énergétiques évoluent. Par exemple, les propriétaires peuvent ajouter des modules tous les deux ou trois ans, à mesure que leur consommation d'énergie et leurs ressources financières augmentent.

1.5.2 Inconvénients des systèmes photovoltaïques

Malgré les avantages multiples des systèmes PV dans la production, l'installation et les impacts environnementaux, ces systèmes présentent quelques inconvénients :

- Certains produits chimiques toxiques, comme le cadmium et l'arsenic, sont utilisés dans le processus de production du PV. Ces incidences sur l'environnement sont mineures et peuvent être facilement maîtrisées grâce au recyclage et à une élimination appropriée.
- L'énergie photovoltaïque est un peu plus chère à produire par rapport aux sources d'énergie conventionnelles comme le pétrole ou le gaz, en partie à cause du coût de mise en œuvre des dispositifs photovoltaïques et en partie à cause des rendements de conversion des équipements. Au fur et à mesure que l'efficacité de la conversion augmente et que les coûts de fabrication diminuent, le coût de l'énergie photovoltaïque deviendra de plus en plus compétitif par rapport aux combustibles traditionnels.
- L'énergie photovoltaïque est une source d'énergie variable. En effet la production d'énergie dépendant du soleil, les installations photovoltaïques peuvent ne pas produire d'énergie du tout pendant une certaines temps, ce qui peut entraîner une pénurie d'énergie si une trop grande partie de l'énergie d'une région provient de l'énergie photovoltaïque.

1.6 Module photovoltaïque

Les cellules PV sont les éléments de base des modules PV. Pour presque toutes les applications, la tension produite par une seule cellule est insuffisante. Par conséquent, les cellules sont connectées ensemble en série pour augmenter la tension. Plusieurs de ces chaînes de cellules en série peuvent être connectées en parallèle pour augmenter le courant. La figure 1.7 montre le passage d'une cellule photovoltaïques jusqu'à un champ de panneaux.

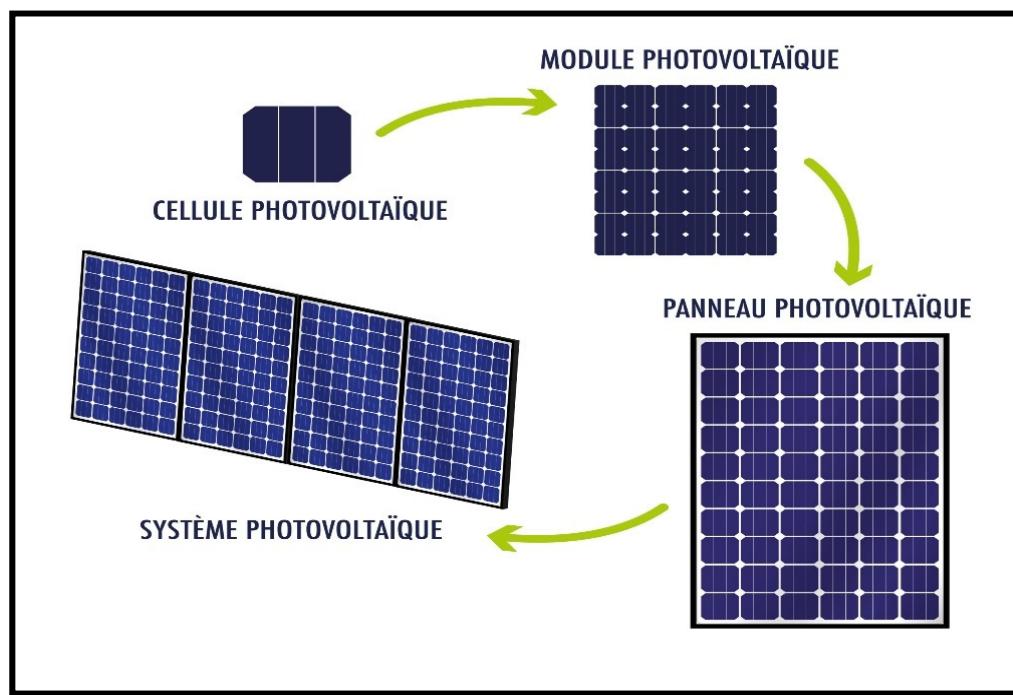


Figure 1.7 Passage d'une cellule photovoltaïque vers un champ de panneaux
Tirée de gre-enr.fr

1.6.1 Modélisation d'une cellule photovoltaïque

La cellule photovoltaïque est l'unité de base d'un module photovoltaïque et c'est l'élément chargé de transformer les rayons du soleil ou les photons directement en énergie électrique.

Le circuit équivalent d'une cellule photovoltaïque est présenté dans la figure 1.8 (Zerouali, Zouirech et al. 2019).

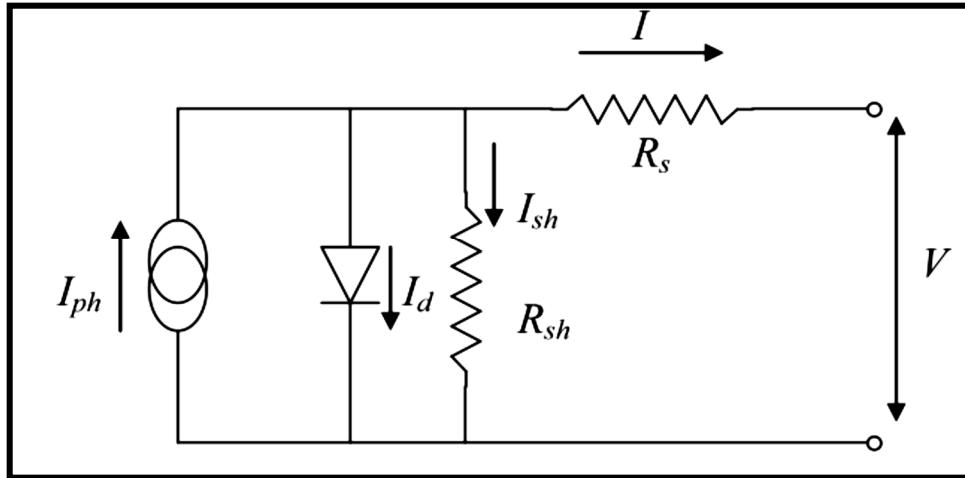


Figure 1.8 Circuit équivalent d'une cellule photovoltaïque
Zerouali, Zouirech et al. 2019

La cellule PV est caractérisée par trois types de courant de base, le photocourant I_{ph} produit par la cellule, le courant de jonction I_d et enfin le courant de la résistance R_{sh} . Ces trois courants sont calculés à partir des équations (1.1), (1.2) et (1.3) (Zerouali, Zouirech et al. 2019).

$$I_d = I_S \left(\exp \left(\frac{q \cdot (V + R_s \cdot I)}{N \cdot K \cdot T} \right) - 1 \right) \quad (1.1)$$

$$I_{ph} = [I_{SC} + K_1(T_C - T_{ref})] \frac{G}{G_{ref}} \quad (1.2)$$

$$I_{sh} = \frac{(V + R_s \cdot I)}{R_{sh}} \quad (1.3)$$

Et enfin le courant de sortie de la cellule est calculé à partir des équations (1.4) et (1.5).

$$I = I_{ph} - I_d - I_{sh} \quad (1.4)$$

$$I = [I_{sc} + K_t(T_c - T_{ref})] \cdot \frac{G}{G_{ref}} - I_s \cdot \left[\exp\left(\frac{q \cdot (V + R_s I)}{N.K.T}\right) \right] - \frac{(V + R_s \cdot I)}{R_{sh}} \quad (1.5)$$

Avec :

- I_{ph} est photocourant d'une cellule photovoltaïque
- I_s est le courant de saturation
- q est la charge d'un électron (1.602×10^{-19} C)
- V est la tension à la borne de la diode (V)
- K est la constante de Boltzmann (1.381×10^{-23} J/K)
- T est la température de jonction
- N est le facteur d'idéalité d'une cellule photovoltaïque
- R_s est la résistance série de la diode photovoltaïque
- R_{sh} est la résistance shunt de la diode photovoltaïque

1.6.2 Courbe caractéristique d'un module photovoltaïque

Les paramètres qui déterminent le fonctionnement d'un module photovoltaïque se reflètent dans leurs courbes caractéristiques, courant tension (I-V) et puissance tension (P-V).

- Courbe courant-tension I-V

Le courant de sortie dépend de l'irradiation actuelle. Plus l'irradiation est élevée, plus le courant est important. Cependant, la tension va se maintenir presque constante et elle ne va pas varier beaucoup, bien qu'elle augmente ou diminue l'irradiation. La figure 1.9 montre la courbe I-V d'un module PV pour 5 différentes valeurs d'irradiation et pour une température constante.

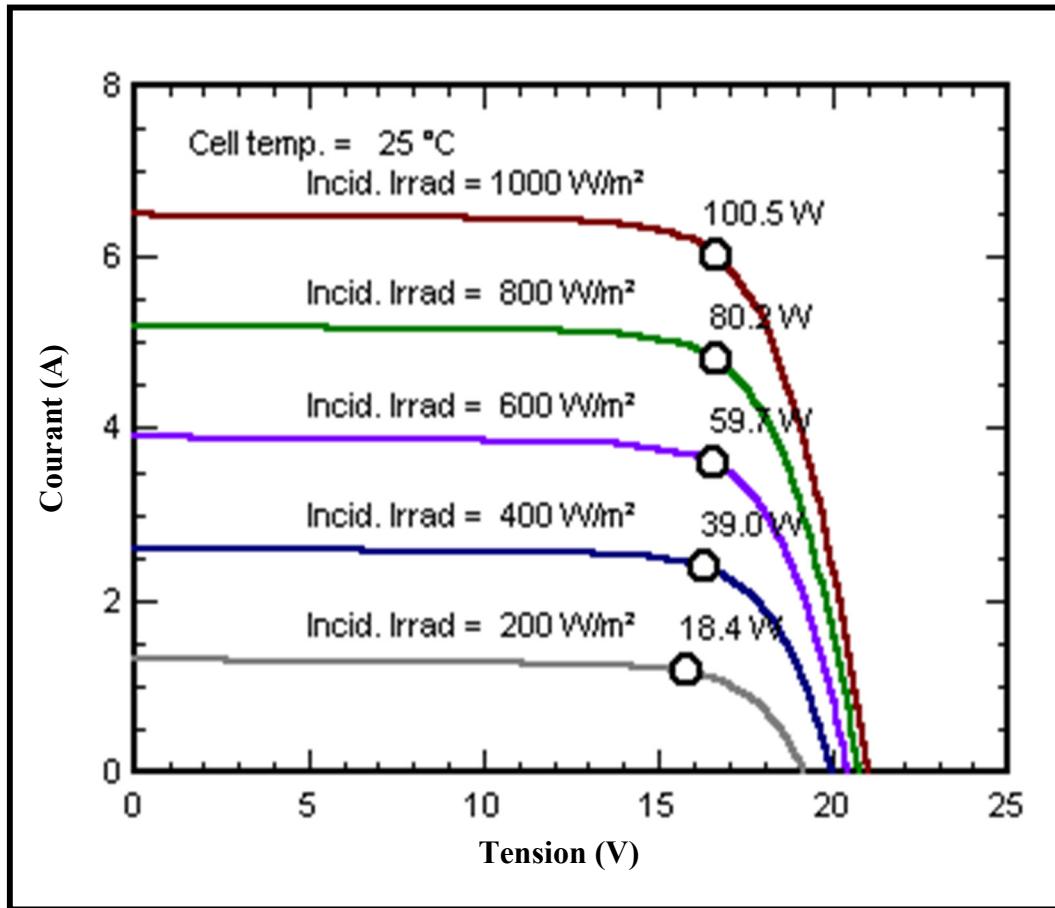


Figure 1.9 Courbe caractéristique I-V d'un module PV pour 5 différentes valeurs d'irradiation et pour une température constante (25 degrés)

En outre, l'efficacité d'un module photovoltaïque diminue lorsque la température augmente, principalement en raison de la diminution de la tension en circuit ouvert. Enfin, le pic du courant va rester plus insensible à la température, bien qu'elle augmente légèrement. La figure 1.10 montre la courbe I-V d'un module PV pour 5 différentes valeurs de température et pour une irradiation constante.

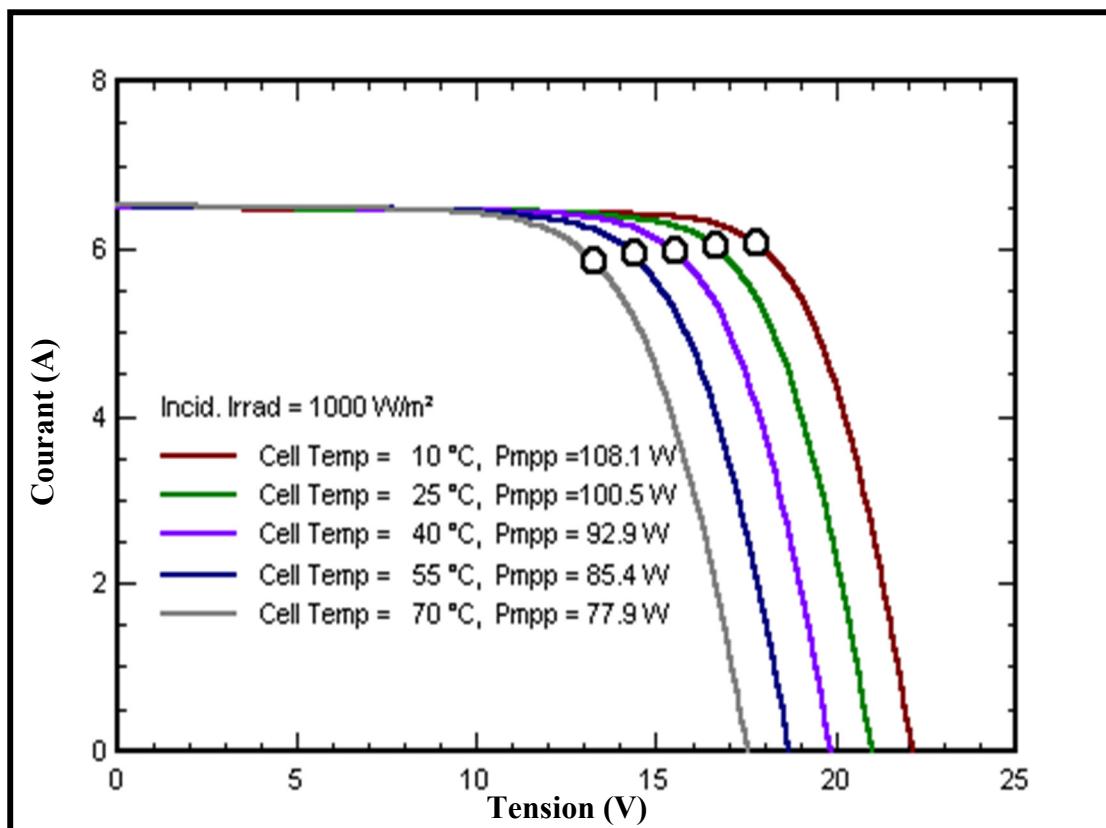


Figure 1.10 Courbe caractéristique I-V d'un module PV pour 5 différentes valeurs de température et pour une irradiation constante (1000 W/m^2)

➤ Courbe puissance-tension P-V.

L'influence de la variation de l'irradiation, à température constante, est fondamentale pour le calcul du point de puissance maximale (MPP). Plus l'irradiation est élevée, plus le MPP du module photovoltaïque est important. La figure 1.11 montre la courbe P-V d'un module PV pour 5 différentes valeurs d'irradiation et pour une température constante.

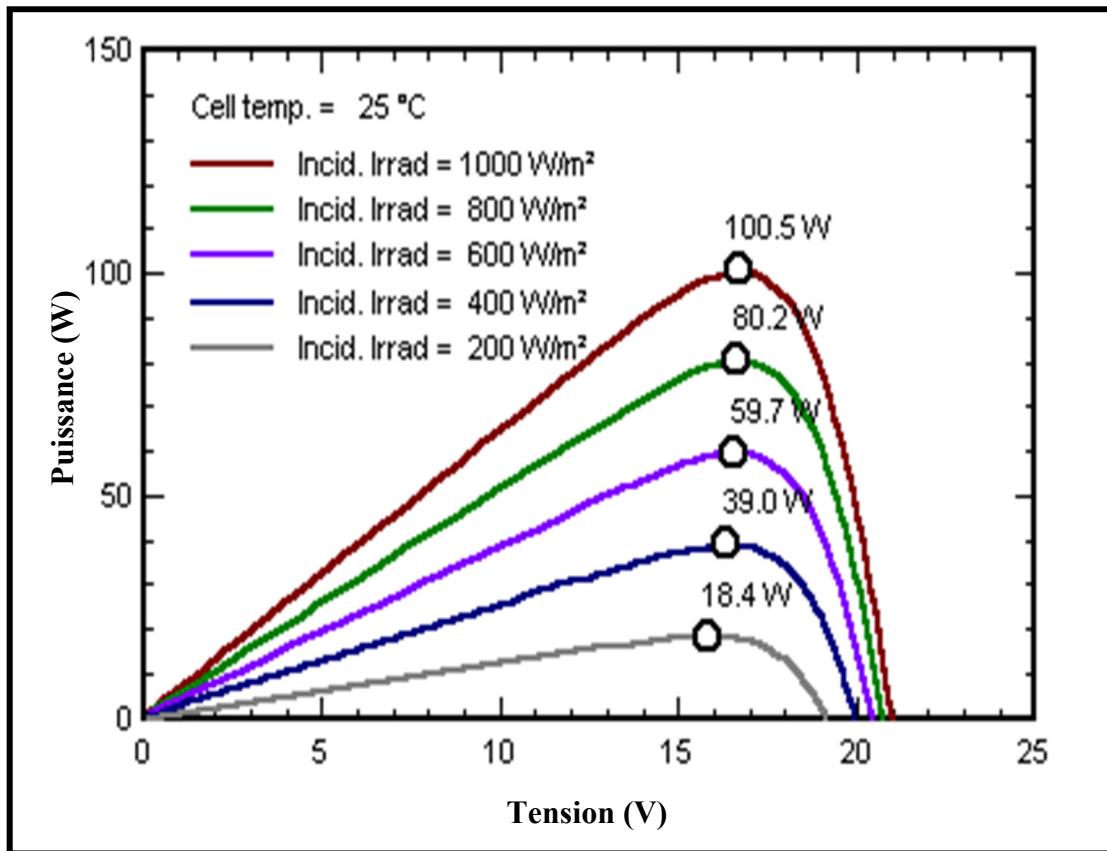


Figure 1.11 Courbe caractéristique P-V d'un module PV pour 5 différentes valeurs d'irradiation et pour une température constante (25 degrés)

Dans le cas où l'irradiation est constante, on peut voir l'influence de la température sur la tension. Plus la température est élevée, plus la tension est faible. La puissance reste presque linéaire jusqu'à une valeur. À partir de cette valeur, la puissance diminue également avec l'augmentation de la température. Ainsi, l'augmentation de la température fait diminuer la tension et la puissance de sortie. La figure 1.12 montre la courbe P-V d'un module PV pour 5 différentes valeurs de température et pour une irradiation constante.

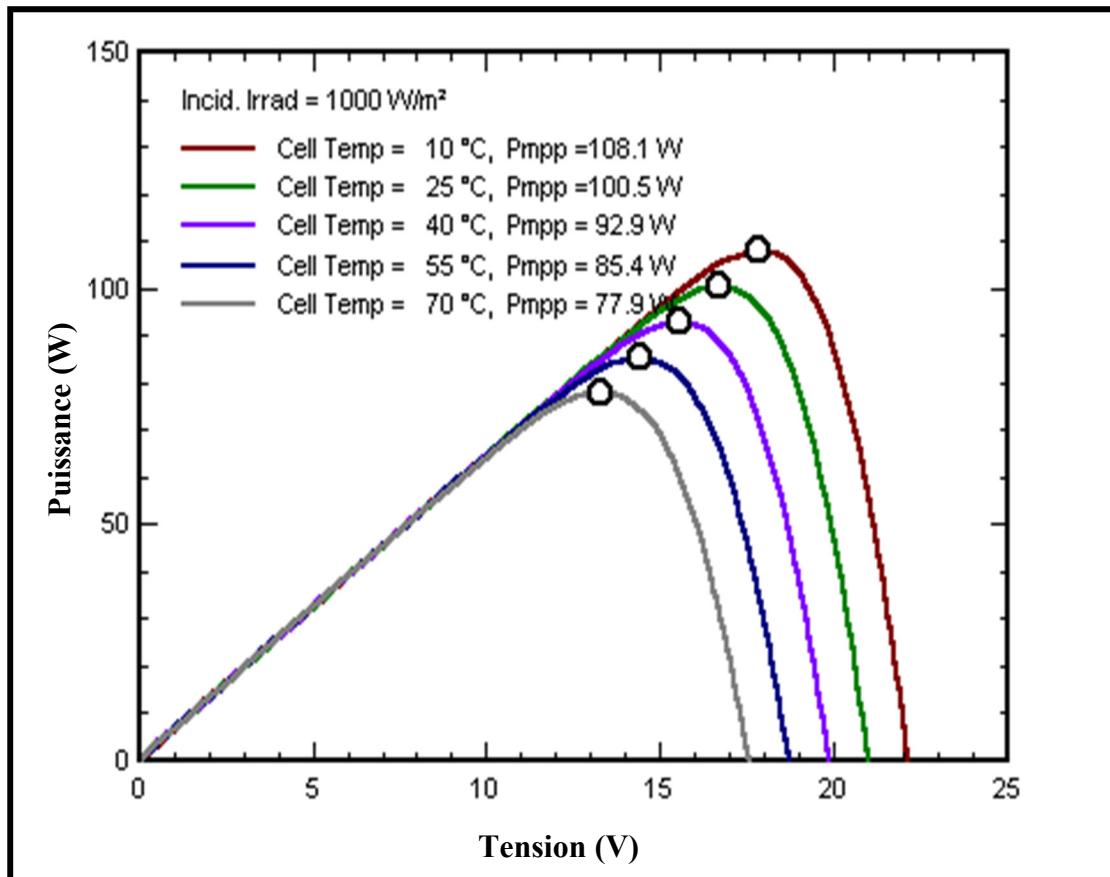


Figure 1.12 Courbe caractéristique P-V d'un module PV pour 5 différentes valeurs de température et pour une irradiation constante (1000 W/m²)

1.7 Convertisseur CC-CC Boost

1.7.1 Modélisation d'un convertisseur CC-CC Boost

Le convertisseur CC-CC Boost est un système qui transmet la tension de sortie à un niveau de tension plus élevé en augmentant la tension entrée du convertisseur. La figure 1.13 montre la forme du circuit de base d'un convertisseur CC-CC Boost (Zerouali, Zouirech et al. 2019).

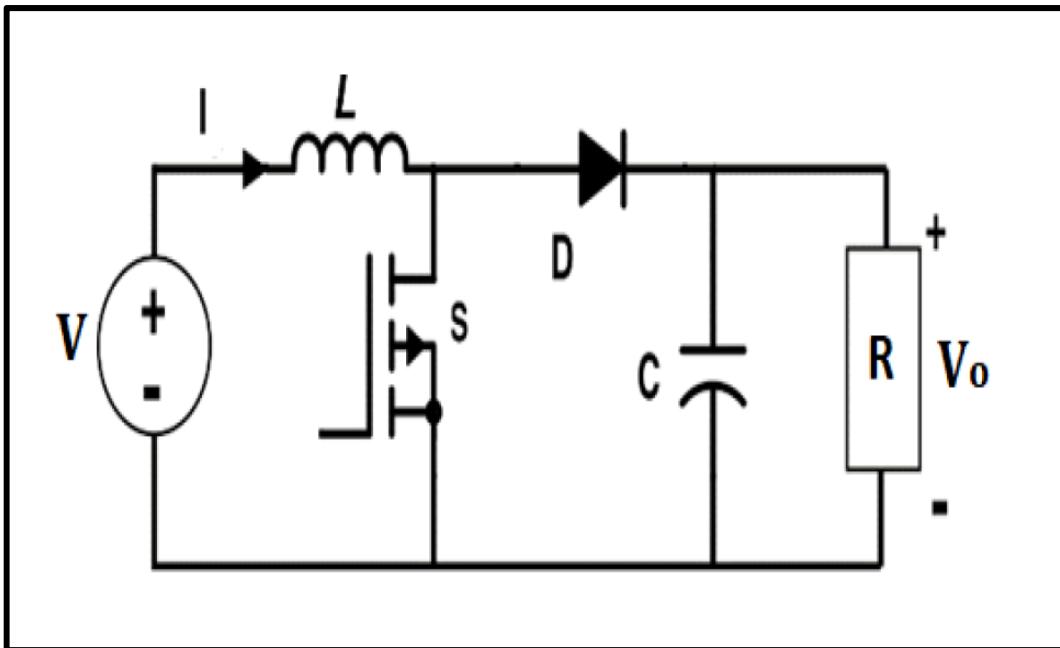


Figure 1.13 Circuit de base d'un convertisseur CC-CC Boost

Comme le montre la figure 1.13, le convertisseur est composé d'une diode, une inductance, une capacité et une résistance. Lorsque la commutation est transmise, la source complète le circuit via l'inducteur et l'interrupteur. Elle stocke de l'énergie sur l'inductance. Dans ce cas, la diode est en polarité inverse et la charge de sortie alimente le condensateur. Le courant du condensateur est élevé. Cela augmente la tension de sortie. De cette façon, la diode est bloquée et le circuit est divisé en deux parties différentes comme le montre la figure 1.14. La tension de sortie reste constante tant que la valeur RC est supérieure à la période de commutation.

