

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

الجمهورية الجزائرية الديمقراطية الشعبية

MINISTRY OF HIGHER EDUCATION
AND SCIENTIFIC RESEARCH

HIGHER SCHOOL IN APPLIED SCIENCES
-T L E M C E N-



المدرسة العليا في العلوم التطبيقية
École Supérieure en
Sciences Appliquées

وزارة التعليم العالي والبحث العلمي

المدرسة العليا في العلوم التطبيقية
- تلمسان -

Mémoire de fin d'étude

Pour l'obtention du diplôme d'Ingénieur

Filière : Automatique
Spécialité : Automatique

Présenté par :

Nor El Houda BEKADA BENCHAIB

Yousra Oum El kheir HAMMADI

Thème

**Prédiction De La Production Énergétique D'un
Système Photovoltaïque À L'Aide De L'IA En
Prenant En Compte Les Données Météo**

Soutenu publiquement, le 20 / 06 / 2026 , devant le jury composé de :

L. F. BOUKLI HACENE
A. CHIALI
I. NEDJAR
R. MOKHTARI
F. MERAD

MAB
MCA
MCA
MCA
MRA

ESSA. Tlemcen
ESSA. Tlemcen
ESSA. Tlemcen
ESSA. Tlemcen
CDS. Oran

Président
Directeur de mémoire
Co- Directeur de mémoire
Examineur 1
Examineur 2

Année universitaire : 2025 /2026

DÉDICACE

Avant tout, je remercie Dieu, le Tout-Puissant, pour toutes les bénédictions qu'Il m'a accordées tout au long de ma vie. Je Le remercie de m'avoir donné la santé, les opportunités, la persévérance et la volonté nécessaires pour accomplir ce parcours. Tout ce que j'ai réalisé jusqu'à aujourd'hui n'aurait pas été possible sans Sa volonté. À Lui reviennent ma reconnaissance et ma profonde gratitude.

Je dédie ce travail à ma mère (Allah yarhamha). Son prénom, **Yasmine**, évoque cette fleur dont le parfum continue à se faire sentir longtemps après son passage. Lorsque je pense à ma mère, c'est exactement cette image qui me vient à l'esprit. Elle aussi a laissé une trace dans le cœur de tous ceux qui l'ont connue et aimée. Elle nous a quittés de façon inattendue quelques semaines avant mon entrée à l'université. Elle n'a pas pu vivre cette expérience à mes côtés ni voir les étapes qui m'ont menée jusqu'à l'aboutissement de ce parcours. Pourtant, elle ne m'a jamais quittée. Je l'ai gardée dans mon cœur à chaque instant, dans chaque réussite, dans chaque difficulté et dans chaque décision. Je continue encore à entendre ses conseils, à me souvenir de son sourire et de nos discussions. Pendant ces cinq années, j'ai souvent essayé d'imaginer les mots qui pourraient exprimer ma gratitude, mais aucun ne me semble suffisant. Tout ce que je peux dire, c'est que son amour, sa force et son souvenir m'ont accompagnée tout au long de ce chemin. Maman, j'espère t'avoir rendue fière. Tout ce que j'ai accompli porte une part de toi. Et si je peux souhaiter une chose pour l'avenir, c'est de réussir à laisser dans la vie des autres une aussi belle empreinte que celle que tu as laissée dans la mienne.

J'adresse également mes plus sincères remerciements à mon père, **Ghouti**. Lorsque je repense à mon parcours, je me souviens encore de la petite fille que j'étais lorsqu'il m'a prise par la main pour m'accompagner à l'école pour la toute première fois. À cet âge-là, je ne pouvais pas imaginer tout le chemin qui m'attendait. Aujourd'hui, après toutes ces années d'études, je réalise qu'il a toujours été présent, avec le même soutien, la même confiance et les mêmes encouragements. Merci d'avoir toujours cru en moi et de m'avoir accompagnée avec constance et amour.

Je remercie également mes frères, **Mohammed** et **Younes**, pour leur présence constante. Younes a toujours été bien plus qu'un frère, il a été un ami précieux et un soutien sur qui j'ai toujours pu compter. Merci à vous deux pour votre affection.

À mon grand-père, **Ben Amer**, qui a été l'une des premières personnes à m'encourager à poursuivre mes études et à croire en l'importance du savoir. J'associe également à cet hommage mes deux grands-mères, **Rachida** et **Fatma**, ainsi que mon autre grand-père, **Mohamed**.

Mes remerciements s'adressent aussi à ma famille, mes proches et mes amis. Leurs encouragements et leur confiance ont rendu ce parcours plus beau et plus enrichissant, et je leur en suis profondément reconnaissante.

Je remercie chaleureusement mon amie et binôme, **Yousra**, avec qui j'ai partagé ces cinq années d'études. Merci pour nos sourires, nos projets et cette belle aventure construite côte à côte. *Graduating with you was the best part of my journey.* Ta présence a rendu ce chemin plus léger et rempli de souvenirs précieux que je garderai toujours avec affection.

Je me remercie également moi-même. Pendant longtemps, je n'aurais jamais pensé écrire ces mots, mais aujourd'hui je choisis de reconnaître le chemin parcouru. Je suis fière de la personne que je suis devenue, des connaissances que j'ai acquises, des objectifs que j'ai atteints et de la persévérance dont j'ai fait preuve. Cette réussite représente plusieurs années de travail, d'apprentissage et d'évolution, et je suis heureuse d'avoir mené cette aventure jusqu'au bout.

À tous ceux qui ont contribué, de près ou de loin, à cette réussite, j'adresse ma plus profonde gratitude.

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

REMERCIEMENTS

Nous souhaitons tout d'abord exprimer notre profonde reconnaissance envers notre encadrant, **M. Anisse CHIALI**, pour avoir accepté de superviser notre recherche. Sa disponibilité, son expertise et sa confiance ont été essentiels tout au long de ce projet de fin d'études.

Nous remercions également notre co-encadrante, **Mme Imane NEDJAR**, pour ses orientations constantes, son soutien et ses précieux conseils qui nous ont permis d'affiner nos analyses et d'enrichir notre réflexion.

Nous tenons à exprimer notre vive gratitude à **M. ADJIM Ramz-Eddine Abderrezak**, responsable du FabLab, pour ses conseils avisés, sa grande disponibilité et son aide technique précieuse lors des phases expérimentales.

Nous adressons nos plus sincères remerciements à **M. Mohamed MEBROUKI**, **Mme Nessrine LARIBI** et **M. Nasr-eddine BENHADJI SERRADJ** pour leur soutien et l'aide concrète qu'ils nous ont apportée à différentes étapes de notre projet.

Nous tenons également à rendre un hommage respectueux à **M. ARICHI Fayssal**, **M. KHEFIF SidiMohammed** et **M. Abdelkarim CHEMIDI**, enseignants qui ont grandement marqué notre parcours universitaire au sein de l'école.

Nous exprimons notre profonde gratitude envers **Dr. BOUKLI HACENE Lotfi Fazil** pour avoir accepté de présider l'honorable jury de notre soutenance, ainsi qu'à **Dr. MOKHTARI Rida** et **Dr. Merad Fayza** pour avoir accepté d'examiner notre travail. Enfin, nous saluons l'engagement des responsables de l'École Supérieure en Sciences Appliquées de Tlemcen (ESSAT) : **M. ROUISSAT Boucherit**, directeur de l'école, **M. MEGNAFI Hichem**, chef de département du second cycle, et **M. ABDI SidiMohammed**, chef de la filière automatique.

Nos remerciements s'adressent enfin à toute l'équipe pédagogique de l'école, ainsi qu'à toutes les personnes qui ont participé de près ou de loin à la réalisation de ce travail.

TABLE DES MATIÈRES

Liste des abréviations	14
Nomenclature	15
Introduction	16
Chapitre 1 : LES SYSTÈMES PHOTOVOLTAÏQUES	18
1.1 Contexte énergétique et rôle du photovoltaïque	18
1.2 Évolution historique du photovoltaïque	19
1.3 Principe de fonctionnement	20
1.3.1 La jonction PN	20
1.3.2 Les étapes de la conversion énergétique	22
1.3.3 Architecture du générateur photovoltaïque (GPV)	22
1.4 Technologies photovoltaïques et types de cellules	23
1.4.1 Cellules au silicium monocristallin	24
1.4.2 Cellules polycristallines	24
1.4.3 Technologies couches minces	25
1.4.4 Comparaison qualitative	26
1.5 Facteurs influençant la production photovoltaïque	27
1.5.1 Données météorologiques	27
1.5.2 Conditions environnementales	28
1.5.3 Variabilité temporelle	28

1.6	Caractéristiques électriques des générateurs photovoltaïques	29
1.6.1	Courbes Courant-Tension et Puissance-Tension	29
1.6.2	Grandeur caractéristique fondamentale	31
1.6.3	Point de puissance maximale MPP	31
1.6.4	Le facteur de forme FF	32
1.6.5	Le rendement de conversion η	32
1.6.6	Influence de l'irradiance et de la température sur les paramètres électriques	32
1.7	Problématique de la prédiction de la production photovoltaïque	34
1.7.1	Difficultés liées à l'intermittence	34
1.7.2	Intérêt de la prévision à court terme	34
1.7.3	Applications principales	34
1.8	Rôle de la prédiction dans les smart grids	35
1.8.1	Gestion proactive de l'énergie SGE	35
1.8.2	Aide à la décision pour les gestionnaires de réseau	36
1.8.3	Pilotage prédictif des systèmes décentralisés	36
1.9	Conclusion	36

Chapitre 2 : Modélisation du système photovoltaïque et développement du prototype **38**

2.1	Systèmes photovoltaïques existants	39
2.1.1	Typologie des systèmes photovoltaïques	39
2.1.2	Architecture générale	40
2.1.3	Principe de fonctionnement du système	41
2.2	Limites des systèmes existants	42
2.2.1	Difficulté d'optimisation de la production et du stockage	42
2.2.2	Gestion énergétique réactive	43
2.2.3	Sensibilité aux conditions météorologiques	44
2.3	Modélisation du générateur photovoltaïque	46
2.3.1	Modèle électrique à une diode	46
2.3.1.1	Architecture du circuit équivalent	46

2.3.1.2	Équation caractéristique	47
2.3.2	Relation analytique simplifiée de la puissance	47
2.4	Présentation du prototype photovoltaïque proposé	48
2.4.1	Description globale du système	48
2.4.1.1	ESP32 (Unité centrale)	48
2.4.1.2	INA219 (Mesure électrique)	49
2.4.1.3	DHT22 (Température et Humidité)	49
2.4.1.4	LDR (Estimation de l'irradiance)	50
2.4.1.5	Panneau photovoltaïque 18 V	50
2.4.1.6	Charge résistive de 2 k Ω	51
2.4.1.7	Module de stockage MicroSD	51
2.4.1.8	Schéma de câblage du prototype	52
2.4.1.9	Conception mécanique du support	52
2.4.1.10	Prototype expérimental réalisé	53
2.4.2	Architecture fonctionnelle du prototype	54
2.4.3	Hypothèses retenues	56
2.5	Analyse du comportement du système photovoltaïque	57
2.5.1	Caractère non linéaire du système	57
2.5.2	Influence des paramètres météorologiques	58
2.5.3	Analyse de sensibilité du modèle	58
2.6	Discretisation et implémentation numérique	59
2.6.1	Choix de la période d'échantillonnage	59
2.6.2	Passage du modèle continu au modèle discret	60
2.6.3	Implémentation dans l'environnement de développement	60
2.7	Acquisition et organisation des données	61
2.7.1	Processus d'acquisition des mesures	61
2.7.2	Structuration en séries temporelles	62
2.7.3	Consolidation de la base de données	62
2.8	Prétraitement des données	62

2.8.1	Nettoyage et intégrité statistique	62
2.8.2	Normalisation des variables	63
2.8.3	Partitionnement chronologique de la base de données	63
2.9	Conclusion	63
Chapitre 3 : Analyse des résultats et validation du modèle		65
3.1	Modèles utilisés pour la prédiction photovoltaïque	65
3.1.1	Le Perceptron Multicouche (PMC)	66
3.1.2	Le réseau Long Short-Term Memory (LSTM)	66
3.1.3	Le réseau Gated Recurrent Unit (GRU)	67
3.1.4	Les Forêts Aléatoires (Random Forests)	68
3.1.5	Le modèle Auto-Régressif à entrée eXogène (ARX)	69
3.2	Méthodologie d'évaluation	70
3.2.1	Indicateurs de performance statistique	70
3.2.1.1	Racine de l'Erreur Quadratique Moyenne (RMSE)	70
3.2.1.2	Erreur Absolue Moyenne (MAE)	70
3.2.1.3	Erreur Absolue Moyenne en Pourcentage (MAPE)	71
3.2.1.4	Coefficient de Détermination (R^2)	71
3.2.2	Protocole de validation	71
3.3	Évaluation et validation sur données théoriques	72
3.3.1	Base de données théorique	72
3.3.2	Résultats statistiques et indicateurs de performance théoriques	73
3.3.3	Analyse graphique des profils de prédiction théoriques	74
3.4	Évaluation et validation sur données expérimentales	75
3.4.1	Présentation de la base de données	75
3.4.2	Configuration expérimentale des modèles évalués	77
3.4.3	Analyse de la dynamique temporelle des prédictions	79
3.4.4	Discussion des résultats	81
3.4.4.1	Analyse des performances des modèles	81
3.4.4.2	Avantages et limites de l'approche proposée	82

3.5 Conclusion	83
--------------------------	----

Bibliographie	86
----------------------	-----------

TABLE DES FIGURES

1.1	La première cellule photovoltaïque produite par Bell Lab	19
1.2	Semi-conducteur de type N	21
1.3	Semi-conducteur de type P	21
1.4	Principe de fonctionnement d'une cellule photovoltaïque	22
1.5	Structure d'un système photovoltaïque	23
1.6	Cellule photovoltaïque en silicium monocristallin	24
1.7	Une cellule photovoltaïque polycristalline	25
1.8	Cellule photovoltaïque amorphe	26
1.9	Cellules solaires GaAs	27
1.10	caractéristiques I-V	30
1.11	caractéristiques P-V	30
1.12	Caractéristiques I-V et P-V	31
1.13	Caractéristique I-V pour différents niveaux de rayonnement	33
1.14	Caractéristique I-V pour différentes valeurs de températures	33
2.1	Types de systèmes photovoltaïques	40
2.2	Architecture générale d'un système photovoltaïque	41
2.3	Synoptique général de la chaîne de conversion et de gestion d'énergie d'un système photovoltaïque	42
2.4	Comparaison des stratégies d'intervention	44
2.5	Impact de la couverture nuageuse sur la production photovoltaïque	45
2.6	Circuit électrique équivalent du modèle à une diode d'une cellule PV	47
2.7	Microcontrôleur ESP32-WROOM-32	49

2.8	Capteur de puissance INA219	49
2.9	Capteur de température et d'humidité DHT22	50
2.10	Capteur de luminosité LDR	50
2.11	Panneau photovoltaïque 18 V	51
2.12	Module de lecture de carte MicroSD	52
2.13	Schéma de câblage du prototype photovoltaïque instrumenté	52
2.14	Modélisation des composants mécaniques du système d'orientation sous SolidWorks	53
2.15	Prototype réel du système photovoltaïque instrumenté	54
2.16	Architecture fonctionnelle du prototype	56
3.1	Architecture du Perceptron Multicouche (PMC) pour la régression	66
3.2	Structure interne d'une cellule Long Short-Term Memory (LSTM)	67
3.3	Architecture générale d'un modèle de Forêt Aléatoire en régression (agrégation par moyenne)	68
3.4	Schéma du protocole de division chronologique des données	72
3.5	Aperçu des dix premières lignes de la base de données générée par modélisation analytique.	73
3.6	Distribution statistique et analyse fréquentielle des variables de la base de données	74
3.7	Aperçu structurel des dix premières lignes de la base de données expérimentale sous Python	75
3.8	Distribution statistique et analyse fréquentielle des variables de la base de données	76
3.9	Évaluation graphique des performances des cinq modèles de prédiction pour chaque métrique	78
3.10	Suivi temporel – Réseau de neurones Perceptron Multicouche (PMC)	79
3.11	Suivi temporel – Réseau récurrent Long Short-Term Memory (LSTM)	80
3.12	Suivi temporel – Réseau récurrent Gated Recurrent Unit (GRU)	80
3.13	Suivi temporel – Modèle linéaire AutoRégressif avec Variables Exogènes (ARX)	80
3.14	Suivi temporel – Modèle d'ensemble Forêt Aléatoire (RF)	81

LISTE DES TABLEAUX

1.1	Comparaison des technologies photovoltaïques	26
3.1	Comparaison numérique des performances des modèles sur l'ensemble de données théoriques de modélisation	73
3.2	Comparaison numérique des performances des modèles sur l'ensemble de test	77

Résumé

L'intégration de l'énergie solaire au sein des réseaux intelligents est freinée par son intermittence liée aux fluctuations météorologiques. Pour y répondre, ce travail propose une approche associant un prototype matériel d'acquisition de données réelles à différents modèles d'apprentissage automatique afin de prévoir la puissance générée. Les résultats confirment la pertinence de cette méthodologie et démontrent que les approches retenues permettent d'anticiper efficacement les variations de production pour optimiser la gestion de l'énergie.

