

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 de Master

Filière : Automatique
Spécialité : Automatique

Présenté par :

Yousra Oum El kheir HAMMADI
Nor El Houda BEKADA BENCHAIB

Thème

Développement D'un Prototype De Plateforme D'IA
Pour La Prévision à Court Terme De La Production
Photovoltaïque à Partir De Données Météo

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

Dr. L.Fazil BOUKLI HACENE	MAB
Dr. Anisse CHIALI	MCA
Dr. Imane NEDJAR	MCA
Dr. MOKHTARI Reda	MCA
Dr. Fayza MERAD	MRA

ESSA. Tlemcen	Président
ESSA. Tlemcen	Directeur de mémoire
ESSA. Tlemcen	Co- Directeur de mémoire
ESSA. Tlemcen	Examineur 1
CDS. Oran	Examineur 2

Année universitaire : 2025 /2026

DÉDICACE

Tout d'abord, Alhamdulillah.

Louange à Allah qui a choisi pour moi ce qui était meilleur que tout ce que j'aurais pu choisir pour moi-même, et qui, dans Sa sagesse infinie, a tracé mon chemin.

Alhamdulillah pour chaque épreuve et chaque bénédiction, pour chaque réussite et chaque échec, et pour chaque moment où j'ai cru que l'impossible se dressait devant moi avant qu'Allah n'ouvre une issue par Sa grâce. Alhamdulillah pour la force, la santé et la patience qui m'ont permis d'atteindre cette étape et de finaliser ce diplôme.

À mon papa,

Merci d'être le père le plus incroyable que j'aurais pu rêver avoir. Tu as toujours été mon modèle, mon inspiration, non seulement par ta responsabilité et ta bienveillance, mais aussi par ta volonté constante d'avancer et... ton fashion-style irréprochable.

Aujourd'hui, Papa, j'espère que ce diplôme viendra s'ajouter à ta collection de mes réussites et souvenirs, comme une nouvelle fierté à garder précieusement.

À ma maman,

Ce parcours n'a jamais été le mien seul, il a toujours été le nôtre. Tu m'as accompagnée dès le début, en croyant en moi bien avant que je comprenne moi-même ce dont j'étais capable. Chaque pas que j'ai fait, tu l'as fait avec moi.

Merci pour tes conseils, ta patience, tes discussions, et même pour avoir écouté toutes mes plaintes. Tu m'as toujours dit que le travail pouvait tout ouvrir. Et aujourd'hui, me voilà, la preuve vivante de tes paroles.

Tu n'es pas seulement ma mère, tu es ma meilleure amie, ma sœur de cœur et mon refuge.

À mes frères et sœurs, y compris Adam,

À **Abderrazak**, mon protecteur et mon bras droit (et chauffeur officiel non déclaré), merci d'avoir toujours été là pour moi.

À **Radjaa**, merci pour ta présence, ta patience face à mes drames quotidiens, et pour ta garde-robe que j'ai parfois empruntée et transformée en moments de style.

Et à Adam, même si tu es plus grand que moi maintenant, tu resteras toujours mon petit Adam. Sache-le : tu as été bien élevé... par moi.

À mes amis,

À mes "**3S**" **Selma** et **Souhila**, ce duo inattendu devenu une véritable famille de cœur. Même si la vie nous a éloignés, rien n'a jamais effacé ce que nous avons partagé.

À **Nor** qui n'a jamais été seulement ma binôme de mémoire, mais une véritable *nour* (lumière) dans ce parcours. Tu as apporté de la clarté, du soutien et beaucoup de souvenirs dans cette aventure. Je suis profondément reconnaissante de t'avoir dans ma vie. J'espère sincèrement être, à tes yeux, comme une sœur, aujourd'hui et pour encore de nombreuses années, incha'Allah.

À mes amies d'enfance, **Nebia** et **Hadil**, vous êtes la preuve que la vraie amitié ne dépend ni du temps ni de la distance.

À mes binômes **Aya** et **Maryliz**, merci d'avoir rendu les TP beaucoup plus légers. Nous avons probablement plus ri que travaillé, et je n'échangerais cela pour rien au monde.

À **Farah et Imene et Alaa ,Assala**, qui ont toujours été présentes pour m'aider et m'accompagner tout au long de cette aventure.

À tous les amis rencontrés durant ces cinq années : merci d'avoir fait partie de mon histoire. Je me souviendrai toujours de vous avec gratitude.

À ma famille,

Merci pour votre amour, votre soutien et vos appels constants qui ont compté bien plus que vous ne pouvez l'imaginer.

Je dédie également ce travail à mon cher oncle, **Monsieur Saleh Berrezoug**. J'espère qu'il serait fier de moi et qu'Allah lui fasse miséricorde et lui accorde le plus haut rang

au Paradis.

À mes grands-parents, mes tantes en particulier Khalida et mes cousines Amina et Marwa, merci pour vos prières, votre soutien et votre présence constante.

Et enfin, à moi-même,

Merci de ne pas avoir abandonné, même lorsque c'était difficile. La petite Yousra serait fière de voir le chemin parcouru.

Merci d'être sortie de ta zone de confort, d'avoir affronté la distance, le stress, les nuits blanches, les sacrifices et les moments de doute.

Ce parcours m'a demandé beaucoup... et j'ai tout donné. Et d'une manière ou d'une autre, j'y suis arrivée.

Aujourd'hui, je regarde en arrière avec un cœur rempli de gratitude, consciente que chaque expérience m'a façonnée et transformée de la fille que j'étais autrefois à la femme que je suis devenue aujourd'hui. Chaque difficulté portait une leçon, chaque retard une sagesse, et chaque prière apparemment sans réponse m'a menée vers quelque chose de meilleur.

HAMMADI Oum El-Kheir Yousra

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 Reda** 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.

الملخص

يهدف هذا العمل إلى تطوير نموذج أولي لنصة قائمة على الذكاء الاصطناعي، مخصصة للتنبؤ قصير المدى بإنتاج الطاقة الكهروضوئية انطلاقاً من البيانات المناخية. يشمل المشروع جمع البيانات ومعالجتها المسبقة، وتصميم نماذج التنبؤ وتدريبها، فضلاً عن تقييمها باستخدام مؤشرات أداء ملائمة. يسعى النموذج الأولي إلى توفير أداة بسيطة لدعم اتخاذ القرار لدى مشغلي محطات الطاقة الشمسية، وإثبات إمكانية تطوير حل مستقبلي موجه نحو التنبؤ بالطاقة وتحسين استهلاكها.

الكلمات المفتاحية: التنبؤ بالطاقة؛ الأنظمة الكهروضوئية؛ الذكاء الاصطناعي؛ البيانات المناخية؛ نموذج أولي للنصة.

Abstract

This work consists of developing an artificial intelligence-based platform prototype for the short-term forecasting of photovoltaic system power output from meteorological data. The project includes the collection and preprocessing of production data and weather variables, the design and training of prediction models, as well as their evaluation using appropriate performance indicators. The prototype aims to provide a simple decision-support tool for solar power plant operators, and to demonstrate the potential of a solution oriented towards energy forecasting and optimization.

Keywords: Energy forecasting; Photovoltaic systems; Artificial intelligence; Meteorological data; Platform prototype.

Résumé

Ce travail consiste à développer un prototype de plateforme basée sur l'intelligence artificielle pour la prévision à court terme de la production d'un système photovoltaïque à partir de données météorologiques. Le projet inclut la collecte et le prétraitement des données de production et des variables météo, la conception et l'entraînement de modèles de prédiction, ainsi que leur évaluation à l'aide d'indicateurs de performance appropriés. Le prototype vise à fournir un outil simple d'aide à la décision pour les exploitants de centrales solaires, et à démontrer le potentiel d'une future solution orientée «prévision et optimisation énergétique».

Mots clés : Prévision énergétique ; Systèmes photovoltaïques ; Intelligence artificielle ; Données météorologiques ; Prototype de plateforme.

TABLE DES MATIÈRES

Liste des abréviations	15
Nomenclature	17
Introduction	19
Contexte de la prévision photovoltaïque et bases de l'intelligence artificielle	21
1.1 Contexte énergétique et enjeux de la prévision PV	21
1.1.1 Transition énergétique et rôle du PV	21
1.1.2 Enjeux techniques associés à la variabilité de la production solaire . . .	22
1.1.3 Importance de la prévision à court terme	22
1.1.4 Problématique et objectifs	22
1.2 Systèmes photovoltaïques et facteurs influents	23
1.2.1 Principe de conversion photovoltaïque.	23
1.2.2 Facteurs influençant la production PV	25
1.2.3 Discrétisation et implémentation numérique	26
1.3 Rôle de la prévision dans les systèmes énergétiques intelligents	28
1.3.1 Horizons de prévision	28
1.3.2 Introduction aux smart grids	29
1.3.3 Intégration de la prévision PV dans la gestion énergétique	29
1.3.4 Applications concrètes	30

1.4	Bases de l'IA pour la prévision	30
1.4.1	Réseaux de neurones	30
1.4.2	Apprentissage des réseaux de neurones	33
1.4.3	Les Forêts Aléatoires (Random Forests)	34
1.5	Conclusion	36
Développement du modèle de prédiction basé sur l'IA		37
2.1	Acquisition et préparation des données	37
2.1.1	Sources des données météorologiques	37
2.1.2	Variables utilisées	39
2.1.3	Prétraitement	39
2.2	Conception des modèles de prédiction	40
2.2.1	Modèles classiques	40
2.2.2	Modèles d'intelligence artificielle	43
2.2.3	Choix des entrées/sorties et architecture	43
2.3	Entraînement et optimisation	44
2.3.1	Fonctions de coût	44
2.3.2	Algorithmes d'optimisation	44
2.3.3	Techniques de régularisation	46
2.4	Évaluation et comparaison des modèles	47
2.4.1	Métriques	47
2.4.2	Analyse des performances	48
2.4.3	Comparaison IA vs modèles classiques	50
2.4.4	Analyse de la dynamique temporelle des prédictions	50
2.4.5	Discussion sur la robustesse et la généralisation	53
2.5	Conclusion	53
Développement de l'application et intégration		55
3.1	Conception de l'application	55
3.1.1	Description de l'architecture de l'application	56