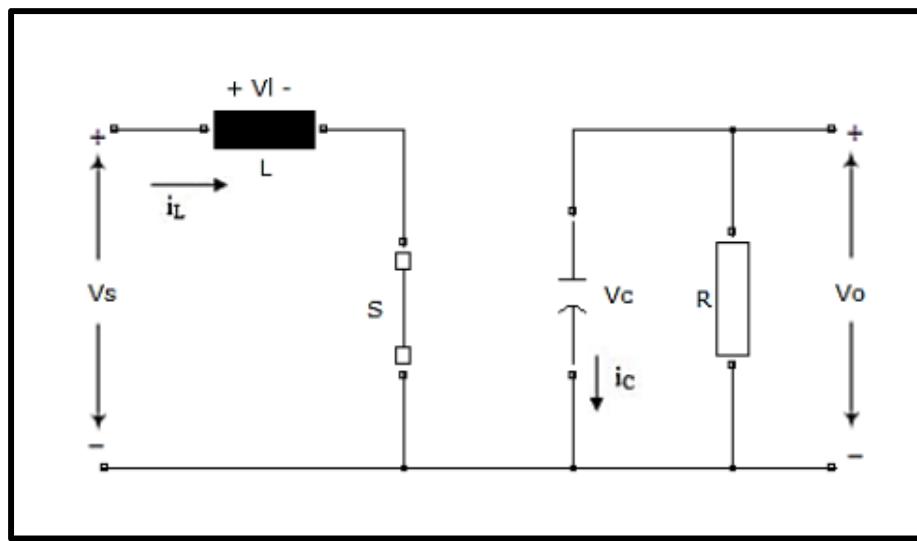


Figure 1.14 Circuit du convertisseur CC-CC Boost lors de la transmission de la commutation

Dès que la commutation bascule, le courant de charge passant par l'inductance commence à circuler à travers la diode vers le condensateur et la charge. L'inductance décharge son énergie et la polarité de la tension sur l'inductance est la même que la polarité de la source de tension et elle est connectée à la charge via la diode comme le montre la figure 1.15.

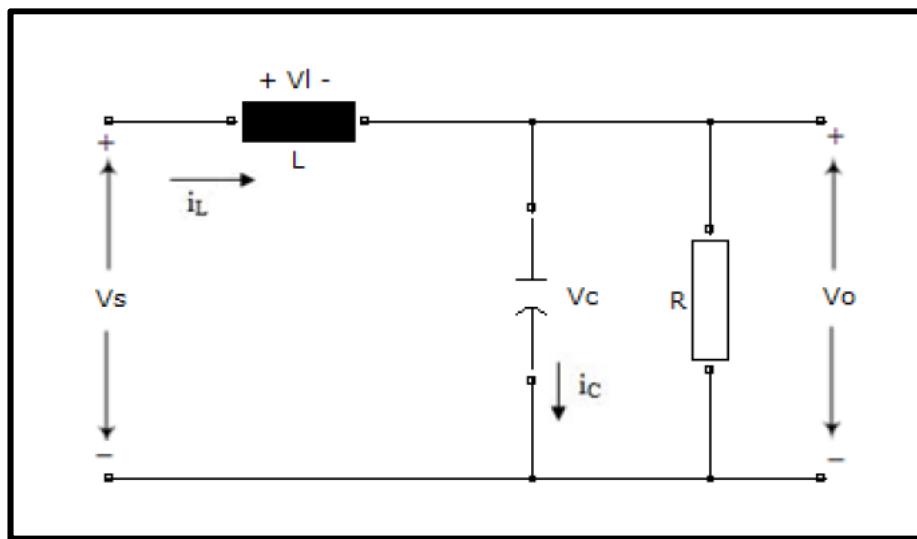


Figure 1.15 Circuit du convertisseur CC-CC Boost lors du basculement de la commutation

1.7.2 Calcul des paramètres d'un convertisseur CC-CC Boost

Le modèle mathématique du convertisseur CC-CC Boost est obtenu par l'application des lois de Kirchhoff à la base du modèle sur le schéma de base du convertisseur, présenté à la figure 1.13. Les équations (1.6) et (1.7) sont déduites à partir de l'état de l'interrupteur S :

Pour $t \in [0, \Delta T]$:

$$\frac{di}{dt} = \frac{V}{L}; \quad \frac{dV_0}{dt} = -\frac{V_0}{RC} K \quad (1.6)$$

Pour $t \in [\Delta T, T]$:

$$\frac{di}{dt} = \frac{V-V_0}{L}; \quad \frac{dV_0}{dt} = \frac{i}{C} - \frac{V_0}{RC} \quad (1.7)$$

Boualem, & Abdelmadjid et al. 2016, Saad, & Abdelaziz et al. 2018 décrivent l'équation (1.8) et (1.9) du gain de transfert de la tension pour un convertisseur CC-CC Boost comme suit :

$$V_0 = \frac{1}{1-D} V \quad (1.8)$$

$$I_0 = (1 - D)I \quad (1.9)$$

La valeur de l'inductance influence les performances du convertisseur CC-CC boost. Pendant l'état TON la valeur de l'inductance peut être donnée dans l'équation (1.10) (Unal, & Ali et al. 2018) :

$$L = \frac{V*D}{\Delta L_L * f} \quad (1.10)$$

Avec :

ΔL_L : Courant d'ondulation estimé de l'inducteur

f : Fréquence de commutation

D : Rapport Cyclique

Le choix de la valeur de la capacité dépend de la tension de sortie et peut s'écrire dans l'équation (1.11) (Unal, & Ali et al. 2018) :

$$C = \frac{I_0 * D}{D V_0 * f} \quad (1.11)$$

Avec :

ΔV_0 : Tension d'ondulation de sortie estimée

f : Fréquence de commutation

D : Rapport Cyclique

1.8 Méthode d'extraction du point de puissance maximum (MPPT)

Le suivi du point de puissance maximale (MPP) d'un réseau photovoltaïque est une étape essentielle d'un système PV. En effet, de nombreuses méthodes MPPT ont été introduites et de nombreuses variantes de chaque méthode ont été proposées pour surmonter des inconvénients spécifiques. Le grand nombre de méthodes proposées peut rendre difficile la détermination de la meilleure technique à adopter lors de la mise en œuvre d'un système PV. Les méthodes varient toutes en termes de complexité, de nombre de capteurs requis, de mise en œuvre numérique ou analogique, de vitesse de convergence, de capacité de suivi et de rentabilité. De plus, le type d'application peut avoir un impact significatif sur le choix de l'algorithme MPPT.

1.8.1 Méthode du courant de court-circuit (FCC)

La technique du courant de court-circuit est l'une des méthodes les plus simples car elle dépend des caractéristiques du système photovoltaïque. Le point de puissance maximale peut être atteint en utilisant le courant maximal comme courant de référence pour le contrôleur dans la relation suivante (1.12) (Fapi, & Wira et al. 2021) :

$$I_{mpp} = k * I_{cc} \quad (1.12)$$

Avec I_{mpp} est le courant du point de puissance maximale, k est un facteur qui varie entre 0.78 et 0.92 et I_{cc} est le courant de court-circuit.

La figure 1.16 présente le schéma bloc de l'algorithme FCC.

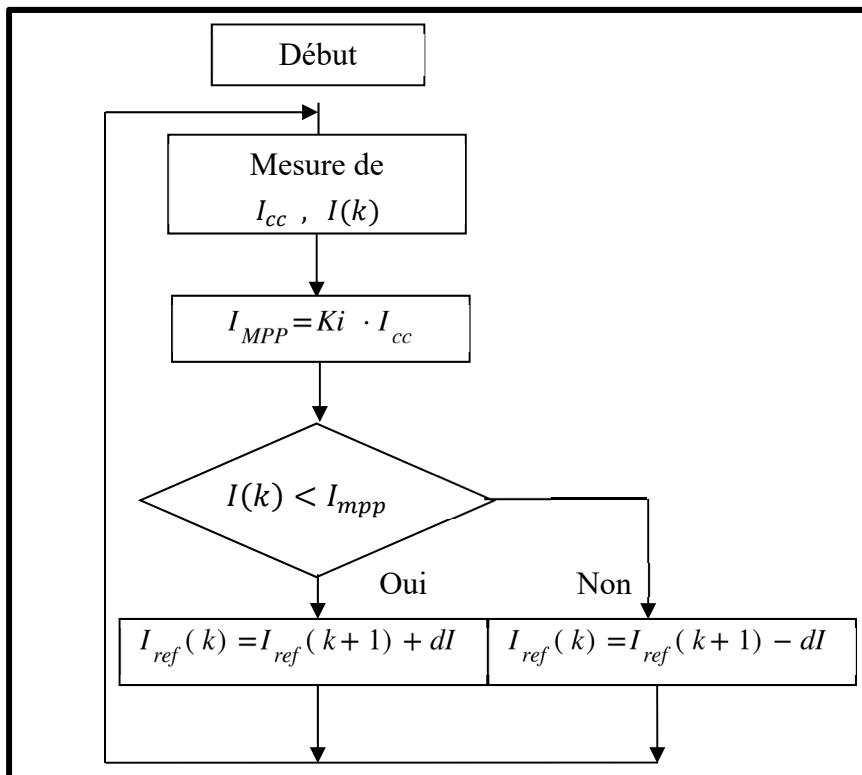


Figure 1.16 Schéma bloc de l'algorithme FCC

1.8.2 Méthode de la tension du circuit ouvert (FCO)

La technique de la tension du circuit ouvert est basée sur la relation linéaire entre la tension du circuit ouvert et la tension du point de puissance maximale. Cette relation est décrite dans l'équation (1.13) (Dmitry, & Saad et al. 2019) :

$$V_{mpp} = k * V_{co} \quad (1.13)$$

Avec V_{mpp} est la tension du point de puissance maximale, V_{co} est la tension du circuit ouvert et k est un facteur qui dépend des caractéristiques du système PV et qui peut varier entre 0.73 et 0.8. En effet, le point du fonctionnement du système PV sera maintenu près de la zone du point de puissance maximale en changeant la tension du système jusqu'à atteindre la tension optimale calculée. Le schéma bloc de l'algorithme est illustré dans la figure 1.17.

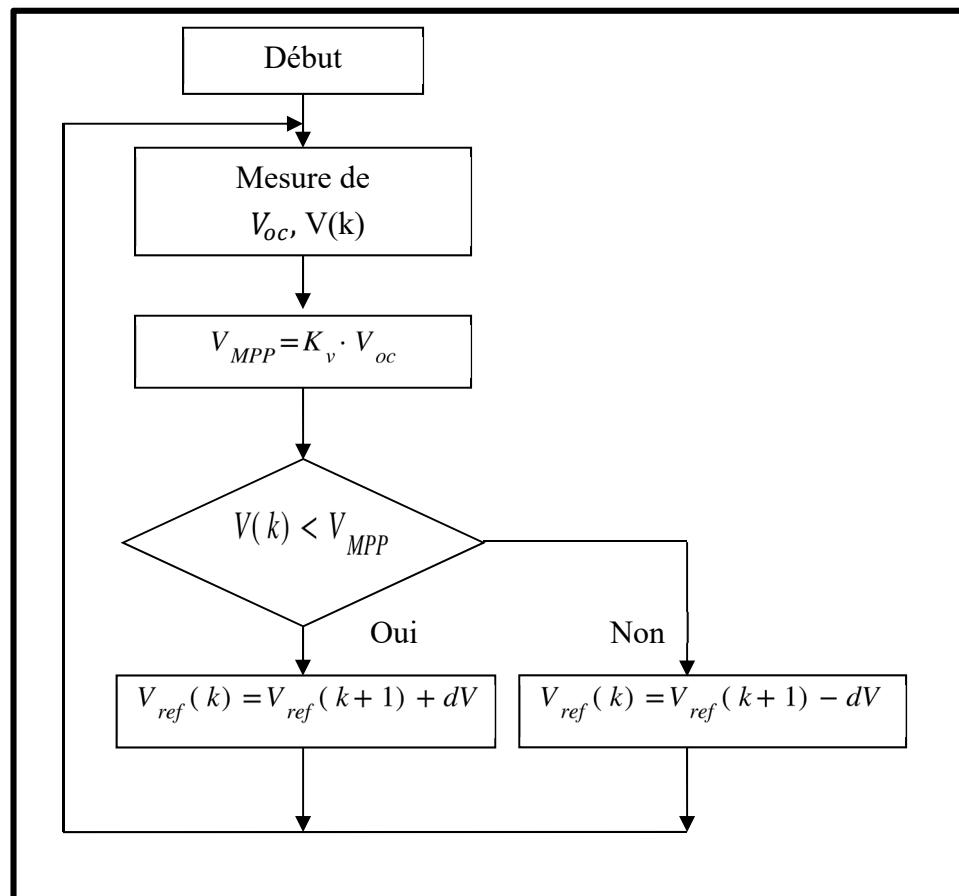


Figure 1.17 Schéma bloc de l'algorithme FCO

1.8.3 Méthode de la perturbation et observation (P&O)

L'algorithme de la perturbation et observation (P&O) est généralement le plus appliqué dans le contrôle de l'algorithme MPPT pour les panneaux PV (Selmi, & Abdul-Niby et al. 2014). Il présente une structure simple, un faible coût, une mise en œuvre facile, un nombre réduit de paramètres, la possibilité d'introduire des améliorations et peut aboutir à une efficacité de haut niveau. Cet algorithme dépend de l'étude de la relation entre la puissance de sortie du module PV et sa tension. Le comportement du panneau PV indiquant le MPP et le principe de fonctionnement est présenté dans la figure 1.18 qui indique que le changement résultant de la puissance PV qui est expliqué comme suit : lorsque le point de fonctionnement du module PV est sur le côté gauche de la courbe ($\Delta P/\Delta V$ est positif), ce qui signifie que la puissance de sortie du module PV augmente, la perturbation de la tension du module PV devrait être augmentée vers le MPP. Si le point de fonctionnement du module se trouve sur le côté droit de la courbe ($\Delta P/\Delta V$ est négatif), la perturbation de la tension du module PV doit être réduite pour atteindre la MPP.

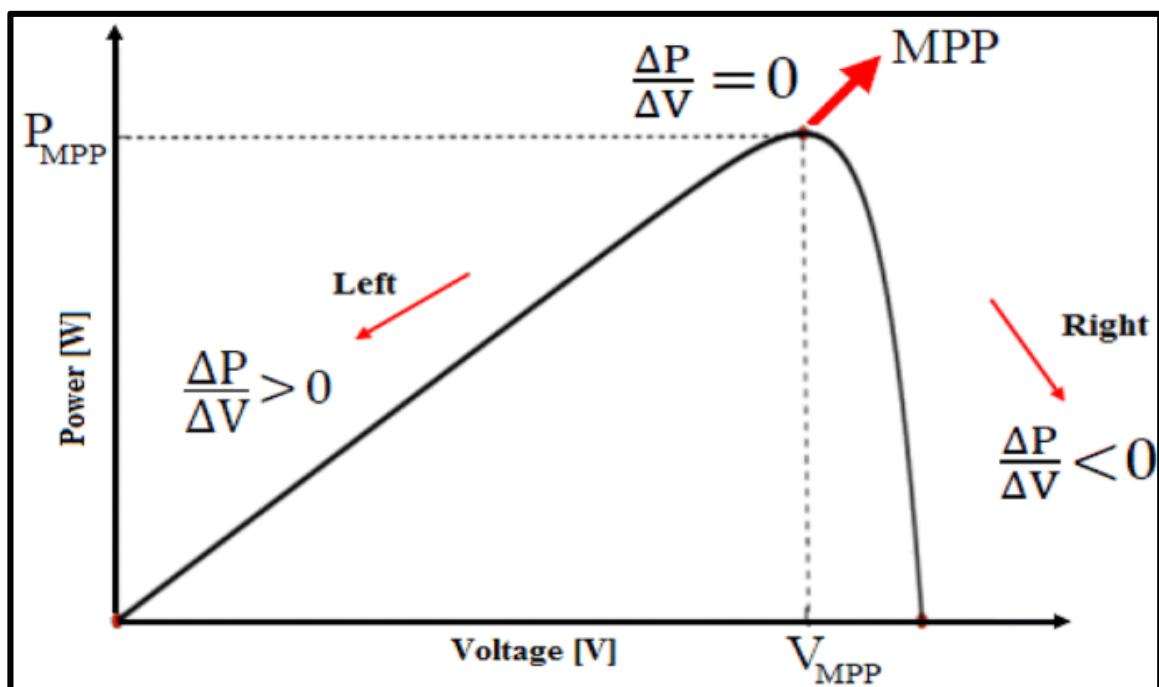


Figure 1.18 Principe de fonctionnement du point MPP pour une panneau PV

La figure 1.19 présente le schéma bloc de la mise en œuvre de l'algorithme P&O. Tout d'abord, la tension et le courant actuels du réseau PV sont mesurés. Après cela, le produit de la tension et du courant donne la puissance réelle du module PV. Ensuite, l'état est vérifié pour savoir si $\Delta P = 0$ ou non. Si ce statut est satisfaisant, alors le point de fonctionnement est au MPP. Si ce statut n'est pas satisfaisant, on vérifiera un autre statut, à savoir que $\Delta P > 0$. Si ce statut est satisfaisant, on vérifiera que $\Delta V > 0$. S'il est satisfaisant, cela indique que le point de fonctionnement se trouve à gauche du MPP. Si le statut $\Delta V > 0$ n'est pas satisfait, cela indique que le point de fonctionnement se trouve du côté droit de la MPP. Ce processus est continuellement répété jusqu'à ce qu'il atteigne le MPP. Ainsi, à tout moment, il existe un compromis entre les incrémentations et le taux d'échantillonnage dans l'algorithme P&O.

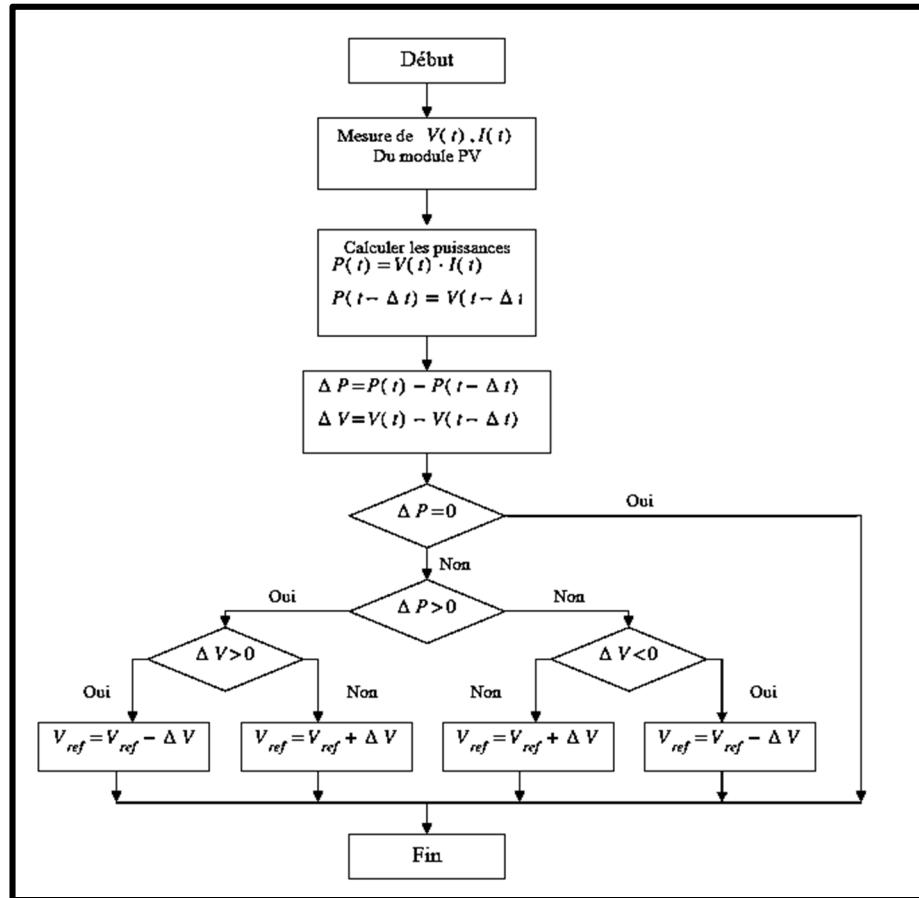


Figure 1.19 Schéma bloc de l'algorithme P&O

1.8.4 Méthode de la conductance incrémentale (INC)

Dans l'algorithme de conductance incrémentale (INC), le contrôleur mesure les changements incrémentiels de la tension et du courant du panneau PV pour prédire l'effet d'un changement de tension (Kriti, & Manju et al. 2018). Cet algorithme nécessite un calcul plus important dans le contrôleur, mais peut réagir plus efficacement aux changements rapides des conditions météorologiques que l'algorithme P&O. Comme l'algorithme P&O, des oscillations peuvent se présenter dans la puissance de sortie. Cette technique prend en entrée la conductance incrémentale ($\Delta I/\Delta V$) du champ photovoltaïque afin de déterminer le signe de la variation de la puissance par rapport à la tension ($\Delta P/\Delta V$). L'algorithme INC détermine le point de puissance maximale en faisant la comparaison entre la conductance incrémentale ($\Delta I/\Delta V$) et celle du réseau (I/V). Quand ces deux valeurs sont égales ($\Delta I/\Delta V = I/V$), la tension de sortie est égale à la tension au MPP. Le contrôleur réagit pour fixer cette tension jusqu'à ce qu'on ait un changement d'irradiation ou une répétition du processus. L'algorithme INC est basé sur le fait qu'au point de puissance maximale $\Delta P/\Delta V = 0$ et $P = VI$. L'algorithme de conductance incrémentale ne comporte que deux capteurs, des capteurs de tension et de courant, qui sont nécessaires pour mesurer la tension et le courant de sortie du dispositif PV. L'organigramme de la mise en œuvre de l'algorithme INC est illustré à la figure 1.20.