Mots clés : Prédiction énergétique ; Système photovoltaïque ; Intelligence artificielle ; Données météorologiques.

Abstract

Integrating solar energy into smart grids is challenged by its intermittency due to meteorological fluctuations. To address this, this work proposes an approach combining a hardware data acquisition prototype with various machine learning models to forecast the generated power. The results confirm the relevance of this methodology and demonstrate that the selected approaches effectively anticipate production variations to optimize energy management.

Keywords : Energy prediction ; Photovoltaic system ; Artificial intelligence ; Meteorological data.

ملخص

يواجه إدماج الطاقة الشمسية داخل الشبكات الذكية صعوبات بسبب تقطعها الناتج عن التقلبات الجوية المتروولوجية. لمواجهة ذلك، يقترح هذا العمل نهجاً يجمع بين نموذج أولي تجريبي لجمع القياسات الحقيقية ونماذج مختلفة للتعلم الآلي للتنبؤ بالطاقة المنتجة. تؤكد النتائج ملاءمة المنهجية المتبعة وتظهر أن المقاربات المعتمدة تسمح باستباق تغيرات الإنتاج بشكل فعال لتحسين تسيير الطاقة.

الكلمات المفتاحية : التنبؤ الطاقوي ؛ نظام ضوئي جهدي ؛ الذكاء الاصطناعي ؛ المعطيات المتروولوجية.

ABRÉVIATIONS

AM	Air Mass.
ARX	AutoRegressive with Exogenous inputs.
CA	Courant Alternatif.
CAO	Conception Assistée par Ordinateur.
CC	Courant Continu.
CSV	Comma-Separated Values.
CTS	Conditions de Test Standards.
GPV	Générateur Photovoltaïque.
GRU	Gated Recurrent Unit.
LSTM	Long Short-Term Memory.
MAE	Erreur Absolue Moyenne.
MAPE	Erreur Absolue Moyenne en Pourcentage.
MPP	Maximum Power Point.
MPPT	Maximum Power Point Tracking.
PMC	Perceptron Multicouche.
RF	Random Forest (Forêt Aléatoire).
RMSE	Erreur Quadratique Moyenne.
SER	Sources d'Énergie Renouvelables.
SGE	Système de Gestion de l'Énergie.
SSE	Système de Stockage d'Énergie.

NOMENCLATURE

A	Facteur d'idéalité de la diode.
FF	Facteur de forme (Fill Factor).
G	Irradiance solaire (W/m^2).
G_{CTS}	Irradiance dans les conditions de test standards ($1000 W/m^2$).
G_{ref}	Irradiance solaire de référence (W/m^2).
Hum	Humidité relative (%).
I_{mpp}	Courant au point de puissance maximale (A).
I_{ph}	Photo-courant généré par la cellule (A).
I_{pv}	Courant de sortie du module photovoltaïque (A).
I_s	Courant de saturation inverse de la diode (A).
I_{sc}	Courant de court-circuit (A).
k	Constante de Boltzmann ($1,38 \times 10^{-23} J/K$).
P_{calc}	Puissance estimée ou calculée en conditions réelles (W).
$P_{\text{max,CTS}}$	Puissance maximale du module dans les conditions de test standards (W).
P_{mpp}	Puissance maximale générée ou au point de puissance maximale (W).
P_{opt}	Puissance optique reçue par le module (W).
q	Charge élémentaire de l'électron ($1,602 \times 10^{-19} C$).
R_p	Résistance parallèle ou shunt (Ω).
R_s	Résistance série (Ω).
T	Température de fonctionnement ou ambiante ($^{\circ}C$).
T_{ref}	Température de référence ($25^{\circ}C$).
V_{mpp}	Tension au point de puissance maximale (V).
V_{oc}	Tension en circuit ouvert (V).
γ	Coefficient de température de la puissance.
Δt	Période ou pas d'échantillonnage (min).

INTRODUCTION GÉNÉRALE

Au cœur de la transition énergétique mondiale, la lutte contre le changement climatique s'impose comme l'un des défis majeurs de notre époque. L'augmentation continue des émissions de gaz à effet de serre, directement liée à la dépendance aux énergies fossiles, a engendré des bouleversements climatiques sans précédent, imposant une réorientation profonde des systèmes de production d'énergie vers des sources renouvelables et propres. Parmi ces sources, l'énergie solaire photovoltaïque occupe une place de choix, grâce à son caractère inépuisable et à sa disponibilité à l'échelle planétaire.

L'Algérie, forte d'un ensoleillement exceptionnel dépassant 3000 heures par an et de niveaux d'irradiation parmi les plus élevés au monde, dispose d'un potentiel solaire considérable. Dans ce cadre, elle a lancé le Programme National des Énergies Renouvelables et de l'Efficacité Énergétique (PNEREE), qui vise à atteindre une capacité de production de 22 000 mégawatts d'origine renouvelable à l'horizon 2030. Ces ambitions témoignent de la volonté nationale d'exploiter pleinement cette ressource naturelle abondante [1].

Cependant, malgré son potentiel prometteur, l'énergie photovoltaïque souffre d'une limitation fondamentale : son intermittence. La production d'électricité dépend directement de conditions météorologiques variables et imprévisibles, telles que l'irradiance solaire, la température ambiante, la couverture nuageuse ou encore l'humidité. Ces fluctuations rendent la gestion des réseaux électriques intégrant une part importante d'énergie solaire particulièrement complexe, notamment en ce qui concerne l'équilibre entre la production et la consommation. Les systèmes de gestion classiques, reposant sur une approche purement réactive, se révèlent insuffisants pour faire face à cette variabilité, ce qui justifie le développement de méthodes de prévision avancées.

C'est dans ce contexte que l'intelligence artificielle offre des perspectives prometteuses. Les modèles d'apprentissage automatique, à travers différentes approches, sont capables d'apprendre des relations complexes et non linéaires entre les paramètres météorologiques et la puissance produite, ouvrant ainsi la voie à une prédiction précise et fiable

de la production photovoltaïque.

L'objectif de ce mémoire est de développer et d'évaluer plusieurs modèles d'intelligence artificielle pour la prédiction de la production énergétique d'un système photovoltaïque, en exploitant à la fois une approche par modélisation mathématique théorique et les données météorologiques collectées sur le terrain. Pour ce faire, un prototype expérimental instrumenté a été conçu et déployé afin d'acquérir des séries temporelles réelles et synchronisées, constituant, aux côtés des données de modélisation, la base d'apprentissage et de validation des modèles développés.

Pour mener à bien cette étude, notre manuscrit est structuré de la manière suivante :

Le Chapitre 1 est consacré aux fondements des systèmes photovoltaïques. Nous y aborderons leur principe de fonctionnement, les différentes technologies de cellules ainsi que les facteurs météorologiques influençant leur production. Il introduira également la problématique de la prédiction et son rôle crucial dans la gestion des réseaux intelligents (Smart Grids).

Le Chapitre 2 détaille la modélisation analytique du système ainsi que la conception et le développement du prototype expérimental. L'architecture matérielle du système d'acquisition y sera présentée, de même que les étapes de prétraitement, de filtrage et d'organisation des données théoriques et réelles en vue de leur exploitation par les algorithmes de prédiction.

Le Chapitre 3 présente et analyse les résultats théoriques et expérimentaux obtenus. Nous évaluerons et comparerons les performances de différents modèles (ARX, PMC, LSTM, GRU et Random Forest) appliqués d'abord sur la base de données de modélisation puis sur les mesures réelles, en nous appuyant sur une méthodologie d'évaluation multi-critères, afin de mettre en évidence les meilleurs compromis entre précision de prédiction et complexité algorithmique.

LES SYSTÈMES PHOTOVOLTAÏQUES

Face aux enjeux du réchauffement climatique et de la crise énergétique, l'énergie solaire s'est imposée comme une solution majeure pour la production d'électricité propre à l'échelle mondiale. Cependant, son intégration massive au sein des réseaux électriques soulève des défis techniques complexes, principalement dus à la nature intermittente du rayonnement solaire.

Ce chapitre a pour objectif de fournir les connaissances fondamentales sur les systèmes photovoltaïques tout en exposant les enjeux liés à la prédiction de leur production. Nous débuterons par une rétrospective historique, de la découverte de l'effet photovoltaïque à l'accélération industrielle actuelle.

Ensuite, nous détaillerons les principes de fonctionnement et comparerons les différentes technologies de cellules selon leurs performances respectives.

L'étude portera également sur les caractéristiques électriques du générateur et l'impact des facteurs environnementaux, tels que l'irradiance et la température.

Enfin, nous introduirons la problématique de la prédiction, outil désormais indispensable pour garantir la stabilité et la gestion intelligente des réseaux smart grids.

1.1 Contexte énergétique et rôle du photovoltaïque

Le réchauffement climatique et la crise énergétique poussent le monde vers des sources d'énergie durables et propres. L'énergie solaire, par sa nature inépuisable, s'est imposée comme une solution majeure à l'échelle mondiale. Elle est considérée comme l'une des ressources renouvelables les plus prometteuses pour la production d'électricité [2].

L'intégration du photovoltaïque dans les réseaux électriques permet de décentraliser la production, de modifier la dynamique des réseaux électriques et de réduire les émissions

du carbone CO_2 tout en répondant à la demande croissante en électricité. Par exemple, des pays comme l'Allemagne et la Chine ont déjà installé des capacités de plusieurs dizaines de gigawatts. Toutefois, cette intégration pose des défis techniques en raison de la nature intermittente du rayonnement solaire [3] [2].

1.2 Évolution historique du photovoltaïque

L'histoire de la technologie photovoltaïque est passée d'une découverte physique accidentelle à une production industrielle massive de plusieurs térawatts. Voici les jalons majeurs de cette évolution [4] :

1839 : La découverte scientifique, le physicien français Alexandre Edmond Becquerel met en évidence pour la première fois l'effet photovoltaïque en observant que l'exposition à la lumière peut augmenter la conductance électrique dans un système d'électrodes.

1883 : Le premier prototype, l'américain Charles Fritts développe la toute première cellule solaire à base de sélénium.

1918 : Avancée matérielle, le scientifique polonais Jan Czochralski met au point une méthode de production de silicium monocristallin, un matériau qui deviendra la base des cellules solaires modernes.

1954 : La cellule pratique au silicium, les laboratoires Bell conçoivent la première cellule solaire au silicium capable de fournir une puissance électrique réelle, affichant un rendement initial compris entre 4,5% et 6%.




FIGURE 1.1 – La première cellule photovoltaïque produite par Bell Lab

1958 : L'application spatiale, le satellite Vanguard I, devient le premier engin spatial à être alimenté par des cellules solaires, fonctionnant ainsi pendant huit ans.

1982 : La première centrale géante, la première centrale photovoltaïque d'une capacité de l'ordre du mégawatt est installée en Californie, aux États-Unis.

2003 : Record industriel, l'installation du Solarpark Hemau en Allemagne marque un tournant en devenant la plus grande centrale au monde à l'époque avec une puissance de 4 MW.

2022-2024 : L'accélération mondiale, alors qu'il a fallu près de sept décennies pour installer le premier térawatt (TW) d'énergie solaire, le deuxième térawatt a été atteint en seulement deux ans, portant la capacité mondiale installée à plus de 2 TW en 2024.

Cette chronologie montre que le défi actuel n'est plus seulement la production, mais l'intégration de cette énergie intermittente dans les réseaux électriques grâce à des outils de prédiction basés sur l'intelligence artificielle.

1.3 Principe de fonctionnement

Un système photovoltaïque fonctionne en convertissant l'énergie lumineuse en électricité. Malgré la découverte de ce phénomène par Edmond Becquerel en 1839, une compréhension complète à l'échelle atomique a requis des années de recherche.

1.3.1 La jonction PN

La brique de base est la cellule photovoltaïque, composée de matériaux semi-conducteurs, généralement le silicium. Pour permettre le mouvement des électrons, le matériau subit un dopage [5].

La zone de type N : On y introduit des impuretés pour créer un excédent d'électrons. Par exemple le silicium dopé au phosphore.




FIGURE 1.2 – Semi-conducteur de type N

La zone de type P : On écrit un déficit d'électrons, ce qui laisse apparaître des trous (charges positives), par exemple le silicium dopé au bore.




FIGURE 1.3 – Semi-conducteur de type P

La formation de la jonction PN : Lorsque ces deux zones sont mises en contact, les électrons de la zone N migrent vers la zone P. Ce déplacement de charges crée un champ électrique interne au niveau de la zone de contact, appelée la jonction PN.

1.3.2 Les étapes de la conversion énergétique

Le processus de génération de courants se déroule en plusieurs étapes physiques clés [6] [7] :

L'absorption des photons : Lorsque la cellule est exposée au soleil, les photons dont l'énergie est supérieure à la bande interdite « band gap » du matériau sont absorbés. Cette énergie est transférée aux électrons de la structure atomique.

La création des paires électrons-trous : L'énergie apportée par les photons excite les électrons situés dans la bande de valence et les projette vers la bande de conduction. Ce mouvement laisse derrière lui un vide appelé « trous », créant ainsi ce qu'on appelle une paire électron-trou.

La séparation et la collecte des charges : Sous l'effet du champ électrique interne de la jonction PN, les électrons sont repoussés vers la zone N et les trous vers la zone P.

La circulation du courant : Lorsqu'on connecte une charge électrique aux bornes de la cellule, les électrons accumulés dans la zone N utilisent ce circuit externe pour rejoindre les trous de la zone P. Ce flux ordonné d'électrons constitue le courant électrique continu (DC).




FIGURE 1.4 – Principe de fonctionnement d'une cellule photovoltaïque

1.3.3 Architecture du générateur photovoltaïque (GPV)

Pour passer de cette réaction microscopique à une production exploitable, les composants sont associés selon une hiérarchie précise [6] :

La cellule : L'unité de base effectuant la conversion.

Le module : Assemblage de cellules connectées en série pour augmenter la tension ou en parallèle pour augmenter le courant.

Le panneau : Union de plusieurs modules sur un support physique.

Le champ ou réseau : Groupement de plusieurs panneaux permettant de former une centrale capable de produire de l'électricité à grande échelle.




FIGURE 1.5 – Structure d'un système photovoltaïque

1.4 Technologies photovoltaïques et types de cellules

Le marché du photovoltaïque repose sur plusieurs technologies de conversion de l'énergie solaire fondées sur l'utilisation de différents matériaux semi-conducteurs [8].

1.4.1 Cellules au silicium monocristallin

Les cellules monocristallines sont fabriquées à partir d'un cristal de silicium unique d'une grande pureté.

- Elles offrent les caractéristiques électriques les plus élevées, avec des rendements de conversion atteignant généralement environ 20%.
- En raison de leur efficacité supérieure, ces modules occupent moins d'espace pour une puissance équivalente.
- Leur processus de fabrication basé sur des plaquettes de silicium reste complexe et coûteux, ce qui les rend moins économiques que d'autres alternatives.




FIGURE 1.6 – Cellule photovoltaïque en silicium monocristallin

1.4.2 Cellules polycristallines

Contrairement aux cellules monocristallines, les cellules polycristallines sont constituées de plusieurs fragments de cristaux de silicium.

- Le rendement est légèrement inférieur, se situant aux alentours de 16%, car elles sont produites à partir d'un silicium moins pur.
- Elles sont plus rentables et offrent un meilleur rapport coût/efficacité pour les installations de grande envergure.

— Elles nécessitent une surface d'installation plus importante pour produire la même quantité d'énergie que les panneaux monocristallins.