3.1.2	Architecture de déploiement sur le Cloud	58
3.1.3	Interface utilisateur	59
3.1.4	Intégration du modèle IA dans l'application	63
3.2	Utilisation pour la gestion énergétique	64
3.2.1	Exploitation des prédictions à court terme	64
3.2.2	Cas d'usage	64
3.3	Analyse des résultats	65
3.3.1	Visualisation des prédictions vs valeurs réelles	65
3.3.2	Étude des erreurs de prédiction	65
3.3.3	Avantages et limites de l'approche proposée	67
3.4	Perspectives et améliorations	68
3.4.1	Extension vers les smart grids	68
3.4.2	Enrichissement de la base de données	68
3.4.3	Intégration de capteurs plus précis	68
3.5	Conclusion	68
 Conclusion		 71
 Annexes		 72
 Bibliographie		 72

TABLE DES FIGURES

1.1	Semi-conducteur de type N	24
1.2	Semi-conducteur de type P	24
1.3	Principe de fonctionnement d'une cellule photovoltaïque	25
1.4	Chaîne fonctionnelle du processus de prédiction photovoltaïque.	27
1.5	Les différents horizons de prévision [1].	29
1.6	Représentation d'un neurone artificiel [2].	31
1.7	Perceptron Multicouche [3].	32
1.8	Architecture LSTM.	33
1.9	Architecture générale d'un modèle de Forêt Aléatoire en régression (agrégation par moyenne)	35
2.1	Régression linéaire simple [4].	41
2.2	Régression linéaire multiple [4].	41
2.3	Évaluation graphique des performances des cinq modèles de prédiction pour chaque métrique	49
2.4	Suivi temporel – Réseau de neurones Perceptron Multicouche (PMC) . . .	51
2.5	Suivi temporel – Réseau récurrent Long Short-Term Memory (LSTM) . . .	51
2.6	Suivi temporel – Réseau récurrent Gated Recurrent Unit (GRU)	51
2.7	Suivi temporel – Modèle linéaire AutoRégressif avec Variables Exogènes (ARX)	52
2.8	Suivi temporel – Modèle d'ensemble Forêts Aléatoires (RF)	52
3.1	Diagramme de cas d'utilisation de la plateforme de prédiction PV.	56
3.2	Diagramme de séquence des interactions entre l'utilisateur et la plateforme. .	58

3.3	Description du projet et présentation de l'équipe.	60
3.4	Page Importation des Données (chargement d'un fichier Excel de 14 657 lignes et 8 colonnes).	61
3.5	Page Prédiction Future Interactive (résultat du modèle PMC).	62
3.6	Page Prédiction Future Interactive (résultat du modèle Forêts Aléatoires).	63
3.7	Courbe Valeurs Réelles vs Prédiction (Modèle PMC).	66
3.8	Courbe Valeurs Réelles vs Prédiction (Modèle Forêts Aléatoires).	66

LISTE DES TABLEAUX

2.1	Variables mesurées par le prototype ESP32	39
2.2	Division chronologique de la base de donnée	40
2.3	Synthèse comparative des performances des modèles sur l'ensemble de test (données normalisées)	48
3.1	Synthèse comparative des performances des modèles sur l'ensemble de test (données normalisées)	61

ABRÉVIATIONS

ARX	Modèle Auto-Régressif à Entrée eXogène.
BESS	<i>Battery Energy Storage System</i> — Système de Stockage d'Énergie par Batterie.
CSV	<i>Comma-Separated Values</i> — Valeurs Séparées par des Virgules.
DC	<i>Direct Current</i> — Courant Continu.
DHT22	Capteur numérique de température et d'humidité (modèle AM2302).
EMS	<i>Energy Management System</i> — Système de Gestion de l'Énergie.
ESP32	Microcontrôleur bi-cœur Xtensa LX6 (Espressif Systems).
GRU	<i>Gated Recurrent Unit</i> — Unité de Récurrence à Portes.
IA	Intelligence Artificielle.
INA219	Capteur de courant/tension à interface I ² C (Texas Instruments).
LDR	<i>Light Dependent Resistor</i> — Résistance Dépendant de la Lumière.
LSTM	<i>Long Short-Term Memory</i> — Réseau à Mémoire à Court et Long Terme.
MAE	<i>Mean Absolute Error</i> — Erreur Absolue Moyenne.
MAPE	<i>Mean Absolute Percentage Error</i> — Erreur Absolue Moyenne en Pourcentage.
MCO	Moindres Carrés Ordinaires.
MLP	<i>Multi-Layer Perceptron</i> — Perceptron Multicouche (voir PMC).

MPPT	<i>Maximum Power Point Tracking</i> — Poursuite du Point de Puissance Maximale.
MSE	<i>Mean Squared Error</i> — Erreur Quadratique Moyenne.
PMC	Perceptron Multicouche.
PNEREE	Programme National des Énergies Renouvelables et de l'Efficacité Énergétique.
PV	Photovoltaïque.
RF	<i>Random Forest</i> — Forêt Aléatoire.
ReLU	<i>Rectified Linear Unit</i> — Unité Linéaire Rectifiée.
RMSE	<i>Root Mean Squared Error</i> — Racine de l'Erreur Quadratique Moyenne.
RNA	Réseau de Neurones Artificiels.
SER	Sources d'Énergie Renouvelables.
STC	<i>Standard Test Conditions</i> — Conditions de Test Standards ($G = 1000 \text{ W/m}^2$, $T = 25^\circ\text{C}$).

NOMENCLATURE

$A(q)$	Polynôme auto-régressif en l'opérateur de retard q^{-1} (modèle ARX).
a_i	Coefficients de la partie auto-régressive du modèle ARX.
$B(q)$	Polynôme de la partie exogène en q^{-1} (modèle ARX).
b_j	Coefficients de la partie exogène du modèle ARX.
$e(t)$	Terme de bruit blanc — erreur résiduelle du modèle ARX.
$f(\cdot)$	Fonction d'activation du neurone artificiel.
G	Irradiance solaire (W/m^2).
HR	Humidité relative (%).
I	Courant débité par le panneau photovoltaïque (A).
I_{mpp}	Courant au point de puissance maximale (A).
k	Indice d'échantillonnage discret ($k \in \mathbb{N}$).
L	Luminosité relative mesurée par le capteur LDR (lux).
$m(t)$	Moyenne mobile des gradients — 1 ^{er} moment (Adam).
n_a	Ordre auto-régressif du modèle ARX.
n_b	Ordre de la partie exogène du modèle ARX.
P	Puissance électrique délivrée (W).
P_{PV}	Puissance produite par le panneau photovoltaïque (mW).
$\hat{P}_{PV}$	Puissance photovoltaïque prédite par le modèle (mW).

$\bar{P}_{PV}$	Moyenne des valeurs réelles de puissance PV (mW).
q^{-1}	Opérateur de retard unitaire ($q^{-1}y(t) = y(t - 1)$).
T	Température ambiante (°C).
T_s	Période d'échantillonnage (<i>min</i>).
t	Variable temporelle continue.
$u(t)$	Vecteur d'entrée du système — variables météorologiques.
U	Rapport cyclique du convertisseur DC/DC (commande MPPT).
$v(t)$	Variance mobile des gradients — 2 ^e moment (Adam).
V	Tension aux bornes du panneau photovoltaïque (V).
V_{mpp}	Tension au point de puissance maximale (V).
w_0	Biais interne du neurone artificiel.
w_i	Poids synaptique associé à l'entrée x_i .
x_i	$i^{\text{ème}}$ entrée du neurone ou variable d'entrée.
X_{min}, X_{max}	Valeurs minimale et maximale de X sur l'ensemble d'entraînement.
X_{norm}	Valeur normalisée de la variable X ($X_{norm} \in [0, 1]$).
$y(t)$	Sortie du système — puissance PV produite (mW).
$\hat{y}(t)$	Valeur prédite par le modèle ARX (mW).
α	Taux d'apprentissage (<i>learning rate</i>).
β_0	Constante du modèle de régression (biais).
$\beta_1, \beta_2, \dots, \beta_n$	Coefficients de pondération de la régression linéaire multiple.
β_1	Hyperparamètre de décroissance du 1 ^{er} moment (Adam, $\beta_1 = 0,9$).
β_2	Hyperparamètre de décroissance du 2 ^e moment (Adam, $\beta_2 = 0,999$).
Δt	Pas d'échantillonnage temporel (1 minute dans ce travail).
ε	Constante de stabilité numérique (Adam, $\varepsilon = 10^{-8}$) ; terme d'erreur résiduelle (régression).
θ	Paramètres du modèle (poids et biais).
$\nabla L(\theta)$	Gradient de la fonction de coût.

INTRODUCTION GÉNÉRALE

Au cœur de la transition énergétique mondiale, l'intégration des sources d'énergie renouvelables dans les réseaux électriques s'impose comme l'un des défis technologiques majeurs de notre époque. Parmi ces sources, l'énergie solaire photovoltaïque occupe une place centrale, grâce à son caractère inépuisable, sa disponibilité à l'échelle planétaire et la baisse continue des coûts de production qui a permis à la capacité installée mondiale de franchir le seuil du térawatt en 2022[5].

L'Algérie, forte d'un ensoleillement exceptionnel dépassant 3 000 heures par an et de niveaux d'irradiation parmi les plus élevés au monde, dispose d'un potentiel solaire considérable. Dans ce cadre, le Programme National des Énergies Renouvelables et de l'Efficacité Énergétique (PNEREE) vise à atteindre une capacité de production de 22 000 mégawatts d'origine renouvelable à l'horizon 2030, témoignant de la volonté nationale d'exploiter pleinement cette ressource naturelle abondante [6].

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 relative. Ces fluctuations engendrent des défis majeurs pour la gestion des réseaux électriques [7, 8], notamment en ce qui concerne l'équilibre entre la production et la consommation, la stabilité de la tension et la planification des réserves de puissance. Face à cette variabilité, les approches réactives classiques de gestion du réseau se révèlent insuffisantes, justifiant le développement d'outils de prévision précis et robustes capables d'anticiper la production photovoltaïque à court terme [9, 10].

C'est précisément dans ce contexte que s'inscrit le présent travail, qui propose une approche complète et intégrée : de la collecte de données météorologiques réelles, assurée par un prototype de mesure embarqué développé au sein de l'école, jusqu'au déploiement d'une plateforme d'intelligence artificielle accessible en ligne, en passant par le développement et la comparaison de plusieurs modèles de prédiction, allant des

approches linéaires classiques aux architectures de réseaux de neurones profonds et aux modèles d'ensemble. L'objectif de ce mémoire est donc de développer, évaluer et déployer une plateforme d'intelligence artificielle pour la prévision à court terme de la production photovoltaïque à partir de données météorologiques, en proposant un outil opérationnel et accessible permettant d'améliorer la gestion énergétique locale.