L'équation (1.14) décrivant mathématiquement l'algorithme INC peut être exprimée comme suit : La puissance de sortie de la source est écrite comme suit :

$$P = V * I \quad (1.14)$$

Le fait que $P=V \cdot I$ est la règle de la chaîne pour la dérivée des produits par rapport à la tension donnent l'équation (1.15) et (1.16) :

$$\frac{\Delta P}{\Delta V} = \frac{\Delta(VI)}{\Delta V} = \frac{I\Delta V}{\Delta V} + \frac{V\Delta I}{\Delta V} = I + \frac{V\Delta I}{\Delta V} \quad (1.15)$$

$$\frac{I}{V} * \frac{\Delta P}{\Delta V} = \frac{I}{V} + \frac{\Delta I}{\Delta V} \quad (1.16)$$

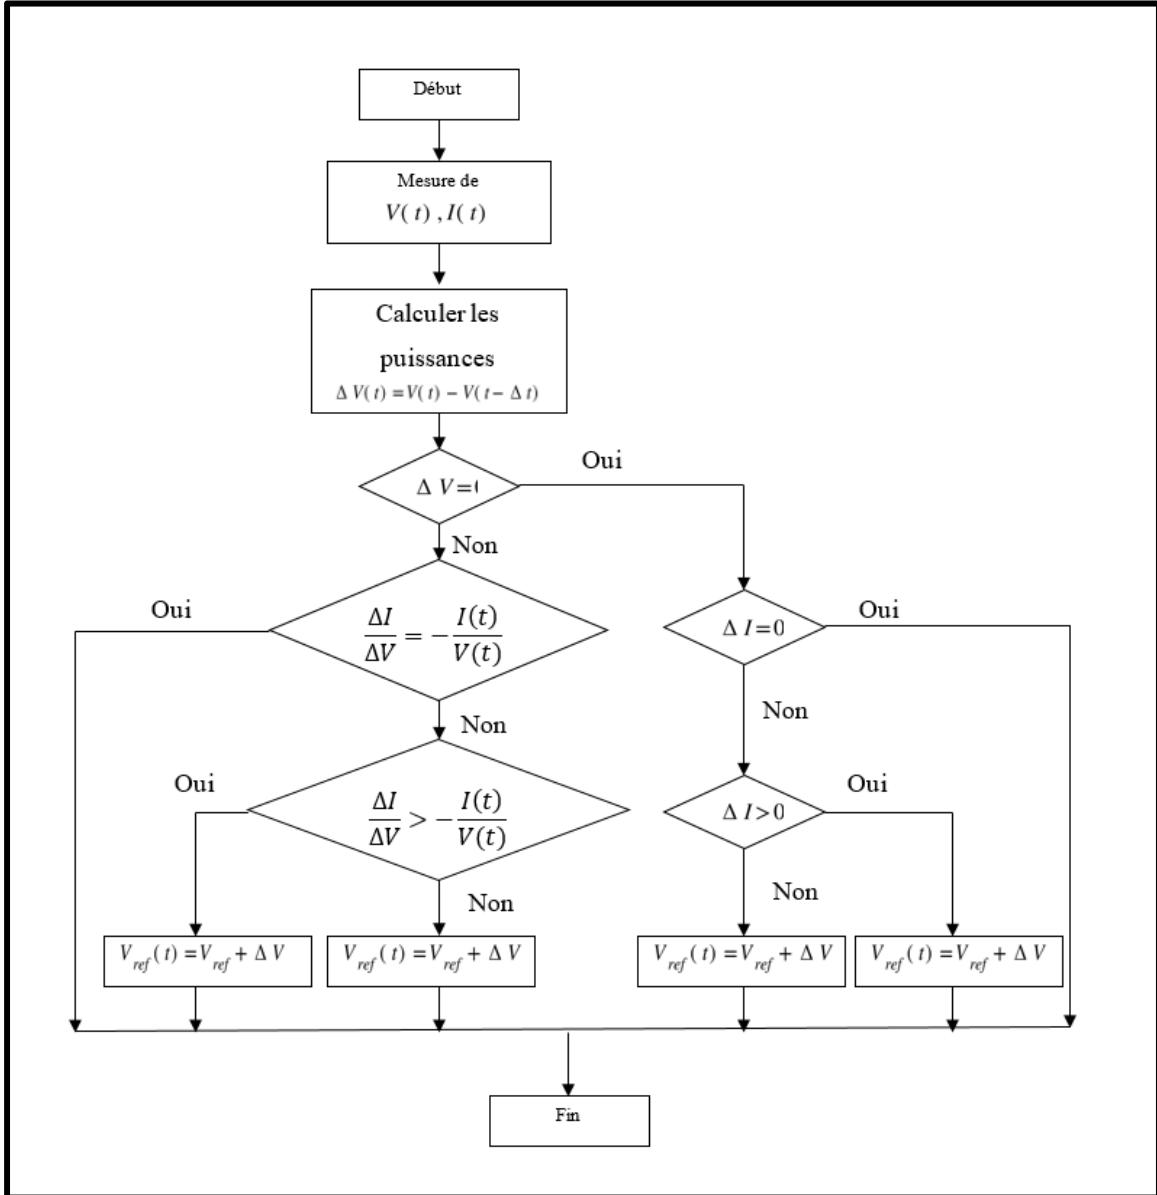


Figure 1.20 Schéma bloc de l'algorithme INC

Dans les conditions normales, la tension de sortie d'une source est positive. La tâche principale de cet algorithme est donc de rechercher le point de fonctionnement en tension pour lequel la conductance est égale à la conductance incrémentale. Ces concepts sont exprimés par les équations (1.17), (1.18) et (1.19) et représentés graphiquement sur la figure 1.20. L'algorithme INC dépend de la pente de la courbe P-V. La pente devient nulle au MPP, augmente (positive)

sur le gauche du MPP et diminue (négative) sur le côté droit du MPP. Les équations de base de cet algorithme sont les suivantes :

$$\frac{\Delta P}{\Delta V} > 0 ; \text{ sur le coté gauche du MPP} \quad (1.17)$$

$$\frac{\Delta P}{\Delta V} = 0 ; \text{ au MPP} \quad (1.18)$$

$$\frac{\Delta P}{\Delta V} < 0 ; \text{ sur le coté droit du MPP} \quad (1.19)$$

La pente ($\Delta P/\Delta V$) peut être calculée à l'aide de la tension et du courant de sortie du module PV. L'algorithme de conductance incrémentale fonctionne en différenciant la puissance de sortie du module PV par rapport à la tension et en fixant le résultat à zéro. Par conséquent, la relation entre la conductance instantanée (I/V) et la conductance incrémentale ($\Delta I/\Delta V$) peut être calculée sur la base des équations (1.20), (1.21) et (1.22) comme suit :

$$\frac{\Delta I}{\Delta V} \geq -\frac{I}{V} ; \text{ sur le coté gauche du MPP} \quad (1.20)$$

$$\frac{\Delta I}{\Delta V} = -\frac{I}{V} ; \text{ au MPP} \quad (1.21)$$

$$\frac{\Delta I}{\Delta V} \leq -\frac{I}{V} ; \text{ sur le coté droit du MPP} \quad (1.22)$$

1.9 Problématiques

1.9.1 Problématique de perte de puissance avec les algorithmes fractionnels

Les méthodes de MPPT dites fractionnelles (FCC et FCO) permettent généralement une estimation précise de la tension V_{mpp} et le courant I_{mpp} , puisque les facteurs de tension et de courant restent presque constants pour des changements d'irradiation et de température.

La tension en circuit ouvert (OCV) et le courant de court-circuit (SCC) sont échantillonnés périodiquement en déconnectant temporairement la charge. La durée et la fréquence du procédé d'échantillonnage a une influence directe sur la précision de la prédiction du V_{mpp} et I_{mpp} . Une fréquence élevée et des cycles d'utilisation rapides permettent d'améliorer la

précision de la prédiction, mais peuvent engendrer une augmentation des pertes au niveau de la puissance.

1.9.2 Problématique des conditions météorologiques avec les algorithmes P&O et INC

Parmi les différentes techniques utilisées, l'algorithme de suivi du point de puissance maximale perturbation et observation (P&O) et la conductance incrémentale sont les méthodes les plus couramment utilisées en raison de leur facilité de mise en œuvre. Deux problèmes principaux sont souvent rencontrés avec le MPPT basé sur P&O et INC :

- En présence d'une irradiation et d'une température qui varient lentement, le point de fonctionnement du système oscille autour du MPP, ce qui engendre la perte d'une quantité plus ou moins importante d'énergie disponible.
- En présence de conditions météorologiques qui changent rapidement, l'algorithme P&O peut être confus. Ceci est dû à la lenteur du suivi.

1.9.3 Problématique de robustesse et de fidélité des algorithmes MPPT basés sur l'intelligence artificielle

Beaucoup de méthodes basées sur l'intelligence artificielle ont été développé pour le suivi du point de puissance maximale. En effet, le contrôleur logique flou (FLC), les réseaux de neurones artificielles (ANN) et les système à inférence neuro-floue adaptatifs (ANFIS) sont parmi les techniques les plus utilisées. Ces systèmes nécessitent un apprentissage et un paramétrage spécifiques pour chaque application et chaque situation, ce qui entraîne une diminution de la fiabilité des modèles formés et de leur capacité à être adaptés à diverses situations et à différentes applications.

1.10 Objectifs de la recherche

Une efficacité de suivi plus élevée, une puissance de sortie optimale et une charge de fonctionnement fiable sont des caractéristiques importantes pour les consommateurs et les investisseurs, s'ils veulent être attirés par l'installation des systèmes PV. Le moyen le plus

efficace pour améliorer l'efficacité moyenne du suivi de la puissance maximale est de renforcer la stabilité et d'augmenter la fiabilité de la production du système PV, est d'utiliser la technique MPPT avec un système de conversion de puissance PV. Fondamentalement, la technique MPPT est un système de contrôle de la puissance qui fournit un rapport cyclique (D) approprié au système de conversion de puissance PV (convertisseur DC-DC) en fonction de la sortie et/ou de l'entrée du module PV pour capturer la puissance maximale en continu, ce qui permet d'obtenir une puissance maximale et de fournir une tension stable dans des conditions météorologiques variables. En général, plusieurs facteurs sont essentiels lorsqu'on cherche à concevoir la meilleure technique MPPT pour un système PV, notamment le coût, l'efficacité, la perte d'énergie, le temps de poursuite, le niveau d'oscillation, la précision de la poursuite MPP et le type de mise en œuvre. En tenant compte de ces éléments, de nombreux types de méthodes MPPT ont été développés pour les systèmes PV, qui peuvent être divisés en deux types : les méthodes classiques (itératives) et les méthodes d'intelligence artificielle. L'objectif principal de cette recherche est de proposer des techniques MPPT communes basées sur l'intelligence artificielle pour un système PV et de la comparer par la suite avec les méthodes conventionnelles.

Les principaux objectifs de ce mémoire sont les suivants :

- La modélisation d'un système PV connecté à une charge conçu à l'aide d'un environnement MATLAB pour évaluer la fonctionnalité d'un module PV. Ce système PV est composé d'un champ PV, d'un convertisseur élévateur DC- DC avec un contrôleur MPPT et une charge.
- Concevoir une technique basée sur le contrôleur logique flou pour améliorer les techniques P&O et INC afin d'avoir un gain en rendement de ces dernières.
- Développer un contrôleur MPPT basé sur système d'inférence neuro-floue adaptatif.
- Tester les différentes méthodes MPPT développées pour les comparer sur la base de leurs caractéristiques communes.

1.11 Méthodologie

Pour atteindre les objectifs de la recherche, le développement des deux algorithmes à base du contrôleur à logique floue et les systèmes d'inférences neuro-floue se fera en quatre étapes. La méthodologie de la recherche est expliquée comme suit :

Dans la première étape, nous effectuerons une revue de la littérature de la plupart des algorithmes MPPT afin de conclure sur leurs avantages et inconvénients.

Ensuite, nous aborderons les méthodes MPPT conventionnelles : la perturbation et observation et la conductance incrémentale, un contrôleur à logique floue et un contrôleur à base d'un système d'inférence neuro-floue seront simulés sur l'outil MATLAB/Simulink afin de tirer les avantages et les limites de chaque méthode.

Puis, une étude approfondie des contrôleurs à logique floue et les systèmes d'inférences neuro-floue sera faite, pour identifier les inconvénients des contrôleurs MPPT proposés dans des études antérieures.

Après, nous réaliserons une nouvelle méthode de contrôleur MPPT à base d'un contrôleur à logique floue sera étudiée pour combiner les avantages des méthodes conventionnelles et les contrôleurs à logique floue et minimiser leurs limites.

Pour les méthodes conventionnelles, une vitesse de suivi réduite et des oscillations élevées autour du MPP seront appliquées.

Pour les méthodes à base de contrôleur à logique floue : pas de fiabilité de suivi face aux différentes configurations du système.

Enfin, une nouvelle méthode basée sur les systèmes d'inférence neuro-floue sera étudiée afin d'obtenir un contrôleur adapté à plusieurs configurations et applications sur les panneaux

photovoltaïques. Plusieurs apprentissages seront effectués afin d'arriver à synthétiser le meilleur modèle.

Toutes les méthodes étudiées seront testées et évaluées à l'aide de l'outil MATLAB/Simulink.

CHAPITRE 2

AMÉLIORATION DES ALGORITHMES P&O ET INC PAR L'INTEGRATION DES CONTROLEURS À LOGIQUE FLOUE

2.1 Introduction

L'extraction de la puissance maximale disponible peut être réalisée en suivant le point de puissance maximale sur la courbe puissance-tension (P-V) dans des conditions de fonctionnement variables telles que les changements d'irradiation, les changements de température et les changements de charge. Ce mécanisme de suivi détermine la meilleure valeur de tension du système et il est réalisé à l'aide du MPPT (Maximum Power Point Tracker). Le MPPT est l'intermédiaire entre les panneaux PV et le reste du système électrique. Il se compose d'un convertisseur de puissance CC-CC et d'un contrôle qui observe le courant et la tension PV et, sur la base des algorithmes perturbation & observation (P&O) et la conductance incrémentale (INC), ajuste le rapport cyclique du convertisseur de puissance Boost CC-CC. En effet, les deux algorithmes agissent sur ce rapport afin d'avoir la bonne valeur pour des entrées (irradiation, température et charge) bien définies. Ces algorithmes ont connu beaucoup de succès au niveau de la mise en œuvre et la configuration. Toutefois ils présentent des limites au niveau du temps du suivie pour atteindre le point de puissance maximale (MPP) et parfois des sorties du système indésirables face à des changements brusques des conditions météorologiques. Dans ce chapitre, une nouvelle méthode d'optimisation des algorithmes MPPT P&O et INC basée sur un contrôleur à logique floue pour un système PV a été introduite.

2.1.1 Études antérieures sur les MPPT à base des FLC

Comme mentionné au chapitre 1, la méthode P&O-MPPT est une méthode populaire pour le PV-MPPT en raison de son faible coût et de sa mise en œuvre simple. Cependant, elle pose de nombreux défis, tels qu'une vitesse de convergence plus faible, une oscillation élevée autour d'un point de puissance maximale MPP, et un problème de dérive associé à un changement

rapide de l'irradiance (Neil & Luis, et al. 2010). Plusieurs modifications ont été introduites sur la base d'une courbe puissance-tension (P-V), mais elles sont considérées comme des solutions insuffisantes pour résoudre tous ces problèmes. Par conséquent, des techniques d'intelligence artificielle basées sur le MPPT ont été proposées pour résoudre les problèmes importants des méthodes MPPT classiques (Abdourraziq & Maaroufi, et al. 2014). De plus, ces techniques n'ont pas besoin de paramètres précis ou de mathématiques complexes pour gérer le système (Napporn & Suttichai 2002). En particulier, la technique FLC-MPPT est l'un des contrôleurs les plus puissants pour un système PV en raison de sa vitesse de convergence élevée et de sa faible fluctuation autour du MPP (Salah & Ouali 2010), (Saban & Neemi, et al. 2017). De plus, elle ne nécessite pas de données d'apprentissage, ce qui lui permet de fonctionner pour différents types de modules PV avec la même conception MPPT. Cependant, les principaux inconvénients sont le problème de dérive susmentionné associé à la variation de l'irradiance et une mise en œuvre complexe par rapport aux méthodes MPPT classiques (Trevor & Xiaofeng 2016), (Muhammad & Mohd, et al. 2014).

Plusieurs types de modifications ont été proposés pour résoudre ces problèmes. Parmi elles, Soufi & Bechouat et al. ont utilisé un algorithme d'optimisation par particules swarm (PSO) pour ajuster le rapport cyclique du convertisseur surveiteur dans la bonne direction pour le FLC-MPPT conventionnel lorsque le rayonnement solaire d'entrée change rapidement. Guenounou & Ajhou et al. ont conçu un contrôleur de gain basé sur l'approche FLC pour l'adaptation en ligne de la taille du pas du FLC-MPPT conventionnel. Alajmi & Ahmed et al. ont développé un nouveau FLC-MPPT basé sur un algorithme de montée en puissance pour un système PV autonome. Harrag & Messalti ont présenté une technique améliorée de suivi du point de puissance maximale en utilisant l'algorithme Fuzzy-IC pour un réseau PV et des piles à combustible. Kottas & Boutalis et al. ont amélioré la méthode FLC-MPPT conventionnelle en ajoutant des réseaux cognitifs flous. Bien que ces propositions réduisent les oscillations autour du MPP et évitent le problème de dérive lors des changements d'irradiation, leur mise en œuvre matérielle devient plus complexe en raison d'une unité de contrôle supplémentaire.

Par conséquent, Obeidi & Zerhuerras et al. ont utilisé un algorithme génétique (AG) pour optimiser les fonctions d'appartenance conçues du contrôleur FLC-MPPT conventionnel pour lequel la base floue avait déjà été créée. De même, Gupta & Garg ont présenté un système de suivi du point de puissance maximale basé sur un système de contrôle asymétrique basé sur un processus de fonctions floues asymétriques pour minimiser le temps de traitement plus long que le FLC-MPPT conventionnel. Avec la même idée, Blaifi & Moulahoul et al. ont présenté le suivi du point de puissance maximale en modélisant l'algorithme de logique floue à l'aide d'un arbre modèle M5P. Subiyanto et al. ont utilisé un HNN (Hopfield neural network) pour régler automatiquement les fonctions d'appartenance conçues du FL-MPPT, au lieu d'adopter une approche par essais et erreurs. De même, Nabipour & Razaz et al. ont conçu un système amélioré de suivi du point de puissance maximale basé sur une logique floue indirecte pour les systèmes PV.

Les résultats de Gupta & Garg indiquent que le contrôleur flou optimisé a obtenu de meilleures performances, des réponses rapides avec moins d'oscillations et a évité le problème de dérive. Cependant, l'implémentation de toutes ces méthodes est plus complexe que pour les techniques MPPT classiques.

2.2 La logique floue

2.2.1 Définition de la logique floue

La logique floue a été créée par Lofti A. Zadeh en 1965 à partir de sa théorie des sous-ensembles flous. Les entités floues sont une façon mathématique de représenter l'imprécision du langage humain, elles peuvent être considérées comme une application de la théorie classique des ensembles. La logique floue est appelée aussi "logique linguistique" en raison du fait que ses valeurs de vérité sont des mots du vocabulaire courant : "plutôt vrai, plutôt faux, loin, assez loin, assez près, fort, faible...". La logique floue est utilisée pour étudier la représentation des connaissances incertaines, pour approximer le raisonnement et pour modéliser les notions vagues du langage naturel.

La logique floue fonctionne en désignant et en appliquant des règles qui combinent les entrées d'un expert avec les sorties souhaitées. Il existe généralement quatre étages déterminants de la logique floue : l'interface de fuzzification, la base de connaissance, le bloc d'inférence et l'interface de défuzzification. Ces quatre blocs sont expliqués ci-dessous. La figure 2.1 montre la structure principale d'un système de logique floue.

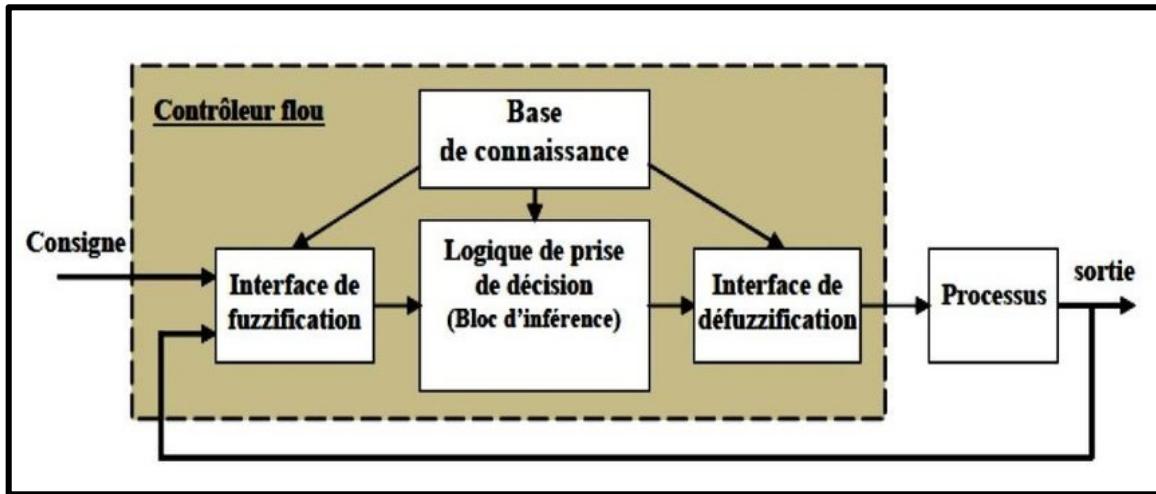


Figure 2.1 Structure principale d'un contrôleur logique floue

- L'interface de fuzzification transforme les entrées en des variables linguistiques que le bloc d'inférence peut ensuite utiliser pour désigner et suivre des règles.
- La base de connaissances comporte des règles Si-ALORS. Ces règles comprennent généralement des quantifications en logique floue effectuées par un expert afin d'atteindre un contrôle optimal.
- Le bloc d'inférence imite de manière optimale la prise de décision des experts en comprenant les informations et en les appliquant, toujours dans le but de contrôler de manière optimale les facteurs d'entrée.
- L'interface de défuzzification transforme les résultats du bloc d'inférence en entrées numériques utilisables qui seront des entrées du système (processus).

2.2.2 La fuzzification

La fuzzification est un processus par lequel des valeurs clairement délimitées sont rendues floues. Pour réaliser la fuzzification, il faut d'abord définir les variables et les termes linguistiques à utiliser. Les valeurs numériques ne sont pas utilisées dans ce processus ; ce sont plutôt des mots et/ou des phrases issues d'un langage naturel qui constituent les variables d'entrée et de sortie. Pour démarrer le processus, une variable linguistique spécifique est décomposée en ses termes linguistiques composites. Prenons, par exemple, un système de panneau photovoltaïque. Dans ce système, l'irradiation solaire (Ir) est la variable linguistique qui désigne la quantité de lumière projeté sur le panneau, qui peut être décrite en termes linguistiques généraux comme "grande" ou "petite". En partant de ce point, irradiation (Ir) = {trop grande, grande, moyenne, petite, trop petite} peut alors servir d'ensemble de décomposition pour la variable linguistique irradiation. Les caractéristiques individuelles de cette décomposition sont étiquetées comme des termes linguistiques et représentent une partie des valeurs totales de l'irradiation. Ensuite, afin de traduire les données d'entrée qui sont numériques en termes linguistiques flous, des fonctions d'appartenance seront appliquées.

2.2.3 La fonction d'appartenance

La fonction d'appartenance est un moyen d'exprimer graphiquement le niveau de participation des entrées. Elle attribue une valeur aux entrées qui peuvent également servir de chevauchements fonctionnels entre les entrées. Ce faisant, la fonction d'appartenance influence fortement la réponse de sortie. Un facteur déterminant de la fonction d'appartenance est sa configuration c'est-à-dire sa forme. Les différentes formes possibles sont les suivantes : gaussienne, triangulaire, trapézoïdale, en cloche généralisée et sigmoïdale. Parmi celles-ci, la forme triangulaire est la plus couramment utilisée, et le degré de la fonction d'appartenance se situe généralement dans la plage [0 1]. Les définitions et les graphiques des différentes fonctions d'appartenance sont illustrés à la figure 2.2.

En outre, les fonctions d'appartenance désignent les différents éléments d'un ensemble comme étant soit discrets, soit continus. La fonction d'appartenance de forme discrète se présente sous

la forme d'une liste, tandis que la forme continue est une fonction mathématique, voir un programme. Généralement, la forme discrète est plus couramment appliquée. Une fonction d'appartenance triangulaire comprend des segments de ligne droite et elle est facile et pratique à appliquer dans le cadre d'une commande floue. Cependant, l'approche de la fonction d'appartenance gaussienne est plus adaptée lorsqu'une sortie lisse et continue est souhaitée.