FIGURE 1.7 – Une cellule photovoltaïque polycristalline

1.4.3 Technologies couches minces

Les technologies à couches minces représentent une alternative aux plaquettes de silicium conventionnelles. Elles consistent à déposer une fine couche de matériau semi-conducteur de quelques nanomètres à quelques micromètres d'épaisseur sur un support flexible ou rigide. Parmi ces technologies :

- Le tellure de Cadmium (CdTe).
- Le disélénuire de Cuivre, Indium et Gallium (CIGS).

Ces modules se distinguent par leur légèreté et leur flexibilité, bien que certains matériaux utilisés comme le cadmium présentent des enjeux de toxicité.




FIGURE 1.8 – Cellule photovoltaïque amorphe

1.4.4 Comparaison qualitative

Le choix d'une technologie dépend des contraintes spécifiques du projet (espace disponible, budget, conditions climatiques). Le tableau suivant résume les différences majeures entre ces types de cellules :

Technologie	Rendement (PCE)	Coût relatif	Usage principal
Monocristallin	Élevé (20%)	Élevé	Toitures résidentielles, espace limité
Polycristallin	Moyen (16%)	Modéré	Grandes centrales, usage industriel
Couches minces	Variable (11%-22%)	Compétitif	Applications flexibles, intégration au bâti

TABLE 1.1 – Comparaison des technologies photovoltaïques

À titre indicatif, il existe également des cellules à très hautes performances basées sur des matériaux de la famille III-V, comme l'Arséniure de Gallium (GaAs). Ce matériau possède un bandgap direct (1,42 eV) et une excellente résistance à la chaleur et aux radiations. Si ces cellules détiennent des records d'efficacité dépassant les 30% et jusqu'à 42,3% en multi-jonctions, leur coût de production très élevé et la rareté du Gallium limitent leur usage à des domaines de pointe, principalement pour les applications

spatiales (satellites) et les systèmes à concentration.




FIGURE 1.9 – Cellules solaires GaAs

1.5 Facteurs influençant la production photovoltaïque

Bien que les caractéristiques d'un module soient définies en laboratoire, sa production réelle sur site est soumise à une grande variabilité. La quantité d'énergie convertie dépend fortement de la source solaire disponible, de l'état de l'environnement immédiat et de la dynamique temporelle des phénomènes atmosphériques.

1.5.1 Données météorologiques

L'irradiance solaire : C'est le paramètre prépondérant. Le flux lumineux reçu par le panneau fluctue selon la clarté du ciel et la présence de masses nuageuses qui absorbent ou diffusent une partie du spectre solaire [9].

La température ambiante : Elle joue un rôle indirect mais crucial en conditionnant la température de fonctionnement des cellules par échanges thermiques. Une chaleur excessive dégrade l'efficacité de la jonction semi-conductrice.

Variables secondaires : D'autres facteurs comme la vitesse du vent (qui permet le refroidissement naturel des modules), l'humidité relative, la pression atmosphérique et

les précipitations influencent également la production d'énergie solaire photovoltaïque [3].

1.5.2 Conditions environnementales

Au-delà de la météo, l'environnement physique du site d'installation impacte la réception du rayonnement :

L'ombrage (partiel ou total) : Il peut être causé par des obstacles fixes (bâtiments, arbres, câbles) ou mobiles (nuages). L'ombrage est particulièrement problématique car il réduit non seulement la puissance, mais modifie aussi la forme de la caractéristique électrique en créant plusieurs pics de puissance locaux [5].

L'accumulation de poussière (soiling) : Le dépôt de particules à la surface du panneau réduit la transmittance du verre protecteur, ce qui diminue la quantité de lumière atteignant réellement les cellules.

Paramètres d'installation : L'angle d'inclinaison et l'orientation des panneaux par rapport au sud géographique déterminent la densité d'énergie captée au cours de la journée.

1.5.3 Variabilité temporelle

La production photovoltaïque est par nature intermittente, ce qui rend son intégration au réseau complexe :

Variabilité cyclique : La production suit les cycles naturels quotidiens, augmentant avec le lever du soleil, atteignant un pic à midi (en fonction de l'orientation et diminuant jusqu'au coucher du soleil).

Variabilité saisonnière : La hauteur du soleil dans le ciel et la durée du jour varient selon les saisons, entraînant des fluctuations importantes de la production d'énergie tout au long de l'année. Par exemple, la production peut être plus faible en hiver en raison de jours plus courts et d'un angle solaire plus faible.

Événements météorologiques extrêmes : Les phénomènes tels que les tempêtes, les fortes chutes de neige ou la grêle peuvent réduire drastiquement la production d'énergie et potentiellement endommager les installations photovoltaïques. Ces événements augmentent l'intermittence de la production photovoltaïque et posent des défis pour la stabilité du réseau.

Fluctuations aléatoires : Les passages nuageux rapides provoquent des variations

brutales et imprévisibles de la puissance de sortie, pouvant déstabiliser la gestion énergétique.

Cette instabilité et cette dépendance vis-à-vis des aléas climatiques justifient pleinement le développement de méthodes de prédiction avancées basées sur l'intelligence artificielle, afin d'anticiper ces fluctuations pour une meilleure gestion des réseaux intelligents [10].

1.6 Caractéristiques électriques des générateurs photovoltaïques

Le comportement électrique d'un module photovoltaïque est intrinsèquement non linéaire et dépend de la technologie des cellules utilisées. Pour caractériser un générateur photovoltaïque (GPV), on analyse les relations entre ses grandeurs électriques fondamentales dans des conditions de test standard (CTS : 1000 W/m², 25°C, AM 1.5) [11].

1.6.1 Courbes Courant-Tension et Puissance-Tension

Le comportement électrique d'un module photovoltaïque est généralement décrit à l'aide des courbes courant-tension (I - V) et puissance-tension (P - V) qui traduisent la relation entre les grandeurs électriques aux bornes du générateur.

La courbe (I - V) : Présente trois zones distinctes, définissant le comportement du module [5] :

- Zone source de courant : Dans cette première partie, le courant produit est quasiment constant et indépendant de la tension V aux bornes du module.
- Zone du coude : C'est la zone de transition entre les deux autres intervalles. Elle représente la zone d'opération préférée car elle contient le point où la puissance P est maximale.
- Zone source de tension : Dans cette partie, la tension varie très peu tandis que le courant I chute brutalement jusqu'à atteindre la tension de circuit ouvert.




FIGURE 1.10 – caractéristiques I-V

La courbe (P - V) : Est déduite de la courbe (I - V) par la relation :

$$P = V \times I \quad (1.1)$$

Elle est indispensable pour visualiser la capacité de transfert énergétique du module vers la charge.




FIGURE 1.11 – caractéristiques P-V

1.6.2 Grandeur caractéristique fondamentale

Toute étude d'un module PV s'appuie sur les données fournies par les constructeurs (datasheets), lesquelles précisent deux points limites essentiels pour la sécurité et le dimensionnement des circuits :

Le courant de court-circuit (I_{sc}) : Il correspond au courant maximal délivré par le générateur lorsque sa tension est nulle ($V = 0$), c'est-à-dire quand les bornes sont directement court-circuitées. Ce courant est physiquement équivalent au photo-courant généré par l'absorption des photons.

La tension en circuit ouvert (V_{oc}) : Il s'agit de la tension maximale mesurable aux bornes du module lorsque celui-ci n'est relié à aucune charge ($I = 0$). Elle résulte de l'accumulation des charges au niveau de la jonction PN isolée.

1.6.3 Point de puissance maximale MPP

La courbe P-V met en évidence l'existence d'un point de fonctionnement particulier, appelé point de puissance maximale (MPP), pour lequel le générateur photovoltaïque délivre sa puissance maximale ($P_{max} = V_{mpp} \times I_{mpp}$). L'exploitation du module à ce point est cruciale pour maximiser le rendement énergétique global du système.




FIGURE 1.12 – Caractéristiques I-V et P-V

1.6.4 Le facteur de forme FF

Le facteur de forme est un indicateur de la qualité de la cellule photovoltaïque et de la propreté de ses courbes électriques. Il correspond au rapport entre la puissance maximale (P_{mpp}) et la puissance théorique formée par le produit ($I_{sc} \times V_{oc}$). Plus le FF est proche de 1 (ou 100 %), plus la cellule est considérée comme performante.[12]

$$FF = \frac{I_{MPP} \cdot V_{MPP}}{I_{sc} \cdot V_{oc}} = \frac{P_{mpp}}{I_{sc} \cdot V_{oc}} \quad \text{avec} \quad 0 < FF < 1 \quad (1.2)$$

Graphiquement, le FF mesure à quel point la courbe (I-V) se rapproche d'une forme rectangulaire idéale. Un FF élevé indique que les pertes internes sont minimales.

1.6.5 Le rendement de conversion η

Il définit l'efficacité avec laquelle le module transforme l'énergie lumineuse reçue en énergie électrique utilisable. Il est calculé comme le rapport entre la puissance maximale produite et la puissance lumineuse reçue. Pour les technologies classiques au silicium, ce rendement se situe généralement entre 15% et 22% [12].

$$\eta = \frac{P_{mpp}}{P_{opt}} = \frac{P_{mpp}}{A \cdot G_{ref}} = \frac{FF \cdot I_{sc} \cdot V_{oc}}{A \cdot G_{ref}} \quad (1.3)$$

Où :

- A est la surface du module (m^2).
- G_{ref} est l'irradiance de référence (W/m^2).

Ce paramètre est la référence principale pour comparer la performance de différentes technologies de cellules.

1.6.6 Influence de l'irradiance et de la température sur les paramètres électriques

La production d'énergie d'un système photovoltaïque est influencée par plusieurs facteurs environnementaux, les conditions météorologiques étant le paramètre prédominant [5].

L'irradiance solaire : Elle est le facteur dominant car elle influence le courant produit par la cellule, ce courant I_{sc} varie proportionnellement à l'intensité du rayonnement, ce qui déplace la courbe (I-V) vers le haut.




FIGURE 1.13 – Caractéristique I-V pour différents niveaux de rayonnement

La température des cellules : Elle représente également un facteur déterminant mais son influence est défavorable. Une augmentation de la température des cellules entraîne une baisse de la tension du circuit ouvert (V_{oc}), par conséquent une diminution de la puissance et un décalage de la courbe vers la gauche.




FIGURE 1.14 – Caractéristique I-V pour différentes valeurs de températures

C'est pourquoi cette étude se concentre sur des modèles reliant les paramètres météorologiques à la puissance produite. Cette approche s'avère indispensable pour concevoir des méthodes de prévision efficaces, répondant ainsi aux défis concrets de la gestion de l'énergie sur le terrain.

1.7 Problématique de la prédiction de la production photovoltaïque

La gestion efficace de l'énergie solaire nécessite de surmonter les défis posés par la nature fluctuante de la ressource. La prédiction de la puissance générée est donc devenue un outil indispensable pour garantir la fiabilité des systèmes énergétiques modernes.

1.7.1 Difficultés liées à l'intermittence

L'énergie photovoltaïque est par nature intermittente et aléatoire, car elle dépend de variables météorologiques incontrôlables telles que l'irradiance, la température ambiante et la nébulosité. Cette dépendance crée des fluctuations rapides de la puissance de sortie, ce qui pose des défis majeurs pour la stabilité du réseau électrique. Les changements soudains, notamment lors du passage de masses nuageuses, introduisent une incertitude qui complique le maintien de l'équilibre entre la production et la consommation. De plus, le caractère stochastique de ces variables environnementales rend la modélisation directe extrêmement complexe sans l'utilisation de données historiques précises [13].

1.7.2 Intérêt de la prévision à court terme

La prévision à court terme, dont l'horizon varie généralement de 1 à 24 heures, est essentielle pour assurer la continuité du service et le suivi de la charge. Elle présente plusieurs avantages stratégiques :

Dispatching économique : Elle permet aux gestionnaires de planifier l'ordre de priorité des sources d'énergie et de réduire les coûts opérationnels liés à l'incertitude.

Stabilité du réseau : En anticipant les variations brusques, les opérateurs peuvent activer des services auxiliaires pour maintenir la tension et la fréquence à des niveaux stables.

Réduction des risques : Une prédiction précise minimise les erreurs de planification, évitant ainsi des pénalités financières sur les marchés de l'électricité.

1.7.3 Applications principales

Les modèles de prédiction sont exploités dans divers domaines technologiques pour améliorer l'efficacité énergétique :

Smart Grids (Réseaux intelligents) : La prévision est un pilier de la gestion intelligente pour équilibrer les flux d'énergie et optimiser l'utilisation des ressources renouvelables à grande échelle.

Optimisation de l'autoconsommation : Dans les systèmes résidentiels, elle permet de planifier le démarrage des appareils énergivores (pompes à chaleur, machine à laver) pendant les pics de production prévus [14].

Gestion du stockage : La prédiction aide à décider des cycles de charge et de décharge des batteries, prolongeant ainsi leur durée de vie et maximisant l'utilisation de l'énergie stockée [14].

Système de pompage : Pour les applications agricoles ou domestiques en zones isolées, elle permet une organisation optimale du pompage « au fil du soleil » en fonction de la météo prévue pour la journée [12].

Commercialisation et marchés de l'énergie : Les prévisions permettent aux producteurs et consommateurs de prendre des décisions éclairées sur l'achat ou la vente d'électricité, tout en minimisant les pénalités financières dues aux écarts entre la production prévue et réelle [15].

Planification et évaluation de sites : Avant la construction d'une installation solaire, les prévisions du rayonnement solaire sont essentielles pour évaluer le potentiel énergétique d'un site et orienter le choix des meilleurs emplacements pour les nouvelles installations [16].

1.8 Rôle de la prédiction dans les smart grids

Le passage des réseaux électriques traditionnels unidirectionnels vers les smart grids (réseaux intelligents) représente une évolution majeure dictée par la nécessité d'intégrer massivement les Sources d'Energie Renouvelables (SER). Contrairement au modèle classique, le Smart grid s'appuie sur un flux d'information bidirectionnel entre les producteurs et les consommateurs, permettant une gestion décentralisée et dynamique de l'énergie. Dans cette infrastructure complexe, la prédiction de la production photovoltaïque devient le moteur essentiel permettant de synchroniser la variabilité de la ressource solaire avec les besoins changeants du réseau [17].

1.8.1 Gestion proactive de l'énergie SGE

Le rôle principal de la prédiction réside dans l'optimisation des Systèmes de Gestion de l'Energie (SGE). En utilisant des algorithmes d'apprentissage automatique (Machine

Learning), ces systèmes analysent les données historiques et en temps réel pour équilibrer l'offre et la demande à chaque instant. Une prévision précise permet d'ajuster les stratégies opérationnelles, de réduire les pertes énergétiques lors de la distribution et d'assurer une régulation efficace de la tension et de la fréquence du réseau. Cette capacité d'anticipation transforme le réseau en une entité résiliente capable de répondre aux fluctuations imprévues sans compromettre la continuité du service [17].

1.8.2 Aide à la décision pour les gestionnaires de réseau

La prévision de puissance offre une base de données cruciale pour la prise de décision stratégique et économique. Permet aux opérateurs de planifier l'engagement des centrales électriques et de programmer les interventions de maintenance de manière proactive plutôt que réactive. En réduisant l'incertitude liée à la production solaire, les gestionnaires peuvent optimiser le dispatching économique, minimisant ainsi le recours aux centrales thermiques de secours, souvent coûteuses et polluantes. À plus grande échelle, ces prévisions facilitent la participation des producteurs aux marchés de l'électricité en affinant les estimations de rendement.

1.8.3 Pilotage prédictif des systèmes décentralisés

La prédiction joue enfin un rôle déterminant dans la gestion des Systèmes de Stockage d'Energie (SSE) et le développement de l'autoconsommation. Étant donné que le stockage massif par les batteries reste onéreux, la prévision permet de piloter intelligemment les cycles de charge et de décharge, l'énergie excédentaire produite durant les pics d'ensoleillement est stockée pour être restituée lors des périodes de faibles générations ou de forte demande. Ce pilotage prédictif permet non seulement de maximiser le taux d'autoconsommation des bâtiments intelligents, mais aussi de prolonger la durée de vie des équipements de stockage en évitant les cycles inutiles ou dommageables [17].

1.9 Conclusion

Ce chapitre a présenté les fondements des systèmes photovoltaïques, de leur évolution historique à leur principe de fonctionnement. Nous avons analysé les différentes technologies de cellule ainsi que les caractéristiques électriques, mettant en évidence des paramètres clés tels que la tension à vide (V_{oc}), le courant de court-circuit (I_{sc}) et le point de puissance maximale MPP.