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

Le Chapitre 1 est consacré au contexte de la prévision photovoltaïque et aux bases de l'intelligence artificielle. Nous y aborderons les enjeux de la transition énergétique, le fonctionnement physique d'une cellule photovoltaïque, les horizons de prévision et leur rôle dans les systèmes énergétiques intelligents, ainsi que les architectures d'IA retenues pour ce travail, notamment les réseaux PMC, LSTM, GRU et les Forêts Aléatoires.

Le Chapitre 2 présente le développement des modèles de prédiction basés sur l'IA. Nous y détaillerons le prototype de mesure ESP32, les deux phases d'acquisition des données, les étapes de prétraitement et de normalisation, la conception et l'entraînement des cinq modèles développés, ainsi que leur évaluation comparative selon des métriques statistiques complémentaires.

Le Chapitre 3 est consacré au développement de la plateforme applicative et à son intégration. Nous y présenterons l'architecture de l'application Streamlit, son déploiement sur le cloud, les cas d'usage envisagés pour la gestion énergétique locale, l'analyse des résultats obtenus et les perspectives d'amélioration et d'extension vers des architectures de smart grid.

CONTEXTE DE LA PRÉVISION PHOTOVOLTAÏQUE ET BASES DE L'IA

Dans le contexte actuel de transition énergétique, l'énergie photovoltaïque occupe une place importante dans la production d'électricité. Toutefois, sa production reste fortement dépendante des conditions climatiques, ce qui rend son comportement variable et parfois difficile à anticiper.

Ce premier chapitre a pour objectif d'établir les fondements théoriques de notre étude. On commencera par situer l'énergie solaire dans son contexte actuel pour en comprendre les enjeux de sa variabilité. Ensuite, on détaillera le fonctionnement physique d'une cellule (jonction PN). Enfin, on présentera les outils d'intelligence artificielle, comme les réseaux PMC, LSTM, GRU et les Forêts Aléatoires, qui vont nous servir à construire nos modèles de prédiction dans la suite de ce travail.

1.1 Contexte énergétique et enjeux de la prévision PV

1.1.1 Transition énergétique et rôle du PV

Le secteur de l'énergie joue un rôle critique dans le changement climatique, étant responsable d'environ 40% des émissions mondiales de CO₂. Pour répondre à l'urgence de la transition énergétique, l'énergie photovoltaïque (PV) s'est imposée comme une solution majeure grâce à sa capacité à produire une électricité propre et décentralisée. Cette technologie a connu une expansion fulgurante, sa capacité installée mondiale bondissant de 5,1 GW en 2005 à 1000 GW en 2022. Cette croissance s'explique par la réduction des pertes liées au transport (production à proximité du lieu de consommation) et par une compétitivité économique accrue due à la baisse continue du prix des modules [5].

1.1.2 Enjeux techniques associés à la variabilité de la production solaire

La production d'un système PV est, par nature, intermittente et dépendante des conditions environnementales. Contrairement aux sources d'énergie conventionnelles comme le gaz ou le charbon qui sont pilotables, la puissance produite par un champ solaire fluctue selon des paramètres météorologiques imprévisibles, tels que le passage de nuages ou les variations de température. Cette dépendance rend la production instable, ce qui crée des défis majeurs pour la gestion du réseau [7] [5]:

Impact sur le réseau électrique : L'injection massive d'une source instable complique le contrôle de la tension et l'équilibrage de la charge. Cela peut compromettre la stabilité et la fiabilité du système électrique mondiale.

Gestion du stockage : Le stockage (batterie) devient essentiel pour lisser les pics de production et restituer l'énergie pendant les périodes de faible ensoleillement ou de forte demande (pic de consommation).

Autoconsommation et économie : Pour le prosommateur la variabilité rend difficile l'alignement direct entre production et consommation locale, nécessitant des systèmes de gestion intelligents.

1.1.3 Importance de la prévision à court terme

Ces différents enjeux mettent en évidence la nécessité de développer des outils de prévision précis et robustes, capables d'anticiper la production PV et de réduire les incertitudes associées [7] [5].

Planification de la production : Permettre aux centrales fossiles d'être réduites ou éteintes lorsque le rendement PV est garanti, optimisant ainsi les coûts et réduisant les émissions.

Sécurité du réseau : Anticiper les fluctuations pour éviter les pannes et gérer les réserves de puissance en temps réel.

Optimisation des actifs : Réduire les pénalités financières liées au déséquilibre sur le marché de l'électricité et maximiser le retour sur investissement des installations PV.

1.1.4 Problématique et objectifs

Le défi majeur de ce projet vient du fait que l'énergie solaire est imprévisible. Contrairement aux centrales électriques classiques, on ne peut pas contrôler la production

des panneaux photovoltaïques car ils dépendent entièrement de la météo. Cette instabilité rend difficile l'intégration du solaire dans le réseau électrique sans risquer de perturber l'équilibre entre la consommation et la production. L'objectif de ce travail est donc de proposer une solution concrète : développer une plateforme d'intelligence artificielle capable de prédire avec précision la production photovoltaïque à court terme. En utilisant des données météo, cet outil permettra d'anticiper les variations de puissance pour mieux gérer le stockage de l'énergie et aider les gestionnaires de réseau à prendre les meilleures décisions en temps réel.

1.2 Systèmes photovoltaïques et facteurs influents

1.2.1 Principe de conversion photovoltaïque.

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.

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 [11].

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




Figure 1.1: Semi-conducteur de type N

[11]

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 1.2: Semi-conducteur de type P

[11]

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.

Etapes de la conversion énergétique

Le processus de génération de courants se déroule en plusieurs étapes physiques clés [2] [12] :

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.

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.

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.

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 1.3: Principe de fonctionnement d'une cellule photovoltaïque [12]

1.2.2 Facteurs influençant la production PV

La production PV varie selon plusieurs facteurs climatiques techniques. Ces éléments influencent directement la quantité d'énergie produite par les panneaux solaires. Il est

donc important de les connaître à fin de mieux comprendre et améliorer les performances d'un système PV [7] [5]:

L'irradiance solaire : C'est le facteur prédominant. La puissance de sortie fluctue de manière non linéaire selon l'intensité du rayonnement reçu.

La température : Une augmentation de la température des modules réduit la tension en circuit ouvert (Voc), entraînant une baisse de la puissance maximale. À l'inverse, des températures basses améliorent le rendement.

L'ombrage et la propreté : Les obstacles (arbres, cheminées, nuages) ou l'accumulation de poussière créent des ombrages partiels. Ces derniers peuvent provoquer des pertes d'énergie annuelles estimées entre 3 % et 6 %.

Orientation et inclinaison : L'angle des panneaux et l'orientation par rapport au sud déterminent la quantité maximale d'énergie captée sur une période donnée.

Facteurs secondaires : Le vent (qui refroidit les modules) et l'humidité influencent également le rendement global.

1.2.3 Discrétisation et implémentation numérique

Passage du modèle continu au modèle discret

Le modèle photovoltaïque étudié est initialement défini en temps continu, où les variables telles que l'irradiation, la température et la puissance dépendent du temps t .

On peut définir le vecteur d'entrée du système par :

$$u(t) = [G(t), T(t)]$$

La sortie du système correspond à la puissance électrique produite :

$$y(t) = P(t)$$

La relation entre les entrées et la sortie est exprimée sous la forme suivante :

$$P(t) = f(G(t), T(t)) \tag{1.1}$$

Cependant, les méthodes de prévision utilisées nécessitent des données sous forme discrète. Pour cela, un processus d'échantillonnage est appliqué, consistant à remplacer

le temps continu t par une variable discrète définie par :

$$t = k \cdot T_s$$

où $k \in \mathbb{N}$ représente l'indice d'échantillonnage et T_s la période d'échantillonnage. Le modèle peut ainsi être exprimé sous la forme :

$$P[k] = f(G[k], T[k]) \quad (1.2)$$




Figure 1.4: Chaîne fonctionnelle du processus de prédiction photovoltaïque.

Ce schéma simple montre que si l'on connaît les conditions climatiques à l'entrée, on peut prédire avec précision l'énergie disponible à la sortie du système.

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 [9] :

- **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 [13].

1.3 Rôle de la prévision dans les systèmes énergétiques intelligents

1.3.1 Horizons de prévision

La prévision de la charge électrique se divise généralement en plusieurs horizons temporels pour répondre aux différents besoins opérationnels et stratégiques des industries énergétiques. On distingue principalement [1]:

Prévision à court terme : Cet horizon s'étend sur une période pouvant aller jusqu'à une semaine. Son objectif principal est d'optimiser le réseau au quotidien, notamment en minimisant l'exécution journalière et les frais d'envoi.

Prévision à moyen terme : Elle est utilisée pour prédire les pics de consommation sur une base hebdomadaire, mensuelle ou annuelle. L'horizon temporel considéré varie d'une année jusqu'à 10 ans en fonction des besoins. Son but est de permettre une planification opérationnelle efficace.

Prévision à long terme (ou longue échéance) : Cette catégorie consiste à estimer la charge électrique jusqu'à 50 ans à l'avance. Elle est indispensable pour faciliter la prise de décisions lourdes, comme la planification et l'expansion physique du réseau énergétique et de ses infrastructures.

Prévision à moyen-long terme : Apparue plus récemment, cette quatrième catégorie s'intercale naturellement entre le moyen et le long terme, et utilise le mois et l'année comme unités de temps principales. Elle est particulièrement cruciale pour la gestion et la planification du réseau dans les pays en développement, où la demande en énergie suit un taux de croissance très dynamique




Figure 1.5: Les différents horizons de prévision [1].

1.3.2 Introduction aux 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'énergie 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 [8].

1.3.3 Intégration de la prévision PV dans la gestion énergétique

Le rôle principal de la prédiction réside dans l'optimisation des systèmes de gestion de l'énergie (EMS). 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 [8].

1.3.4 Applications concrètes

Développer un prototype de plateforme d'IA pour la prévision PV réside dans sa capacité à transformer une donnée météo en une action bénéfique pour le réseau. Les applications se concentrent principalement sur trois piliers [10] [8]:

Gestion du stockage (BESS) : La prévision permet de planifier les cycles de charge et de décharge des batteries. Cela permet d'avoir toujours une réserve d'urgence en cas de baisse soudaine de la production solaire.