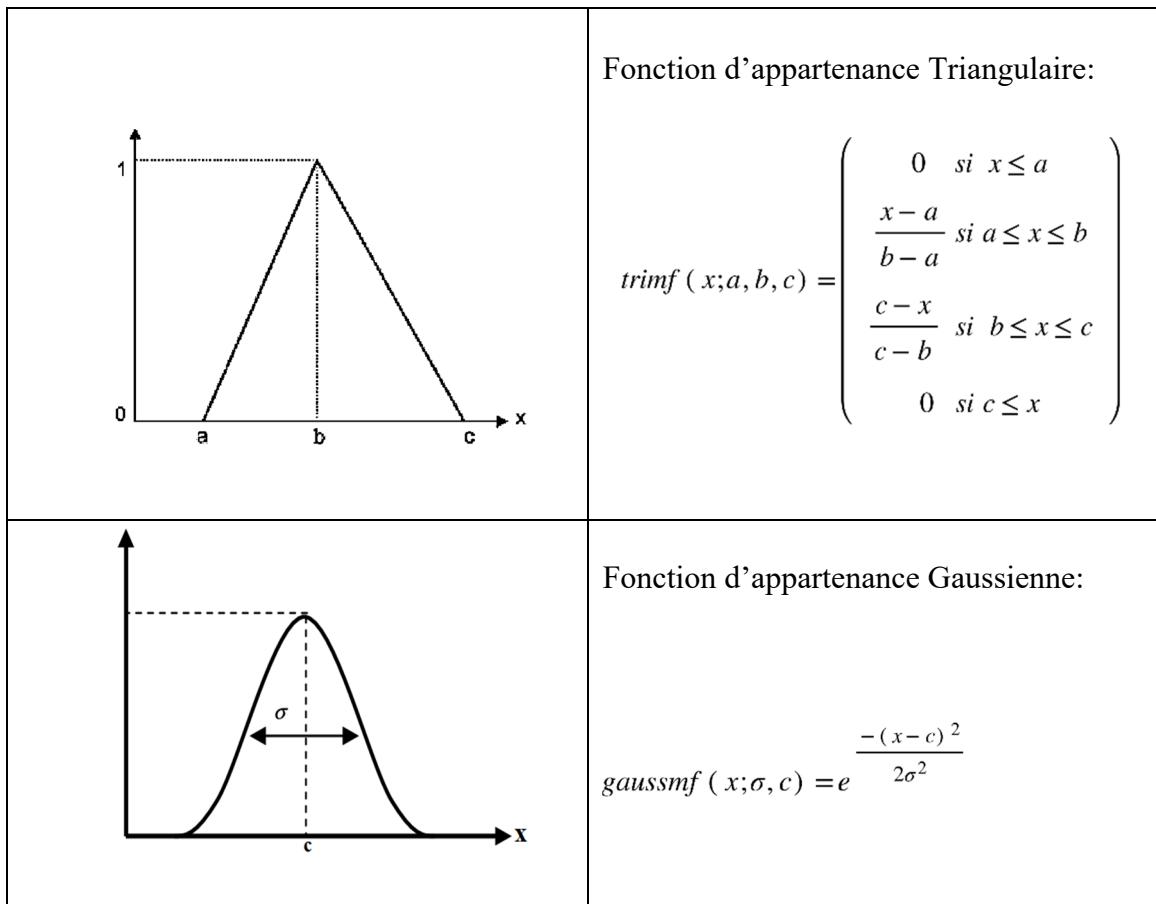


Figure 2.2 Graphiques des différentes fonctions d'appartenance d'un contrôleur logique floue

2.2.4 Les règles floues

Des règles floues sont développées pour contrôler les variables de sortie dans un système qui comporte un contrôleur logique floue. L'objectif principal des systèmes flous est de créer une

base théorique permettant d'établir des hypothèses et des associations logiques entre des termes de référence inexacts. Dans les systèmes technologiques de logique floue, on appelle cela le raisonnement approximatif. Les principaux sujets et verbes de la logique floue sont constitués d'ensembles flous et d'opérateurs flous, ou d'énoncés de règles dites "Si-Alors". Ces derniers sont appliqués lors de l'élaboration des énoncés conditionnels "Si-Alors" qui constituent l'identité et la base de la logique floue. Ainsi, par exemple, si une règle floue affirme que si x est A , alors y doit être B si A et B sont des valeurs désignées par des ensembles flous stipulant une plage de X et Y , respectivement. Dans cette règle, la partie " Si " est considérée comme l'antécédent ou la prémissé, tandis que la partie " Alors " est désignée comme le conséquent conditionnel ou la conclusion. En fin de compte, une règle floue est, à la base, une règle Si-Alors qui comporte à la fois des conditions et une conclusion. Le processus de contrôle par logique floue part d'un ensemble de données d'entrée provenant d'un nombre quelconque de capteurs (tension, courant, irradiation, température) ; ces données sont ensuite introduites dans le système de contrôle. Simultanément, les valeurs de ces variables d'entrée subissent une modification appelée fuzzification, qui transforme les valeurs discrètes en une large gamme de valeurs. Les entrées floues sont ensuite mesurées par rapport à une série de règles de production, et les règles sélectionnées génèrent les sorties. Enfin, les données de sortie sont défuzzifiées par des commandes de contrôle.

2.2.5 La défuzzification

Le processus de défuzzification est un moyen de transformer la sortie floue du bloc d'inférence en une sortie clairement définie en appliquant des fonctions d'appartenance telles que celles utilisées lors de la fuzzification. Les exemples d'approches de défuzzification comprennent le centre de gravité (COG), la bissectrice de surface (BOA), la moyenne pondérée, la moyenne du maximum (MOM), le premier des maxima et le dernier des maxima. Bien que chaque procédure de défuzzification soit basée sur les propriétés de l'application, le choix d'une stratégie de défuzzification appropriée est basé sur l'expérience.

2.3 Méthodologie

2.3.1 Système étudié

Les techniques MPPT basées sur des algorithmes conventionnels (P&O, INC) prennent généralement en entrée la tension et le courant générés par le panneau. Ses méthodes sont incrémentales car elles prennent en entrée le pas incrémental fixé selon une règle, ni trop grand pour éviter une grande oscillation autour du MPP, ni trop petit pour éviter une lente vitesse de suivi. Ainsi, en analysant le problème d'un point de vue logique, le pas incrémental peut être interprété comme une variable floue. Nous avons donc développé une méthode hybride basée sur la logique floue qui fournit à l'algorithme P&O et INC le paramètre d'incrémentation adapté à la position de fonctionnement du système. Ceci est mis en place pour corriger le problème des algorithmes de suivi du point de puissance maximale, nous voulons donc avoir le moins d'oscillation autour du MPP et une vitesse de suivi élevée et donc une meilleure performance. Le schéma fonctionnel du modèle proposé est présenté à la figure 2.3.

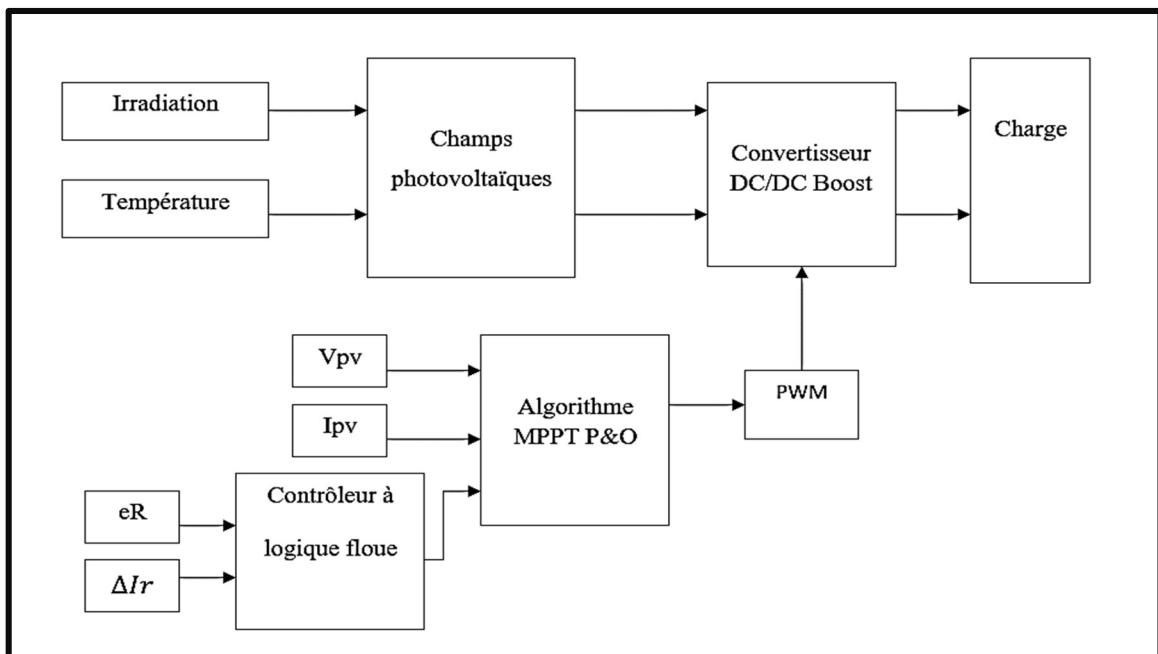


Figure 2.3 Schéma fonctionnel du modèle proposé

2.3.2 Structure du contrôleur à logique floue

La structure du contrôleur à logique floue est basée sur des ensembles flous où une variable est membre d'un ou plusieurs ensembles avec un degré d'appartenance spécifié. Le schéma fonctionnel de la commande MPPT basée sur la logique floue est illustré à la figure 2.4.

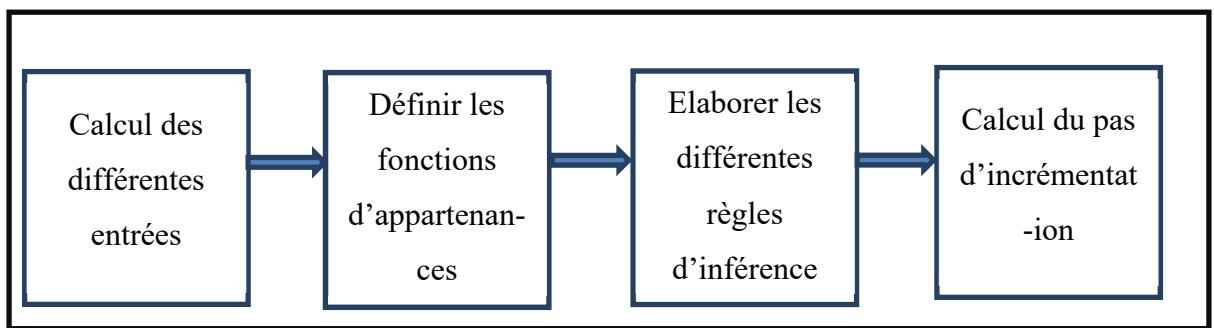


Figure 2.4 Schéma fonctionnel de la commande MPPT basée sur la logique floue

2.3.3 Configuration du contrôleur logique floue

Chaque variable d'entrée/sortie dans le contrôleur logique floue est nécessaire pour définir la surface de contrôle qui peut être exprimée en notations d'ensemble flous en utilisant des niveaux linguistiques. Chaque variable d'entrée et de sortie des valeurs linguistiques divise son univers de discours en intervalles adjacents pour former les fonctions d'appartenance. La valeur membre représente le degré d'appartenance d'une variable à un niveau particulier. Dans notre cas, nous avons deux entrées eR et ΔIr déterminées à partir des équations (2.1) et (2.2) :

$$eR = \frac{V}{I} - \frac{\frac{dV}{dt}}{\frac{dI}{dt}} \quad (2.1)$$

$$\Delta Ir = Ir - \frac{dIr}{dt} \quad (2.2)$$

Où Ir est l'irradiation solaire, V et I sont respectivement la tension et le courant du réseau PV. Les ensembles flous pour chaque variable d'entrée et de sortie sont définis comme le montre les figures 2.5, 2.6 et 2.7. Cinq sous-ensembles flous, NS (Négatif Petit), NM (Négatif

Moyen), NB (Négatif Grand), Z (Zéro), PS (Positif Petit), PM (Positif Moyen) et PB (Positif Grand), ont été choisis pour les variables d'entrée et de sortie du contrôleur flou. Comme le montre les figures 2.5,2.6 et 2.7, des formes trapézoïdales et triangulaires ont été adoptées pour les fonctions d'appartenance. La plage des fonctions d'appartenance des entrées a été modifiée en fonction des différents tests effectués lors de la simulation. En outre, l'incrément du rapport cyclique qui représente la sortie du contrôleur flou était compris entre zéro et 10^{-3} afin de l'adapter face aux variations grandes ou petites des entrées.

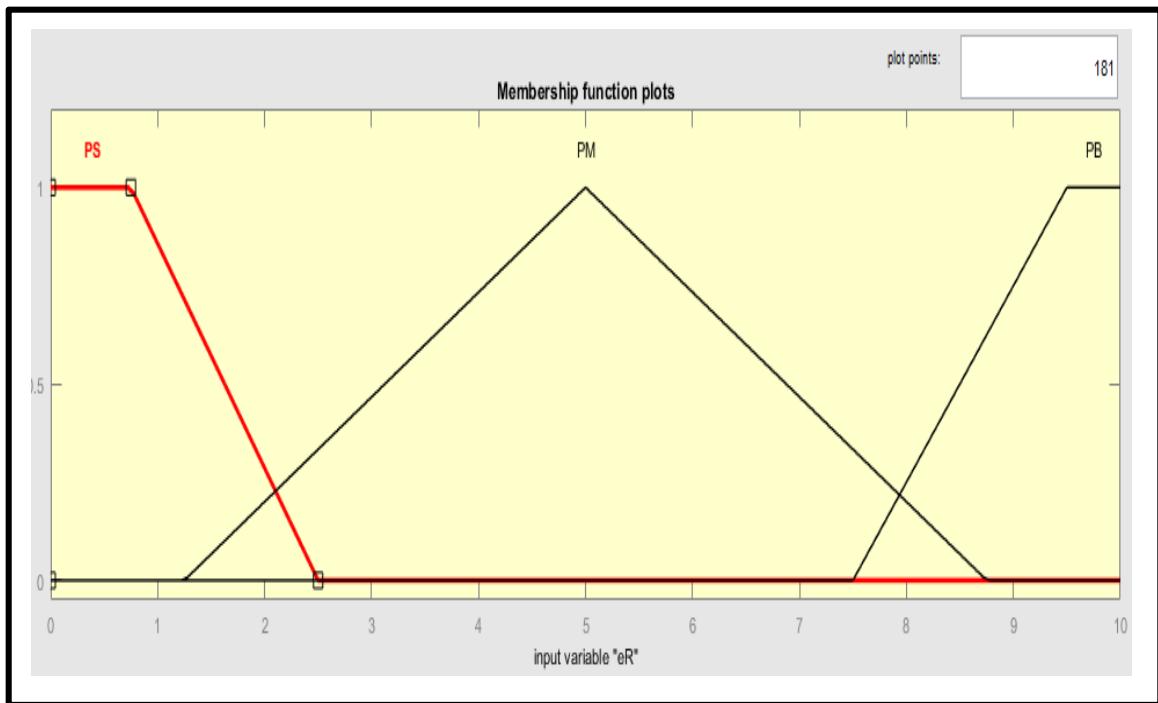


Figure 2.5 Fonctions des ensembles flous de la première entrée du contrôleur

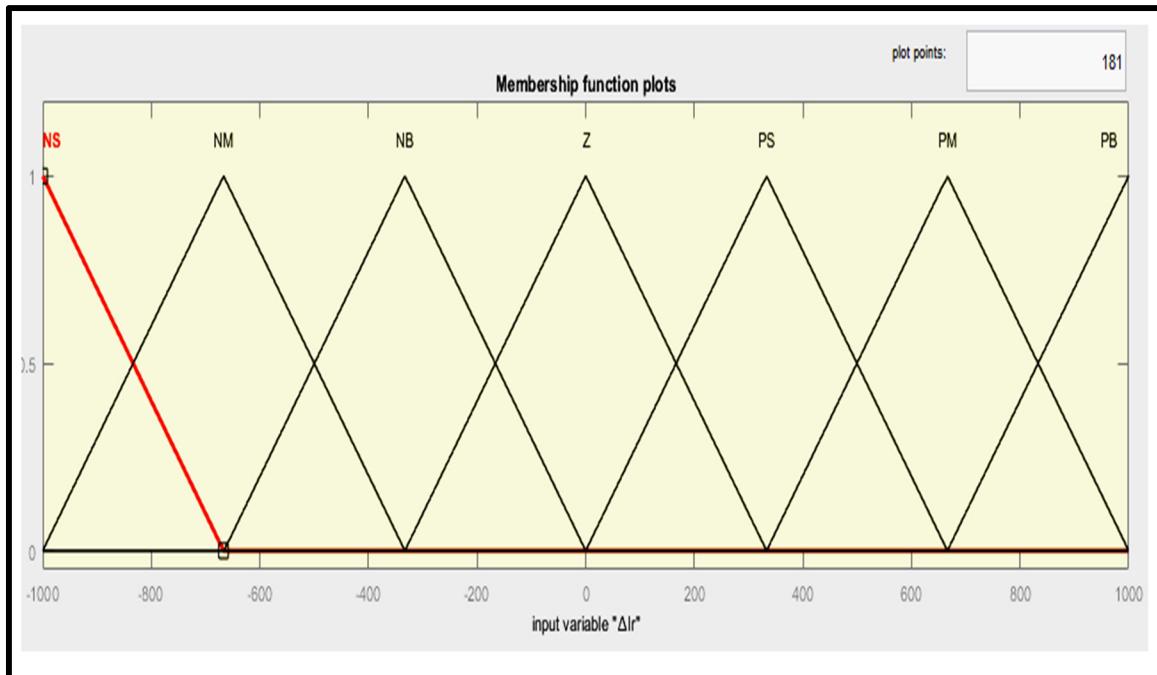


Figure 2.6 Fonctions des ensembles flous de la deuxième entrée du contrôleur

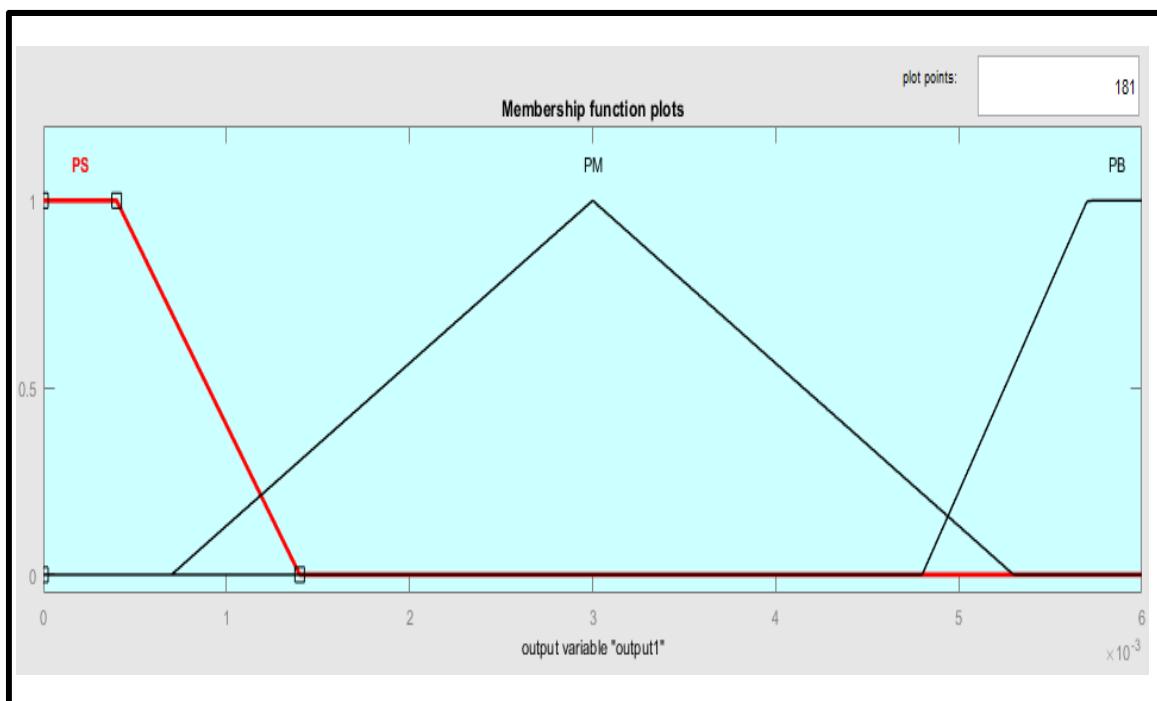


Figure 2.7 Fonctions des ensembles flous de la sortie du contrôleur

Dans l'étape d'inférence, des décisions sont prises. En fait, on crée une relation logique entre les entrées et les sorties tout en définissant les règles d'appartenance. Ensuite, la table des règles d'inférence est établie. Enfin, dans la défuzzification, les sous-ensembles flous de sortie sont convertis en valeurs numériques. Le Tableau 2.1 présente les règles des fonctions d'appartenance. La figure 2.8 montre la courbe tridimensionnelle utilisée pour afficher la relation entre les entrées et les sorties floues.

Tableau 2.1 Règles des fonctions d'appartenance
du contrôleur floue

ΔI_r eR	NS	NM	NB	Z	PS	PM	PB
PS	PS	PS	PM	PM	PS	PS	PM
PM	PS	PM	PB	PM	PS	PM	PM
PB	PB	PB	PB	PM	PM	PB	PB

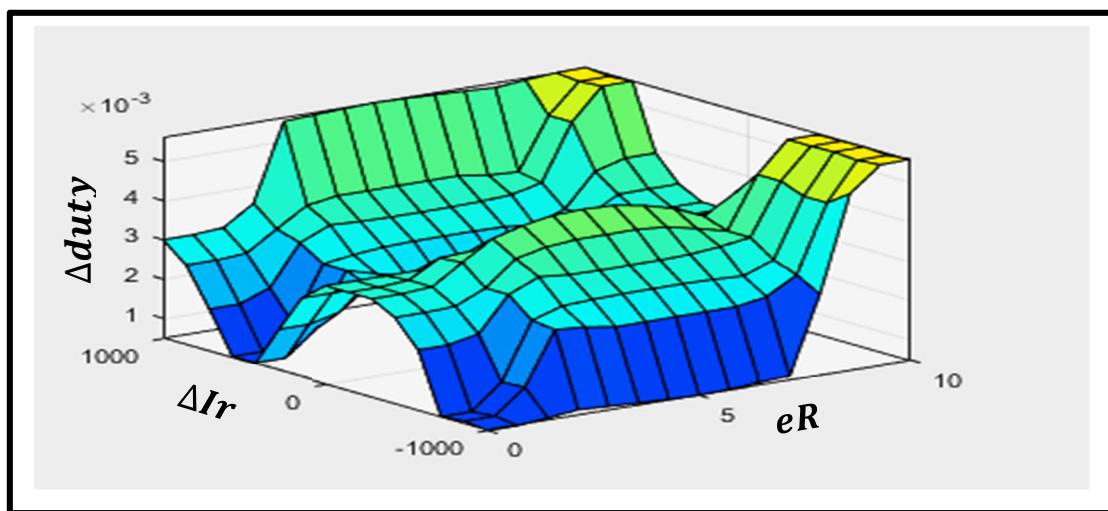


Figure 2.8 Courbe tridimensionnelle des relations entre les entrées et la sortie floue

Les règles de contrôle floues sont extraites en analysant le comportement du système. Les différentes conditions de fonctionnement sont prises en compte afin d'améliorer les performances de suivi en termes de réponse dynamique et de robustesse. L'algorithme peut être expliqué comme suit, nous prenons 3 exemples afin d'analyser le comportement du contrôleur.

Exemple 1 : On a une grande variation de l'irradiation solaire, dans ce cas, la valeur de l'incrément doit être très grande afin que le système s'approche du point de la puissance maximale rapidement. Pendant un calcul d'un nouveau rapport cyclique, la valeur de la variation de l'irradiation solaire ΔIr sera fixe, la valeur de la différence entre le rapport tension/courant eR sera variable et s'approche de zéro. Plus la valeur de eR est petite plus la valeur de l'incrément s'approche de zéro. À la fin, on aura une valeur de l'incrément presque égale à zéro et le système sera maintenu dans le point de la puissance maximale et on n'aura presque pas d'oscillation.

Exemple 2 : On a une variation moyenne de l'irradiation solaire, dans ce cas, la valeur de l'incrément doit être ni trop grande pour ne pas dépasser le point de puissance maximale, ni trop petite pour que le système ne prenne pas beaucoup d'itération afin d'atteindre le point de puissance maximale. Et puis lorsque le contrôleur s'approche du point optimal du système, il se comporte exactement comme dans le premier exemple, c'est-à-dire, une valeur de l'incrément très faible et presque égale à zéro.

Exemple 3 : On a une petite variation de l'irradiation solaire, dans ce cas la valeur de l'incrément sera petite et s'atténue de plus en plus jusqu'à atteindre zéro lorsque la valeur de eR sera zéro.

2.4 Résultat de simulation et discussions

Pour tester la performance de la méthode FLC proposée, un modèle MATLAB-SIMULINK pour le système PV a été développé. Le système étudié est composé d'un champ photovoltaïque connecté au bus DC intermédiaire via un convertisseur CC-CC Boost suivi

d'une charge linéaire. Les paramètres de simulation sont énumérés dans le Tableau 2.2. Le convertisseur CC-CC Boost est contrôlé par l'algorithme MPPT qui prend comme entrée la tension et le courant du PV et la sortie du FLC. Le système schématique construit sur Matlab/Simulink est présenté à la figure 2.9.