L'étude a également souligné la forte dépendance de la production vis-à-vis de l'irradiance et de la température, ce qui engendre une intermittence problématique pour la stabilité des réseaux. Cette variabilité justifie l'intérêt de la prédiction énergétique basée sur l'intelligence artificielle pour une gestion optimale dans le cadre des smart grids. Le chapitre suivant sera consacré à la modélisation du système photovoltaïque et à la génération des données.

MODÉLISATION DU SYSTÈME PHOTOVOLTAÏQUE ET DÉVELOPPEMENT DU PROTOTYPE

La transition vers des réseaux électriques intelligents (Smart Grids) impose une intégration massive et fiable des énergies renouvelables, en particulier du photovoltaïque. Toutefois, comme évoqué précédemment, cette source d'énergie reste fortement contrainte par son caractère intermittent et sa dépendance directe aux fluctuations météorologiques. Dans ce contexte, les approches de gestion énergétique purement réactives montrent leurs limites, car elles ne permettent pas d'anticiper les variations de production et compliquent le maintien de l'équilibre entre l'offre et la demande.

L'objectif de ce chapitre est de poser l'ensemble des bases théoriques, matérielles et logicielles nécessaires à la constitution de nos jeux de données. Pour cela, trois axes fondamentaux sont développés.

Tout d'abord, nous présentons la modélisation mathématique et électrique du générateur photovoltaïque. Cette étape essentielle permet d'établir les équations physiques régissant le système et de construire une base de données théorique idéale, exempte de perturbations externes.

Ensuite, la conception et la mise en œuvre pratique d'un prototype instrumenté basé sur un microcontrôleur ESP32 sont détaillées, avec pour objectif la collecte sur le terrain de séries temporelles réelles, fiables et synchronisées.

Enfin, nous présentons la chaîne de traitement logicielle appliquée à ces mesures brutes, incluant les étapes de nettoyage, de filtrage et de structuration des données. Cette combinaison rigoureuse entre modélisation déterministe, acquisition expérimentale sur le terrain et préparation algorithmique des variables constitue le socle indispensable à la création de deux bases de données distinctes, prêtes à être exploitées par les modèles de prédiction présentés dans la suite de ce manuscrit.

2.1 Systèmes photovoltaïques existants

L'intégration de l'énergie solaire repose sur des configurations techniques variées, adaptées aux besoins de l'utilisateur et à la disponibilité du réseau électrique public. Cette section détaille les typologies d'installations, leurs composants principaux et leur mode opératoire global.

2.1.1 Typologie des systèmes photovoltaïques

Les systèmes photovoltaïques peuvent être classés selon leur mode de fonctionnement et leur interaction avec le réseau électrique. Les configurations utilisées dans les applications modernes sont les systèmes connectés au réseau, autonomes et hybrides.

Système connecté au réseau (grid-connected) : Dans cette configuration, l'onduleur injecte la totalité ou le surplus de la production directement dans le réseau public. Ce système est le plus économique car il se dispense du stockage par batteries, le réseau servant de tampon pour absorber les excédents [18].

Système autonome (off-grid) : Cette architecture est dédiée à l'alimentation de sites isolés (pompage désertique, zones rurales) non raccordés au réseau conventionnel. Elle nécessite impérativement un dispositif de stockage (batteries) pour garantir la continuité du service durant les périodes sans soleil [18].

Système hybride : Solution avancée combinant le raccordement au réseau et le stockage local. Ce type d'installation permet de maximiser l'autoconsommation et d'améliorer la résilience des réseaux intelligents en gérant les flux entre la production, les batteries et le réseau public.




FIGURE 2.1 – Types de systèmes photovoltaïques

2.1.2 Architecture générale

L'efficacité et la fiabilité d'une installation photovoltaïque reposent sur l'interconnexion de plusieurs blocs fonctionnels assurant la conversion, l'adaptation et la gestion de l'énergie produite. L'architecture globale permet ainsi de transformer l'énergie solaire captée en une énergie électrique exploitable par la charge ou injectée dans le réseau [19].

Cette architecture se décompose en plusieurs blocs fonctionnels :

Générateur photovoltaïque : Ensemble de cellules interconnectées formant des modules puis des panneaux. Il assure la conversion de l'énergie solaire en courant électrique continu, constituant ainsi la source principale du système.

Convertisseur DC/DC (étage d'adaptation avec MPPT) : Interface électronique placée entre le générateur photovoltaïque et le reste du système. Son rôle est d'adapter en permanence la tension et le courant fournis par les panneaux afin de fonctionner au point de puissance maximale (MPPT). Il permet ainsi d'optimiser l'extraction de l'énergie en fonction des variations d'irradiation et de température, tout en fournissant une tension adaptée aux étages suivants.

Onduleur (convertisseur DC/AC) : Dispositif de conversion du courant continu en courant alternatif sinusoïdal. Il assure l'adaptation de la tension et de la fréquence afin de répondre aux normes du réseau électrique ou aux exigences des charges AC.

Régulateur et stockage d'énergie : Ensemble constitué d'un système de gestion de charge et d'un parc de batteries. Il permet de stocker l'énergie produite en excès

et de garantir l'équilibre énergétique du système en fonction de la production et de la demande.

Dispositifs de protection : Ensemble de composants tels que les diodes de bypass et anti-retour, assurant la protection du système contre les surcharges, les courts-circuits et les courants inverses.

Unité de mesure et capteurs : Ensemble de capteurs de courant, de tension et parfois de température, fournissant les données nécessaires au contrôle et à la supervision du système.

Charge électrique : Ensemble des équipements alimentés par le système, pouvant fonctionner en courant continu ou alternatif selon l'application.




FIGURE 2.2 – Architecture générale d'un système photovoltaïque [20]

2.1.3 Principe de fonctionnement du système

Le fonctionnement du système repose sur une chaîne de transfert et de conversion d'énergie optimisée pour répondre aux besoins de la charge ou du réseau [19].

Chaîne de conversion et flux d'énergie

Le flux énergétique suit un parcours structuré pour assurer l'efficacité de l'installation :

Génération et optimisation : Le courant continu (DC) produit par les modules photovoltaïques est d'abord traité par un convertisseur DC/DC. Ce dernier intègre la

fonction de recherche du point de puissance maximale (MPPT), indispensable pour extraire en temps réel la puissance optimale disponible selon les conditions de fonctionnement.

Conversion finale : L'énergie est ensuite transmise à l'onduleur, qui convertit le courant continu en courant alternatif (AC). Ce signal est alors directement utilisable pour l'alimentation des équipements électriques ou pour l'injection dans le réseau de distribution.

Rôle du régulateur de charge

Dans les configurations intégrant un stockage, le régulateur de charge assure la gestion intelligente des cycles de la batterie. Il prévient notamment la surcharge et la décharge profonde des batteries, deux phénomènes susceptibles de réduire leur durée de vie.




FIGURE 2.3 – Synoptique général de la chaîne de conversion et de gestion d'énergie d'un système photovoltaïque [21]

2.2 Limites des systèmes existants

Malgré le développement croissant des systèmes photovoltaïques, plusieurs limitations empêchent encore leur exploitation optimale au sein des infrastructures énergétiques. Ces contraintes sont essentiellement liées à l'intermittence naturelle de la ressource et au manque d'anticipation intelligente, rendant la gestion de la stabilité et de l'équilibre du réseau particulièrement complexe [17].

2.2.1 Difficulté d'optimisation de la production et du stockage

La production photovoltaïque se caractérise par une forte intermittence liée aux variations des conditions météorologiques, rendant difficile le maintien d'un équilibre stable entre la production et la demande énergétique. Bien que les systèmes de stockage

par batteries permettent d'atténuer ces fluctuations, leur capacité limitée ainsi que les contraintes de charge et de décharge compliquent davantage la gestion énergétique du système [2].

En l'absence de mécanismes de prévision, le pilotage énergétique reste essentiellement réactif, empêchant l'anticipation des variations futures de production. Cette limitation peut conduire à une exploitation inefficace du stockage, où une partie du surplus énergétique produit durant les périodes de fort ensoleillement n'est pas valorisée de manière optimale. De plus, une gestion inadéquate des cycles de charge peut affecter les performances et la durée de vie des batteries [2].

Ainsi, l'optimisation simultanée de la production photovoltaïque, du stockage et de la consommation constitue un défi majeur pour les systèmes énergétiques modernes.

2.2.2 Gestion énergétique réactive

La plupart des installations actuelles reposent sur une approche de pilotage dite « réactive », où les décisions sont prises en réponse immédiate aux événements constatés sur le système. Contrairement aux architectures intelligentes, ces dispositifs n'intègrent pas de vision future de la production énergétique [2].

SGE classiques : Les systèmes de gestion de l'énergie traditionnels s'appuient exclusivement sur des mesures instantanées. Ils agissent pour compenser les écarts entre la production et la demande uniquement une fois que ceux-ci sont physiquement détectés, ce qui limite leur efficacité face à la volatilité de la ressource.

Commande conventionnelle : Les régulateurs et les boucles de contrôle standard fonctionnent sur un mode de correction a posteriori. Ils attendent de constater une chute ou une hausse brutale de la puissance photovoltaïque injectée avant d'enclencher les mesures de compensation ou de régulation nécessaires.

Absence d'anticipation : Ce mode opératoire est marqué par une absence de prédiction. Le système est incapable d'ajuster son état de fonctionnement ou son niveau de stockage en amont d'une fluctuation, se contentant de subir les variations de puissance au moment où elles surviennent.

Limites des stratégies fixes : Les règles de gestion statiques et pré-programmées ne peuvent pas s'adapter dynamiquement à l'évolution du système. Cette rigidité empêche une intégration sécurisée et économique de l'énergie photovoltaïque, car le système manque de flexibilité pour gérer proactivement les besoins du réseau.

La Figure 2.4 illustre la hiérarchie des stratégies de gestion selon l'horizon d'intervention. On y distingue d'abord la gestion réactive qui intervient après l'événement

comme c'est le cas pour les systèmes actuels. Le schéma présente également la gestion préventive qui agit de manière planifiée mais aveugle, ainsi que la gestion prédictive qui permet d'anticiper l'événement avant qu'il ne survienne. Cette comparaison met en évidence le retard systématique de l'approche réactive par rapport aux besoins réels du système.




FIGURE 2.4 – Comparaison des stratégies d'intervention [22]

2.2.3 Sensibilité aux conditions météorologiques

La performance globale et la stabilité d'une installation photovoltaïque sont intrinsèquement liées à la dynamique de l'atmosphère. Contrairement à l'étude physique de la cellule, l'enjeu réside ici dans l'imprévisibilité des variations météorologiques qui transforment la production solaire en une ressource intermittente et hautement volatile [2].

Fluctuations rapides et impact des nuages : La variabilité de la couverture nuageuse est le facteur prépondérant provoquant des fluctuations soudaines de la puissance injectée. Ces changements rapides, ou « rampes », peuvent survenir en quelques minutes, voire quelques secondes, rendant la stabilisation du réseau et le maintien de l'équilibre puissance-charge extrêmement complexes pour les gestionnaires d'énergie.




FIGURE 2.5 – Impact de la couverture nuageuse sur la production photovoltaïque

Incertitude et nature chaotique : La nature chaotique des systèmes météorologiques, incluant les incertitudes liées à la température, à l'humidité et à la poussière atmosphérique, introduit une incertitude majeure dans la planification énergétique. Cette complexité fait que la production ne suit pas un profil stable, mais une série de variations irrégulières qui nuisent à la fiabilité du système électrique.

Difficulté de stabilisation du réseau : Cette forte dépendance aux aléas climatiques pose des défis critiques pour la gestion des réseaux intelligents (smart grids), notamment en matière de réponse en fréquence et de compensation de puissance réactive. Sans une capacité d'anticipation de ces fluctuations météo, l'intégration à grande échelle de l'énergie photovoltaïque menace la sécurité et l'exploitation économique du réseau électrique.

En résumé, ce n'est pas seulement la valeur des paramètres météo qui importe, mais leur instabilité temporelle, qui rend la gestion énergétique difficilement prévisible sans le secours de modèles de prédiction avancés.

L'ensemble des défis identifiés dans les sections précédentes souligne une problématique majeure : l'intermittence et la variabilité inhérentes à la production solaire, fortement dépendantes des facteurs atmosphériques, créent des obstacles critiques pour la stabilité des réseaux intelligents. Les systèmes de gestion actuels, limités par une approche réactive ou des modèles physiques rigides, peinent à garantir une insertion sécurisée du photovoltaïque à grande échelle. L'absence d'une prévision précise complique non seulement la planification (unit commitment), mais augmente également les coûts liés à la régulation de la fréquence et de la puissance réactive [2].

Ces limitations démontrent la nécessité de développer des approches capables d'an-

ticiper les variations de production. Dans ce contexte, les techniques de modélisation basées sur l'intelligence artificielle apparaissent comme des solutions prometteuses pour optimiser la gestion énergétique. Cette nécessité de transition vers un pilotage prédictif justifie la conception du prototype présenté dans la section suivante.

2.3 Modélisation du générateur photovoltaïque

La modélisation d'un générateur photovoltaïque (GPV) constitue une étape essentielle pour représenter son comportement électrique à l'aide de relations exploitables numériquement. En ingénierie des systèmes, cette approche permet de simuler le fonctionnement théorique du générateur et d'évaluer ses performances sous différentes conditions environnementales avant d'affronter les perturbations du monde réel.

2.3.1 Modèle électrique à une diode

Le modèle monodiode, couramment appelé modèle à cinq paramètres, représente le standard académique pour caractériser une cellule photovoltaïque. Ce choix offre un excellent compromis entre fidélité physique et simplicité algorithmique, facilitant l'extraction des paramètres à partir des fiches techniques des constructeurs.

2.3.1.1 Architecture du circuit équivalent

Ce modèle s'appuie sur une structure électrique représentative des processus physiques au sein de la cellule. Il se compose d'une source de courant (photocourant I_{ph}), d'une diode en parallèle (jonction PN), d'une résistance shunt (R_p) simulant les courants de fuite, et d'une résistance série (R_s) rendant compte des pertes ohmiques [23].




FIGURE 2.6 – Circuit électrique équivalent du modèle à une diode d'une cellule PV

2.3.1.2 Équation caractéristique

En appliquant la loi des nœuds au circuit équivalent (Figure 2.6), le courant de sortie I_{pv} délivré par le générateur est défini par l'expression non linéaire suivante [23] :

$$I_{pv} = I_{ph} - I_s \left[\exp \left(\frac{q(V_{pv} + I_{pv}R_s)}{AkT} \right) - 1 \right] - \frac{V_{pv} + I_{pv}R_s}{R_p} \quad (2.1)$$

Où :

- I_{pv} : courant de sortie du module (A).
- V_{pv} : tension aux bornes du module (V).
- I_{ph} : photo-courant généré, proportionnel à l'irradiance (A).
- I_s : courant de saturation inverse de la diode (A).
- A : facteur d'idéalité de la diode.
- q : charge élémentaire de l'électron ($1,602 \times 10^{-19}$ C).
- k : constante de Boltzmann ($1,38 \times 10^{-23}$ J/K).
- T : température effective de la cellule (K).
- R_s : résistance série (Ω).
- R_p : résistance parallèle ou shunt (Ω).

2.3.2 Relation analytique simplifiée de la puissance

Afin de faciliter l'exploitation numérique et d'éviter la résolution itérative complexe du modèle électrique complet, une relation analytique directe reliant la puissance produite aux principaux paramètres météorologiques est adoptée [24] :

$$P_{calc}(G, T) = P_{max,CTS} \cdot \frac{G}{G_{CTS}} \cdot [1 + \gamma(T - T_{ref})] \quad (2.2)$$

Où :

- P_{calc} : puissance estimée en conditions réelles (W).
- $P_{max,CTS}$: puissance maximale du module dans les conditions de test standards (W).
- G : irradiance solaire mesurée sur le plan du panneau (W/m^2).
- G_{CTS} : irradiance de référence ($1000 W/m^2$).
- T : température de fonctionnement ou ambiante ($^{\circ}C$).
- T_{ref} : température de référence ($25^{\circ}C$).
- γ : coefficient de température de la puissance.