Optimisation de l'autoconsommation : Dans les micro-réseaux, l'IA synchronise la demande avec la production locale. Elle permet de déclencher automatiquement des charges flexibles (véhicules électriques, pompes à chaleur) au moment où le gisement solaire est maximal, réduisant ainsi la dépendance au réseau principal.

Stabilité et flexibilité du réseau : En réduisant le "fossé d'information" entre la production réelle et attendue, la prévision aide à maintenir l'équilibre offre-demande. Elle permet d'activer des réserves de flexibilité à l'avance, évitant les instabilités de tension et les pénalités financières sur les marchés de l'électricité.

1.4 Bases de l'IA pour la prévision

1.4.1 Réseaux de neurones

Neurone artificiel :

Une unité de traitement de l'information dotée d' n entrées $(x_1, x_2, \dots, x_n)$ et d'une seule sortie (y) . Son rôle est de produire un signal de sortie en appliquant une fonction d'activation (ou fonction de seuillage) sur une somme pondérée des entrées[2].

Conformément à l'architecture classique, la sortie du neurone peut être exprimée sous la forme mathématique suivante :

$$y(x) = f \left(w_0 + \sum_{i=1}^M w_i x_i \right) \quad (1.3)$$

Où :

- f est la fonction d'activation : Elle introduit une non-linéarité indispensable pour modéliser des systèmes complexes comme les générateurs photovoltaïques.
- $x = \{x_1, x_2, \dots, x_M\}$ est le vecteur des entrées : Dans notre projet, cela correspond aux variables météorologiques (irradiation et température).

- $w = \{w_1, w_2, \dots, w_M\}$ représente le vecteur des poids synaptiques : ils traduisent l'importance de chaque entrée. Le réglage de ces poids lors de la phase d'apprentissage permet l'identification précise du système.
- w_0 est le biais : Il représente le seuil interne du neurone et permet d'ajuster le déclenchement de la fonction d'activation.




Figure 1.6: Représentation d'un neurone artificiel [2].

Il est généralement structuré de trois types de couches interconnectées [14]:

Couche d'entrée : C'est l'interface qui reçoit les données externes du système. Dans le cadre d'un projet de prévision photovoltaïque, elle reçoit typiquement des variables comme la température (T) et l'irradiation (G).

Couches cachées : Situées entre l'entrée et la sortie, ces couches constituent le cœur du réseau. Elles utilisent des fonctions d'activation non linéaires (comme la sigmoïde tangentielle) afin de modéliser des relations complexes que des modèles simples ne pourraient pas représenter.

Couche de sortie : Elle fournit le résultat final du traitement. Pour une commande MPPT, elle peut délivrer des grandeurs telles que la tension optimale (V_{mpp}), le courant optimal (I_{mpp}) ou directement le rapport cyclique (U) nécessaire au convertisseur.

Dans le cadre de la modélisation et de la prévision de la production photovoltaïque, deux architectures majeures se distinguent : le Perceptron Multicouche (PMC) et les réseaux à mémoire à court et long terme (LSTM).

Perceptron Multicouche (PMC)

Cette architecture constitue la forme la plus classique des réseaux de neurones de type "feedforward". Dans cette configuration, l'information circule de manière strictement

unidirectionnelle, de la couche d'entrée vers la couche de sortie. Grâce à l'utilisation de fonctions d'activation non linéaires au sein des couches cachées, le PMC est capable de modéliser des relations complexes et non linéaires. Cette architecture est largement utilisée dans les problèmes d'identification et de prévision [3][2].




Figure 1.7: Perceptron Multicouche [3].

Architecture LSTM (Long Short-Term Memory)

Contrairement au PMC, le LSTM a été conçu pour résoudre le problème de la disparition du gradient (vanishing gradient), un obstacle majeur lors de l'entraînement des réseaux récurrents classiques. Sa particularité réside dans sa capacité à maintenir une « mémoire » stable sur de longues périodes grâce à une structure interne sophistiquée qui s'appuie sur trois "portes" analogiques [3]:

Porte d'oubli (Forget gate) : Elle joue un rôle de filtre initial en analysant l'entrée actuelle et l'état précédent pour décider quelles informations passées ne sont plus pertinentes et peuvent être supprimées.

Porte d'entrée (Input gate) : Elle prend ensuite le relais pour identifier, parmi les nouvelles données entrantes, celles qui sont suffisamment significatives pour être intégrées et mises à jour dans la mémoire de la cellule.

Porte de sortie (Output gate) : Enfin, en combinant l'état de la mémoire actualisée et l'entrée présente, cette porte détermine l'information qui sera transmise comme sortie finale du réseau à l'instant t .




Figure 1.8: Architecture LSTM.

Architecture GRU

Le GRU est une variante simplifiée du LSTM, elle permet de mémoriser des dépendances à long terme tout en évitant le problème de disparition du gradient[3]. Sa structure repose sur deux portes principales :

- **Porte de mise à jour** (*Update gate*) : elle contrôle la proportion d'information passée à conserver et la proportion de nouvelle information à intégrer dans l'état caché.
- **Porte de réinitialisation** (*Reset gate*) : elle détermine dans quelle mesure l'état précédent doit être oublié lors du calcul du nouvel état candidat.

Par rapport au LSTM, le GRU fusionne les états de cellule et caché en un seul vecteur, ce qui réduit le nombre de paramètres entraînaables. Cette compacité le rend particulièrement adapté aux jeux de données de taille limitée, comme celui collecté dans ce projet.

1.4.2 Apprentissage des réseaux de neurones

Il s'agit du processus par lequel un réseau ajuste ses poids synaptiques de manière itérative afin d'optimiser ses performances sur une tâche spécifique. Durant cette phase, le réseau est testé et ses paramètres sont modifiés jusqu'à ce qu'il fournisse une réponse satisfaisante. On peut distinguer trois types principaux d'apprentissage (supervisé, non supervisé et par renforcement), ce travail se concentre exclusivement sur l'apprentissage supervisé[15] [2] :

Apprentissage supervisé

Cette méthode est caractérisée par la présence d'un "professeur" qui possède une connaissance approfondie de l'environnement. Le réseau reçoit des entrées associées à des sorties désirées (données étiquetées). Il calcule l'écart entre sa propre prédiction et la sortie réelle pour ajuster ses poids afin de minimiser cette erreur. C'est la méthode la plus utilisée pour l'identification du point de puissance maximale (MPPT) dans les systèmes photovoltaïques.

1.4.3 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 [16].

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 1.9: 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 surapprentissage.

1.5 Conclusion

Ce premier chapitre nous a permis d'établir les fondements théoriques nécessaires à la compréhension du problème traité dans ce mémoire.

Nous avons d'abord situé l'énergie photovoltaïque dans son contexte énergétique actuel, en mettant en évidence les défis liés à la variabilité de sa production et l'importance de la prévision pour une meilleure intégration au réseau électrique.

Nous avons ensuite décrit le fonctionnement physique d'une cellule photovoltaïque, depuis la jonction PN jusqu'à la génération du courant électrique.

Enfin, les bases de l'intelligence artificielle ont été introduites, notamment les architectures PMC, LSTM, GRU et les Forêts Aléatoires, qui seront utilisées dans les chapitres suivants pour développer et évaluer les modèles de prévision.

DÉVELOPPEMENT DU MODÈLE DE PRÉDICTION BASÉ SUR L'IA

Dans la continuité des fondements théoriques présentés dans le chapitre précédent, ce chapitre est consacré au développement et à l'évaluation des modèles de prédiction de la puissance photovoltaïque à partir des données météorologiques collectées par le prototype ESP32.

L'objectif principal est de construire et comparer plusieurs modèles capables de reproduire la dynamique de la production PV, en allant des approches classiques linéaires aux réseaux de neurones récurrents et aux modèles d'ensemble. Cette diversité permet d'analyser à la fois des approches linéaires, non linéaires et interprétables.

L'évaluation repose sur des métriques statistiques complémentaires permettant d'apprécier la précision, la robustesse et la capacité de généralisation de chaque modèle, afin d'identifier le meilleur compromis entre précision et complexité dans le contexte de ce projet.

2.1 Acquisition et préparation des données

2.1.1 Sources des données météorologiques

Les données utilisées dans ce travail ont été collectées à l'aide d'un prototype de station de mesure embarquée, développé au sein du FabLab de l'école. Ce système repose sur un microcontrôleur ESP32[17], chargé de la gestion de l'acquisition, du traitement et de l'enregistrement des données interfacé avec plusieurs capteurs :

- **DHT22** : Mesure de la température ambiante ($\pm 0,5^{\circ}\text{C}$) et de l'humidité relative ($\pm 2\%$) [18];
- **INA219** : Mesure de la tension et du courant aux bornes du panneau PV, permettant le calcul direct de la puissance instantanée produite ($P = V \times I$) [19];

- **LDR (Estimation de l'irradiance)** :Capteur de luminosité dont la résistance varie en fonction de l'intensité lumineuse incidente. Il est utilisé comme indicateur relatif de l'ensoleillement, permettant de corrélérer les variations de luminosité avec la production PV mesurée [20];
- **Panneau photovoltaïque** :Le panneau constitue le générateur primaire du système, assurant la conversion du rayonnement solaire en énergie électrique sous forme de courant continu (DC). Le module retenu possède une tension nominale de 18V, ce qui permet une caractérisation électrique sur une plage parfaitement compatible avec les limites d'entrée du capteur INA219 (fixées à 26V maximum). Ce choix garantit à la fois la précision des relevés et une sécurité optimale durant les phases d'expérimentation;
- **Module carte SD** :Stockage local des données au format CSV, avec horodatage de chaque enregistrement[21];
- **Support imprimé en 3D** :Conçu et fabriqué au FabLab, il assure le maintien mécanique et le positionnement fixe des composants du prototype, notamment l'orientation du panneau PV .

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 :

Phase 1 (Acquisition semi-automatique) :

Dans un premier temps, le prototype était alimenté via câble USB connecté à un ordinateur. Les données transmises par l'ESP32 étaient reçues et 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.