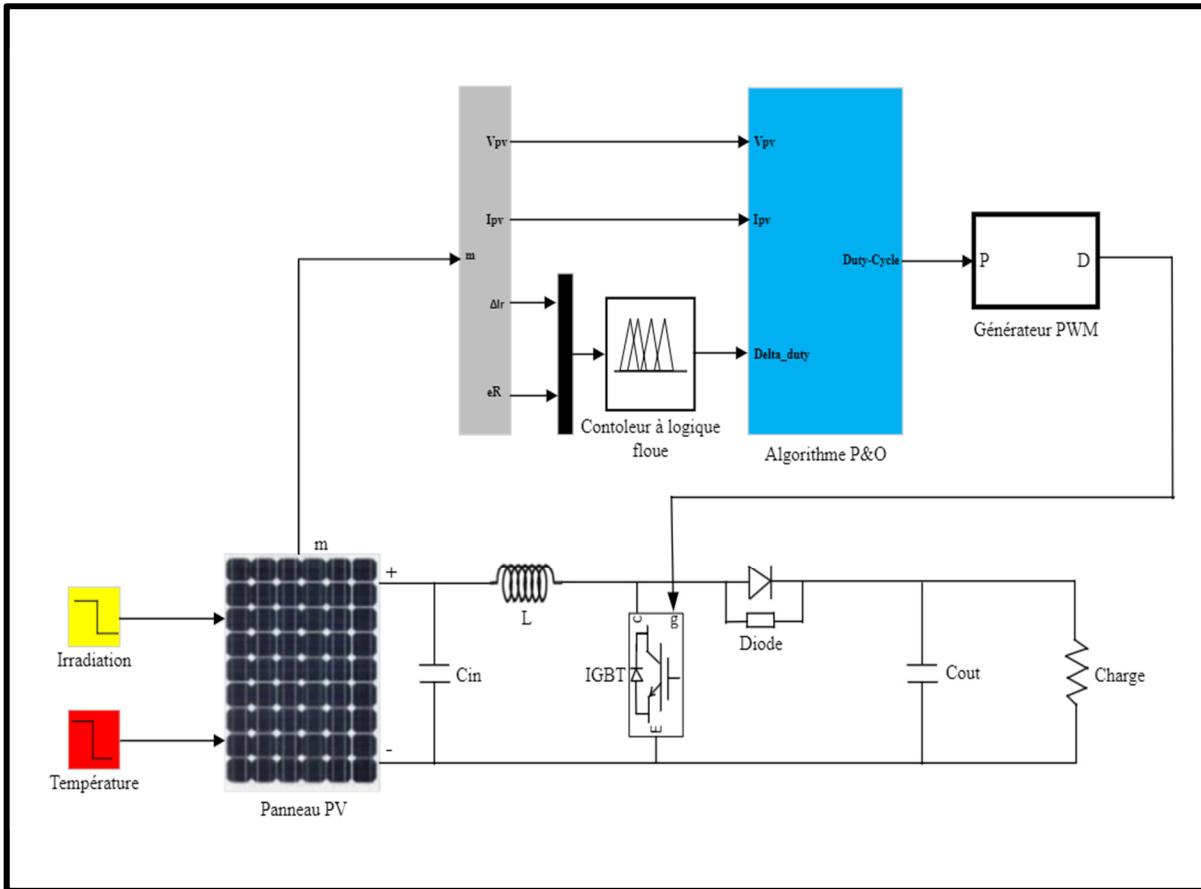


Figure 2.9 Schéma Simulink du système étudié

Pour les différents tests effectués, les algorithmes INC, P&O et le modèle hybride (P&O et FLC) ont été utilisés. À chaque fois, la réponse du système en puissance est prise pour faire une comparaison qualitative entre les différents algorithmes. La figure 2.10 montre le schéma de principe du modèle Simulink permettant de calculer l'efficacité d'un algorithme MPPT afin d'effectuer une comparaison quantitative entre les différentes méthodes. L'efficacité est calculée à partir de l'équation (2.3) :

$$Efficacité = \frac{1}{T} \int_0^T \left(1 - \left| \frac{P_{MPP}(t) - P_{PV}(t)}{P_{MPP}(t)} \right| \right) dt \quad (2.3)$$

Pour évaluer la méthode FLC proposée, le test standard EN50530 sur l'efficacité MPPT a été utilisé 3 scénarios différents ont été effectués (Xingshuo, & Wen et al. 2021) :

Scénario 1 : Tester les trois algorithmes (P&O, INC et notre modèle hybride) pour un changement d'irradiation toutes les 0,5 secondes puis toutes les 0,1 secondes afin de conclure sur l'efficacité des algorithmes dans le cas de changements rapides des conditions météorologiques. Les courbes des différentes valeurs d'irradiations pour les 2 tests sont présentées dans les figures 2.11 et 2.12. Les courbes de puissance de sortie pour les 2 tests sont présentées dans les figures 2.13 et 2.14. Les différents rendements et temps de réponse sont présentés dans le Tableau 2.3.

Scénario 2 : Tester les trois algorithmes pour des valeurs d'irradiation aléatoires de 0 à 1000 w/m² pendant différentes périodes (1 minute, 10 minutes et 30 minutes) avec un temps de commutation de 0.05 secondes pour conclure sur l'efficacité des algorithmes pour de longues périodes de fonctionnement. Les différents résultats obtenus sont présentés dans le Tableau 2.4.

Scénario 3 : Tester le modèle hybride P&O et contrôleur logique floue pour différentes configurations de champs photovoltaïques afin de conclure sur la fiabilité du modèle pour une variété de technologies et de configurations. Les différents résultats obtenus sont présentés dans le Tableau 2.5.

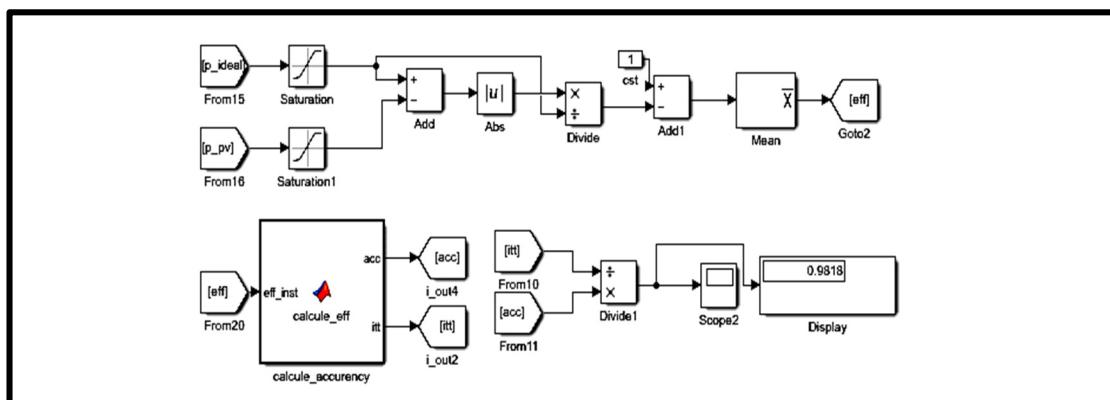


Figure 2.10 Schéma Simulink pour le calcul du rendement des algorithmes MPPT

Tableau 2.2 Paramètres de simulation

Panneau photovoltaïque	
Module	Trina Solar TSM
Cellules par module	Ncell=60
Tension du circuit ouvert	Voc=37.9 V
Tension maximale à la MPP	Vmp=31.7 V
Courant de court-circuit	Isc=8.67 A
Courant maximal à la MPP	Imp=8.2 A
Champs photovoltaïque	
Chaines parallèles	Np=4
Module connecté en série par chaîne	Ns=2
Convertisseur CC-CC Boost	
Fréquence de commutation	F=5 kHz
Inductance	L= 0.085e-3 H
Capacité	C= 10e-4 F

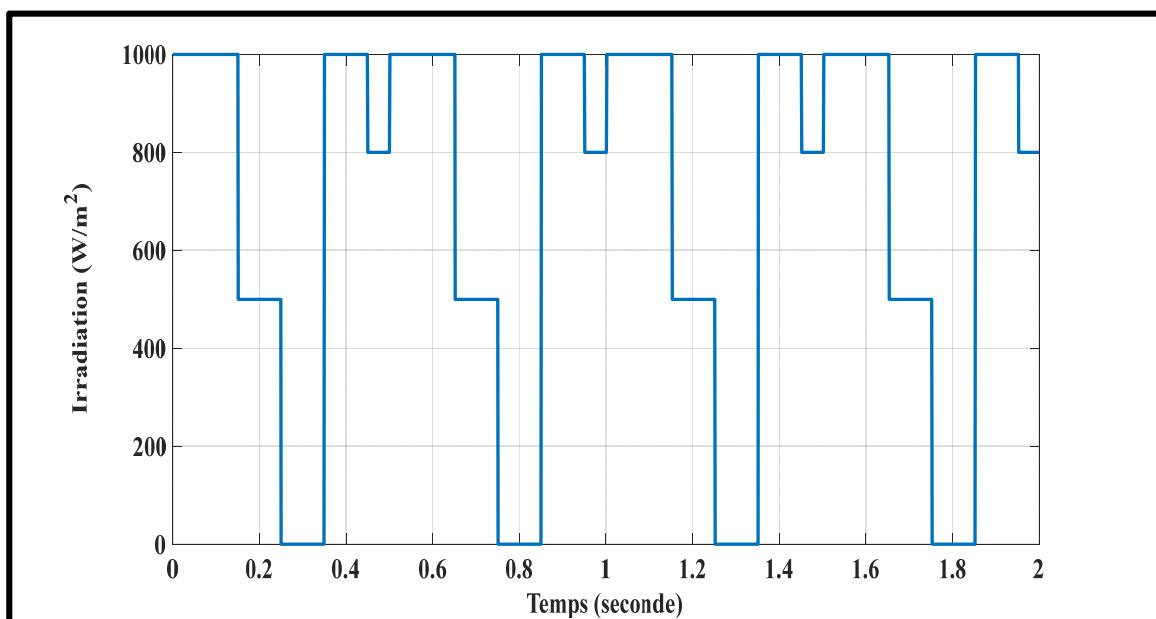


Figure 2.11 Courbe d'irradiation pour un changement chaque 0.1 seconde

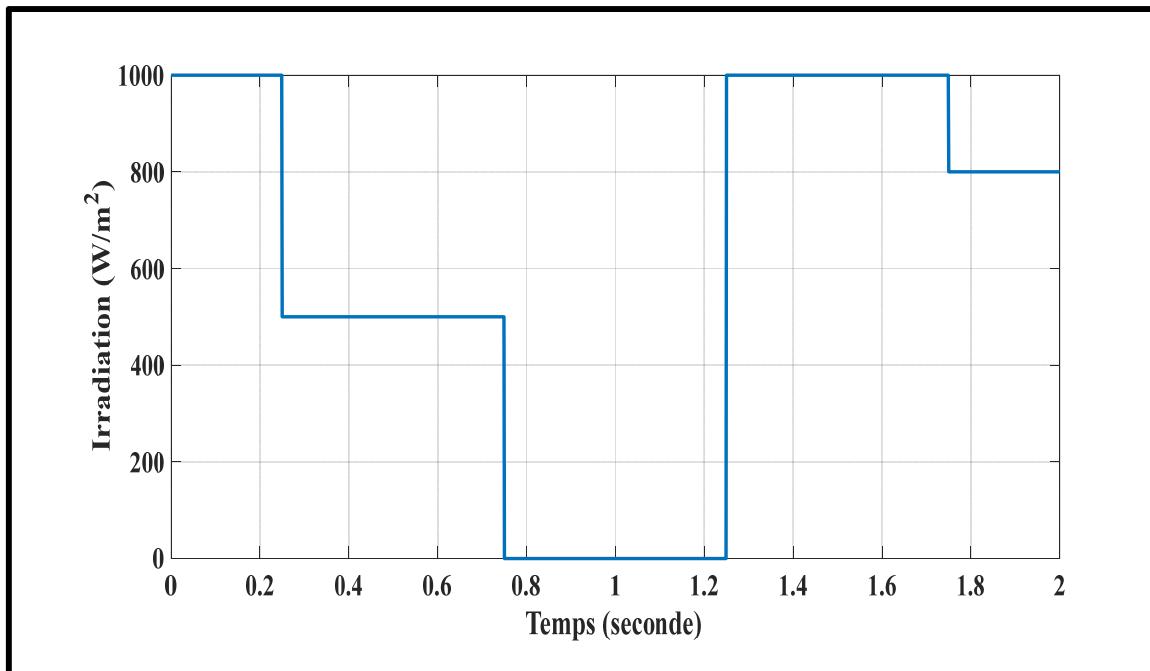


Figure 2.12 Courbe d'irradiation pour un changement chaque 0.5 seconde

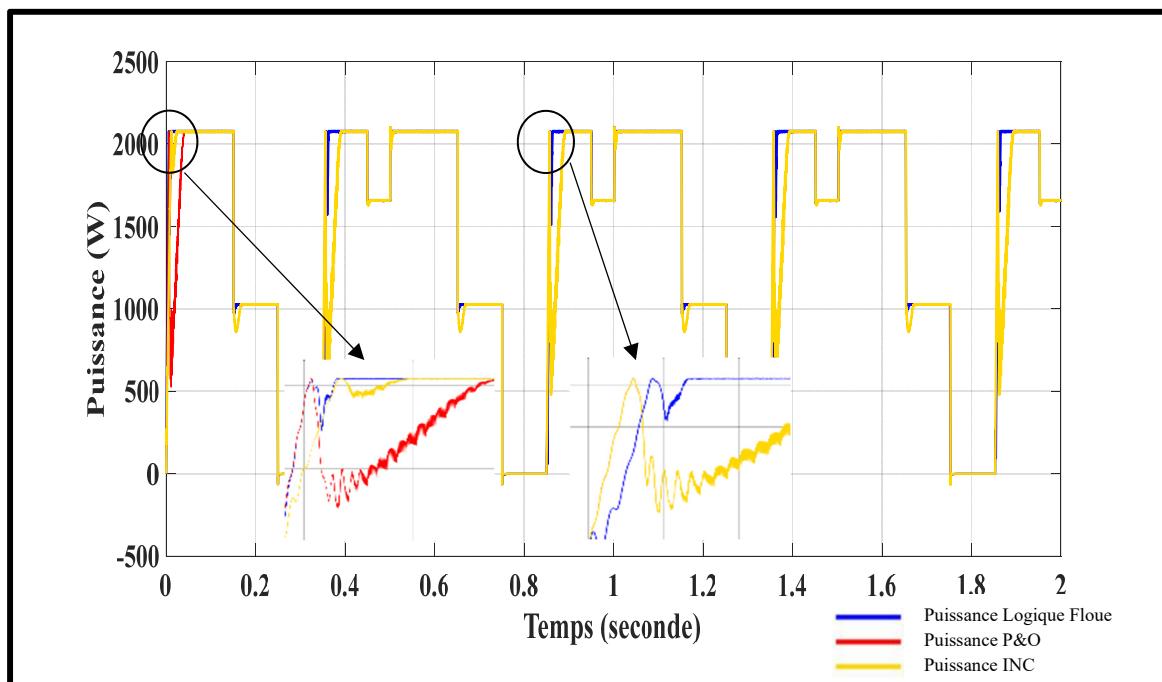


Figure 2.13 Courbe de puissance des trois algorithmes du premier test

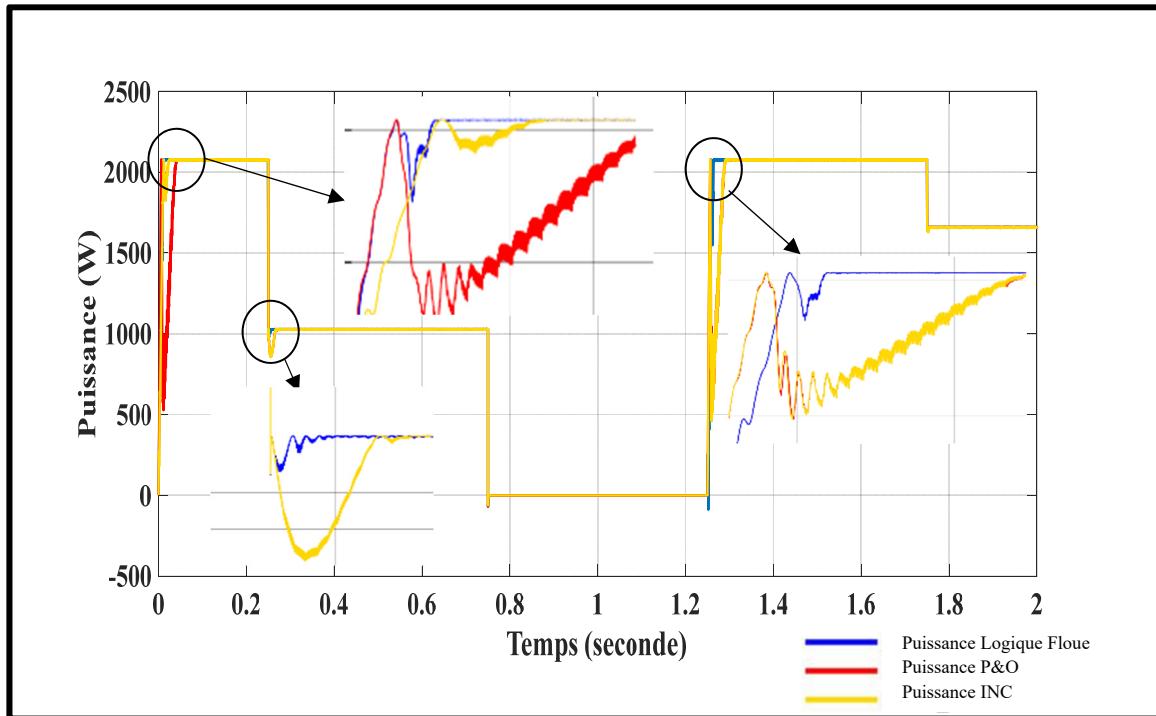


Figure 2.14 Courbe de puissance des trois algorithmes du deuxième test

Tableau 2.3 Efficacité et temps de réponse des différents algorithmes pour les deux tests du scénario 1

Algorithmes	Temps de réponse	Efficacité (test1)	Efficacité (test2)
Fuzzy+P&O	9.15 ms	98.16%	97.18%
P&O	41 ms	96.31%	94.92%
INC	24 ms	96.75%	95.32%

Tableau 2.4 Efficacité des trois algorithmes pour les 3 tests du scénario 2

Algorithmes	Test1 (1 minute)	Test2 (10 minutes)	Test3 (30 minutes)
Fuzzy+P&O	92.39%	93.14%	93.16%
P&O	86.21%	87.54%	87.55%
INC	86.57%	87.89%	87.88%

Tableau 2.5 Efficacité de l'algorithme P&O et contrôleur logique floue pour différente configuration de champs photovoltaïque

Module	Chaînes parallèles/séries	Efficacité
Renesola Jangsu JC315M-24	8/4	98.64%
Ritek PM285	20/10	99.12%
Samsung SDI LPC247SM-8	12/2	98.6 %
BIPV BIPVV054-S16	4/2	98.12%

2.5 Conclusion

Une technique proposée de suivi du point de puissance maximale basée sur le contrôle de la logique floue pour un système PV connecté au réseau a été présentée, qui a la capacité de suivre le MPP lorsqu'il y a de grandes fluctuations d'irradiation. Les avantages et les inconvénients du contrôleur FLC ont été discutés. Les fonctions d'appartenance du contrôleur FLC ont été ajustées sur la base d'un algorithme P&O modifié afin d'incorporer les avantages du P&O-MPPT et du FLC et d'éliminer leurs inconvénients. Les P&O-MPPT, INC-MPPT et

la méthode proposée ont été simulés, puis comparés, en fonction de leurs caractéristiques communes.

Le test standard EN50530 a été utilisé pour calculer l'efficacité de la méthode proposée dans des conditions météorologiques variables. Les différentes sorties du système PV et les résultats de la simulation révèlent l'efficacité de la méthode proposée, même en présence de diverses expériences d'irradiation, de temps de fonctionnement et de différentes configurations de champs photovoltaïques. On peut constater que le modèle hybride proposé est plus efficace que les autres modèles présentés dans cet article. Il s'agit clairement d'un domaine important pour de nouvelles recherches, autour de nouvelles technologies basées sur des outils d'intelligence artificielle qui peuvent mettre fin aux limitations des algorithmes d'incrémantation.

CHAPITRE 3

NOUVELLE METHODE DE SUIVI DU POINT DE PUISSANCE MAXIMALE D'UN SYSTÈME PHOTOVOLTAIQUE BASÉE SUR LE SYSTÈME D'INFERENCE NEURO-FLOUE ADAPTATIF

3.1 Introduction

De nombreuses recherches ont été menées pour améliorer l'efficacité des systèmes utilisant des panneaux photovoltaïques. Cela a conduit au développement d'algorithmes de contrôle basés sur l'intelligence artificielle, qui devient de plus en plus importante dans le domaine de l'énergie, en raison de sa capacité à contrôler des systèmes complexes.

Plusieurs algorithmes ont été développés pour le suivi du point de puissance maximale (MPPT), parmi ces méthodes il y a le contrôleur à logique floue (FLC), Il existe également des modèles basés sur les réseaux neuronaux artificiels (ANN) et d'autres qui utilisent le système d'inférence floue neurologique adaptatif (ANFIS) qui est un réseau de neurones artificiels basé sur le système d'inférence floue. Le principal inconvénient de ces systèmes est la nécessité d'un apprentissage et d'un paramétrage spécifiques pour chaque application et chaque situation, ce qui entraîne une diminution de la fiabilité des modèles formés et de leur capacité à être adaptés à diverses situations et à différentes applications. Globalement, nous visons dans cette recherche à développer une solution basée sur le système d'inférence neuro-floue adaptatif (ANFIS) afin d'améliorer certaines limitations des algorithmes d'intelligence artificielle pour le suivi du point de puissance maximale.

3.2 Études antérieures sur les MPPT basées sur L'ANFIS

Le contrôleur MPPT basé sur des techniques d'intelligence artificielle pour un système PV a été largement utilisé ces dernières années. Cela est dû au fait qu'il peut résoudre les problèmes importants associés aux méthodes MPPT classiques. De plus, ces techniques ne nécessitent pas de résolutions mathématiques complexes ou de paramètres précis lors de la gestion du système. En particulier, le système ANFIS-MPPT est l'un des contrôleurs les plus puissants

pour un système PV, car il présente moins de fluctuations autour du point MPP optimisé, une vitesse de suivi rapide et un faible temps de calcul.

Cependant, les principaux inconvénients sont le manque de données précises d'entraînement et le réglage du modèle ANFIS. Par conséquent, plusieurs types d'ANFIS-MPPT ont été conçus en utilisant différents types de données d'apprentissage. Parmi eux, Lasheen & Abdel-Salam ont développé une technique MPPT basée sur les techniques ANFIS adaptatives et Hill Climbing (HC) pour augmenter l'énergie générée par un système PV. Cette technique proposée est une combinaison de deux étapes pour ajuster le rapport cyclique de propriété d'un convertisseur CC-CC Boost pour le suivi MPP.

Dans la première étape, le rapport cyclique est estimé, tandis que dans la seconde, le rapport cyclique exact correspondant au point MPP optimisé est déterminé. Afin de lancer l'apprentissage du système ANFIS, les plages de la température ambiante et de l'irradiation solaire sont déterminées, en fonction de la latitude et de la longitude du site du système PV. Avec la même idée, Farzaneh & Reza et al. ont présenté une technique MPPT intelligente pour le système PV en utilisant la technique hybride ANFIS et optimisée à l'aide du Particle Swarm Optimization (PSO) pour réduire le temps de convergence de l'algorithme MPPT dans des conditions partiellement ombragées. L'irradiation solaire et la température de fonctionnement sont sélectionnées comme entrées, tandis que le rapport cyclique optimal (D_m) est la sortie, qui est optimisée en utilisant l'algorithme PSO. Les données du système ANFIS sont collectées à partir de différents scénarios de fonctionnement du système PV dans des conditions d'ombrage partiel variables. Bien que ces propositions augmentent l'efficacité du système PV, leur mise en œuvre devient trop complexe en raison d'une unité de calcul supplémentaire.

Murdianto & Penangsang et al. ont conçu un MPPT intelligent basé sur ANFIS pour un système PV afin de générer une puissance de sortie maximale. Ce travail implique l'utilisation de la puissance maximale pour le stockage d'énergie en utilisant un convertisseur SEPIC. L'irradiation solaire et la température sont sélectionnées comme entrées, le courant PV optimal au MPP (I_m) étant la sortie du modèle ANFIS. Les données du système ANFIS sont collectées

à partir des caractéristiques de la courbe du réseau PV dans des conditions météorologiques variables. Aldair & Obed et al. ont conçu et mis en œuvre une technique ANFIS-MPPT en utilisant une carte FPGA pour les systèmes photovoltaïques autonomes afin de démontrer l'utilité d'ANFIS. L'irradiation solaire et la température de fonctionnement sont sélectionnées comme entrées du modèle ANFIS, tandis que le courant optimal est la sortie. Les données d'apprentissage sont utilisées pour définir la fonction d'appartenance d'entrée de la méthode proposée en supposant que le panneau photovoltaïque est situé dans le sud de l'Irak. Mayssa & Sbita ont présenté une approche intelligente pour optimiser l'efficacité d'un système PV par la technique ANFIS-MPPT. Le système se compose d'une matrice PV, d'un contrôleur MPPT, d'un convertisseur DC/DC et d'une pompe à moteur DC. Le courant du PV et la puissance du PV sont sélectionnés comme entrée, le rapport cyclique étant la sortie de la méthode MPPT proposée. Les données du système ANFIS sont collectées à partir de plusieurs expériences réalisées sur un réseau PV sous différentes valeurs d'irradiation solaire et une température constante à 25°C.