Cette formulation met en évidence la proportionnalité de la puissance par rapport à l'irradiance solaire, tout en quantifiant la dégradation des performances induite par l'élévation thermique. Elle constitue le socle mathématique utilisé pour générer notre base de données théorique.

2.4 Présentation du prototype photovoltaïque proposé

Le prototype développé constitue une plateforme expérimentale destinée à l'acquisition de séries temporelles photovoltaïques pour la modélisation prédictive par intelligence artificielle. Contrairement à une installation de puissance, ce système a été optimisé pour collecter des grandeurs environnementales et électriques en conditions réelles afin de constituer une base d'apprentissage fiable.

2.4.1 Description globale du système

Pour garantir une collecte de données exhaustive, le système s'appuie sur une unité centrale coordonnant un ensemble de capteurs, dédiés à la mesure des performances énergétiques et des conditions climatiques en temps réel.

2.4.1.1 ESP32 (Unité centrale)

Il s'agit d'un module microcontrôleur (MCU) générique puissant, intégrant nativement des connectivités Wi-Fi et Bluetooth. Il dispose d'un processeur performant et

d'un ensemble riche de périphériques tels que des ports GPIO et des interfaces de communication série. Ce microcontrôleur a été retenu pour son faible coût, sa facilité d'interfaçage avec divers capteurs via ses ports GPIO et sa capacité à transmettre les mesures sans fil, ce qui simplifie la centralisation des données [25].



FIGURE 2.7 – Microcontrôleur ESP32-WROOM-32

2.4.1.2 INA219 (Mesure électrique)

L'INA219 est un amplificateur de mesure de courant bidirectionnel et un moniteur de puissance doté d'une interface compatible I2C. Il peut mesurer la tension du bus (jusqu'à 26 V) et la chute de tension aux bornes d'un shunt pour en déduire le courant. Ce composant permet de déterminer avec précision la puissance électrique produite ($P = V \times I$). Sa capacité à fournir des lectures numériques directes via I2C garantit une base de données conforme aux lois de l'électrocinétique tout en filtrant efficacement le bruit [26].



FIGURE 2.8 – Capteur de puissance INA219

2.4.1.3 DHT22 (Température et Humidité)

Ce capteur numérique de type capacitif est capable de mesurer la température ambiante avec une précision de $\pm 0.5^{\circ}\text{C}$ ainsi que l'humidité relative. Il transmet un signal numérique calibré via un bus de communication unique (single-bus). Le choix du DHT22

repose sur sa fiabilité pour corrélérer l'influence thermique aux variations de production. Bien que l'irradiance soit le facteur primaire, l'humidité est également enregistrée pour enrichir la base de données environnementale, permettant d'étudier l'influence des conditions atmosphériques globales sur la production. [27].




FIGURE 2.9 – Capteur de température et d'humidité DHT22

2.4.1.4 LDR (Estimation de l'irradiance)

La photorésistance (Light Dependent Resistor) est une cellule photoconductrice dont la valeur ohmique diminue drastiquement lorsque l'intensité lumineuse augmente. Dans ce projet, elle est utilisée comme un indicateur économique permettant de suivre les variations relatives de l'éclairement solaire. Sa sensibilité spectrale permet de capturer efficacement l'intermittence du gisement solaire, constituant ainsi un paramètre crucial pour l'apprentissage des modèles d'intelligence artificielle [28].



FIGURE 2.10 – Capteur de luminosité LDR

2.4.1.5 Panneau photovoltaïque 18 V

Le panneau photovoltaïque constitue le générateur primaire du système, assurant la conversion du rayonnement solaire en énergie électrique sous forme de courant continu. Le module retenu possède une tension nominale de 18 V, ce qui permet une caractérisation électrique sur une plage de mesure parfaitement compatible avec les limites d'entrée du capteur INA219 (fixées à 26 V maximum). Ce choix garantit à la fois la précision des relevés et une sécurité optimale durant les phases d'expérimentation.



FIGURE 2.11 – Panneau photovoltaïque 18 V

2.4.1.6 Charge résistive de 2 k Ω

La charge résistive est un composant passif qui oppose une résistance fixe au passage du courant électrique, permettant ainsi la caractérisation du panneau. Elle a été dimensionnée uniquement pour autoriser la circulation d'un courant mesurable sans objectif d'alimentation énergétique réelle. Cette charge est constituée de deux résistances de 1 k Ω montées en série, créant une charge équivalente de 2 k Ω . Cette configuration permet de limiter le courant circulant dans le circuit, évitant ainsi toute surchauffe des composants durant les phases prolongées d'acquisition de données.

2.4.1.7 Module de stockage MicroSD

Le module de stockage MicroSD est un adaptateur de lecture et d'écriture pour cartes mémoire utilisant l'interface de communication SPI (*Serial Peripheral Interface*). Intégré dans la seconde phase du développement, il permet de sauvegarder les relevés de mesures localement sous forme de fichiers de données. Ce choix technologique garantit l'intégrité des informations en cas de défaillance du réseau Wi-Fi et assure une autonomie accrue au prototype lors des campagnes d'acquisition prolongées [29].



FIGURE 2.12 – Module de lecture de carte MicroSD

2.4.1.8 Schéma de câblage du prototype

Le schéma de câblage présenté à la Figure 2.13 illustre les connexions réalisées entre l'ESP32, les différents capteurs, le module MicroSD et le panneau photovoltaïque. Il a servi de référence pour l'assemblage du prototype et la collecte des mesures expérimentales.




FIGURE 2.13 – Schéma de câblage du prototype photovoltaïque instrumenté

2.4.1.9 Conception mécanique du support

Pour garantir des conditions expérimentales optimales et maximiser la captation du flux lumineux, un support mécanique dédié a été conçu sous l'environnement de CAO SolidWorks. L'inclinaison du panneau photovoltaïque est un paramètre critique influençant directement l'irradiance reçue. Pour le site expérimental, un angle d'inclinaison fixe de $37,5^\circ$ par rapport à l'horizontale a été retenu, ce qui correspond à l'optimum

théorique pour maximiser la collecte énergétique annuelle moyenne.

Le système se compose d'un bras de maintien profilé, d'une platine de fixation inclinée à l'angle requis et d'un cadre adapté au module de 18 V. L'ensemble de l'étude mécanique est centralisé sur la Figure 2.14.




FIGURE 2.14 – Modélisation des composants mécaniques du système d'orientation sous SolidWorks

2.4.1.10 Prototype expérimental réalisé

Après la phase de conception et de modélisation mécanique sous SolidWorks, une réalisation pratique du prototype photovoltaïque a été mise en œuvre afin de valider expérimentalement le système proposé. L'ensemble des composants électroniques et électriques a été intégré sur une plateforme expérimentale regroupant le panneau photovoltaïque, le microcontrôleur ESP32, les différents capteurs de mesure ainsi que le système de stockage des données.

La Figure 2.15 présente la réalisation finale de notre système à travers différentes vues d'ensemble et de détails de la plateforme. Le prototype développé permet l'acquisition en temps réel des paramètres météorologiques et électriques nécessaires à la constitution de la base de données utilisée dans cette étude. Cette implémentation pratique a également permis de vérifier le bon fonctionnement des différentes liaisons matérielles ainsi que la stabilité globale du système dans des conditions réelles d'utilisation.




FIGURE 2.15 – Prototype réel du système photovoltaïque instrumenté

2.4.2 Architecture fonctionnelle du prototype

L'architecture fonctionnelle du prototype est structurée selon une chaîne de traitement de l'information allant de la mesure physique à l'exploitation prédictive. Ce flux est divisé en trois phases majeures :

1. **Phase d'Acquisition (Captation et Numérisation)** : Le système est configuré pour enregistrer une mesure toutes les minutes, afin de capter les variations fines des grandeurs météorologiques et électriques. L'acquisition des données s'est déroulée en deux phases distinctes :
 - **Acquisition semi-automatique** : Dans un premier temps, le prototype était alimenté via un câble USB connecté à un ordinateur. Les données transmises par l'ESP32 étaient enregistrées à l'aide du logiciel CoolTerm,

puis sauvegardées dans un fichier Excel (.xlsx). Les acquisitions étaient organisées en blocs de 3 heures, répartis sur trois créneaux journaliers (matin, midi et après-midi), sur une durée d'environ 15 jours. Cette phase a permis de constituer un premier jeu de données réel et de valider la cohérence des mesures avant le déploiement autonome.

- **Acquisition autonome** : Dans un second temps, le système a été rendu entièrement autonome grâce à une batterie externe (powerbank), libérant le prototype de toute contrainte d'infrastructure. L'ESP32 enregistre désormais les données en continu sur une carte SD. La récupération s'effectue par extraction physique de la carte, dont les fichiers sont ensuite transférés vers l'environnement Python. Cette automatisation a permis d'augmenter significativement le volume et la continuité des données collectées, sans intervention humaine.

2. **Phase de Prédiction (Exploitation par l'IA)** : Le flux de données aboutit à l'intégration dans les modèles d'intelligence artificielle. Le prototype développé fournit la base de données brute qui subira un prétraitement, notamment une normalisation (Min-Max scaling). Cette technique transforme les données pour qu'elles soient bornées dans un intervalle, généralement $[0, 1]$, selon la relation suivante [9] :

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2.3)$$

Où :

- x : représente la valeur originale.
- $x_{\min}$ et $x_{\max}$: sont respectivement les valeurs minimale et maximale de la caractéristique.

Une fois normalisées, ces séries temporelles synchronisées alimentent les modèles de type LSTM ou GRU pour apprendre la relation complexe entre la météo et la production électrique.

L'intégration de ces phases au sein du prototype est schématisée dans l'architecture fonctionnelle présentée sur la Figure 2.16. Ce schéma illustre la continuité du flux d'information, depuis la captation physique jusqu'à la génération des séries temporelles normalisées destinées aux modèles de prédiction.




FIGURE 2.16 – Architecture fonctionnelle du prototype

2.4.3 Hypothèses retenues

Afin de simplifier la modélisation expérimentale et d'encadrer les conditions de collecte de données, les hypothèses suivantes ont été adoptées pour le développement du prototype :

- **Représentation de l'irradiance** : L'éclairement est représenté par la réponse de la photorésistance (LDR), supposée proportionnelle aux variations de puissance lumineuse reçue sur le site d'expérimentation.
- **Simplification thermique** : La température ambiante mesurée par le capteur DHT22 est utilisée comme variable d'influence majeure. L'équilibre thermique du panneau photovoltaïque est supposé corrélé à son environnement immédiat [27].
- **Charge constante** : La charge résistive de 2 kΩ est maintenue fixe afin de garantir que toute fluctuation de puissance mesurée provient exclusivement des aléas météorologiques et non d'une variation de l'impédance de sortie.
- **Approche par l'IA** : Le système vise à établir une corrélation entre les paramètres météorologiques et la production électrique. Cette approche est jugée suffisante pour l'entraînement des modèles d'intelligence artificielle, sans nécessiter une précision de mesure absolue de type laboratoire de métrologie.

2.5 Analyse du comportement du système photovoltaïque

Cette section examine la dynamique du générateur photovoltaïque (GPV) afin d'analyser son comportement sous des conditions environnementales variables. Cette étude est fondamentale pour évaluer les performances du module face aux fluctuations des paramètres extérieurs.

2.5.1 Caractère non linéaire du système

Le générateur photovoltaïque présente un comportement électrique complexe qui évolue selon l'irradiance solaire et la température. Cette dépendance se traduit par une réponse non linéaire des caractéristiques du module [11].

- **Non-linéarité des relations électriques** : Les relations liant le courant, la tension et la puissance ne suivent pas une progression linéaire simple. Sur une courbe caractéristique courant-tension ($I - V$), le courant demeure relativement stable sur une large plage de tension avant de chuter brusquement à l'approche de la tension de circuit ouvert (V_{oc}). Cette rupture illustre la complexité de la modélisation mathématique du système.
- **Interactions multifactorielles** : La réponse du système résulte de l'interaction de plusieurs variables météorologiques. Alors que l'irradiance (G) modifie principalement l'amplitude du courant produit, la température des cellules (T) agit essentiellement sur les niveaux de tension. Le générateur fonctionne ainsi comme un système à paramètres variables.
- **Déplacement du point de puissance maximale (MPP)** : Le point de puissance maximale correspond au sommet de la courbe $P - V$. Ce point d'équilibre change de position selon les conditions atmosphériques, ce qui interdit un fonctionnement à point fixe. Le maintien d'une extraction d'énergie optimale nécessite donc l'utilisation de techniques de suivi du point de puissance maximale (MPPT) [5].

La nature non linéaire du GPV impose de considérer le module non pas comme un générateur statique, mais comme un système dynamique adaptatif. Cela justifie l'application de méthodes de contrôle et d'optimisation pour sécuriser l'exploitation de l'énergie produite face à l'intermittence du gisement solaire.

2.5.2 Influence des paramètres météorologiques

L'analyse du comportement du système photovoltaïque repose sur sa sensibilité aux facteurs environnementaux. Cette étude permet d'évaluer comment les variations d'irradiance et de température influencent les caractéristiques électriques du panneau photovoltaïque ainsi que la puissance produite par le prototype expérimental.

- **Influence de l'irradiance** : Les données expérimentales collectées à l'aide du capteur LDR montrent qu'une augmentation de l'éclairement solaire entraîne une hausse significative du courant et de la puissance délivrés par le panneau photovoltaïque. Durant les périodes de fort ensoleillement, la tension mesurée a atteint près de 20 V, tandis que la puissance produite a dépassé 248 mW. À l'inverse, lors des faibles niveaux d'éclairement ou des passages nuageux, la puissance devient très faible, voire quasi nulle. Ces résultats confirment que l'irradiance constitue le facteur principal influençant la production énergétique du système photovoltaïque.
- **Influence de la température** : Les mesures réalisées avec le capteur DHT22 montrent que l'augmentation de la température ambiante influence directement le comportement électrique du panneau photovoltaïque. Une élévation thermique prolongée provoque une diminution progressive du rendement du système, se traduisant notamment par une légère réduction de la tension de sortie. Les données expérimentales collectées indiquent que ces augmentations de température correspondent souvent à une stabilisation ou une diminution relative de la puissance finale malgré un éclairement élevé. Ce comportement reste parfaitement cohérent avec les propriétés physiques connues des cellules photovoltaïques en silicium.
- **Impact des variations climatiques** : En conditions réelles, les variations météorologiques provoquent des fluctuations rapides des grandeurs électriques mesurées. Les passages nuageux entraînent des diminutions brusques de l'éclairement détecté par la LDR, accompagnées d'une chute immédiate du courant et de la puissance produite. Ces variations mettent en évidence le caractère fortement dynamique et intermittent de la production photovoltaïque, rendant nécessaire l'utilisation de modèles intelligents capables d'anticiper de manière fiable les variations futures de production.

2.5.3 Analyse de sensibilité du modèle

Cette sous-section évalue la sensibilité du système photovoltaïque aux variations de ses paramètres d'entrée afin de hiérarchiser leur influence sur la production. L'analyse de

sa dynamique permet de confirmer la nécessité de recourir à des modèles adaptatifs face aux fluctuations environnementales [30].

- **Hiérarchie des paramètres d'influence** : Le système réagit de manière différenciée selon la nature des perturbations. L'irradiance solaire (G) se positionne comme le paramètre dominant et direct de la production de courant. Toute variation notable du flux lumineux engendre une réponse proportionnelle immédiate de l'intensité du courant, fixant ainsi le seuil supérieur de la puissance maximale disponible.
- **Sensibilité thermique et rendement** : Alors que l'irradiance dicte l'amplitude du courant, la température (T) exerce une influence critique et inversement proportionnelle sur la tension. Une élévation thermique des cellules accentue l'agitation des porteurs de charge, ce qui contracte la tension en circuit ouvert (V_{oc}) et dégrade par conséquent le rendement de conversion global du générateur.
- **Limites de prédictibilité en conditions critiques** : La corrélation entre les variables d'entrée et la puissance de sortie se complexifie sous un faible éclaircissement (notamment en dessous de 600 W/m^2). Dans ces zones d'intermittence ou lors des transitions nuageuses rapides, les écarts entre les approximations statiques et le comportement dynamique réel s'accroissent.

L'analyse de sensibilité met en évidence que les interactions couplées entre l'irradiance et la température dominent le comportement du générateur. La complexité de ces variations justifie l'adoption d'approches intelligentes capables de s'ajuster en temps réel aux conditions changeantes de l'environnement.