Phase 2 (Acquisition autonome):

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

2.1.2 Variables utilisées

Les grandeurs mesurées par la station de mesure sont résumées dans le tableau 2.1 :

Table 2.1: Variables mesurées par le prototype ESP32

Capteur	Variable mesurée	Unité
LDR	Luminosité relative	lux
DHT22	Température ambiante	°C
DHT22	Humidité relative	%
INA219	Tension aux bornes du panneau	V
INA219	Courant débité	A
INA219	Puissance PV produite ($P = V \times I$)	mW
ESP32	Horodatage (date + heure)	—

2.1.3 Prétraitement

Avant d'être injectées dans les modèles d'IA, les données brutes stockées en format Excel subissent un nettoyage rigoureux via un script Python:

Nettoyage des données

Les données brutes collectées durant les deux phases d'acquisition ont nécessité plusieurs opérations de nettoyage avant toute utilisation [8]:

Valeurs manquantes : les interruptions d'acquisition (coupures d'alimentation, extraction de la carte SD) ont généré des valeurs manquantes. Celles-ci ont été traitées par interpolation linéaire entre les deux points voisins valides, préservant ainsi la continuité temporelle des séries.

Valeurs aberrantes : certaines mesures physiquement incohérentes ont été détectées et supprimées, notamment :

- les valeurs d'irradiance négatives (erreurs de capteur) remplacées par zéro ;
- les pics anormaux détectés par seuillage (valeurs dépassant 3 écarts-types de la moyenne).

Normalisation

Les variables présentent des plages de valeurs très différentes (ex. irradiance : 0–1000 W/m², humidité : 0–100%, puissance : 0–2483 mW). Sans normalisation, les variables à grande plage domineraient l'apprentissage du modèle.

La méthode Min-Max a été adoptée, ramenant toutes les variables dans l'intervalle $[0, 1]$ selon la formule [22] :

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (2.1)$$

où X_{min} et X_{max} sont calculés uniquement sur l'ensemble d'entraînement, puis appliqués aux ensembles de validation et de test, afin d'éviter toute fuite d'information (*data leakage*).

Division de la base de donnée

La base de données finale a été divisé de manière chronologique en trois sous-ensembles distincts, comme l'illustre le tableau 2.2 [9]:

Table 2.2: Division chronologique de la base de donnée

Ensemble	Proportion	Utilisation
Entraînement	70%	Ajustement des paramètres du modèle
Validation	15%	Réglage des hyperparamètres, early stopping
Test	15%	Évaluation finale des performances

2.2 Conception des modèles de prédiction

2.2.1 Modèles classiques

Régression Linéaire

La régression linéaire est un modèle statistique qui permet d'établir une relation mathématique entre une variable de sortie (variable dépendante) et une ou plusieurs variables d'entrée (variables indépendantes). Elle se décline en deux formes [4] :

- **Régression linéaire simple** : Elle modélise la relation entre une seule variable d'entrée x et une variable de sortie y :

$$y = \beta_0 + \beta_1 \cdot x + \varepsilon \quad (2.2)$$




Figure 2.1: Régression linéaire simple [4].

- **Régression linéaire multiple** : Elle généralise le cas précédent à plusieurs variables d'entrée $x_1, x_2, \dots, x_n$:

$$y = \beta_0 + \beta_1 \cdot x_1 + \beta_2 \cdot x_2 + \dots + \beta_n \cdot x_n + \varepsilon \quad (2.3)$$




Figure 2.2: Régression linéaire multiple [4].

où :

- y : variable de sortie (valeur à prédire) ;
- $x_1, x_2, \dots, x_n$: variables d'entrée (grandeurs mesurées) ;
- β_0 : constante du modèle, appelée biais, représente la valeur de y lorsque toutes les entrées sont nulles ;
- $\beta_1, \beta_2, \dots, \beta_n$: coefficients de pondération, chaque β_i exprime l'influence de la variable x_i sur la sortie y ;
- ε : terme d'erreur résiduelle, représente l'écart entre la valeur prédite par le modèle et la valeur réelle observée.

Dans le cadre de ce travail, la régression linéaire multiple est appliquée en utilisant les grandeurs mesurées par le prototype (L, T, HR, V, I) comme variables d'entrée, et la puissance photovoltaïque P_{PV} comme variable de sortie. Ce modèle est utilisé comme référence (*baseline*) afin d'évaluer l'apport des approches basées sur l'intelligence artificielle.

Modèle ARX (Auto-Régressif à entrée eXogène)

Le modèle ARX décrit le comportement d'un système dynamique discret en reliant la sortie actuelle aux sorties précédentes ainsi qu'aux entrées précédentes [23]. Sa structure générale s'écrit sous la forme :

$$A(q)y(t) = B(q)u(t) + e(t) \quad (2.4)$$

où :

- $y(t)$: sortie du système (puissance PV produite)
- $u(t)$: entrée du système (variables météorologiques mesurées : L, T, HR, V, I)
- $e(t)$: terme de bruit blanc (erreur résiduelle)
- $A(q)$ et $B(q)$: polynômes en l'opérateur de retard q^{-1} , définis par :

$$A(q) = 1 + a_1q^{-1} + \dots + a_{n_a}q^{-n_a} \quad (2.5)$$

$$B(q) = b_1q^{-1} + \dots + b_{n_b}q^{-n_b} \quad (2.6)$$

avec q^{-1} l'opérateur de retard unitaire tel que $q^{-1}y(t) = y(t - 1)$, n_a l'ordre auto-régressif et n_b l'ordre de la partie exogène.

Les paramètres a_i et b_j du modèle ARX sont estimés, au même titre que les coefficients de la régression linéaire, en minimisant la somme des carrés des erreurs de prédiction (méthode des moindres carrés ordinaires — MCO) :

$$\min_{a_i, b_j} \sum_{t=1}^n (\hat{y}(t) - y(t))^2 \quad (2.7)$$

où $\hat{y}(t)$ est la valeur prédite par le modèle et $y(t)$ la valeur réelle observée.

Cette approche linéaire est basée sur une régression multiple avec un horizon de retard rétrospectif fixé à 20 pas de temps ($\text{lag} = 20$).

2.2.2 Modèles d'intelligence artificielle

Les architectures PMC, LSTM, GRU et Forêts Aléatoires, dont les fondements théoriques ont été présentés au chapitre 1, ont 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.
- **Forêt Aléatoire (RF)** : Modèle d'ensemble constitué de 50 arbres de décision indépendants avec un état fixe (`random_state = 42`) pour assurer la reproductibilité et lisser les fluctuations.

2.2.3 Choix des entrées/sorties et architecture

Variables d'entrée

Les trois grandeurs directement mesurées par le prototype ESP32 constituent les entrées communes à tous les modèles :

- Température ambiante T (°C) ;
- Humidité relative HR (%) ;
- Valeur brute du capteur LDR (indicateur de luminosité).

Ce choix est motivé par leur disponibilité immédiate via le prototype et leur corrélation directe avec la production photovoltaïque.

Variable de sortie

La variable de sortie unique est la puissance photovoltaïque instantanée P_{PV} en mW, calculée par le capteur INA219 selon $P_{PV} = V \times I$.

2.3 Entraînement et optimisation

2.3.1 Fonctions de coût

Durant l'entraînement, le modèle cherche à minimiser l'écart entre les valeurs prédites $\hat{P}_{PV}$ et les valeurs réelles P_{PV} . Deux fonctions de coût sont utilisées [24]:

Erreur Quadratique Moyenne (MSE)

$$MSE = \frac{1}{n} \sum_{i=1}^n \left(P_{PV}^{(i)} - \hat{P}_{PV}^{(i)} \right)^2 \quad (2.8)$$

La MSE utilise la norme L2 (mise au carré), ce qui pénalise fortement les grandes erreurs. Elle constitue la fonction de coût principale minimisée durant l'entraînement.

Erreur Absolue Moyenne (MAE)

$$MAE = \frac{1}{n} \sum_{i=1}^n \left| P_{PV}^{(i)} - \hat{P}_{PV}^{(i)} \right| \quad (2.9)$$

La MAE utilise la norme L1 (valeur absolue), plus robuste aux valeurs aberrantes. Elle est utilisée comme métrique de suivi complémentaire et s'exprime directement en Watts (W).

2.3.2 Algorithmes d'optimisation

L'optimisation consiste à ajuster les paramètres du modèle (poids et biais) afin de minimiser la fonction de coût. Deux approches sont présentées :

Descente de gradient (Gradient Descent)

La descente de gradient est la méthode de base de l'optimisation des réseaux de neurones. À chaque itération, les paramètres θ sont mis à jour dans la direction opposée au gradient de la fonction de coût [25] :

$$\theta = \theta - \alpha \cdot \nabla L(\theta) \quad (2.10)$$

où :

- θ : paramètres du modèle (poids et biais) ;
- α : taux d'apprentissage (*learning rate*) ;
- $\nabla L(\theta)$: gradient de la fonction de coût.

Cependant, la descente de gradient classique présente des limitations : elle est lente à converger et sensible au choix du taux d'apprentissage α .

Algorithme Adam (Adaptive Moment Estimation)

Adam est une variante améliorée de la descente de gradient, proposée par Kingma & Ba (2014) [26]. Il combine deux techniques :

- le **Momentum** : accélère la convergence dans les directions cohérentes ;
- le **RMSProp** : adapte le taux d'apprentissage pour chaque paramètre individuellement.

Ses équations de mise à jour sont :

$$m(t) = \beta_1 \cdot m(t-1) + (1 - \beta_1) \cdot \nabla L(t) \quad (2.11)$$

$$v(t) = \beta_2 \cdot v(t-1) + (1 - \beta_2) \cdot \nabla L(t)^2 \quad (2.12)$$

$$\hat{m}(t) = \frac{m(t)}{1 - \beta_1^t} \quad (2.13)$$

$$\hat{v}(t) = \frac{v(t)}{1 - \beta_2^t} \quad (2.14)$$

$$\theta(t) = \theta(t-1) - \alpha \cdot \frac{\hat{m}(t)}{\sqrt{\hat{v}(t)} + \varepsilon} \quad (2.15)$$

où :

- $m(t)$: moyenne mobile des gradients (1^{er} moment) ;
- $v(t)$: variance mobile des gradients (2^{ème} moment) ;
- $\beta_1 = 0.9, \beta_2 = 0.999$: hyperparamètres de décroissance ;
- $\varepsilon = 10^{-8}$: constante de stabilité numérique ;
- $\alpha = 0.001$: taux d'apprentissage retenu dans ce travail.