Kharb & Shimi et al. ont modélisé un contrôleur MPPT intelligent basé sur ANFIS pour résoudre la complexité du mécanisme de suivi et la nature non linéaire d'un système PV. La température et l'irradiation des conditions météorologiques sont utilisées comme entrées des données d'apprentissage de la méthode proposée, tandis que la sortie est la valeur de la puissance maximale du réseau PV à une opération de température et un niveau d'irradiation spécifiques (P_m). Iqbal & Abu-Rub et al. ont conçu une technique MPPT intelligente basée sur ANFIS pour un système solaire PV afin de réduire le temps de suivi de la convergence en cas de changement rapide des conditions météorologiques. Le point clé de cette proposition est que la puissance maximale du module PV est ajustée dans des conditions spécifiques. Le MPPT ANFIS proposé est entraîné par des valeurs d'irradiation solaire et de température d'un module PV dans des conditions météorologiques variables et la sortie est la puissance maximale. Iqbal & Abu-Rub et al. ont conçu un contrôleur MPPT intelligent basé sur ANFIS pour générer la puissance maximale d'un système PV en fonctionnement autonome. La génération de la puissance maximale de la charge est assurée par un ANFIS-MPPT adaptatif avec un onduleur quasi-Z-source.

3.3 Structure d'un contrôleur ANFIS

Une technique neuro-floue appelée Adaptive network based fuzzy inference system (ANFIS) a été utilisée comme outil principal dans la présente recherche. Le système d'inférence floue basé sur le réseau adaptatif (ANFIS) est une technique neuro-floue où la fusion est faite entre le réseau de neurones et le système d'inférence floue. Dans l'ANFIS, les paramètres peuvent être estimés de telle manière que les modèles flous de Sugeno et de Tsukamoto sont représentés par l'architecture ANFIS. Encore une fois, avec des contraintes mineures, le modèle ANFIS ressemble fonctionnellement au réseau à fonction de base radiale. Cette méthodologie ANFIS comprend un système hybride de logique floue et une technique de réseau de neurones. La logique floue prend en compte l'imprécision et l'incertitude du système à modéliser, tandis que le réseau de neurones lui confère une certaine adaptabilité. En utilisant cette méthode hybride, un modèle flou initial et ses variables d'entrée sont d'abord dérivés à l'aide des règles extraites des données d'entrée et de sortie du système à modéliser. Ensuite, le réseau de neurones est utilisé pour affiner les règles du modèle flou initial afin de produire le modèle ANFIS final du système.

3.3.1 Réseau de neurones artificiels

Les réseaux de neurones artificiels (ANN) ont de nombreuses applications de classification et de régression dans de nombreux domaines : reconnaissance de formes, problèmes de voix et de classification. C'est un réseau qui étudie comment des modèles simples de cerveaux biologiques peuvent être utilisés pour résoudre des tâches de calculs difficiles, telles que les tâches de modélisation prédictives que nous voyons dans l'apprentissage automatique. L'objectif n'est pas de créer des modèles réalistes du cerveau, mais de développer des algorithmes robustes et des structures de données que nous pouvons utiliser pour modéliser notre problématique. La puissance de ce réseau de neurones provient de sa capacité d'apprendre la représentation des données d'entraînement et de les relier avec la meilleure façon aux variables de sortie que nous prédissons. Mathématiquement, ils sont capables d'apprendre n'importe quelle fonction de mappage et se sont avérés être des algorithmes

d'approximation universelle. La capacité prédictive de ces réseaux provient de la structure hiérarchique des multicouches de réseau. La structure de données peut sélectionner (apprendre à représenter) des entités à différentes échelles ou des combinaisons en entités de niveau supérieur. Par exemple, des lignes, des collections de lignes et des formes.

3.3.1.1 Le neurone artificiel

Le modèle mathématique d'un neurone artificiel j est donné à la figure 3.1. Cette figure représente la base de la conception d'un réseau de neurone.

Un neurone est principalement un intégrateur qui établit une somme pondérée de ses entrées données. Le résultat net_j de cette addition est ensuite transmis vers une fonction d'activation φ qui génère la sortie o_j du neurone. Les entrées du neurone sont représentées par les vecteurs $\{x_1, x_2, \dots, x_n\}$, tandis que $\{w_{1j}, w_{2j}, \dots, w_{nj}\}$ constituent les poids du neurone j .

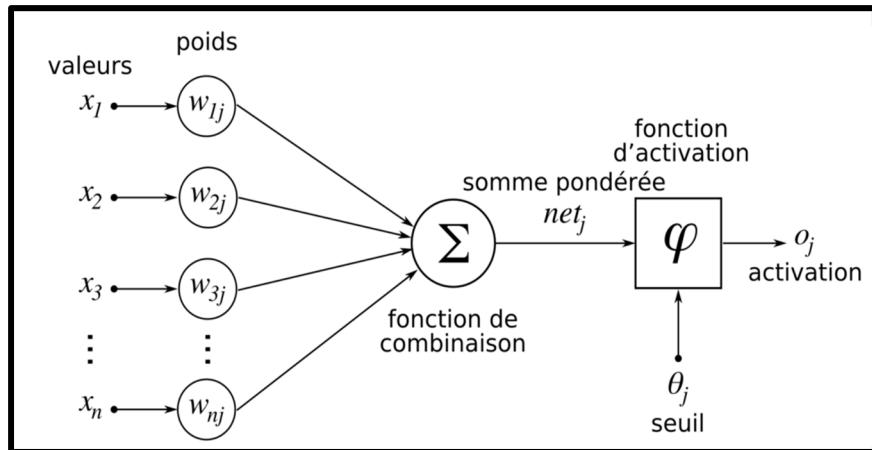


Figure 3.1 Architecture d'un réseau de neurones avec une seule couche cachée

La sortie net_j de l'intégrateur est donnée par l'équation (3.1) :

$$net_j = \sum_{m=0}^n w_{mj} * x_m \quad (3.1)$$

Et la sortie o_j de neurone j est données par l'équation (3.2) :

$$o_j = \varphi(net_j) \quad (3.2)$$

3.3.1.2 Fonction d'activation

La fonction d'activation φ définit l'état du neurone en fonction de son entrée locale net . C'est cette valeur qui sera transférée aux neurones en aval. Il y a plusieurs formes possibles de la fonction d'activation. Les plus fréquentes sont données dans le tableau 3.1 :

Tableau 3.1 Différentes formes des fonctions d'activation d'un réseau de neurones

Fonction d'activation	Formule $\varphi(net)$	Allure graphique
Sigmoïde	$\varphi(net) = 1/(1 + e^{-a*net})$ a : paramètre de la pente	
Tangente hyperbolique	$\varphi(net) = \tanh(net)$	
Seuil	$\varphi(net) = \begin{cases} 1 & \text{si } net \leq 0 \\ 0 & \text{sinon} \end{cases}$	
Linéaire	$\varphi(net) = a * net + b$	

3.3.1.3 Composition d'un réseau de neurones

Le réseau de neurones artificiel est généralement organisé en couches. Les couches sont constituées de nombreux "nœuds" interconnectés qui contiennent une "fonction d'activation". Un réseau de neurones peut contenir les 3 couches suivantes : Un réseau de neurones est constitué généralement de trois couches :

- Une couche d'entrée : le rôle de la couche d'entrée est de recevoir en entrée les valeurs des attributs pour chaque observation. En général, le nombre de nœuds d'entrée dans une couche d'entrée est égal au nombre de variables. La couche d'entrée présente les modèles au réseau, qui les communique à une ou plusieurs "couches cachées".
- Des couches cachées : elles appliquent des transformations données aux valeurs d'entrée à l'intérieur du réseau. Dans ce cas, les entrées qui proviennent d'autres nœuds cachés ou de nœuds d'entrée sont connectés à chaque nœud. Les arcs sortants sont connectés aux nœuds de sortie ou à d'autres nœuds cachés.
- Une couche de sortie : les couches cachées sont ensuite reliées à une "couche de sortie". La couche de sortie reçoit des connexions des couches cachées ou de la couche d'entrée. Elle renvoie une valeur de sortie qui correspond à la prédiction de la variable de réponse

La figure 3.2 montre la composition d'un réseau présentant une couche d'entrée, une couche cachée et une couche de sortie, c'est l'architecture la plus utilisée dans la modélisation.

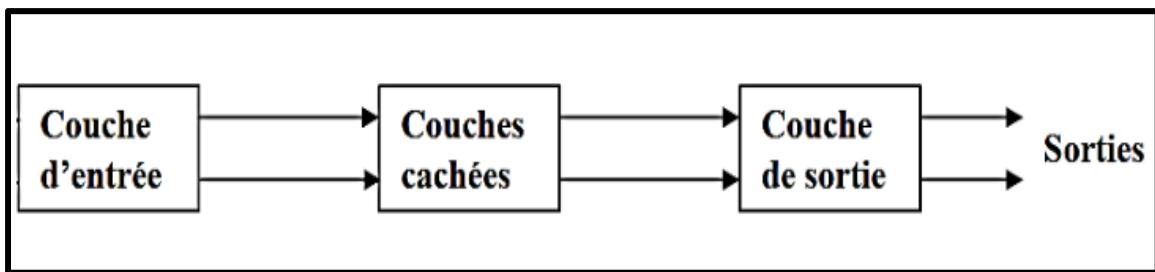


Figure 3.2 Composition d'un réseau de neurones

3.3.1.4 Apprentissage d'un réseau de neurones

Une fois l'architecture définie, elle doit subir une phase d'apprentissage. Cette phase correspond à la phase de développement du réseau. Au cours de cette phase, des adaptations

sont apportées aux poids des connexions du réseau, le plus souvent à travers des algorithmes particuliers, de manière à obtenir des valeurs plus optimales pour ces poids. À l'issue de cette étape, le réseau converge vers un comportement adapté au problème que l'on veut résoudre, c'est-à-dire vers la réponse attendue (ou désirée). Cette étape nécessite des exemples d'apprentissage et un algorithme de calcul. Le problème d'optimisation consiste à déterminer les coefficients du réseau en minimisant une fonction d'erreur globale, dite fonction de perte. Cette optimisation se fait de manière itérative et répétitive, en changeant les poids en fonction du gradient de la fonction de perte. Quant aux types d'apprentissage, trois principales branches ont été définies en fonction du mode d'apprentissage : supervisé, semi-supervisé ou non supervisé. Dans cette étude, nous procéderons à un apprentissage supervisé puisque les données sont collectées directement à partir des simulations des panneaux photovoltaïques.

3.3.1.5 Apprentissage supervisé

Ce type de calcul est le plus courant, l'utilisateur possède un critère précis de comportement de référence qu'il désire faire apprendre au réseau. Schématiquement, il s'agit d'évaluer les poids synaptiques minimisant l'erreur sur une base d'apprentissage, celle-ci comprend un ensemble de données d'observation dont on connaît à la fois les entrées et les sorties désirées. La figure 3.3 présente le schéma fonctionnel d'un réseau de neurones avec apprentissage supervisé.

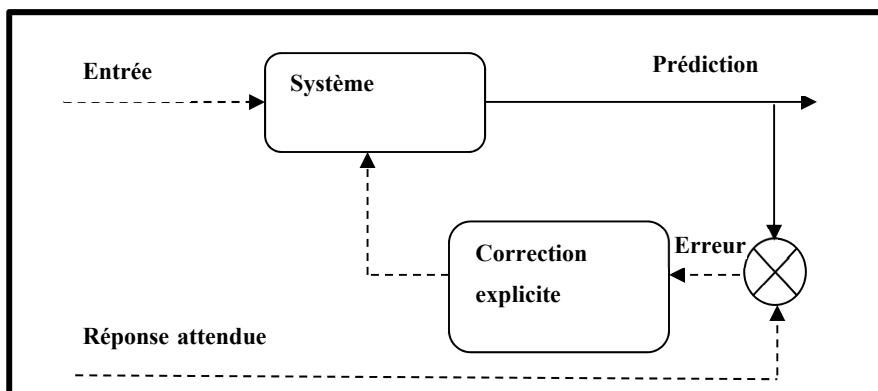


Figure 3.3 Schéma bloc d'un réseau de neurones avec un apprentissage supervisé

3.3.1.6 Fonction d'erreur (loss_function)

Afin de quantifier et mesurer la pertinence et le taux d'erreur du réseau de neurones, nous avons désormais besoin de ce que l'on appelle une fonction de perte ("loss_function").

Cette fonction d'erreur est la différence entre la valeur désirée pour le neurone de sortie et sa valeur obtenue par propagation. Les différentes fonctions d'erreur qu'on peut utiliser dans un réseau de neurones artificiels sont représentées dans le tableau 3.2.

Tableau 3.2 Fonctions d'erreur utilisés dans un réseau de neurones

Fonction de perte	Formule
Erreur quadratique moyenne	$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}$ Avec y_i : Nombre d'exemples d'apprentissage i : ième élément d'apprentissage y_i : Étiquette de vérité terrain pour le ième élément d'apprentissage. \hat{y}_i : Prédiction pour le ième élément d'apprentissage.
Erreur moyenne absolue	$MAE = \frac{\sum_{i=1}^n y_i - \hat{y}_i }{n}$
Entropie croisée	CrossEntropyLoss $= -(y_i \log(\hat{y}_i) + (1 - y_i)\log(1 - \hat{y}_i))$

3.3.2 Système d'inférence neuro-floue adaptative (ANFIS)

Après la description des réseaux de neurones (ANN), on s'intéresse dans cette section à une nouvelle architecture appelée Système d'Inférence Neuro-Floue Adaptatif (ANFIS), qui a été largement utilisée pour représenter ou approximer un système non linéaire.

Cette section décrit alors une classe de Neuro-Fuzzy ainsi que les architectures et les procédures d'apprentissage des réseaux adaptatifs. La structure de réseau sous-jacente est un sur-ensemble de toutes sortes de paradigmes de réseaux de neurones avec une capacité d'apprentissage supervisé. Les systèmes neuro-flous, qui sont la combinaison d'ANN et de systèmes flous, ont généralement l'avantage de permettre une traduction facile du système final en un ensemble de règles "si-alors". Le système flou peut être considéré comme une structure de réseau de neurones avec des connaissances distribuées à travers les connexions. La recherche et les applications sur la stratégie d'inférence neuro-floue ont clairement montré que les systèmes hybrides neuronaux et flous sont bénéfiques dans des domaines tels que l'applicabilité des algorithmes existants pour les réseaux de neurones artificiels (ANN), et l'adaptation directe des connaissances articulées comme un ensemble de règles linguistiques floues. Le système d'inférence neuro-floue adaptatif (ANFIS) est un système d'inférence floue mis en œuvre dans le cadre d'un réseau de neurones adaptatif.

3.3.2.1 Réseau de neurones adaptatif

Comme son nom l'indique, un réseau adaptatif est une structure de réseau constituée de nœuds et de liens directionnels, dont le comportement global d'entrée-sortie est déterminé par les valeurs d'une collection de paramètres modifiables par lesquels les nœuds sont connectés.

Le système adaptatif utilise un algorithme d'apprentissage hybride pour identifier les paramètres des systèmes d'inférence floue de type Sugeno. Il applique une combinaison de la méthode des moindres carrés et de la méthode de descente de gradient par rétropropagation pour former les paramètres des fonctions d'appartenance des SIF afin d'émuler un ensemble de données de formation donné (Rahil & Mahdi 2014). Dans la phase avant de l'algorithme

d'apprentissage, les paramètres conséquents identifient l'estimation des moindres carrés. Dans la phase arrière, les signaux d'erreur, qui sont les dérivés de l'erreur au carré par rapport à la sortie de chaque nœud, se propagent en arrière de la couche de sortie vers la couche d'entrée.

Dans ce passage en arrière, les paramètres de prémisses sont mis à jour par l'algorithme de descente de gradient. La phase d'apprentissage ou de formation du réseau de neurones est un processus visant à déterminer les valeurs des paramètres pour qu'ils correspondent suffisamment aux données de formation. La formation ANFIS peut utiliser des algorithmes alternatifs pour réduire l'erreur de la formation. Une combinaison de l'algorithme de descente de gradient et de l'algorithme des moindres carrés est utilisée pour une recherche efficace des paramètres optimaux. Le principal avantage d'une telle approche hybride est qu'elle converge beaucoup plus rapidement, car elle réduit les dimensions de l'espace de recherche de la méthode de rétropropagation utilisée dans les réseaux de neurones (Hazlina & Jonathan et al. 2010). ANFIS est le modèle flou de Sugeno placé dans le cadre du système adaptatif qui sert à la construction et à la validation du modèle développé pour faciliter la formation et l'adaptation.

3.3.2.2 Algorithme d'apprentissage de rétropropagation

La technique de la rétropropagation est un algorithme d'apprentissage efficace et pratique. Le réseau de neurones à rétropropagation est essentiellement un réseau d'éléments de traitement simples travaillant ensemble pour produire une sortie complexe. On peut découper son fonctionnement en deux temps : une phase forward (vers l'avant) et une phase backward (vers l'arrière).

La phase forward :

- La couche d'entrée propage les composantes d'un vecteur d'entrée particulier à chaque nœud de la couche cachée suivante.
- Les nœuds de la couche cachée calculent les valeurs de sortie, qui deviennent des entrées pour les nœuds de la couche de sortie.

- Les nœuds de la couche de sortie calculent la sortie du réseau pour le vecteur d'entrée particulier.
- La passe avant produit un vecteur de sortie pour un vecteur d'entrée donné en fonction de l'état actuel des poids du réseau. Comme les poids du réseau sont initialisés à des valeurs aléatoires, il est peu probable que l'on obtienne des sorties raisonnables avant la formation. Les poids sont ajustés pour réduire l'erreur en propageant l'erreur de sortie en arrière dans le réseau. Ce processus est à l'origine du nom du réseau de neurones à rétropropagation et est connu sous le nom de passage en arrière.

La phase backward :

- Calculer les valeurs d'erreur pour chaque nœud de la couche de sortie. Ceci peut être calculé car la sortie désirée pour chaque nœud est connue.
- Calculer l'erreur pour les nœuds de la couche cachée. Ceci est réalisé en attribuant une partie de l'erreur de chaque nœud de la couche de sortie au nœud de la couche cachée, qui alimente ce nœud de sortie. La valeur d'erreur due à chaque nœud de couche cachée dépend de la taille du poids attribué à la connexion entre les deux nœuds.
- Ajuster les valeurs de poids pour améliorer les performances du réseau en utilisant la règle du Delta.
- Calculer l'erreur globale pour tester les performances du réseau.

L'ensemble d'apprentissage est présenté de manière répétée au réseau et les valeurs de poids sont ajustées jusqu'à ce que l'erreur globale soit inférieure à une tolérance pré-déterminée. Comme la règle Delta suit le chemin le plus décent le long de la surface d'erreur, les minima locaux peuvent entraver la formation. Le terme de momentum compense ce problème dans une certaine mesure.

3.3.2.3 Architecture de l'ANFIS

On détaille davantage la structure interne du système d'inférence neuro-floue adaptatif (ANFIS) basé sur le réseau adaptatif. Ce réseau est un réseau multicouche de type feed-forward composé de nœuds connectés par des liens dirigés, dans lequel chaque nœud exécute une fonction particulière sur ses signaux entrants pour générer une sortie de nœud unique.

Chaque lien dans un réseau adaptatif spécifie la direction du flux de signaux d'un nœud à l'autre ; aucun poids n'est associé au lien. Plus précisément, la configuration d'un réseau adaptatif exécute une fonction de nœud statique sur ses signaux entrants pour générer une sortie de nœud unique et chaque fonction de nœud est une fonction paramétrée avec des paramètres modifiables ; en changeant ces paramètres, les fonctions de nœud ainsi que le comportement global du réseau adaptatif, sont modifiées. "La figure montre que l'architecture complète du système est constituée de cinq couches : la couche floue, la couche produit, la couche normalisée, la couche dé-floue et la couche de sortie totale. A l'intérieur des données d'entrée/sortie pour un ensemble donné de paramètres, la méthode ANFIS modélise un système d'inférence flou (FIS) dont les paramètres de la fonction d'appartenance sont accordés (ajustés) en utilisant soit un algorithme de rétropropagation seul, soit en permutation avec une méthode de type moindres carrés. L'objectif principal de l'ANFIS est de déterminer les valeurs optimales des paramètres du système d'inférence flou équivalent en appliquant un algorithme d'apprentissage. L'optimisation des paramètres est effectuée de telle sorte que, pendant la session d'apprentissage, l'erreur entre la cible et la sortie réelle soit minimisée. Un algorithme hybride est utilisé pour l'optimisation, qui est la combinaison de l'estimation des moindres carrés et de la méthode de descente de gradient. Les paramètres à optimiser dans ANFIS sont les paramètres de prémissse. Ces paramètres définissent la forme des fonctions d'appartenance. Afin de réduire la mesure de l'erreur, l'une des nombreuses routines d'optimisation peut être appliquée après la constitution des fonctions d'appartenance. Le jeu de paramètres d'un réseau adaptatif permet aux systèmes flous d'apprendre des données qu'ils modélisent. Dans notre travail on suppose que le système adaptatif considéré possède deux entrées V1 et V2 et une sortie f. Examinons un système d'inférence flou de Takagi, Sugeno et Kang (TSK) du premier ordre contenant deux règles :

- Règle 1 : Si (c est V_1) & (d est D_1) Alors $f_1 = p_1 * v + q_1 * d + r_1$
- Règle 1 : Si (c est V_2) & (d est D_2) Alors $f_2 = p_2 * v + q_2 * d + r_2$

Où p_1, p_2, q_1, q_2, r_1 et r_2 sont des paramètres linéaires et V_1, V_2, D_1 et D_2 des paramètres non linéaires, dans lesquels V_1 et D_1 sont les fonctions d'appartenance d'ANFIS (antécédent). p_1, q_1, r_1 sont les paramètres conséquents. Pour refléter les capacités d'adaptation, nous utilisons à la fois le cercle et le carré. Un cercle indique un nœud fixe tandis que le carré indique un nœud adaptatif, c'est-à-dire que le paramètre peut être modifié pendant l'adaptation ou la formation.

Lors de la conception du modèle ANFIS, il est extrêmement important que le nombre d'époques d'apprentissage, le nombre de fonctions d'appartenance et le nombre de règles floues soient réglés avec précision. Le mappage de ces paramètres est très important pour le système, car il peut conduire le système à sur-adapter les données. Cet ajustement peut être obtenu en utilisant un algorithme hybride combinant la méthode des moindres carrés et la méthode de descente de gradient avec une méthode d'erreur quadratique moyenne. La plus petite différence entre la sortie ANFIS et l'objectif souhaité signifie un meilleur système ANFIS (plus précis). Nous avons donc tendance à réduire l'erreur d'apprentissage dans le processus d'entraînement. Par conséquent, L'intégration entre la logique floue et le réseau de neurones est appelée ANFIS. Le réseau de neurones a beaucoup d'entrées et a aussi des sorties multiples, mais la logique floue a beaucoup d'entrées et une seule sortie, donc la combinaison de ces deux est connue comme ANFIS. La figure 3.4 représente l'architecture basique d'un ANFIS.

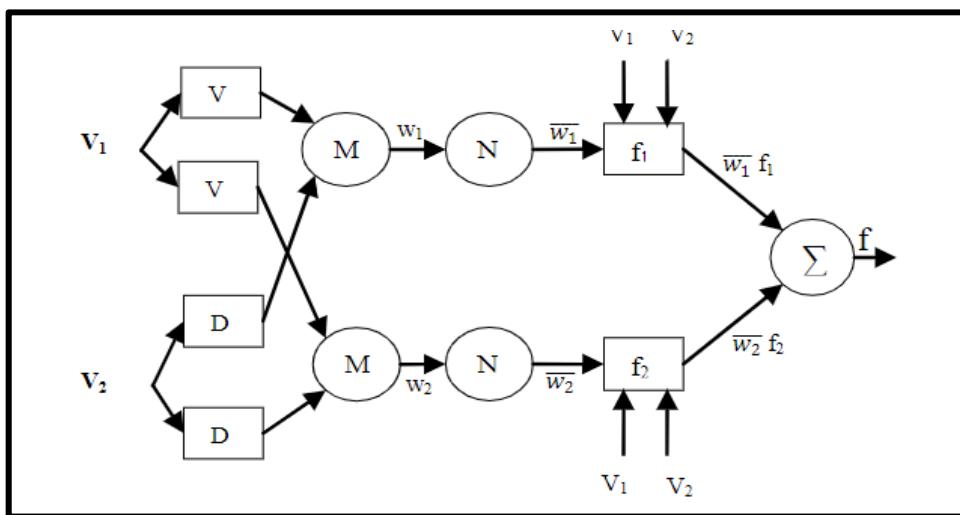


Figure 3.4 Architecture basique d'un ANFIS

3.3.2.4 Couches de l'ANFIS

Pour des raisons de simplicité, le système d'inférence floue est composé de deux entrées v , d et d'une sortie f . Un bref résumé des cinq couches de l'algorithme ANFIS est présenté ci-dessous.