2.6 Discrétisation et implémentation numérique

Le modèle photovoltaïque repose sur des équations physiques régies par des phénomènes continus. Cependant, l'exploitation numérique et la simulation du système exigent une représentation discrète des variables pour permettre leur traitement informatique. Cette étape est essentielle pour transformer les formulations analytiques en séries temporelles exploitables par les outils de calcul.

2.6.1 Choix de la période d'échantillonnage

Bien que les grandeurs d'influence évoluent de manière continue, les systèmes d'acquisition opèrent sur des valeurs échantillonnées à des instants précis. Le choix de la période

d'échantillonnage (Δt) détermine la fidélité de la dynamique représentée. Dans le cadre de cette étude, un pas de $\Delta t = 1$ **minute** a été retenu pour les raisons suivantes [14] :

- **Capture des dynamiques transitoires** : Cet intervalle permet de suivre les fluctuations rapides de l'irradiance induites par les passages nuageux, indispensables pour les prévisions à très court terme.
- **Représentativité des données** : Un pas de temps plus large risquerait de lisser artificiellement les variations météorologiques, entraînant une perte d'information sur le comportement réel du générateur.
- **Adaptation aux conditions climatiques locales** : Ce choix est particulièrement pertinent compte tenu de la forte variabilité météorologique de l'Algérie. Entre les régions méditerranéennes du Nord, sujettes à une couverture nuageuse changeante, et les zones arides comme Ghardaïa, caractérisées par des conditions parfois sévères, un échantillonnage fin est indispensable pour modéliser localement la réponse du système [31].

2.6.2 Passage du modèle continu au modèle discret

Pour permettre l'implémentation numérique, le modèle est transposé du domaine temporel continu (t) vers un domaine discret (t_k). Les variables physiques sont ainsi transformées en séquences de points numériques définies par la relation suivante :

$$t_k = k \cdot \Delta t \quad \text{avec } k = 0, 1, 2, \dots \quad (2.4)$$

Sous cette forme, les entrées et sorties du modèle deviennent des séries temporelles, structurées sous forme de vecteurs numériques :

- $G(k)$: l'irradiance solaire ;
- $T(k)$: la température ;
- $Hum(k)$: l'humidité ;
- $P(k)$: la puissance électrique.

2.6.3 Implémentation dans l'environnement de développement

L'implémentation numérique du modèle est réalisée dans l'environnement Python, choisi pour sa robustesse dans le traitement des séries temporelles et la manipulation de grands jeux de données. Le processus suit une logique de traitement automatisé [14] :

- **Structuration des données** : Les mesures brutes sont organisées en une base de données cohérente avec le pas de temps défini.
- **Calcul numérique du modèle** : Le programme évalue la puissance produite à chaque instant k , en intégrant les non-linéarités du générateur identifiées précédemment.
- **Organisation des sorties** : Les résultats sont structurés pour permettre une analyse comparative directe avec les données réelles acquises sur le terrain.

Cette structure numérique constitue l'étape finale nécessaire avant l'exploitation des séries temporelles pour l'apprentissage.

2.7 Acquisition et organisation des données

Cette section formalise la transition entre la capture physique des phénomènes météorologiques et la constitution d'un ensemble de données structuré. Cette étape est déterminante pour la fidélité des modèles prédictifs, car la qualité de la prévision dépend directement de la représentativité des mesures collectées sur le terrain.

2.7.1 Processus d'acquisition des mesures

L'acquisition repose sur un prototype instrumenté conçu pour collecter les données réelles et construire la base de données.

- **Variables d'influence** : Outre l'irradiance solaire (G) et la température des cellules (T), l'humidité relative (Hum) a été intégrée. Bien que souvent considérée comme secondaire, l'humidité impacte la transparence atmosphérique et l'absorption spectrale, modifiant ainsi le gisement solaire effectif reçu par le module.
- **Résolution temporelle** : Un pas d'échantillonnage de $\Delta t = 1$ minute a été retenu. Cette haute résolution est indispensable pour capturer les dynamiques transitoires rapides (passages nuageux intermittents), caractéristiques essentielles des modèles de prévision à très court terme.
- **Chaîne matérielle et autonomie** : Les signaux sont numérisés via un micro-contrôleur ESP32. La méthode d'enregistrement a évolué d'une transmission série (via *CoolTerm*) vers un stockage local sur carte SD.

2.7.2 Structuration en séries temporelles

Pour transformer ces mesures brutes en un problème d'apprentissage supervisé, les données sont organisées en séquences chronologiques.

- **Vecteur d'entrée et cible** : Chaque échantillon à l'instant k est défini par les vecteurs suivants :

$$X(k) = [G(k), T(k), Hum(k)] \quad ; \quad Y(k) = [P(k)] \quad (2.5)$$

- **Approche par fenêtre glissante (*Sliding Window*)** : Afin de permettre aux modèles d'apprendre les dépendances temporelles non linéaires, les entrées ne sont pas traitées de manière isolée mais sous forme de séquences de pas successifs, permettant de capturer l'inertie thermique et les tendances météorologiques.

2.7.3 Consolidation de la base de données

La base de données a été construite à partir d'une campagne de mesures réelles menée sur une période de 47 jours, du 27 avril 2026 au 12 juin 2026. Les données collectées par le prototype sont exportées sous format CSV pour être traitées. Un alignement temporel est ensuite appliqué pour synchroniser précisément chaque mesure environnementale d'entrée avec la puissance électrique produite au même instant k , éliminant ainsi tout décalage entre les capteurs.

Il convient de souligner que le prototype reste pleinement opérationnel et continue de collecter des données sur le terrain au-delà de cette période. Néanmoins, les données arrêtées au 12 juin 2026 constituent la base de données fixe exploitée pour les analyses et l'entraînement des modèles présentés dans ce mémoire.

2.8 Prétraitement des données

Le prétraitement est une phase charnière visant à maximiser le rapport signal/bruit de la base de données avant l'apprentissage.

2.8.1 Nettoyage et intégrité statistique

Malgré les précautions lors de l'acquisition, la base de données brute peut présenter des artefacts :

- **Filtrage des anomalies** : Les valeurs physiquement incohérentes ou issues d'erreurs de transmission sont identifiées et supprimées.
- **Interpolation** : Les lacunes mineures de mesure sont complétées par interpolation linéaire pour maintenir la continuité temporelle, ce qui est indispensable pour le bon fonctionnement des réseaux récurrents (LSTM, GRU) [17].

2.8.2 Normalisation des variables

Une étape de normalisation Min-Max est appliquée aux données afin d'harmoniser les différentes échelles des variables et de faciliter leur exploitation par les modèles d'intelligence artificielle, comme présenté précédemment dans la phase de prédiction.

2.8.3 Partitionnement chronologique de la base de données

La base de données est divisée selon une logique chronologique afin de respecter la nature temporelle des séries, comme présenté plus en détail dans le chapitre consacré à l'évaluation des modèles. Ce pipeline robuste constitue le socle sur lequel repose l'évaluation comparative des modèles ARX, PMC, RF, LSTM et GRU développés dans le chapitre suivant.

2.9 Conclusion

Ce chapitre a posé les fondations indispensables à notre démarche prédictive à travers une approche rigoureuse combinant modélisation théorique, ingénierie matérielle et traitement logiciel.

Tout d'abord, la modélisation analytique et électrique du générateur photovoltaïque a permis d'appréhender le comportement physique intrinsèque du système. Cette étape purement déterministe a conduit à la formulation mathématique des équations régissant le panneau et a permis de générer une première base de données théorique idéale, représentant le fonctionnement du système à l'abri de toute perturbation externe.

Ensuite, afin de confronter nos futurs modèles aux exigences complexes du terrain, un prototype expérimental instrumenté autour d'un microcontrôleur ESP32 a été entièrement développé. Ce dispositif a rendu possible la mesure et la synchronisation en temps réel des variables électriques et des indicateurs météorologiques environnementaux, palliant ainsi les limites des architectures de gestion classiques.

Enfin, la mise en œuvre d'une chaîne algorithmique de prétraitement a permis de nettoyer, filtrer et structurer ces mesures brutes. L'analyse de ces signaux a confirmé la forte non-linéarité du système ainsi que sa sensibilité critique face aux fluctuations physiques de l'irradiance et de la température, tout en consolidant une seconde base de données, expérimentale, fiable et saine.

L'aboutissement de ce travail nous permet de disposer de deux bases de données distinctes et complémentaires : l'une issue des lois physiques théoriques et l'autre dictée par les réalités du terrain. Le chapitre suivant sera ainsi entièrement consacré à la présentation théorique de nos modèles d'intelligence artificielle et à la définition de leurs critères d'évaluation, avant de procéder à leur entraînement et à l'analyse de leurs performances respectives sur ces deux jeux de données indépendants.

ANALYSE DES RÉSULTATS ET VALIDATION DU MODÈLE

Dans la continuité des fondements théoriques présentés dans le chapitre précédent, ce chapitre est consacré à la modélisation du système photovoltaïque ainsi qu'à l'évaluation expérimentale des approches de prédiction développées dans ce travail.

L'objectif principal est de construire et comparer plusieurs modèles d'intelligence artificielle capables de reproduire la dynamique de la puissance photovoltaïque à partir des variables météorologiques et des données historiques du système.

Dans un premier temps, nous présentons les différentes architectures utilisées, allant des modèles classiques de régression aux réseaux de neurones récurrents et aux systèmes hybrides neuro-flous. Cette diversité permet d'analyser à la fois des approches linéaires, non linéaires et interprétables.

Ensuite, nous décrivons la méthodologie d'évaluation adoptée, basée sur des métriques statistiques complémentaires permettant d'apprécier la précision, la robustesse et la capacité de généralisation de chaque modèle.

Enfin, ce chapitre présente et analyse les résultats expérimentaux obtenus sur un ensemble de test indépendant, afin de mettre en évidence les performances comparatives des différentes approches et d'identifier les compromis entre précision et complexité.

3.1 Modèles utilisés pour la prédiction photovoltaïque

Dans le cadre de cette étude, plusieurs approches fondées sur l'automatique classique, l'apprentissage statistique et les architectures de réseaux profonds sont mobilisées. L'objectif est de modéliser la relation complexe, et parfois fortement non linéaire, entre les variables météorologiques et la puissance photovoltaïque produite.

L'enjeu principal de cette phase est d'identifier l'algorithme offrant le meilleur compromis entre la précision des estimations, la robustesse face à l'intermittence et la capacité de généralisation du système.

3.1.1 Le Perceptron Multicouche (PMC)

Le Perceptron Multicouche (PMC) constitue l'architecture fondamentale pour la régression non linéaire. Il est structuré en plusieurs couches successives : une couche d'entrée recevant les variables météorologiques (G, T, Hum), une ou plusieurs couches cachées assurant le traitement intermédiaire, et une couche de sortie délivrant la puissance prédite.

Son fonctionnement repose sur l'intégration des signaux d'entrée via une combinaison linéaire associée à des poids synaptiques. Le résultat est ensuite transformé par une fonction d'activation non linéaire, permettant au réseau d'apprendre des représentations complexes à partir des données historiques [6].

Pour la prédiction photovoltaïque, le PMC capture efficacement les interactions directes entre les paramètres climatiques et la production électrique. Cependant, sa structure traite chaque échantillon de manière isolée, ce qui limite son aptitude à appréhender la dynamique temporelle inhérente aux séries chronologiques.




FIGURE 3.1 – Architecture du Perceptron Multicouche (PMC) pour la régression

3.1.2 Le réseau Long Short-Term Memory (LSTM)

Pour pallier cette absence de mémoire, l'architecture Long Short-Term Memory (LSTM) est introduite. Ce type de réseau récurrent est spécifiquement conçu pour le traitement

de données séquentielles en résolvant les problématiques de disparition du gradient sur de longs intervalles temporels [32].

Sa structure interne s'appuie sur une "cellule d'état" capable de stocker une information stable sur des périodes étendues. Un mécanisme de trois portes (oubli, entrée et sortie) régule le flux d'information, permettant au modèle de préserver les tendances météorologiques pertinentes tout en filtrant les variations non pertinentes.

L'intérêt du LSTM réside dans sa capacité à identifier les motifs saisonniers et l'inertie du système photovoltaïque. Cette approche séquentielle s'avère particulièrement robuste pour la prévision à court terme, où l'historique récent influence fortement la production immédiate.




FIGURE 3.2 – Structure interne d'une cellule Long Short-Term Memory (LSTM)

3.1.3 Le réseau Gated Recurrent Unit (GRU)

Le réseau Gated Recurrent Unit (GRU) constitue une variante optimisée et simplifiée de l'architecture LSTM. Il est également conçu pour mémoriser les dépendances temporelles à long terme au sein des séries chronologiques tout en contournant le phénomène de disparition du gradient [33]. Sa dynamique interne est gouvernée par deux portes principales :

- **La porte de mise à jour** (Update gate) : elle contrôle la proportion d'informations issues du passé à conserver et la quantité de nouvelles données à intégrer dans l'état caché actuel.
- **La porte de réinitialisation** (Reset gate) : elle détermine le niveau d'oubli de l'état précédent lors de l'estimation du nouvel état candidat.

Par rapport au modèle LSTM, le GRU présente la particularité de fusionner l'état de cellule et l'état caché en un unique vecteur d'état. Cette réduction structurelle diminue significativement le nombre de paramètres internes à optimiser, accélérant ainsi la phase d'apprentissage. Cette compacité algorithmique s'avère particulièrement avantageuse pour prévenir les risques de surapprentissage lorsque le volume de données collecté est contraint.

3.1.4 Les Forêts Aléatoires (Random Forests)

Les Forêts Aléatoires constituent une méthode d'apprentissage d'ensemble reposant sur la combinaison de nombreux arbres de décision construits de manière indépendante. Chaque arbre est entraîné sur un sous-ensemble aléatoire des données et utilise une sélection aléatoire de variables lors de la construction de ses nœuds, ce qui favorise la diversité au sein de la forêt [34].

Dans le cadre d'un problème de régression, la prédiction finale est obtenue en agrégeant les résultats de l'ensemble des arbres, généralement par calcul de leur moyenne. Ce mécanisme permet de réduire la variance du modèle et d'améliorer sa capacité de généralisation.




FIGURE 3.3 – Architecture générale d'un modèle de Forêt Aléatoire en régression (agrégation par moyenne)

Pour la prédiction photovoltaïque, les Forêts Aléatoires offrent une bonne robustesse face au bruit et aux valeurs aberrantes présentes dans les données météorologiques. Elles permettent également de modéliser efficacement les relations non linéaires entre les variables climatiques et la puissance produite, tout en limitant les risques de sur-apprentissage.

3.1.5 Le modèle Auto-Régressif à entrée eXogène (ARX)

Contrairement aux structures boîte-noire neuronales, le modèle ARX est une approche mathématique linéaire issue de la théorie de l'identification des systèmes. Il formalise le comportement dynamique d'un système discret en établissant une relation de cause à effet entre la sortie instantanée, ses états historiques (composante auto-régressive) ainsi que l'historique des variables exogènes du milieu [35]. Sa formulation mathématique générale s'énonce ainsi :

$$A(q)y(t) = B(q)u(t) + e(t) \quad (3.1)$$

où :

- $y(t)$ désigne la variable de sortie du système, correspondant ici à la puissance photovoltaïque produite.
- $u(t)$ représente le vecteur d'entrée exogène, regroupant les variables météorologiques et électriques mesurées (L, T, HR, V, I).
- $e(t)$ modélise un bruit blanc gaussien, traduisant l'erreur résiduelle d'ajustement.
- $A(q)$ et $B(q)$ caractérisent les polynômes exprimés en fonction de l'opérateur de retard unitaire q^{-1} (défini par $q^{-1}y(t) = y(t-1)$), structurés comme suit :

$$A(q) = 1 + a_1q^{-1} + \dots + a_{n_a}q^{-n_a} \quad (3.2)$$

$$B(q) = b_1q^{-1} + \dots + b_{n_b}q^{-n_b} \quad (3.3)$$

Les entiers n_a et n_b fixent respectivement l'ordre auto-régressif et l'ordre exogène du modèle. L'estimation des coefficients de pondération a_i et b_j s'effectue par une optimisation mathématique directe visant à minimiser la somme des carrés des écarts de prédiction via la méthode des Moindres Carrés Ordinaires (MCO) :

$$\min_{a_i, b_j} \sum_{t=1}^n (\hat{y}(t) - y(t))^2 \quad (3.4)$$

où $\hat{y}(t)$ et $y(t)$ désignent respectivement les puissances photovoltaïques estimées et mesurées sur le site.