Adam est retenu pour l'entraînement de tous les modèles neuronaux (PMC, LSTM, GRU) car il converge plus rapidement que la descente de gradient classique et nécessite peu de réglages manuels [26].

2.3.3 Techniques de régularisation

Afin de prévenir le surapprentissage (overfitting), qui se manifeste par de bonnes performances sur les données d'entraînement mais de mauvaises performances sur les données de test, deux techniques de régularisation ont été appliquées [27] :

Arrêt anticipé (Early Stopping) :

L'entraînement est automatiquement interrompu lorsque la fonction de coût sur l'ensemble de validation ne s'améliore plus pendant un nombre défini d'époques consécutives, appelé patience.

Dropout :

Le Dropout désactive aléatoirement une fraction p des neurones à chaque itération d'entraînement, forçant le réseau à ne pas dépendre excessivement de neurones spécifiques. Les taux retenus sont :

- $p = 0.2$ pour le PMC
- $p = 0.3$ pour le LSTM et le GRU

2.4 Évaluation et comparaison des modèles

2.4.1 Métriques

Afin d'évaluer objectivement les performances des modèles développés, quatre métriques complémentaires ont été retenues [24]:

Dans les expressions ci-dessous, n désigne le nombre total d'échantillons du jeu de test, $P_{PV}^{(i)}$ la valeur réelle de la puissance au pas de temps i , et $\hat{P}_{PV}^{(i)}$ la valeur prédite correspondante :

Racine de l'Erreur Quadratique Moyenne (RMSE)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(P_{PV}^{(i)} - \hat{P}_{PV}^{(i)} \right)^2} \quad (2.16)$$

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 pics d'erreur ponctuels.

Erreur Absolue Moyenne (MAE)

La MAE, dont l'expression a été introduite en section 2.3.1 comme fonction de coût, est également retenue comme métrique d'évaluation. Contrairement au RMSE, elle traite toutes les erreurs de manière uniforme et est plus robuste aux valeurs aberrantes.

Erreur Absolue Moyenne en Pourcentage (MAPE)

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{P_{PV}^{(i)} - \hat{P}_{PV}^{(i)}}{P_{PV}^{(i)}} \right| \quad (2.17)$$

Le MAPE exprime l'erreur en pourcentage relatif, ce qui facilite la comparaison entre modèles indépendamment de l'échelle des données. Toutefois, il peut devenir instable lorsque les valeurs réelles $P_{PV}^{(i)}$ sont proches de zéro.

Coefficient de Détermination (R^2)

$$R^2 = 1 - \frac{\sum_{i=1}^n \left(P_{PV}^{(i)} - \hat{P}_{PV}^{(i)} \right)^2}{\sum_{i=1}^n \left(P_{PV}^{(i)} - \bar{P}_{PV} \right)^2} \quad (2.18)$$

où $\bar{P}_{PV}$ désigne la moyenne des valeurs réelles. Le R^2 mesure la proportion de variance de la puissance PV expliquée par le modèle. Une valeur proche de 1 indique un excellent ajustement, tandis qu'une valeur proche de 0 signifie que le modèle n'explique pas mieux que la moyenne.

2.4.2 Analyse des performances

Les performances des modèles ont été évaluées sur un ensemble de test indépendant. Afin d'assurer une comparaison homogène, les données ont été normalisées à l'aide de la mise à l'échelle Min-Max. L'ensemble des indicateurs statistiques calculés pour les cinq configurations est rassemblé dans le tableau 2.3 :

Table 2.3: Synthèse comparative des performances des modèles sur l'ensemble de test (données normalisées)

Modèle	RMSE	MAE	MAPE (%)	R^2
PMC	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

Pour visualiser plus distinctement le comportement de chaque approche face aux erreurs, la figure 2.3 présente une analyse comparative graphique de l'ensemble des indicateurs de précision sous forme de grille.




Figure 2.3: 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 :

- **Le 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.

2.4.3 Comparaison IA vs modèles classiques

Les résultats obtenus révèlent un constat nuancé : le modèle classique ARX affiche des performances compétitives ($R^2 = 0,9334$), mais est surpassé par l'ensemble des modèles d'intelligence artificielle sur toutes les métriques évaluées. C'est notamment le modèle d'ensemble Forêts Aléatoires (RF) qui se distingue le plus nettement, en enregistrant la meilleure erreur relative (MAPE = 3,3305%) et la plus faible erreur absolue (MAE = 0,0055), surclassant ainsi le modèle ARX sur le plan de la précision opérationnelle.

Cette observation confirme que l'augmentation de la complexité algorithmique, lorsqu'elle est bien maîtrisée, apporte un gain significatif par rapport aux approches linéaires classiques. Les modèles IA présentent en effet des avantages structurels importants :

- **Capture des non-linéarités** : les fonctions d'activation et les mécanismes d'agrégation permettent de modéliser des relations complexes entre les variables météorologiques et la puissance PV, ce que le modèle ARX ne peut pas faire ;
- **Robustesse au bruit** : le RF, grâce à l'agrégation de multiples arbres de décision, filtre efficacement le bruit des capteurs et réduit le sur-apprentissage ;
- **Mémoire temporelle** : les architectures LSTM et GRU intègrent un mécanisme de mémoire interne permettant de capturer les dépendances temporelles sur plusieurs pas de temps ;
- **Flexibilité** : les modèles IA peuvent s'adapter à des dynamiques plus complexes avec davantage de données d'entraînement.

2.4.4 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 du jeu de données de test sur une fenêtre continue de 500 minutes (Figures 2.4 à 2.8).




Figure 2.4: Suivi temporel – Réseau de neurones Perceptron Multicouche (PMC)




Figure 2.5: Suivi temporel – Réseau récurrent Long Short-Term Memory (LSTM)




Figure 2.6: Suivi temporel – Réseau récurrent Gated Recurrent Unit (GRU)




Figure 2.7: Suivi temporel – Modèle linéaire AutoRégressif avec Variables Exogènes (ARX)




Figure 2.8: Suivi temporel – Modèle d'ensemble Forêts Aléatoires (RF)

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

- **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 rétro-spectif 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.

2.4.5 Discussion sur la robustesse et la généralisation

- **Robustesse aux bas régimes** : durant les 400 premières minutes, caractérisées par un signal de puissance globalement stable et bas, le Forêts Aléatoires (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 (15,1502%).
- **Absence de surapprentissage** : La comparaison des performances sur les jeux de validation et de test confirme l'absence de surapprentissage pour tous les modèles évalués, grâce à la bonne adéquation entre la taille des données et la complexité des architectures choisies.
- **Stabilité temporelle** : L'évaluation temporelle montre que tous les modèles reproduisent correctement la tendance globale de la production photovoltaïque. Le modèle RF présente la meilleure stabilité sur les régimes de faible puissance, suivi du GRU qui offre un bon compromis entre précision et robustesse, tandis que le PMC se distingue par sa réactivité lors des pics de production.

2.5 Conclusion

Ce chapitre a présenté l'ensemble de la chaîne de développement des modèles de prédiction basés sur l'IA, depuis l'acquisition et le prétraitement des données collectées par le prototype ESP32, jusqu'à l'évaluation comparative des approches développées.

L'étude expérimentale a permis de comparer cinq familles de modèles, allant des approches linéaires (régression, ARX) aux réseaux de neurones profonds (PMC, LSTM, GRU), en passant par le modèle Forêts Aléatoires(RF).

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 PMC s'est distingué par la meilleure précision absolue globale ($RMSE = 0,0234$; $R^2 = 0,9458$), confirmant la puissance des architectures neuronales directes pour capturer les pics de production. La forêt aléatoire (RF) s'est imposée comme la solution la plus équilibrée, enregistrant la meilleure précision relative ($MAPE = 3,3305\%$) et la plus faible erreur absolue ($MAE = 0,0055$). Les modèles récurrents GRU et LSTM ont offert un comportement intermédiaire satisfaisant, tandis que le modèle ARX reste une alternative compétitive et légère ($R^2 = 0,9334$), viable pour des environnements embarqués aux ressources limitées.

De manière générale, ces résultats soulignent l'existence d'un compromis fondamental entre la précision des prédictions et la complexité des modèles, et mettent en évidence

l'importance d'une évaluation multi-critères pour sélectionner l'architecture la mieux adaptée au contexte applicatif visé. Les modèles ainsi développés constituent la base de la plateforme de prévision présentée dans le chapitre suivant.

DÉVELOPPEMENT DE L'APPLICATION ET INTÉGRATION

Ce chapitre présente la plateforme applicative conçue pour les rendre accessibles et utilisables en pratique. L'objectif est de proposer un outil simple permettant à un utilisateur de saisir des données météorologiques et d'obtenir instantanément une estimation de la puissance photovoltaïque produite, sans nécessiter de compétences particulières en intelligence artificielle.

Nous présentons successivement l'architecture de l'application, son déploiement sur le cloud, les cas d'usage envisagés pour la gestion énergétique, puis une analyse des résultats et des limites de l'approche.

3.1 Conception de l'application

Avant de détailler l'architecture technique, le diagramme de cas d'utilisation présenté ci-dessous offre une vue d'ensemble des fonctionnalités accessibles à l'utilisateur de la plateforme.

La plateforme s'articule autour de cinq cas d'utilisation principaux :

- **Consultation de l'accueil** : l'utilisateur découvre l'objectif du projet et les fonctionnalités disponibles.
- **Importation des données** : point d'entrée du traitement, cette étape déclenche automatiquement la sélection d'un modèle parmi les cinq architectures proposées (PMC, LSTM, GRU, ARX et Forêts Aléatoires)condition nécessaire à l'exploitation des données chargées.
- **Visualisation des graphiques** : les données importées sont représentées sous forme de courbes temporelles, offrant un aperçu visuel de leur évolution.

- **Évaluation des modèles IA** : les performances de chaque modèle sont consultables via les métriques RMSE, MAE, MAPE et R^2 , dont l'affichage est systématiquement inclus.
- **Lancement d'une prédiction** : fonctionnalité centrale de l'outil, elle implique au préalable l'ajustement des paramètres météorologiques (éclairage solaire, humidité relative, température) au moyen de curseurs interactifs, avant de générer l'estimation de puissance photovoltaïque.

Les relations include traduisent une dépendance fonctionnelle obligatoire : chaque cas d'utilisation déclenche automatiquement le cas inclus, garantissant ainsi la cohérence du flux d'interaction de l'interface Streamlit.