Couche 1 :

Chaque nœud d'entrée i de cette couche est un nœud adaptatif qui produit le grade d'appartenance de l'étiquette linguistique. Il s'agit d'une couche floue, dans laquelle v et d sont les entrées du système. $O_{1,i}$ est la sortie du noeud i de la couche 1. Chaque noeud adaptatif est un nœud carré avec une fonction carrée représentée par l'équation (3.3) et (3.4) :

$$O_{1,i} = \mu_{v,i}(V) \text{ pour } i = 1,2 \quad (3.3)$$

$$O_{1,i} = \mu_{v,i}(V) \text{ pour } i = 1,2 \quad (3.4)$$

Où $O_{1,i}$ et $O_{1,j}$ désignent la fonction de sortie et $\mu_{v,i}$ et $\mu_{d,j}$ désignent la fonction d'appartenance. Par exemple, si nous choisissons la fonction d'appartenance triangulaire $\mu_{v,i}(v)$ est donné par l'équation (3.5) :

$$\mu_{v,i}(v) = \max \left[\min \left(\frac{v-a_i}{b_i-a_i}, \frac{c_i-v}{c_i-b_i} \right), 0 \right] \quad (3.5)$$

Où $\{a_i, b_i, c_i\}$ sont les paramètres de la fonction d'appartenance triangulaire. Dans un autre exemple, si nous choisissons $\mu_{v,i}(v)$ en forme de cloche est donné par l'équation (3.6):

$$\mu_{v,i}(v) = 1 / (1 + \{\left(\frac{v-c_i}{a_i}\right)^2\}^{b_i}) \quad (3.6)$$

Où $\{a_i, b_i, c_i\}$ sont les paramètres qui modifient les formes de la fonction d'appartenance. En conséquence, les valeurs de a_i et c_i peuvent être ajustées pour faire varier le centre et la largeur de la fonction d'appartenance, puis b_i est utilisé pour contrôler les pentes aux points de

croisement avec la fonction d'appartenance suivante. Les paramètres de cette couche sont appelés "paramètres de prémisses".

Couche 2 :

Cette couche vérifie les poids de chaque fonction d'appartenance. Elle reçoit les valeurs d'entrée v_i de la première couche et agit comme une fonction d'appartenance pour représenter les ensembles flous des variables d'entrée respectives. Chaque nœud de cette couche est un nœud fixe étiqueté M et la sortie est calculée par le produit de tous les signaux entrants. La sortie de cette couche peut être représentée par l'équation (3.7) :

$$O_{2,i} = w_i = \mu_{v,i}(v) * \mu_{Dj}(d), i = 1,2 \quad (3.7)$$

Ce produit présente les niveaux d'activation des règles. En général, le niveau d'activation d'une règle est donné par le produit des degrés d'appartenance d'entrée. Ainsi, cette valeur est transmise au degré d'appartenance de la sortie à l'ensemble flou correspondant.

Couche 3 :

Chaque nœud de cette couche est marqué de façon fixe par un cercle étiqueté N, indiquant la normalisation de niveau d'activation de la couche précédente. Cette couche effectue la correspondance préalable des règles floues, c'est-à-dire qu'elle calcule le niveau d'activation de chaque règle. Le nombre de couches étant égal au nombre de règles floues. Le i ème nœud de cette couche calcule le rapport entre le niveau d'activation de la i ème règle et la somme des niveaux d'activation de toutes les règles. La sortie de cette couche peut être exprimée par \overline{w}_i en utilisant l'équation (3.8) :

$$O_{3,i} = \overline{w}_i = \frac{w_i}{w_1+w_2}, \quad i = 1,2 \quad (3.8)$$

Par commodité, les sorties de cette couche seront appelées les niveaux d'activation des règles normalisées.

Couche 4 :

Cette couche fournit des valeurs de sortie y , résultant de l'inférence des règles. La sortie résultante est simplement un produit des niveaux d'activation des règles normalisées et du polynôme du premier ordre. La sortie pondérée de la règle est représentée par la fonction de nœud suivante représenté par l'équation (3.9) :

$$O_{4,i} = \overline{w_i} * f_i = \overline{w_i}(p_i v + q_i d + r_i), \quad i = 1, 2 \quad (3.9)$$

Où $O_{4,i}$ présente la sortie de la couche 4. Dans cette couche p_i , q_i , et r_i sont des paramètres linéaires ou des paramètres conséquents.

Couche 5 :

Cette couche est appelée couche de sortie. Elle additionne toutes les entrées provenant de la couche 4 et transforme les résultats de la classification floue en valeurs pertinentes non floues. Cette couche est constituée d'un seul nœud fixe étiqueté par " Σ ". Ce nœud calcule la somme de tous les signaux entrants à l'aide de l'équation (3.10) :

$$O_{5,i} = \sum_i \overline{w_i} * f_i = (\sum_i w_i * f_i) / (w_1 + w_2), \quad i = 1, 2 \quad (3.10)$$

Ainsi, on observe que lorsque les valeurs du paramètre de prémissé sont fixées, la sortie globale du réseau adaptatif peut être exprimée comme une combinaison linéaire d'un paramètre conséquent. Le réseau construit a exactement la même fonction qu'un modèle flou de Sugeno.

On peut observer que l'architecture ANFIS se compose de deux couches adaptatives : la première couche et la quatrième couche. Les trois paramètres modifiables $\{a_i, b_i, c_i\}$ sont appelés paramètres de prémissé dans la première couche et dans la quatrième couche. Il y a également trois paramètres modifiables $\{p_i, q_i, r_i\}$ se rapportant au polynôme du premier ordre. Ces paramètres sont appelés paramètres conséquents.

3.3.2.5 Apprentissage de l'ANFIS

Les techniques d'apprentissage neuro-adaptatif offrent une méthode permettant à la procédure de modélisation floue d'apprendre des informations sur un ensemble de données. Elles calculent les paramètres des fonctions d'appartenance qui permettent au système d'inférence floue associé de suivre les données d'entrée/sortie données. Les paramètres associés aux fonctions d'appartenance changent au cours du processus d'apprentissage. Afin de faire face plus efficacement aux problèmes du monde réel, la tâche de l'algorithme d'apprentissage pour cette architecture est d'accorder tous les paramètres modifiables, pour formuler la sortie ANFIS correspondant aux données de formation.

Pour améliorer le taux de convergence, le réseau hybride peut être entraîné par un algorithme d'apprentissage hybride combinant la méthode des moindres carrés et la méthode de descente de gradient. La méthode des moindres carrés peut être utilisée pour identifier les valeurs optimales du paramètre conséquent sur la couche 4 avec le paramètre de prémissé fixé. Le vecteur de gradient fournit une mesure de la façon dont le système d'inférence floue modélise les données d'entrée et sortie pour une configuration bien définie des paramètres. Lorsque le vecteur de gradient est obtenu, l'une des nombreuses fonctions d'optimisation peut être appliquée afin d'ajuster les paramètres pour la réduction de la valeur de l'erreur. Lorsque les paramètres de base ne sont pas fixes, l'espace de recherche s'élargit et la convergence de l'apprentissage devient plus lente. L'algorithme hybride est composé d'une passe avant (LSM) et d'une passe arrière (GDM). Une fois les paramètres conséquents optimaux trouvés, le passage en arrière commence. Au cours de ce passage, les erreurs sont propagées en arrière et les paramètres de prémissé correspondant aux ensembles flous du domaine d'entrée sont mis à jour par la méthode de descente de gradient. ANFIS utilise une combinaison de l'estimation des moindres carrés et de la rétropropagation pour l'estimation des paramètres des fonctions d'appartenance. Deux passes dans l'algorithme d'apprentissage hybride pour ANFIS sont présentées dans le tableau 3.3 :

Tableau 3.3 Les passes de l'algorithme d'apprentissage hybride

	Passe Avant	Passe Arrière
Paramètres de prémissé	Fixes	Descente de gradient
Paramètres conséquents	Moindres carrés	Fixes
Signaux	Sorties des nœuds	Signaux d'erreur

L'erreur de sortie est utilisée pour adapter les paramètres d'apprentissage au moyen d'un algorithme de rétropropagation standard afin de minimiser la fonction d'erreur quadratique moyenne définie par l'équation (3.11). Il a été prouvé que cet algorithme hybride est très efficace pour entraîner le système ANFIS.

$$E(\theta) = \sum_{i=1}^m (z_i - a_i^T \theta)^2 = e^T e = (z - A\theta)^T (z - A\theta) \quad (3.11)$$

Où $e = z - A\theta$ est le vecteur d'erreur produit par un choix spécifique de θ . Dans l'équation, l'erreur quadratique est minimisée et appelée l'estimateur des moindres carrés (LSE). Par conséquent, l'algorithme d'apprentissage hybride peut être appliqué directement. Plus précisément, les signaux d'erreur prolifèrent vers l'arrière et les paramètres de prémissé sont mis à jour par la méthode de descente de gradient (GD) ; les sorties des nœuds avancent jusqu'à la couche 3 et les paramètres conséquents sont identifiés par la méthode des moindres carrés (LSE). Cet apprentissage hybride est structuré comme suit : les paramètres linéaires et non linéaires sont illustrés à chaque itération de GD pour mettre à jour les paramètres non linéaires, LS suit pour identifier les paramètres linéaires.

3.4 Modèle proposé

Les méthodes basées sur l'IA, comme les réseaux de neurones, nécessitent beaucoup d'efforts pour être ajustées afin d'extraire le point de puissance maximale MPP le plus optimal. L'inconvénient principal de ces systèmes est la nécessité d'un apprentissage et d'un paramétrage spécifiques pour chaque application et chaque situation, ce qui entraîne une

diminution de la fiabilité des modèles formés et de leur capacité à être adaptés à diverses situations et à différentes applications. En outre pour les contrôleurs à base de la logique floue FLC, ils dépendent de la formation de la base de règles et des fonctions d'appartenance. Le FLC avec des paramètres constants est inapproprié dans une application où les conditions de fonctionnement changent dans une large gamme et où la connaissance experte disponible n'est pas fiable. Donc, il n'existe pas de méthode standard pour définir précisément les paramètres du contrôleur et pour la poursuite du point de puissance maximale MPP. La solution à ce problème est l'utilisation d'un système ANFIS qui a la capacité de réajuster ses paramètres pour obtenir les meilleures performances.

Les techniques MPPT basées sur l'intelligence artificielle nécessitent des bases de données spécifiques à des systèmes particuliers et à des conditions prédéfinies. Ces exigences réduisent les performances des algorithmes en termes de robustesse et de fiabilité. En effet, les bases de données sont construites soit à partir de données météorologiques (température et irradiation), soit à partir de données dynamiques du système (tension, courant et puissance). Habituellement, deux types de modèles sont générés : les modèles établis par des réseaux de neurones artificiels (ANN) où nous pouvons collecter les données de nombreux systèmes PV. L'inconvénient de cette méthode est qu'une grande quantité de données est nécessaire pour avoir un modèle précis et un réseau multicouche, ce qui entraîne un modèle de grande taille donc un calculateur plus sophistiqué est nécessaire.

Le deuxième modèle généré est basé sur le système d'inférence neuro-flou adaptatif (ANFIS) qui est entraîné à partir de paramètres statiques tels que l'irradiation et la température. En testant ces modèles, le changement des caractéristiques du panneau PV, le suivi du point de puissance maximale sera impossible et les sorties d'erreur seront estimées.

Dans notre étude, une phase a été ajoutée avant l'algorithme MPPT pour prédire la puissance maximale que le panneau PV peut fournir. Cette phase est un réseau ANFIS qui prend comme entrée l'irradiation, la température et la réponse du système PV pour un court temps de fonctionnement (fixé à 3 ms). Après avoir prédit la puissance maximale, cette variable devient

une entrée pour l'algorithme MPPT, qui prend également la température et l'irradiation mesurées en entrée, puis prédit la valeur du cycle de service pour contrôler le thermistor du convertisseur CC-CC Boost. Le schéma fonctionnel du système est présenté à la figure 3.5.

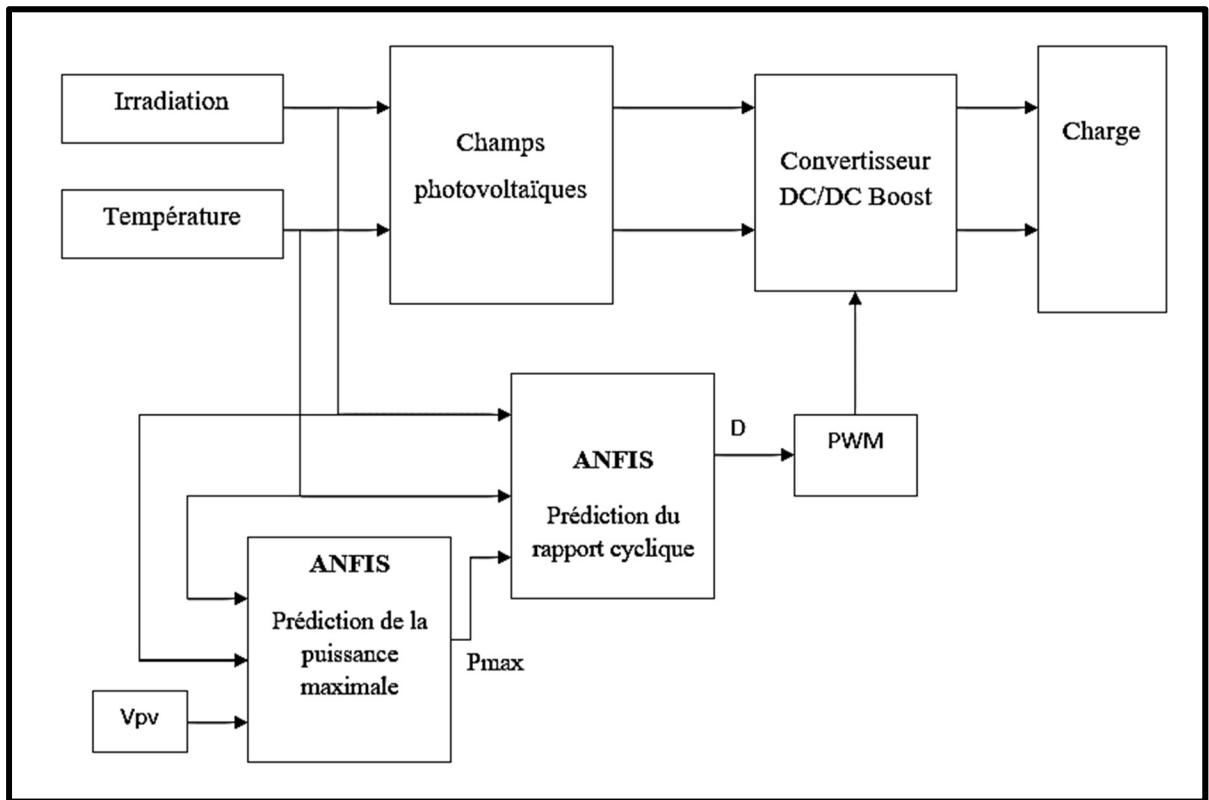


Figure 3.5 Schéma bloc du système PV + contrôleur ANFIS étudié

3.5 Apprentissage des deux modèles ANFIS

Le calcul des paramètres du contrôleur ANFIS est effectué pendant la phase d'apprentissage. Pour cela, un certain nombre de séquences d'association d'entrée et de sortie est requis. Afin de réaliser cette étape, nous utilisons une méthode d'apprentissage hybride. Cette méthode est une combinaison de la descente du gradient et l'estimation des moindres carrés. La méthode de descente du gradient nous permet d'ajuster l'erreur des prémisses, tandis que la méthode des moindres carrés (LSM) ajuste les paramètres linéaires (conséquence ou conclusion). Le processus d'apprentissage est itératif, il prend fin si on atteint le nombre total des itérations, où on a obtenu une erreur entre la sortie souhaitée et la sortie calculée par le modèle ANFIS.

inférieur ou égale à l'erreur fixée au début de l'apprentissage. Dans notre étude, deux modèles ont été formés :

Modèle 1 : Pour prédire la puissance maximale que le panneau photovoltaïque peut fournir. Le modèle prend comme entrée 4 variables qui sont l'irradiation solaire, la température et 2 paramètres qui sont liés à la réponse en puissance du panneau pour une période définie au début de la configuration. La figure 3.6 montre la courbe d'apprentissage du modèle.

Modèle 2 : pour prédire la valeur du cycle de service nécessaire pour que le panneau fonctionne à son point de puissance maximale. Le modèle prend comme entrée 3 variables qui sont l'irradiation solaire, la température et la puissance maximale. La figure 3.7 montre la courbe d'apprentissage du modèle.

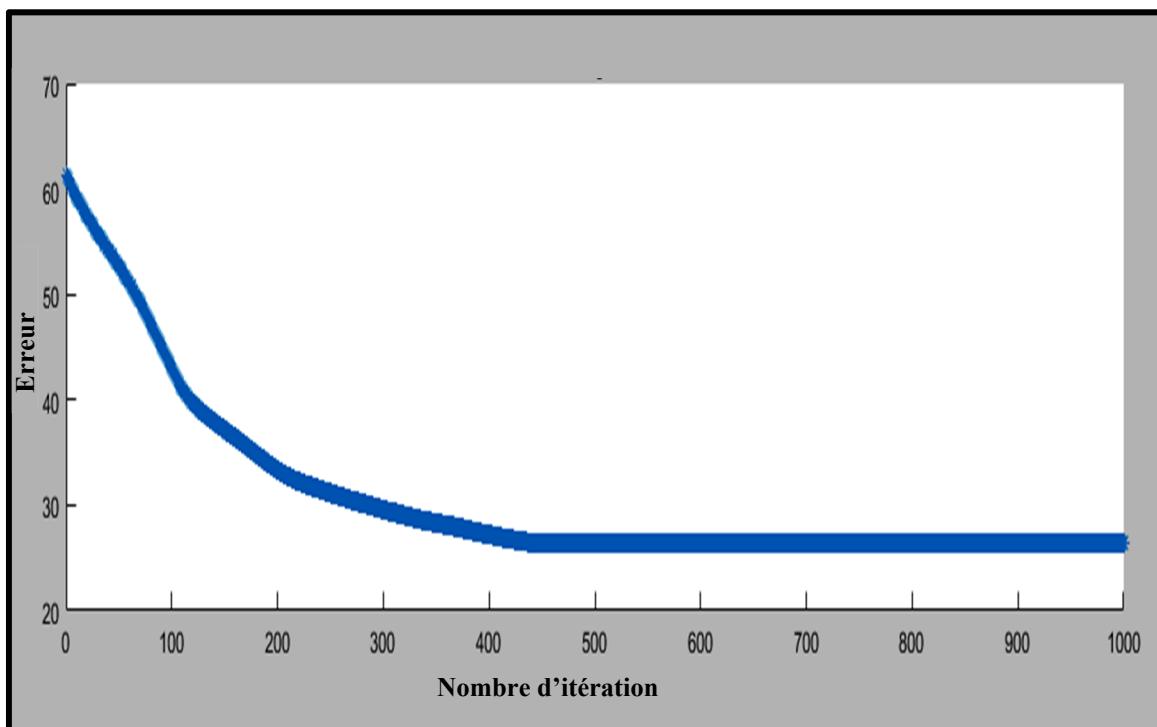


Figure 3.6 Courbe d'apprentissage du modèle 1'ANFIS

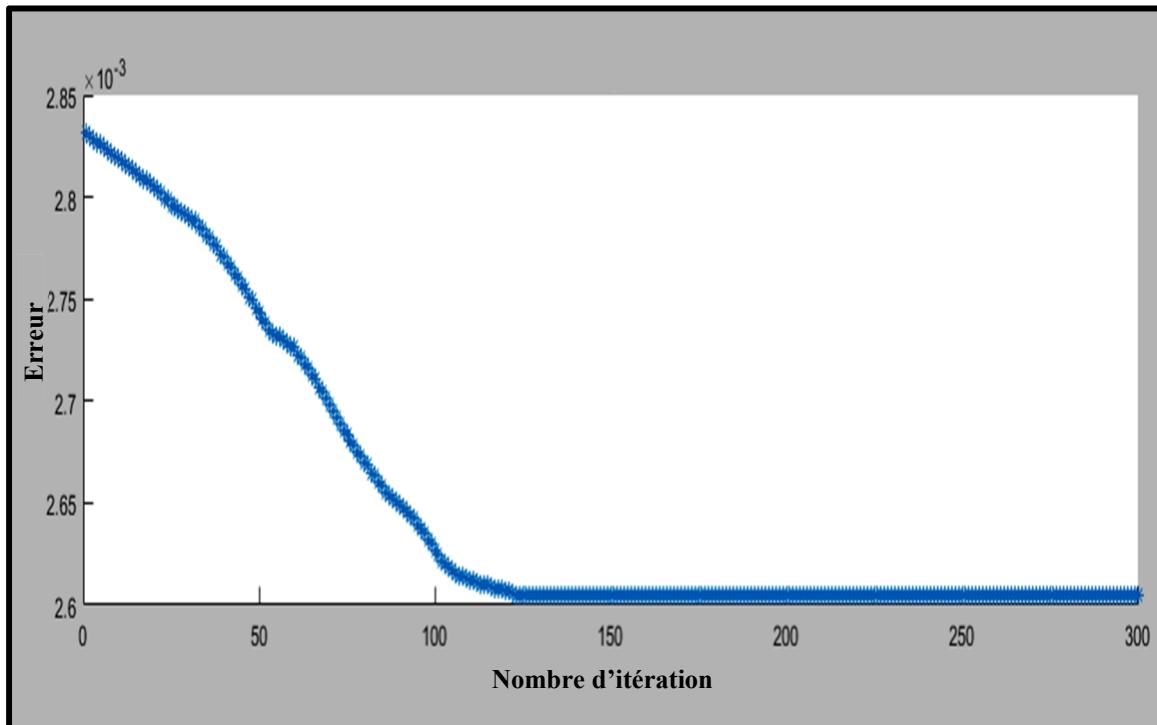


Figure 3.7 Courbe d'apprentissage du modèle 1'ANFIS

3.6 Résultat et discussions

Dans ce chapitre, un modèle MATLAB/Simulink pour un système PV autonome basé sur un contrôleur MPPT-ANFIS est simulé au lieu d'un système PV connecté au réseau car les données d'entraînement du modèle ANFIS sont collectées à partir d'un système PV à micro-réseau. Ce système PV est composé d'une matrice PV, d'un convertisseur CC-CC Boost avec un contrôleur MPPT et d'une charge résistive. Le réseau PV est composé de cinq modules PV connectés en série. Les paramètres du convertisseur DC-DC sont 0.5mH , $65\mu\text{F}$ et $850\mu\text{F}$ qui sont déterminés en utilisant les équations (1.10) et (1.11). Alors que la charge résistive, la fréquence de commutation, la diode de courant et le temps de mise à jour sont choisis à 15Ω , 5kHz , 10A et $500\mu\text{s}$, respectivement. Pour évaluer les performances, les méthodes ANFIS-MPPT, P&O-MPPT conventionnelle, INC-MPPT conventionnelle sont simulées dans des conditions similaires. L'objectif de cette simulation est de visualiser les différentes courbes de la puissance de sortie du système avec l'algorithme de contrôle proposé et d'autres algorithmes conventionnels (P&O et INC), afin de comparer les vitesses de suivi des différents modèles, ainsi que l'efficacité qui peut être calculée à partir du schéma fonctionnel présenté à la figure 3.8.

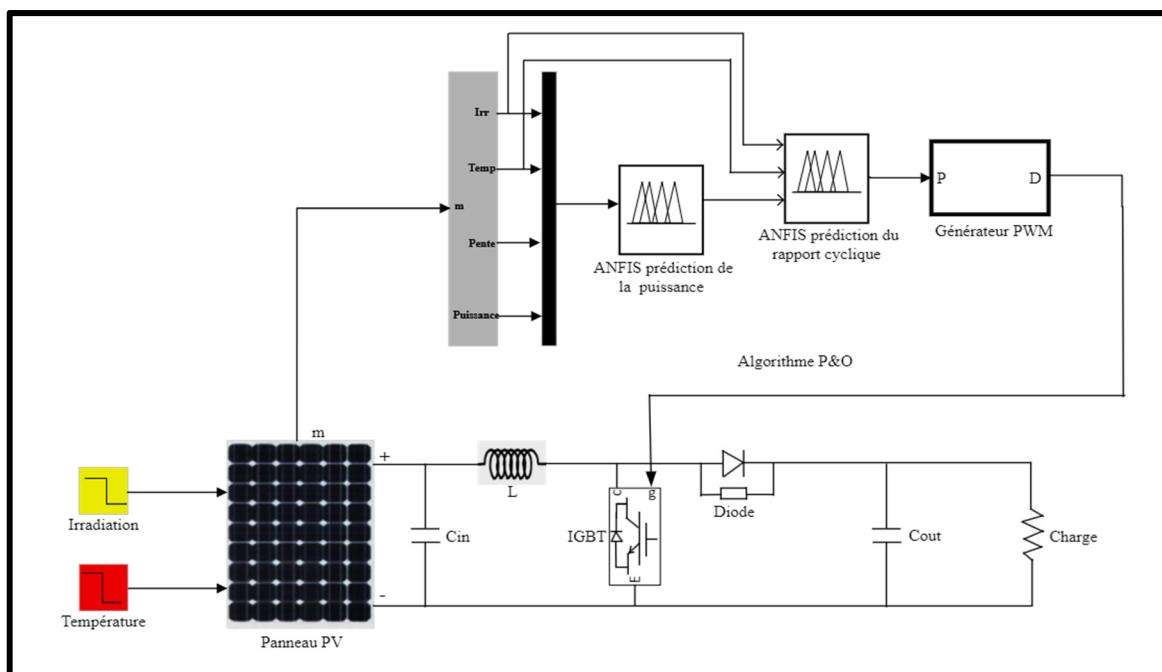


Figure 3.8 Schéma Simulink du système étudié

On considère les variations de température et d'irradiation données dans les figures 3.9 et 3.10. La figure 3.11 montre la variation de la puissance aux bornes du panneau PV en fonction des variations de température et d'irradiation.