Dans l'application de prédiction photovoltaïque, l'intégration du modèle ARX se justifie par sa simplicité de calcul algorithmique et sa transparence mathématique. Il s'impose comme une référence de base linéaire essentielle pour mesurer l'apport réel des mécanismes non linéaires introduits par les architectures profondes concurrentes.

3.2 Méthodologie d'évaluation

Afin d'évaluer les performances des modèles, plusieurs métriques statistiques sont utilisées pour quantifier l'erreur entre les valeurs prédites et les valeurs réelles. Cette approche multidimensionnelle permet d'apprécier la précision des prévisions sous différents angles, qu'il s'agisse de l'erreur moyenne ou de la sensibilité aux écarts extrêmes.

3.2.1 Indicateurs de performance statistique

Afin d'évaluer objectivement les performances des différents modèles développés, quatre métriques statistiques complémentaires ont été retenues [36].

Dans les expressions mathématiques ci-dessous, n désigne le nombre total d'échantillons du jeu de test, $P_{PV}^{(i)}$ représente la valeur réelle de la puissance photovoltaïque observée au pas de temps i , $\hat{P}_{PV}^{(i)}$ correspond à la valeur prédite par le modèle, et $\bar{P}_{PV}$ désigne la moyenne des valeurs réelles.

3.2.1.1 Racine de l'Erreur Quadratique Moyenne (RMSE)

Le $RMSE$ est exprimé dans la même unité que la variable de sortie (Watts). Il pénalise fortement les grandes erreurs de prédiction en raison de l'élévation au carré, ce qui le rend particulièrement sensible aux écarts et aux pics d'erreur ponctuels :

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(P_{PV}^{(i)} - \hat{P}_{PV}^{(i)} \right)^2} \quad (3.5)$$

3.2.1.2 Erreur Absolue Moyenne (MAE)

La MAE représente l'erreur moyenne absolue entre les valeurs réelles et prédites. Contrairement au $RMSE$, elle traite tous les écarts de manière uniforme et s'avère beaucoup plus robuste face aux valeurs aberrantes :

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_{PV}^{(i)} - \hat{P}_{PV}^{(i)}| \quad (3.6)$$

3.2.1.3 Erreur Absolue Moyenne en Pourcentage (MAPE)

Le *MAPE* exprime l'erreur sous forme de pourcentage relatif, ce qui facilite la comparaison directe des performances indépendamment de l'échelle des données. Toutefois, ce critère peut devenir instable ou indéterminé lorsque les valeurs réelles $P_{PV}^{(i)}$ sont nulles ou proches de zéro (notamment durant la nuit) :

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{P_{PV}^{(i)} - \hat{P}_{PV}^{(i)}}{P_{PV}^{(i)}} \right| \quad (3.7)$$

3.2.1.4 Coefficient de Détermination (R^2)

Le coefficient R^2 mesure la proportion de la variance de la puissance réelle expliquée et capturée par le modèle. Une valeur proche de 1 indique un ajustement parfait, tandis qu'une valeur proche de 0 signifie que le modèle n'est pas plus performant qu'une simple estimation par la moyenne :

$$R^2 = 1 - \frac{\sum_{i=1}^n (P_{PV}^{(i)} - \hat{P}_{PV}^{(i)})^2}{\sum_{i=1}^n (P_{PV}^{(i)} - \bar{P}_{PV})^2} \quad (3.8)$$

3.2.2 Protocole de validation

La fiabilité des résultats repose sur une méthode de validation rigoureuse. Comme établi précédemment, le jeu de données est soumis à un split chronologique (70% entraînement, 15% validation, 15% test) afin de respecter la causalité temporelle des mesures.

Une validation temporelle stricte est appliquée afin d'éviter toute fuite d'information entre les ensembles d'apprentissage et de test. Les modèles sont ainsi évalués sur des données jamais vues lors de la phase d'entraînement, permettant une comparaison directe entre les puissances prédites et réelles en conditions opérationnelles.




FIGURE 3.4 – Schéma du protocole de division chronologique des données

3.3 Évaluation et validation sur données théoriques

Dans cette optique, il est nécessaire de commencer par présenter la structure et les caractéristiques principales du jeu de données théorique utilisé pour l'évaluation.

3.3.1 Base de données théorique

À l'aide de la formulation analytique développée au Chapitre 2, une base de données exempte de bruits expérimentaux a été construite. Un aperçu des dix premières lignes de ce jeu de données théorique (comprenant l'irradiance, la température et la puissance calculée) est illustré par la Figure 3.5.

	day	minute	hour	irradiance	temperature	power	time_index
0	0	0	0.000000	-19.932323	24.896391	3.697806	0
1	0	1	0.016667	-39.145588	26.614252	3.731336	1
2	0	2	0.033333	-13.046685	25.080728	0.711182	2
3	0	3	0.050000	19.924135	26.257553	9.708556	3
4	0	4	0.066667	35.035681	24.708668	7.600659	4
5	0	5	0.083333	10.661444	26.171073	3.704443	5
6	0	6	0.100000	42.986278	25.030593	7.758585	6
7	0	7	0.116667	14.286764	24.774345	4.093380	7
8	0	8	0.133333	3.554616	26.998869	2.700890	8
9	0	9	0.150000	-4.882363	26.547467	2.952080	9

FIGURE 3.5 – Aperçu des dix premières lignes de la base de données générée par modélisation analytique.

Afin d'évaluer objectivement la capacité de nos algorithmes à capturer cette logique physique pure, nos cinq modèles d'intelligence artificielle (MLP, Random Forest, ARX, LSTM et GRU) ont été entraînés et testés sur ce jeu de données de modélisation.

3.3.2 Résultats statistiques et indicateurs de performance théoriques

Les indicateurs de performance statistique calculés sur l'ensemble de test indépendant de cette base déterministe sont regroupés et classés par ordre d'efficacité dans le Tableau 3.1.

Modèle	RMSE	MAE	MAPE (%)	R^2
MLP	0,0214	0,0170	4,8843	0,9909
RF	0,0227	0,0181	5,3354	0,9898
ARX	0,0323	0,0257	7,5128	0,9792
LSTM	0,0325	0,0259	7,6731	0,9790
GRU	0,0329	0,0262	7,5279	0,9784

TABLE 3.1 – Comparaison numérique des performances des modèles sur l'ensemble de données théoriques de modélisation

L'analyse du Tableau 3.1 révèle que l'ensemble des modèles affiche des performances remarquables, avec des coefficients de détermination R^2 tous supérieurs à 0,97. Le Perceptron Multicouche (PMC) et la Forêt Aléatoire (RF) se distinguent particulièrement en obtenant des scores de précision exceptionnels ($R^2 > 0,99$ et $MAPE < 5,5\%$).

Ce comportement d'ajustement quasi-parfait confirme que les modèles d'apprentissage

supervisé parviennent à décoder sans difficulté les dynamiques non linéaires issues des équations déterministes de la physique lorsqu'elles ne sont soumises à aucune incertitude externe.

3.3.3 Analyse graphique des profils de prédiction théoriques

Pour affiner cette analyse, la Figure 3.6 présente la superposition visuelle entre les puissances théoriques cibles et les puissances prédites par chacun des fiches modèles.




FIGURE 3.6 – Distribution statistique et analyse fréquentielle des variables de la base de données

Cette évaluation graphique corrobore parfaitement les indicateurs statistiques, les courbes de prédiction épousant fidèlement la trajectoire de la puissance théorique. Cette étape valide avec rigueur l'implémentation de notre chaîne algorithmique d'ingénierie et jus-

tifie son extension face aux perturbations du monde réel.

3.4 Évaluation et validation sur données expérimentales

Après avoir validé le comportement des modèles dans un environnement théorique idéal, il est essentiel de présenter la structure et la nature des données réelles collectées par notre prototype expérimental. La base de données brute est constituée d'enregistrements chronologiques continus, combinant les grandeurs électriques mesurées et les paramètres environnementaux exogènes.

3.4.1 Présentation de la base de données

La base de données expérimentale utilisée dans cette étude est constituée d'enregistrements chronologiques continus regroupant les variables électriques mesurées ainsi que les paramètres environnementaux associés au système photovoltaïque.

La Figure 3.7 présente un aperçu des dix premiers échantillons de cette base de données, illustrant la structure des données ainsi que la synchronisation temporelle des différentes variables d'acquisition.

	Date	Heure	Tension_V	Courant_mA	Puissance_mW	Temp_C	Hum_%	LDR_Raw
0	2026-04-28	10:44:45	4.33	2.20	9.53	17.8	80.9	1360
1	2026-04-28	10:45:45	4.43	2.72	12.06	17.8	80.9	1379
2	2026-04-28	10:46:45	4.42	2.80	12.39	17.8	81.2	1373
3	2026-04-28	10:47:45	4.50	2.80	12.59	17.8	81.3	1388
4	2026-04-28	10:48:45	4.58	2.52	11.55	17.8	81.3	1391
5	2026-04-28	10:49:45	4.67	2.60	12.15	17.8	81.1	1407
6	2026-04-28	10:50:45	4.70	2.40	11.27	17.8	80.7	1387
7	2026-04-28	10:51:45	4.74	2.72	12.88	17.8	80.9	1391
8	2026-04-28	10:52:45	4.87	3.00	14.62	17.8	81.0	1410
9	2026-04-28	10:53:45	4.91	3.00	14.72	17.8	81.1	1430

FIGURE 3.7 – Aperçu structurel des dix premières lignes de la base de données expérimentale sous Python

Pour approfondir l'analyse de notre base de données expérimentale, la Figure 3.8 présente les histogrammes de distribution de l'ensemble des variables physiques et électriques. Ces graphiques permettent d'étudier la dispersion et la fréquence d'apparition des différentes plages de valeurs mesurées sur le terrain.




FIGURE 3.8 – Distribution statistique et analyse fréquentielle des variables de la base de données

L'examen de ces distributions montre que les grandeurs électriques (courant, tension et puissance) présentent une forte concentration de données dans les basses plages, ce qui correspond aux périodes d'intermittence ou de couverture nuageuse. En ce qui concerne les facteurs météorologiques exogènes, la température ambiante reste fortement concentrée autour d'un point de fonctionnement stable (entre 20°C et 25°C), tandis que le capteur de luminosité (LDR) couvre une large dynamique allant jusqu'à plus de 3500 unités brutes, offrant ainsi un jeu de données riche pour l'apprentissage

des modèles.

3.4.2 Configuration expérimentale des modèles évalués

Chaque modèle a été configuré de manière empirique pour s'adapter aux données collectées :

- **Perceptron Multicouche (PMC)** : Réseau direct à deux couches cachées (64 et 32 neurones), entraîné sur un maximum de 50 époques pour capter les relations statiques globales.
- **Long Short-Term Memory (LSTM)** : Réseau récurrent intégrant une couche de 32 unités avec un horizon historique de 20 pas de temps pour mémoriser les dépendances séquentielles à court terme.
- **Gated Recurrent Unit (GRU)** : Alternative récurrente plus légère à 32 unités, entraînée sur 5 époques avec l'optimiseur Adam et une taille de lot (batch size) de 32.
- **Modèle AutoRégressif avec Variables Exogènes (ARX)** : Approche linéaire basée sur une régression multiple avec un horizon de retard rétrospectif fixé à 20 pas de temps ($\text{lag} = 20$).
- **Forêt Aléatoire (RF)** : Modèle d'ensemble constitué de 50 arbres de décision indépendants avec un état fixe ($\text{random_state} = 42$) pour assurer la reproductibilité et lisser les fluctuations.

Analyse comparative et discussion des performances

Une fois l'entraînement des modèles finalisé, leurs performances prédictives ont été évaluées sur l'ensemble de test à l'aide de quatre métriques standards : la racine de l'erreur quadratique moyenne (RMSE), l'erreur absolue moyenne (MAE), l'erreur moyenne absolue en pourcentage (MAPE) et le coefficient de détermination (R^2). Le tableau 3.2 regroupe l'ensemble des résultats numériques obtenus.

Modèle	RMSE	MAE	MAPE (%)	R^2
MLP	0,0234	0,0081	15,1502	0,9458
LSTM	0,0250	0,0068	6,0216	0,9382
GRU	0,0237	0,0072	10,6895	0,9447
ARX	0,0248	0,0080	13,2738	0,9334
RF	0,0239	0,0055	3,3305	0,9435

TABLE 3.2 – Comparaison numérique des performances des modèles sur l'ensemble de test

Pour visualiser plus distinctement le comportement de chaque approche face aux erreurs, la figure 3.9 présente une analyse comparative graphique de l'ensemble des indicateurs de précision sous forme de grille.




FIGURE 3.9 – Évaluation graphique des performances des cinq modèles de prédiction pour chaque métrique

L'examen des résultats révèle que l'ensemble des modèles affiche d'excellentes capacités d'apprentissage, avec des coefficients R^2 tous supérieurs à 0,93, validant ainsi la pertinence des variables exogènes sélectionnées lors de l'acquisition.

Cependant, l'analyse fine des erreurs apporte des nuances fondamentales :

- **La Forêt Aléatoire (RF)** : C'est le modèle le plus robuste et équilibré sur le plan opérationnel. Bien que son R^2 soit très légèrement inférieur à celui du PMC, il obtient la plus faible erreur absolue moyenne ($MAE = 0,0055$) et surclasse nettement toutes les autres approches sur la métrique relative avec un MAPE de seulement 3,33%. Cette performance confirme sa capacité à lisser efficacement le bruit des capteurs sans sur-apprentissage.
- **Le Perceptron Multicouche (PMC)** : Il atteint la plus faible erreur globale brute ($RMSE = 0,0234$) et le meilleur R^2 (0,9458). Cela indique qu'il capture de manière optimale les pics de production lors des fortes variations de luminosité,

même si ses erreurs relatives sur les bas régimes de puissance augmentent son MAPE à 15,15%.

- **Les modèles récurrents (LSTM et GRU) :** Ils affichent un comportement intermédiaire très satisfaisant. Le GRU présente un excellent compromis général ($RMSE = 0,0237$, $MAPE = 10,68\%$), se montrant un peu plus stable et réactif que le LSTM sur ce jeu de données spécifique.
- **Le modèle linéaire ARX :** Il ferme la marche tout en restant compétitif ($R^2 = 0,9334$). Ses performances prouvent que l'intégration d'un horizon historique (fixé à 20 pas) permet à une régression classique de suivre efficacement la tendance globale de la production.

3.4.3 Analyse de la dynamique temporelle des prédictions

Afin d'évaluer la capacité des modèles à suivre les fluctuations en temps réel de la puissance photovoltaïque et à absorber l'intermittence, les profils prédits ont été superposés aux mesures réelles. Cette analyse graphique a été menée sur un jeu de données de test extrait d'une base de données globale comprenant plus de 15 710 observations. Les simulations ont été projetées sur une fenêtre continue de 500 minutes (Figures 3.10 à 3.14).




FIGURE 3.10 – Suivi temporel – Réseau de neurones Perceptron Multicouche (PMC)

3.4 ÉVALUATION ET VALIDATION SUR DONNÉES EXPÉRIMENTALES




FIGURE 3.11 – Suivi temporel – Réseau récurrent Long Short-Term Memory (LSTM)




FIGURE 3.12 – Suivi temporel – Réseau récurrent Gated Recurrent Unit (GRU)




FIGURE 3.13 – Suivi temporel – Modèle linéaire AutoRégressif avec Variables Exogènes (ARX)




FIGURE 3.14 – Suivi temporel – Modèle d’ensemble Forêt Aléatoire (RF)

L’examen visuel des chroniques temporelles confirme les conclusions tirées de l’analyse statistique :

- **Robustesse aux bas régimes** : durant les 400 premières minutes, caractérisées par un signal de puissance globalement stable et bas, la forêt aléatoire (RF) et les modèles récurrents (LSTM et GRU) collent parfaitement à la courbe de terrain. Le PMC montre quant à lui un léger biais systématique négatif persistant en basse puissance, ce qui explique son MAPE plus élevé (15,15%).
- **Réactivité aux transitions rapides** : lors de la forte rampe de puissance survenant après la 400^{ème} minute, le PMC fait preuve d’une excellente réactivité et rattrape instantanément la courbe réelle lors de la montée en pic, confirmant sa supériorité sur le critère du R^2 global (0,9458).
- **Comportement de l’ARX corrigé** : suite à l’alignement de son horizon rétrospectif à 20 pas de temps ($lag = 20$), le modèle linéaire ARX parvient à filtrer efficacement le bruit de fond et à suivre la tendance dynamique ascendante sans déphasage majeur, validant l’apport des variables exogènes météo même pour des structures algorithmiques non complexes.