Figure 3.1: Diagramme de cas d'utilisation de la plateforme de prédiction PV.

3.1.1 Description de l'architecture de l'application

La plateforme développée dans le cadre de ce projet repose sur le framework *Streamlit*, un outil open-source Python permettant de déployer rapidement des applications web interactives orientées données et intelligence artificielle, sans nécessiter de connaissances en développement web.

L'architecture de l'application s'articule autour de trois couches fonctionnelles interconnectées :

- **Couche acquisition** : les données météorologiques collectées par le prototype ESP32 (température, humidité relative, luminosité LDR) constituent les entrées de la plateforme. Ces grandeurs sont saisies manuellement par l'utilisateur via l'interface web, ou importées depuis un fichier CSV ou Excel.
- **Couche traitement et prédiction** : les valeurs saisies sont normalisées à l'aide du scaler Min-Max sauvegardé lors de l'entraînement (`scaler.pkl`), puis injectées dans le modèle IA sélectionné par l'utilisateur. Cinq modèles sont disponibles : LSTM, GRU, PMC, ARX et Forêts Aléatoires, chargés depuis leurs fichiers respectifs (`.keras` pour les modèles neuronaux récurrents, `.pkl` pour les autres).
- **Couche présentation** : la puissance photovoltaïque prédite est affichée à l'utilisateur sous forme de métriques numériques (en mW et en W), accompagnée d'une indication visuelle sur la cohérence de la valeur par rapport à la plage normale observée.

Le diagramme de séquence ci-dessous illustre le déroulement temporel détaillé des interactions entre l'utilisateur, l'interface web, le module de données et les modèles d'IA, depuis l'ouverture de l'application jusqu'à l'obtention d'une prédiction.




Figure 3.2: Diagramme de séquence des interactions entre l'utilisateur et la plateforme.

3.1.2 Architecture de déploiement sur le Cloud

Le déploiement de la plateforme web de prédiction s'appuie sur une architecture Cloud moderne basée sur la synchronisation continue entre un gestionnaire de version (GitHub) et une plateforme d'hébergement (Streamlit Community Cloud). Cette infrastructure garantit une mise à jour automatique de l'application dès que le code source est modifié, sans aucune intervention manuelle sur le serveur.

L'infrastructure se divise en trois composants principaux :

- 1. Le Répertoire Source (GitHub)** Il sert de dépôt centralisé et public pour l'ensemble des ressources de l'application : le script principal (`app.py`), le fichier de

configuration des dépendances (`requirements.txt`), le jeu de données d'étalonnage (`Classeur1.xlsx`) et les modèles d'intelligence artificielle entraînés (fichiers `.pk1` et `.h5`). Toute modification du code sur GitHub est immédiatement détectée et déclenchée pour mettre à jour l'application en direct.

2. Le Serveur Cloud (Streamlit Community Cloud) C'est la machine virtuelle distante qui prend en charge l'exécution de l'application. Lors du lancement, ce serveur effectue automatiquement les opérations suivantes :

- **Clonage** : téléchargement automatique de l'intégralité des fichiers depuis le dépôt GitHub ;
- **Gestion de l'environnement** : création d'un environnement virtuel isolé sous Python 3.11, garantissant la compatibilité avec les bibliothèques de deep learning ;
- **Installation des dépendances** : lecture du fichier `requirements.txt` et installation des bibliothèques nécessaires (Streamlit, pandas, TensorFlow, scikit-learn, etc.) ;
- **Exécution** : compilation et exécution en continu du script principal `app.py`.

3. L'Utilisateur Final (Le Navigateur Web) N'importe quel utilisateur, membre du jury, collaborateur ou ingénieur accède à l'application via une URL publique unique de la forme:

`https://plateforme-pv-nzr3gwesjnhlmy8hpf3b8a.streamlit.app/`.

Le navigateur de l'utilisateur n'exécute aucun calcul lourd : il envoie simplement les requêtes au serveur Streamlit. Le serveur cloud traite les données via les modèles (GRU, LSTM, ARX, Forêts Aléatoires, PMC), génère les prédictions énergétiques, et renvoie uniquement l'affichage des graphiques et des résultats à l'écran de l'utilisateur.

3.1.3 Interface utilisateur

L'interface utilisateur est accessible via un navigateur web à l'adresse publique générée par Streamlit Community Cloud. Elle est organisée de manière simple et intuitive autour des éléments suivants :

Page d'accueil (Description et À propos)

La page d'accueil réunit la description générale du projet et les informations relatives à l'équipe. Elle présente l'objectif de la plateforme, les fonctionnalités disponibles (importation de données, comparaison de modèles, prédiction interactive).

Description du Projet

Ce projet de fin d'études a pour objectif de développer une **plateforme intelligente de prédiction de la production d'énergie photovoltaïque (PV)**.

À partir de données réelles collectées sur un système PV (tension, courant, puissance, température, humidité, éclairage), plusieurs modèles d'intelligence artificielle ont été entraînés, comparés et intégrés dans cette interface interactive.

Ce que la plateforme permet :

-  Importer vos propres données de mesure (fichier Excel ou CSV)
-  Visualiser et comparer les performances des 5 modèles entraînés
-  Effectuer des prédictions interactives en temps réel selon les conditions météo

Figure 3.3: Description du projet et présentation de l'équipe.

Importation des Données

Cette page permet à l'utilisateur de charger son propre fichier de mesures au format Excel (.xlsx) ou CSV. Une fois le fichier importé, la plateforme affiche le nombre de lignes et de colonnes détectées, un aperçu des dix premières lignes, ainsi que les statistiques descriptives de chaque variable (min, max, moyenne, écart-type).

Dans les tests effectués, le fichier **Classeur1.xlsx** contenant **14 657 lignes et 8 colonnes** a été chargé avec succès, confirmant la capacité de la plateforme à traiter de grands volumes de données réelles.

Importation des Données

Chargez votre fichier :

 Classeur1.xlsx 0.7MB

 Fichier chargé — 14657 lignes, 8 colonnes

 Aperçu des 10 premières lignes

 Statistiques descriptives

Figure 3.4: Page Importation des Données (chargement d'un fichier Excel de 14 657 lignes et 8 colonnes).

Évaluation & Performance

Cette page affiche les métriques de performance du modèle sélectionné sur l'ensemble de test : RMSE, MAE, MAPE et R^2 . Elle présente également la courbe comparative entre les valeurs réelles mesurées et les valeurs prédites par le modèle.

Le tableau 3.1 résume les performances des cinq modèles intégrés dans la plateforme, telles qu'observées sur l'ensemble de test :

Table 3.1: Synthèse comparative des performances des modèles sur l'ensemble de test (données normalisées)

Modèle	RMSE	MAE	MAPE (%)	R^2
PMC	0,0231	0,0066	8,65%	0,9475
LSTM	0,0268	0,0124	28,95%	0,9293
GRU	0,0234	0,0060	7,40%	0,9460
ARX	0,0248	0,0080	13,27%	0,9334
RF	0,0234	0,0054	3,30%	0,9460

Prédiction Future Interactive

Cette page constitue le cœur fonctionnel de la plateforme. Elle permet à l'utilisateur d'effectuer une prédiction en temps réel en ajustant trois paramètres météorologiques via des curseurs interactifs :

- **Éclairement (LDR)** : de 0 à la valeur maximale mesurée ;
- **Humidité (%)** : de 0 à 100 ;
- **Température (°C)** : de 0 à 50.

Un bouton “*Lancer la prédiction*” déclenche instantanément le calcul. La puissance estimée est affichée en mW, accompagnée du biais du modèle et d’une note de recommandation indiquant les forces du modèle sélectionné.

Le menu déroulant latéral permet de basculer entre les cinq modèles disponibles (PMC, LSTM, GRU, ARX, Forêts Aléatoires). Pour des conditions identiques (Éclairement = 1500, Humidité = 65 %, Température = 25 °C), le modèle PMC retourne **165,86 mW** ($R^2 = 0,9475$) et le modèle Forêts Aléatoires retourne **165,80 mW** (MAPE = 3,30 %, meilleure erreur relative parmi tous les modèles).




Figure 3.5: Page Prédiction Future Interactive (résultat du modèle PMC).




Figure 3.6: Page Prédiction Future Interactive (résultat du modèle Forêts Aléatoires).

3.1.4 Intégration du modèle IA dans l'application

L'intégration des modèles IA entraînés dans la plateforme Streamlit suit un pipeline structuré en quatre étapes :

1. **Chargement du scaler** : au démarrage de l'application, le normaliseur Min-Max utilisé durant l'entraînement est chargé depuis le fichier `scaler.pkl`. Cela garantit que les données d'entrée subissent exactement la même transformation que lors de la phase d'apprentissage ;
2. **Chargement du modèle sélectionné** : selon le choix de l'utilisateur, la fonction `load_selected_model()` charge le modèle approprié. Les modèles LSTM et GRU sont chargés au format `.keras` via `keras_load_model()`, tandis que les modèles PMC, ARX et Forêts Aléatoires sont chargés au format `.pkl` via la bibliothèque `pickle` ;
3. **Prétraitement et mise en forme** : les trois valeurs saisies (température, humidité, LDR) sont organisées dans un tableau NumPy et normalisées via `scaler.transform()` ;
4. **Prédiction et affichage** : le modèle génère la puissance PV prédite en mW, qui est directement affichée à l'utilisateur sans dénormalisation (la variable cible ayant été entraînée en mW).

3.2 Utilisation pour la gestion énergétique

3.2.1 Exploitation des prédictions à court terme

La plateforme développée génère des prédictions de puissance photovoltaïque à partir des grandeurs météorologiques mesurées par le prototype ESP32. Bien que l'objectif principal de ce travail soit la prévision de la production PV, les résultats obtenus ouvrent des perspectives concrètes pour la gestion énergétique locale.

Connaître à l'avance la puissance que le panneau va produire constitue une information précieuse pour tout système de gestion énergétique intelligent. Cette section présente les principaux cas d'usage dans lesquels les prédictions générées par la plateforme pourraient être exploitées.

3.2.2 Cas d'usage

Optimisation de la consommation

La prévision de la production PV permet d'anticiper les périodes de forte disponibilité d'énergie solaire. Un gestionnaire énergétique pourrait exploiter ces informations pour décaler les charges consommatrices (appareils électriques, systèmes de climatisation, pompes) vers les créneaux où la production PV est la plus importante, réduisant ainsi le recours au réseau électrique ou à des sources d'énergie fossile.