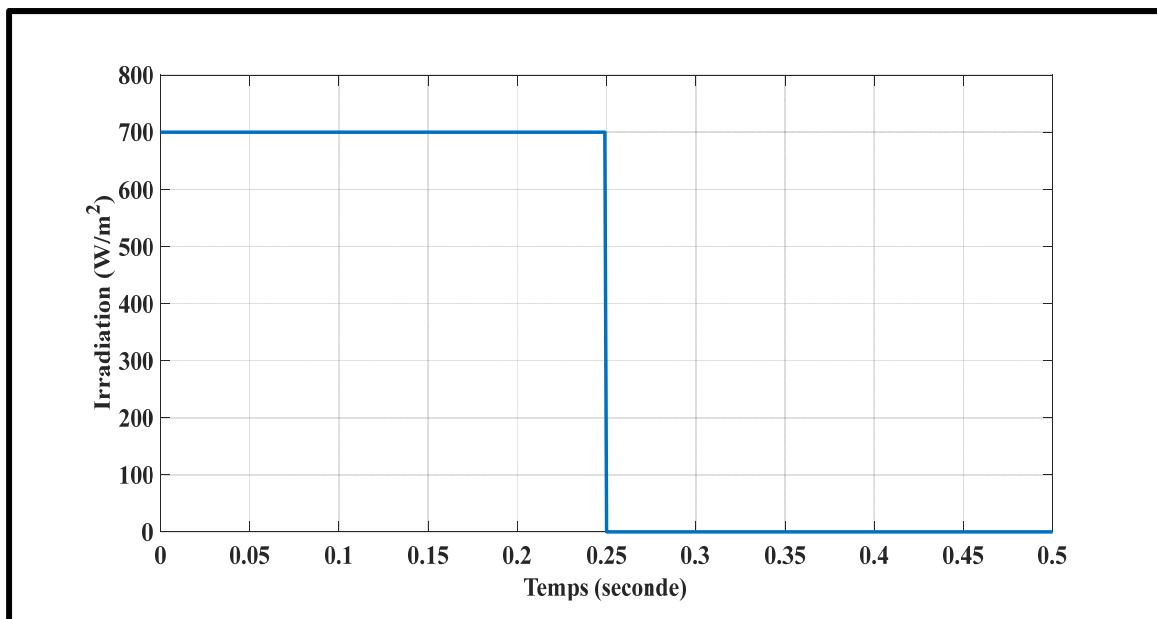


Figure 3.9 Courbe de variation de l'irradiation

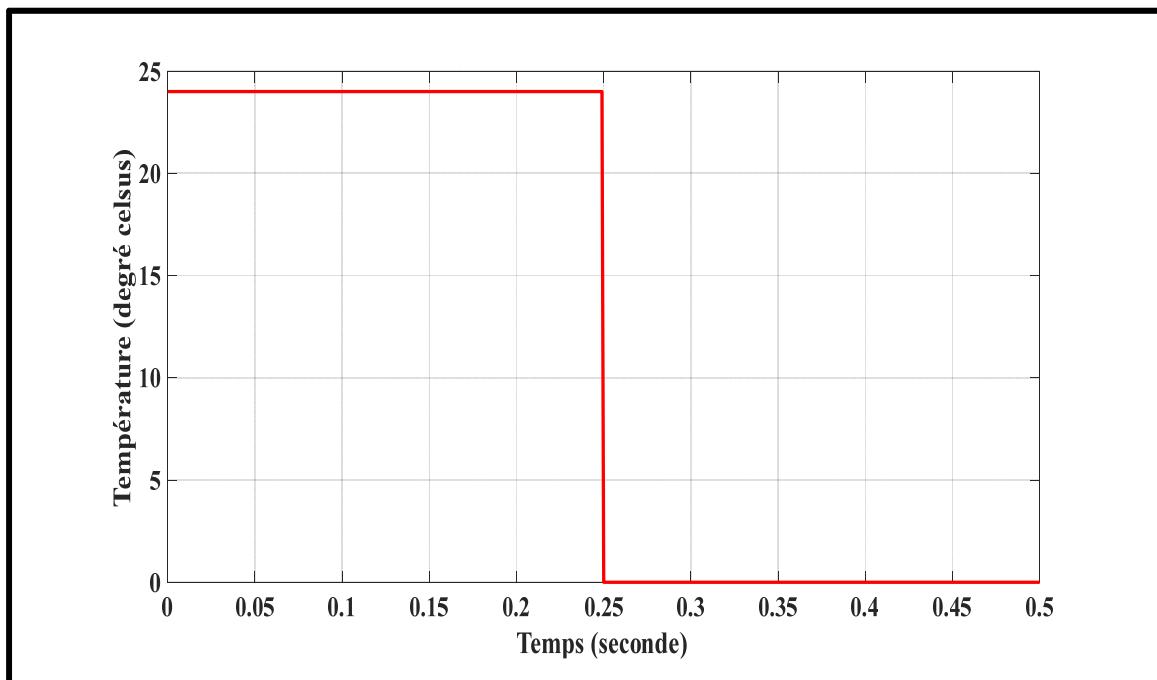


Figure 3.10 Courbe de variation de la température

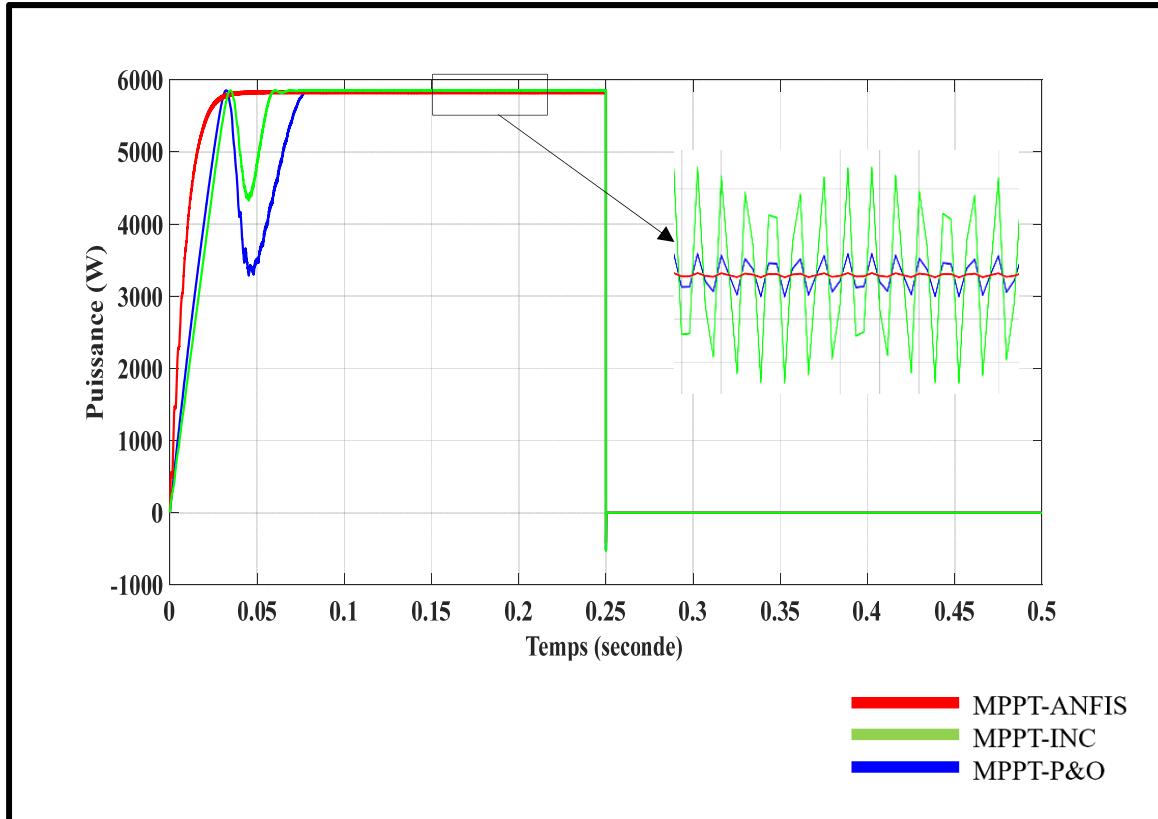


Figure 3.11 Courbe de puissance à la borne du PV des trois algorithmes P&O, INC et MPPT-ANFIS

Les algorithmes basés sur le système d'inférence neuro-flou adaptatif (ANFIS) se sont révélés plus efficaces que les algorithmes P&O et INC et ont un temps de réponse plus court. Cependant, ce type de modèle, qui est synthétisé à partir d'une base de données, est fortement dépendant des données collectées pour l'apprentissage.

Dans notre étude, nous avons essayé de corriger cette faiblesse en ajoutant une phase qui s'intègre à l'algorithme MPPT afin d'ajouter un paramètre qui caractérise le panneau PV, de sorte que le modèle puisse être fonctionnel pour toute configuration définie. Le tableau 3.4 montre les différentes efficacités de l'algorithme pour de multiples configurations afin de vérifier sa fiabilité.

Tableau 3.4 Efficacité de l'algorithme pour des différentes configurations de champs PV

Module	Modules parallèle/série	Efficacité
Trinsa Solar TSM-260PA05	4/8	99.32%
Suntech Power STP2240-20	10/20	99.52%
Suntech Power STP260-VRM	2/10	99.67%
T & Solar TSS3-248	4/16	99.88%
MCV Technologies MCV-190	4/8	99.36%

Comme résultat, le MPPT basé sur l'ANFIS prend moins de temps pour traiter le phénomène de dérive, comme le montre la figure 3.11. En outre, le MPPT est plus robuste dans le traitement de la bonne direction lors d'un changement rapide de l'irradiation solaire. En d'autres termes, ce problème était plus efficace sur le INC-MPPT conventionnel que sur le P&O-MPPT conventionnel. Afin d'évaluer plus en détail le ANFIS-MPPT proposé, le tableau 3.5 compare ses propriétés avec les ANFIS-MPPT conventionnels, les INC-MPPT conventionnels et les P&O-MPPT conventionnels. Comme on peut le constater, le système ANFIS-MPPT étudié présente le temps de convergence le plus court, la moindre oscillation autour du point MPP et la puissance de sortie la plus élevée. De plus, il est le plus précis dans le suivi du point MPP et évite le phénomène de dérive et le plus important, il est efficace pour différentes configurations de champs photovoltaïques.

Tableau 3.5 Comparaison des propriétés des algorithmes conventionnels et l'algorithme ANFIS étudié

Algorithmes	Temps de réponse	Oscillations	Efficacité d'adaptation
INC	24 ms	Moyenne	Forte
P&O	41 ms	Élevée	Forte
ANFIS conventionnel	6 ms	Réduite	Pas d'adaptation
ANFIS étudié	2 ms	Réduite	Forte

3.7 Conclusion

Ce chapitre présente un nouvel algorithme de suivi du point de puissance maximale (MPP) basé sur deux contrôleurs ANFIS (Adaptive neuro fuzzy inference system) pour l'application d'un système photovoltaïque. L'algorithme développé a été implémenté sur Matlab/Simulink, les résultats de la simulation montrent que le MPPT avec ANFIS offre une meilleure efficacité que les techniques conventionnelles comme P&O et INC et une vitesse de suivi plus élevée.

De plus, le modèle développé est fiable pour plusieurs configurations de champ photovoltaïque. Avec ces résultats, nous avons pu éliminer certaines limitations des algorithmes basés sur l'intelligence artificielle, qui manquent de fiabilité lorsque l'on change la configuration des systèmes utilisés.

Les algorithmes basés sur le système d'inférence neuro-flou adaptatif (ANFIS) se sont révélés plus efficaces que les algorithmes P&O et INC et ont un temps de réponse plus court. Cependant, ce type de modèle, qui est synthétisé à partir d'une base de données, est fortement dépendant des données collectées pour l'apprentissage

CONCLUSION

L'efficacité, la stabilité et la fiabilité d'un système photovoltaïque sont considérées comme des facteurs majeurs pour établir cette ressource énergétique sur le marché. Dans cette recherche, des techniques courantes de suivi du point de puissance maximale, y compris la perturbation et l'observation, la conductance incrémentale, le contrôle par logique floue, le système d'inférence neuro-adaptatif, ont été proposées pour un système PV connecté au réseau afin de maximiser la puissance de sortie d'un réseau PV. L'objectif est également d'améliorer la stabilité et la fiabilité de la conversion d'énergie photovoltaïque, en particulier dans le contexte d'un changement rapide des conditions atmosphériques. Ce qui suit est un aperçu de la portée, des principales contributions et des conclusions de l'étude.

Une revue complète des différentes méthodes PV-MPPT, y compris les techniques FCC, FOC, P&O, INC, FLC, ANN, ANFIS et PSO, basée sur leurs principales caractéristiques, a été présentée. En outre, les avantages et les inconvénients de chaque méthode MPPT ont été décrits et discutés afin d'aider les chercheurs à comprendre et donc à choisir la technique MPPT appropriée pour résoudre leurs problèmes spécifiques. D'après les résultats de cette évaluation, les contrôleurs MPPT utilisant des techniques d'intelligence artificielle sont plus complexes, plus coûteux et plus difficiles à mettre en œuvre. Cependant, ils ont une efficacité de suivi plus élevée, une vitesse de suivi plus rapide et moins d'oscillation que les méthodes MPPT classiques.

La modélisation et le contrôle du système PV ont été développés en utilisant MATLAB/Simulink pour tester la performance des différents contrôleurs MPPT. Les résultats primaires ont prouvé que l'utilisation d'un contrôleur MPPT avec le système PV augmente la puissance PV de sortie, réduit le temps de convergence et minimise les fluctuations MPP. Par conséquent, l'efficacité moyenne de suivi du système PV est améliorée, ainsi que la stabilité et la fiabilité de la production PV lorsqu'elle se connecte au réseau.

Bien que plusieurs techniques aient été conçues, l'algorithme Perturb and Observe est largement utilisé pour le MPPT en raison de son faible coût et de sa simplicité de mise en œuvre. Cependant, les principaux inconvénients de cette méthode sont un long temps de convergence, une grande oscillation autour du point de puissance maximale, et un problème de dérive associé aux changements rapides de l'irradiance. Par conséquent, le P&O-MPPT modifié basé sur le contrôleur à logique floue a été proposé pour résoudre les principaux problèmes de l'algorithme P&O conventionnel. Cependant, les systèmes PV connectés au réseau basés sur l'algorithme P&O conventionnel et l'algorithme P&O modifié fournissent une tension continue fluctuante dans des conditions météorologiques qui changent rapidement.

Une technique efficace de suivi du point de puissance maximale basée sur le système d'inférence neuro-flou adaptatif (ANFIS) utilisant un ensemble de données photovoltaïques a été conçu à partir d'un autre algorithme MPPT. Une technique d'ajustement de courbe a été utilisée pour analyser les données de simulation d'entrée et optimiser le réglage du modèle ANFIS, ce qui a permis d'éviter au système de subir une erreur d'apprentissage élevée. Les résultats ont démontré que la méthode proposée présente une puissance générée plus élevée et ne s'écarte pas du point MPP optimal dans différentes conditions climatiques que les autres méthodes, atteignant des rendements supérieurs à 99,6 %. De plus cette méthode offre une adaptabilité envers différentes configurations de champs photovoltaïques, ce qui constitue une faiblesse majeure des méthodes ANFIS conventionnelles.

RECOMMANDATION

L'amélioration de l'efficacité du suivi d'un système PV dans des conditions atmosphériques changeant rapidement a été démontrée dans ce travail. Il serait bénéfique d'améliorer les performances du système PV dans une condition d'ombrage partiel. Cette condition se produit lorsqu'il y a un ombrage, qui peut être causé par l'ombre d'un arbre ou par la poussière, c'est-à-dire sur une partie du réseau PV. Dans ce cas, le générateur PV génère plusieurs MPP. Par conséquent, l'efficacité totale de production du générateur PV installé diminue. Pour résoudre ce problème, on peut utiliser le même principe des méthodes proposées dans cette recherche afin de développer des algorithmes pour le suivi du MPP dans une condition d'ombrage partiel.

LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES

- A. Harrag and S. Messalti (2017), How fuzzy logic can improve PEM fuel cell MPPT. International Journal of Hydrogen Energy 43(1): 537-550.
- A. A. Aldair, A. A. Obed, and A. F. Halihal (2018), Design and implementation of ANFIS reference model controller based MPPT using FPGA for photovoltaic system. Renewable and Sustainable Energy Reviews 82(3): 2202-2217.
- A. Iqbal, H. Abu-Rub and S. M. Ahmed (2010), Adaptive neuro-fuzzy inference system based maximum power point tracking of a solar PV module. 2010 IEEE International Energy Conference, 2010, pp. 51-56, doi: 10.1109/ENERGYCON.2010.5771737.
- B. N. Alajmi, K. H. Ahmed, S. J. Finney and B. W. Williams (2011), Fuzzy-Logic-Control Approach of a Modified Hill-Climbing Method for Maximum Power Point in Microgrid Standalone Photovoltaic System. IEEE Transactions on Power Electronics, vol. 26, no. 4, pp. 1022-1030, April 2011, doi: 10.1109/TPEL.2010.2090903.
- C. B. Salah and M. Ouali (2010), Comparison of fuzzy logic and neural network in maximum power point tracker for PV systems. Electric Power Systems Research 83(1): 43-50.
- C. Larbes, S.M. Aït Cheikh, T. Obeidi and A. Zerguerras (2009), Genetic algorithms optimized fuzzy logic control for the maximum power point tracking in photovoltaic system. Renewable Energy 34(10): 2093-2100.
- D. Baimel, S. Tapuchi, Y. Levron and J. Belkov (2019), Improved Fractional Open Circuit Voltage MPPT Methods for PV Systems. Grid Connected Photovoltaic Systems. 8(3): 321.
- D. Murdianto, O. Penangsang, and A. Priyadi (2015), Modeling and simulation of MPPT bidirectional using adaptive neuro fuzzy inference system (ANFIS) in distributed energy generation system. Intelligent Technology and Its Applications (ISITIA). 2015, pp. 207-212, doi: 10.1109/ISITIA.2015.7219980.
- F. Mayssa and L. Sbita (2012), Advanced ANFIS-MPPT control algorithm for sunshine photovoltaic pumping systems. First International Conference on Renewable Energies and Vehicular Technology. 2012, pp. 167-172, doi: 10.1109/REVET.2012.6195265.
- H. Hamdan and J. M. Garibaldi (2010), Adaptive neuro-fuzzy inference system (ANFIS) in modelling breast cancer survival. International Conference on Fuzzy Systems. 2010, pp. 1-8, doi: 10.1109/FUZZY.2010.5583997.

- J. Farzaneh, R. Keypour, and A. Karsaz (2019), A novel fast maximum power point tracking for a PV system using hybrid PSO-ANFIS algorithm under partial shading conditions. International Journal of Industrial Electronics, Control and Optimization. 2. 47-58. 10.22111/IECO.2018.25721.1056.
- K. Jain, M. Gupta and A. Kumar Bohre (2019), Implementation and Comparative Analysis of P&O and INC MPPT Method for PV System. India International Conference on Power Electronics (IICPE). 2018, pp. 1-6, doi: 10.1109/IICPE.2018.8709519.
- L. Sabiyanto, A. Mohamed and H. Shareef (2012), Hopfield Neural Network Optimized Fuzzy Logic Controller for Maximum Power Point Tracking in a Photovoltaic System. International journal of photoenergy, 2012. 1-13. 10.1155/2012/798361.
- M. Zerouali, S. Zouirech, A. E. Ougli, B. Tidhaf and H. Zrouri (2019), Improvement of Conventional MPPT Techniques P&O and INC by Integration of Fuzzy Logic. International Renewable and Sustainable Energy Conference (IRSEC), 2019, pp. 1-6, doi: 10.1109/IRSEC48032.2019.9078330.
- M. A. Abdourraziq, M. Maaroufi and M. Ouassaid (2014), A new variable step size INC MPPT method for PV systems. International Conference on Multimedia Computing and Systems (ICMCS), 2014, pp. 1563-1568, doi: 10.1109/ICMCS.2014.6911212.
- M. Ammirrul, A. Mohd, M. Amran, M. Radzi, A. C. Soh, and N. A. Rahim (2014), Development of adaptive perturb and observe-fuzzy control maximum power point tracking for photovoltaic boost dc – dc converter. IET Renewable Power Generation. 8(2): 183-194.
- M. Nabipour, M. Razaz, S. G. Seifossadat, and S. S. Mortazavi (2017), A new MPPT scheme based on a novel fuzzy approach. Renewable and Sustainable Energy Reviews. 2017 ScienceGate. 74(5): 1147-1169.
- M. Lasheen and M. Abdel-salam (2020), A novel hybrid Maximum Power Point Tracking Technique using Hill Climbing and ANFIS Techniques for PV Applications. International Journal of Renewable Energy. 112: 1096-1106.
- N. Fapi, P. Wira, and M. Kamta (2021). Real-Time Experimental Assessment of a New MPPT Algorithm Based on the Direct Detection of the Short-Circuit Current for a PV System. Renewable Energy and Power Quality Journal. 19. 598-603. 10.24084/repqj19.358.
- N. S. D. Souza, L. A. C. Lopes and X. Liu (2010), Comparative study of variable size perturbation and observation maximum power point trackers for PV systems. Electric Power Systems Research. 80(3): 296-305.

- N. Patcharaprakiti and S. Premrudeepreechacharn (2002), Maximum power point tracking using adaptive fuzzy logic control for grid-connected photovoltaic system. Power Engineering Society Winter Meeting, 2002, pp. 372-377 vol.1, doi: 10.1109/PESW.2002.985022.
- N. Gupta and R. Garg (2017), Tuning of asymmetrical fuzzy logic control algorithm for SPV system connected to grid. International Journal of Hydrogen Energy. 42(26): 16375-16385.
- O. Guenounou, B. Dahhou, and F. Chabour (2014), Adaptive fuzzy controller based MPPT for photovoltaic systems. Energy Conversion and Management. 78: 843-850.
- R. K. Kharb, S. L. Shimi, S. Chatterji, and M. F. Ansari (2014). Modeling of solar PV module and maximum power point tracking using ANFIS. Renewable and Sustainable Energy Reviews. 33: 602-612.
- R. Kianaz, H. Rahil and M. Mahdi. (2014). A Fuzzy Inference System for Assessment of the Severity of the Peptic Ulcers. Computer Science & Information Technology. 4. 10.5121/csit.2014.4527.
- S. Ozdemir, N. Altin and I. Sefa (2017), Fuzzy logic based MPPT controller for high conversion ratio quadratic boost converter. International Journal of Hydrogen Energy, 42(28): 17748-17759.
- S. ali Blaifi, S. Moulahoum, R. Benkercha, B. Taghezouit, and A. Saim (2017), M5P model tree based fast fuzzy maximum power point tracker. Solar Energy. 163: 405-424.
- T. Selmi, M. Abdul-Niby, L. Devis and A. Davis (2014), P&O MPPT implementation using MATLAB/Simulink. Ninth International Conference on Ecological Vehicles and Renewable Energies (EVER), 1-4. 10.1109/EVER.2014.6844065.
- T. H. Kwan and X. Wu (2016), Maximum power point tracking using a variable antecedent fuzzy logic controller. Grid Connected Photovoltaic Systems, 137: 189-200.
- T. L. Kottas, Y. S. Boutalis and A. D. Karlis (2006), New maximum power point tracker for PV arrays using fuzzy controller in close cooperation with fuzzy cognitive networks. IEEE Transactions on Energy Conversion. vol. 21, no. 3, pp. 793-803, Sept. 2006, doi: 10.1109/TEC.2006.875430.
- U. Yilmaz, A. Kircay and S. Borekci (2018), PV system fuzzy logic MPPT method and PI control as a charge controller, Renewable and Sustainable Energy Reviews, 81(1): 994-1001.

X. Li, H. Wen, Y. Hu, Y. Du and Y. Yang (2021), A Comparative Study on Photovoltaic MPPT Algorithms Under EN50530 Dynamic Test Procedure. IEEE Transactions on Power Electronics, vol. 36, no. 4, pp. 4153-4168, April 2021, doi: 10.1109/TPEL.2020.3024211.

Y. Soufi, M. Bechouat, and S. Kahla (2014), Fuzzy-PSO controller design for maximum power point tracking in photovoltaic system. International Journal of Hydrogen Energy. 42(13): 8680-8688.