3.4.4 Discussion des résultats

Cette section propose une discussion synthétique des résultats obtenus, en mettant l’accent sur leur interprétation globale ainsi que sur les limites de l’approche adoptée.

3.4.4.1 Analyse des performances des modèles

Les résultats expérimentaux mettent en évidence des comportements différenciés entre les modèles testés, sans qu’une supériorité absolue d’une seule famille ne soit systématique.

Les principales tendances observées sont les suivantes :

- **Le modèle d'ensemble forêt aléatoire** : il s'impose comme la solution la plus équilibrée du panel, enregistrant une excellente précision globale et surclassant nettement tous les autres modèles sur l'erreur relative avec un MAPE minimal de 3,33%. Son analyse temporelle montre une capacité remarquable à filtrer le bruit de fond des capteurs lors des régimes de basse puissance.
- **Le PMC** : il affiche la plus haute précision absolue sur l'ensemble de test, caractérisé par le plus faible RMSE (0,0234) et le meilleur coefficient R^2 (0,9458). Il s'avère extrêmement réactif pour capturer les pics de production lors des variations brutales de luminosité, bien qu'il concède un léger biais en bas régime.
- **Les modèles récurrents GRU et LSTM** : ils affichent des performances intermédiaires très proches et satisfaisantes, avec un léger avantage pour le GRU qui offre un meilleur compromis entre la précision globale et le coût d'entraînement face à la structure plus lourde du LSTM.
- **L'ARX** : une fois son horizon rétrospectif correctement ajusté à 20 pas de temps ($lag = 20$), il délivre des performances tout à fait compétitives ($R^2 = 0,9334$). Il valide l'importance capitale de l'intégration des variables exogènes météo pour suivre la tendance principale, même avec une structure dénuée de non-linéarité.

Ces observations confirment que l'augmentation de la complexité algorithmique ne garantit pas systématiquement une amélioration de toutes les métriques, notamment lorsqu'un modèle d'ensemble statistique ou un réseau direct bien configuré parvient à capter l'essentiel de la dynamique du système.

3.4.4.2 Avantages et limites de l'approche proposée

L'approche adoptée dans ce travail présente plusieurs avantages :

- Une comparaison multi-modèles couvrant des approches linéaires, neuronales directes, récurrentes et d'ensemble.
- Une évaluation basée sur plusieurs métriques complémentaires ($RMSE$, MAE , $MAPE$, R^2), assurant une analyse équilibrée entre erreurs absolues et relatives.
- Une validation sur un ensemble de test indépendant garantissant la robustesse des résultats.
- Une analyse combinant aspects quantitatifs et représentations graphiques temporelles pour une meilleure interprétation.

Cependant, certaines limites doivent être prises en considération :

- L'étude repose sur une seule base de données locale, ce qui peut limiter la généralisation immédiate des conclusions à d'autres microclimats sans réentraînement.
- Les modèles neuronaux profonds et la forêt aléatoire pourraient bénéficier d'un réglage encore plus fin de leurs hyperparamètres par optimisation bayésienne.
- L'analyse est principalement centrée sur un horizon de prédiction à très court terme (pas de temps à la minute).

En résumé, les résultats montrent qu'il existe un compromis important entre le type d'erreur minimisé et la complexité opérationnelle du modèle. Dans certains scénarios, des architectures d'ensemble comme la forêt aléatoire surpassent les réseaux récurrents profonds, ce qui souligne l'importance d'une évaluation multi-critères dans les problèmes de prédiction de puissance photovoltaïque.

3.5 Conclusion

Ce chapitre a présenté la modélisation du système photovoltaïque ainsi que l'évaluation comparative de plusieurs approches d'intelligence artificielle appliquées à la prédiction de la puissance générée.

L'étude expérimentale a permis de comparer différentes familles de modèles, allant des approches linéaires aux réseaux de neurones profonds, en passant par des modèles d'ensemble. Les résultats obtenus montrent que la performance des modèles ne dépend pas uniquement de leur complexité algorithmique, mais également de leur adéquation avec la dynamique des données étudiées.

Le modèle de forêt aléatoire (RF) s'est distingué par sa régularité générale et sa précision sur les erreurs relatives, s'affirmant comme une solution hautement fiable pour une exploitation industrielle stable. Les réseaux de neurones (PMC, GRU et LSTM) ont démontré leur puissante capacité à intégrer les variations non linéaires, le PMC s'octroyant la meilleure précision absolue sur les pics de puissance. Enfin, le modèle ARX a prouvé qu'une approche mathématique classique, lorsqu'elle exploite un horizon historique adapté, constitue une alternative simple et légère parfaitement adaptée à des environnements embarqués.

De manière générale, les résultats obtenus soulignent l'existence d'un compromis fondamental entre la précision des prédictions et les contraintes de calcul. Cette analyse met en évidence l'importance d'une évaluation multi-critères pour sélectionner l'architecture de prédiction optimale pour les micro-réseaux photovoltaïques.

CONCLUSION GÉNÉRALE

Ce mémoire a présenté une démarche complète allant de la compréhension théorique des systèmes photovoltaïques jusqu'au développement, à l'implémentation et à l'évaluation de modèles d'intelligence artificielle dédiés à la prédiction de leur production énergétique en fonction des variables météorologiques.

Le travail a débuté par une étude approfondie des fondements physiques et technologiques des systèmes photovoltaïques, en analysant l'influence directe des paramètres climatiques, tels que l'irradiance solaire et la température, sur les performances des modules. Cette analyse a permis de mettre en œuvre la modélisation mathématique du générateur pour générer une première base de données théorique, tout en mettant en évidence la nature intermittente et non linéaire de la production photovoltaïque.

Afin de constituer une base de données réelle, fiable et représentative, un prototype expérimental instrumenté a été conçu et déployé dans le cadre de ce projet. Basé sur un microcontrôleur ESP32 et un ensemble de capteurs mesurant l'irradiance, la température, l'humidité et la puissance électrique produite, ce dispositif a permis de collecter des séries temporelles synchronisées en conditions réelles. Ces données expérimentales, complétant l'approche théorique, ont constitué le socle d'apprentissage et de validation de l'ensemble des modèles développés.

La partie centrale de l'étude a été consacrée au développement et à la comparaison de plusieurs approches de prédiction sur ces deux bases de données, incluant un modèle linéaire de référence (ARX), un perceptron multicouche (PMC), des réseaux de neurones récurrents (LSTM et GRU), ainsi qu'un modèle d'ensemble basé sur les forêts aléatoires (Random Forest).

Les résultats obtenus montrent que sur le jeu théorique, les modèles affichent un ajustement quasi-parfait ($R^2 > 0,9$). Sur l'ensemble de test expérimental indépendant, les modèles confirment leur robustesse avec des coefficients de détermination R^2 supérieurs à 0,93, validant la pertinence des variables météorologiques utilisées et la qualité des bases de données construites.

Dans ce contexte expérimental, la Forêt Aléatoire (Random Forest) s'est distinguée comme le modèle le plus performant en termes d'erreur relative, atteignant un MAPE de 3,33%, ce qui traduit une excellente robustesse face au bruit et aux fluctuations des mesures expérimentales. Le Perceptron Multicouche (PMC) a quant à lui obtenu les meilleures performances en termes d'erreur globale et de coefficient de détermination, avec un RMSE de 0,0234 et un R^2 de 0,9458, confirmant sa capacité à capturer efficacement les variations rapides de la production photovoltaïque.

Les modèles récurrents LSTM et GRU ont montré des performances intermédiaires satisfaisantes, en exploitant efficacement les dépendances temporelles des séries, avec un avantage en termes de compromis précision/complexité pour le GRU. Le modèle ARX, malgré sa structure linéaire, a également présenté des performances compétitives, démontrant que l'intégration de variables exogènes et d'un historique temporel adapté permet d'estimer correctement la tendance globale du système.

De manière générale, ces résultats montrent que les modèles les plus performants ne sont pas nécessairement les plus complexes sur le plan algorithmique. Dans le cadre de cette étude, les méthodes d'ensemble, en particulier la Random Forest, ont montré une grande efficacité pour gérer le bruit des données et améliorer la robustesse des prédictions. Les modèles neuronaux récurrents et multicouches restent néanmoins pertinents pour capturer les dynamiques non linéaires du système, ce qui souligne que la performance dépend avant tout de l'adéquation entre le modèle et la nature des données.

Enfin, ce travail ouvre des perspectives intéressantes, notamment l'extension des horizons de prédiction, l'intégration de données météorologiques issues de services externes (API), ainsi que le déploiement des modèles les plus légers sur des systèmes embarqués (Edge AI) pour une gestion énergétique en temps réel. L'enrichissement futur de la base de données sur des périodes plus longues et dans des conditions climatiques variées permettra également d'améliorer la généralisation des modèles et leur robustesse.

Bibliographie

- [1] Ministère de l'Énergie et des Mines (MEM). Programme algérien de développement des Énergies nouvelles et renouvelables et de l'efficacité Énergétique. *Revue des Énergies Renouvelables (CDER)*, (20) :29–31, Avril 2011.
- [2] Can Wan, Jian Zhao, Yonghua Song, Zhao Xu, Jin Lin, and Zechun Hu. Photovoltaic and solar power forecasting for smart grid energy management. *CSEE Journal of Power and Energy Systems*, 1(4) :38–46, 2015. (accès : 2026-02-20).
- [3] Wen-Chang Tsai, Chia-Sheng Tu, Chih-Ming Hong, and Whei-Min Lin. A Review of State-of-the-Art and Short-Term Forecasting Models for Solar PV Power Generation. *Energies*, 16(14), 2023. (accès : 2026-02-20).
- [4] Saeed Al-Ali, Abdul Ghani Olabi, and Montaser Mahmoud. A review of solar photovoltaic technologies : Developments, challenges, and future perspectives. *Energy Conversion and Management : X*, 27 :101057, 2025. (accès : 2026-02-20).
- [5] Mondher Ouari and Yakoub Zine. *Étude des commandes MPPT d'un système photovoltaïque*. PhD thesis, École Nationale Polytechnique, 2020. (accès : 2026-02-21).
- [6] Abderrahim Hadjiat and Lynda Bemmerzouk. *Optimisation du transfert d'énergie à partir d'un panneau solaire*. PhD thesis, ESSA Tlemcen, 2024. (accès : 2026-02-21).
- [7] Sahour Dounia and Guessab Borhane. Etude et modélisation d'un panneau photovoltaïque. Working paper, Université 8Mai 1945 – Guelma, 2021. (accès : 2026).
- [8] Athil S. Al-Ezzi and Mohamed Nainar M. Ansari. Photovoltaic Solar Cells : A Review. *Applied System Innovation*, 5(4), 2022. (accès : 2026-02-22).
- [9] Meryem Khelil and Walid Sahel. *Estimation de l'irradiation solaire basée sur l'intelligence artificielle*. PhD thesis, ESSA Tlemcen, 2025. (accès : 2026-02-22).
- [10] R. Ahmed, V. Sreeram, Y. Mishra, and M. D. Arif. A review and evaluation of the state-of-the-art in PV solar power forecasting : Techniques and optimization.

- Renewable and Sustainable Energy Reviews*, 124 :109792, 2020. (accès : 2026-02-22).
- [11] Sangram Bana and R.P. Saini. A mathematical modeling framework to evaluate the performance of single diode and double diode based SPV systems. *Energy Reports*, 2 :171–187, 2016. (accès : 2026-02-21).
 - [12] Souheyb Mohammed Belhadj. *ÉTUDE ET RÉALISATION D’UN SYSTÈME DE POMPAGE PHOTOVOLTAÏQUE*. PhD thesis, ESSA Tlemcen, 2019. (accès : 2026-02-22).
 - [13] Kelachukwu J. Iheanetu. Solar Photovoltaic Power Forecasting : A Review. *Sustainability*, 14(24), 2022. (accès : 2026-02-23).
 - [14] Paweł Kut and Katarzyna Pietrucha-Urbanik. Forecasting Short-Term Photovoltaic Energy Production to Optimize Self-Consumption in Home Systems Based on Real-World Meteorological Data and Machine Learning. *Energies*, 18(16), 2025. (accès : 2026-02-23).
 - [15] L. R. Visser, T. A. AlSkaif, A. Khurram, J. Kleissl, and W. G. H. J. M. van Sark. Probabilistic solar power forecasting : An economic and technical evaluation of an optimal market bidding strategy. *Applied Energy*, 370 :123573, 2024. (accès : 2026-02-23).
 - [16] Yosoon Choi, Jangwon Suh, and Sung-Min Kim. GIS-Based Solar Radiation Mapping, Site Evaluation, and Potential Assessment : A Review. *Applied Sciences*, 9(9), 2019. (accès : 2026-02-23).
 - [17] Mahmoud Kiasari, Mahdi Ghaffari, and Hamed H. Aly. A Comprehensive Review of the Current Status of Smart Grid Technologies for Renewable Energies Integration and Future Trends : The Role of Machine Learning and Energy Storage Systems. *Energies*, 17(16), 2024. (accès : 2026-02-23).
 - [18] Abdelhamid Elhaddi and Khaled Kouadri. *Système de Prédiction de puissance à court-terme pour les centrales photovoltaïques*. PhD thesis, Université de Ghardaïa, 2022. (accès : 2026-05-04).
 - [19] Mohamed A. Eltawil and Zhengming Zhao. Grid-connected photovoltaic power systems : Technical and potential problems—a review. *Renewable and Sustainable Energy Reviews*, 14(1) :112–129, 2010.
 - [20] ResearchGate. Figure (I.1) : Schéma simplifié d’un système PV. https://www.researchgate.net/figure/Figure-I1-Schema-simplifie-dun-systeme-PV_fig1_320910708, 2017. Consulté en ligne sur ResearchGate.
 - [21] Qu’est-ce que le MPPT de l’onduleur photovoltaïque et quelle est sa fonction ?
 - [22] DATA BOOST INDUSTRY. FR - Maintenance prédictive - Partie 1 : Le pitch projet.

- [23] Ali Dali. *Synthèse de commande et observateur pour une classe de systèmes dynamiques hybrides : théorie et applications*. PhD thesis, École Nationale Polytechnique, 2021. (accès : 2026-05-10).
- [24] A. Dobos. PVWatts Version 5 Manual. Technical Report NREL/TP-6A20-62641, 1158421, National Renewable Energy Laboratory (NREL), 2014. (accès : 2026-04-03).
- [25] alldatasheet.com. Esp-wroom-32 datasheet, pdf, 2026. (accès : 2026-05-09).
- [26] alldatasheet.com. Ina219 datasheet, pdf, 2026. (accès : 2026-05-09).
- [27] DHT22 Datasheet, PDF - Alldatasheet, 2026. (accès : 2026-05-09).
- [28] LDR Sensor Module Datasheet | PDF, 2026. (accès : 2026-05-09).
- [29] Module adaptateur pour carte micro SD : Brochage, spécifications, fiche technique, fonctionnement, applications, alternatives, 2026. (accès : 2026-05-10).
- [30] Shisheng Lun, Shanshan Du, Guofeng Guo, and Yuhan Wang. A simplified model for photovoltaic modules based on improved translation equations. *Solar Energy*, 101 :140–152, 2014.
- [31] Comparative Study of Feature Selection Techniques for Machine Learning-Based Solar Irradiation Forecasting to Facilitate the Sustainable Development of Photovoltaics : Application to Algerian Climatic Conditions, 2025. (accès : 2026-05-19).
- [32] Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural Computation*, 9(8) :1735–1780, 1997.
- [33] Mehdi Debeche, Abdesselam Babouri, and Leila Boucerredj. Classification des données basée sur les réseaux de neurones récurrents. Mémoire de fin d'études de master, Université de Constantine 1, 2022.
- [34] Leo Breiman. Random forests. *Machine Learning*, 45(1) :5–32, 2001.
- [35] Omar El Farouk Boukhetta. Identification paramétrique d'une machine asynchrone. Mémoire de master, Université de la Polynésie française, 2015.
- [36] Davide Chicco, Matthijs J. Warrens, and Giuseppe Jurman. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7 :e623, 07 2021. (accès : 2026-05-22).