À titre d'exemple, si la plateforme prédit une puissance de 200 mW pour les 30 prochaines minutes, le système pourrait déclencher automatiquement des charges non critiques durant ce créneau, maximisant ainsi l'autoconsommation solaire.

Gestion du stockage (batteries)

Dans un système équipé d'un dispositif de stockage par batteries, les prédictions à court terme permettraient d'optimiser les cycles de charge et de décharge :

- si une forte production est anticipée, la batterie peut être chargée en priorité avant que le panneau n'atteigne sa puissance maximale ;
- si une chute de production est prévue (passage nuageux, variation de luminosité), la décharge contrôlée de la batterie peut être planifiée pour compenser le déficit énergétique.

Cette gestion prédictive prolongerait la durée de vie des batteries en évitant les cycles de charge et décharge non optimaux, tout en assurant une continuité de l'alimentation électrique.

Aide à la décision énergétique

Les prédictions fournies par la plateforme constituent un outil d'aide à la décision pour le gestionnaire du système énergétique. En disposant d'une estimation fiable de la puissance PV à venir, il lui est possible de prendre des décisions éclairées concernant :

- le moment optimal pour alimenter des charges prioritaires depuis le panneau solaire ;
- la nécessité de recourir à une source d'énergie complémentaire (réseau, générateur) en cas de production insuffisante ;
- la planification de la maintenance du système en fonction des prévisions de production.

3.3 Analyse des résultats

3.3.1 Visualisation des prédictions vs valeurs réelles

Les résultats de prédiction obtenus sur l'ensemble de test ont été visualisés en superposant les valeurs prédites par chaque modèle aux valeurs réelles mesurées par le capteur INA219. Cette comparaison graphique met en évidence la capacité de chaque modèle à reproduire la dynamique temporelle de la production photovoltaïque, comme illustré dans les figures ci-dessous.

De manière générale, tous les modèles parviennent à suivre la tendance globale de la puissance PV. Le modèle **Forêts Aléatoires** présente la meilleure erreur relative avec un MAPE de **3,30 %**, soit une erreur presque trois fois inférieure à celle du PMC (8,65 %). Les modèles neuronaux (LSTM, GRU, PMC) montrent un léger lissage des pics, caractéristique de leur capacité de généralisation.

3.3.2 Étude des erreurs de prédiction

L'analyse quantitative des erreurs de prédiction révèle que :

Valeurs Réelles vs Prédiction — Modèle MLP




Figure 3.7: Courbe Valeurs Réelles vs Prédiction (Modèle PMC).

Valeurs Réelles vs Prédiction — Modèle RF




Figure 3.8: Courbe Valeurs Réelles vs Prédiction (Modèle Forêts Aléatoires).

- Le modèle **PMC** obtient le meilleur R^2 (**0,9475**) et le RMSE le plus faible (0,0231), indiquant une excellente explication globale de la variance de la puissance PV ;
- Le modèle **Forêts Aléatoires** se distingue par la plus faible erreur relative (MAPE = **3,30%**) et le MAE le plus bas (**0,0054**), indiquant une meilleure sensibilité aux faibles valeurs de puissance.

Les erreurs de prédiction sont principalement concentrées sur les transitions rapides

de luminosité (passages nuageux soudains), ce qui représente la principale limite des modèles à entrées météorologiques statiques.

3.3.3 Avantages et limites de l'approche proposée

L'approche adoptée dans ce travail présente plusieurs avantages notables :

- Une comparaison multi-modèles couvrant des approches linéaires (ARX), neuronales (PMC, LSTM, GRU) et d'ensemble (Forêts Aléatoires), offrant une vision globale et représentative de l'état de l'art ;
- Une évaluation basée sur plusieurs métriques complémentaires (RMSE, MAE, MAPE, R^2), assurant une analyse équilibrée qui ne se limite pas à un seul indicateur de performance ;
- Une validation sur un ensemble de test indépendant, constitué de données non vues durant l'entraînement, garantissant la robustesse et la fiabilité des résultats obtenus ;
- Une interface web interactive déployée sur le Cloud, accessible à tout utilisateur via une URL publique, sans installation requise.

Cependant, certaines limites doivent être prises en considération :

- L'étude repose sur une seule base de données collectée sur une période limitée, ce qui peut restreindre la généralisation des conclusions à d'autres contextes géographiques ou climatiques ;
- Les modèles neuronaux profonds (LSTM, GRU, PMC) pourraient bénéficier d'un réglage plus fin des hyperparamètres (nombre de couches, taille des batchs, taux d'apprentissage) afin d'exploiter pleinement leur capacité de modélisation ;
- L'analyse est principalement centrée sur un horizon de prédiction à court terme instantané ; une extension vers des prédictions multi-pas (15, 30 ou 60 minutes) constituerait un approfondissement pertinent.

Ces limites ne remettent pas en cause la validité des résultats obtenus, mais définissent les axes prioritaires pour les travaux futurs présentés dans la section suivante.

3.4 Perspectives et améliorations

Les travaux réalisés dans ce mémoire constituent une base solide pour des développements futurs. Plusieurs axes d'amélioration et d'extension sont envisagés :

3.4.1 Extension vers les smart grids

L'intégration de la plateforme dans un réseau intelligent (*smart grid*) permettrait d'exploiter les prédictions PV à l'échelle d'un quartier ou d'un microréseau. En combinant les prévisions de production de plusieurs générateurs PV distribués avec les prévisions de consommation, un système de gestion énergétique centralisé pourrait optimiser les flux d'énergie en temps réel, réduire les pertes et améliorer la résilience du réseau.

3.4.2 Enrichissement de la base de données

Une collecte de données sur une période plus longue (plusieurs mois, couvrant différentes saisons) permettrait d'améliorer significativement la robustesse et la généralisation des modèles, en particulier pour les modèles d'apprentissage profond (LSTM, GRU) qui bénéficient davantage de grands volumes de données.

3.4.3 Intégration de capteurs plus précis

Le remplacement du capteur LDR par un pyranomètre calibré et l'ajout de variables météorologiques supplémentaires (vitesse du vent, couverture nuageuse, angle d'incidence solaire) permettraient d'améliorer la qualité des entrées et, par conséquent, la précision des prédictions.

3.5 Conclusion

Ce chapitre a présenté la plateforme web développée pour exploiter les modèles de prédiction dans un contexte réel. Grâce à une architecture claire et un déploiement cloud accessible via une URL publique, l'application permet à tout utilisateur d'obtenir une prédiction de puissance PV à partir de simples données météorologiques.

Les cas d'usage analysés montrent le potentiel de cet outil pour la gestion énergétique locale. Les limites identifiées, notamment le volume de données limité, constituent les

principaux axes d'amélioration pour les travaux futurs, en particulier l'extension vers des architectures de smart grid et l'enrichissement de la base de données collectées.

CONCLUSION GÉNÉRALE

Ce mémoire a présenté une démarche complète et intégrée, allant de la collecte de données météorologiques réelles en conditions d'exploitation jusqu'au déploiement d'une plateforme d'intelligence artificielle accessible en ligne, en passant par le développement, l'évaluation et la comparaison de plusieurs modèles de prédiction de la production photovoltaïque à court terme.

Le travail a débuté par l'établissement des fondements théoriques nécessaires à la compréhension du problème traité, en situant l'énergie photovoltaïque dans son contexte énergétique actuel et en détaillant les mécanismes physiques régissant le fonctionnement d'une cellule solaire. Les bases de l'intelligence artificielle ont également été introduites, posant les jalons des architectures utilisées dans la suite du travail.

Afin de constituer une base de données réelle, fiable et représentative, un prototype de mesure embarqué a été conçu et déployé au sein de l'école. Ce dispositif a fonctionné en deux phases successives : une première phase semi-automatique ayant permis de valider la cohérence des mesures, suivie d'une phase d'acquisition entièrement autonome, alimentée par batterie, assurant une collecte continue et ininterrompue des grandeurs météorologiques et électriques. Ces données, après des étapes rigoureuses de nettoyage, de filtrage et de normalisation, ont constitué le socle d'entraînement et de validation de l'ensemble des modèles développés.

La partie centrale de ce travail a été consacrée au développement et à la comparaison systématique de cinq approches de prévision : le modèle autorégressif ARX comme référence linéaire, le Perceptron Multicouche (PMC), les réseaux de neurones récurrents LSTM et GRU, ainsi que le modèle d'ensemble Forêt Aléatoire (RF).

Les résultats expérimentaux obtenus sur un ensemble de test indépendant ont mis en évidence l'efficacité des approches capables de capturer la dynamique temporelle à court terme du système. Le PMC s'est distingué par la meilleure précision absolue globale, atteignant un coefficient de détermination R^2 de 0,9475 et une erreur quadratique $RMSE = 0,0231$, confirmant la puissance des architectures neuronales directes

pour capturer les pics de production lors des fortes variations de luminosité. La Forêt Aléatoire (RF) s'est quant à elle imposée comme la solution la plus équilibrée sur le plan opérationnel, enregistrant la meilleure précision relative ($\text{MAPE} = 3,30\%$) et la plus faible erreur absolue ($\text{MAE} = 0,0054$), grâce à sa capacité remarquable à filtrer le bruit des capteurs en régime de faible puissance. Les architectures récurrentes GRU et LSTM ont démontré un comportement intermédiaire satisfaisant, tandis que le modèle ARX, grâce à son horizon rétrospectif ajusté à 20 pas de temps ($\text{lag} = 20$), a prouvé qu'une approche linéaire classique reste compétitive ($R^2 = 0,9334$) et parfaitement viable pour des environnements embarqués aux ressources limitées.

L'ensemble de ces modèles a été intégré dans une plateforme web interactive, développée sous le framework Streamlit et déployée sur le cloud, rendant la prédiction de la puissance photovoltaïque accessible à tout utilisateur via une simple interface de saisie. Cette dimension applicative constitue l'apport original de ce travail, franchissant le pas entre un modèle fonctionnel en laboratoire et un outil réellement opérationnel.

De manière générale, les conclusions de ce travail soulignent qu'une augmentation de la complexité algorithmique garantit une supériorité sur l'ensemble des critères d'évaluation, et qu'une évaluation multi-critères approfondie reste indispensable pour sélectionner la structure de modélisation la mieux adaptée au contexte d'application et au volume de données disponibles.

Ce travail ouvre des perspectives concrètes et prometteuses pour de futures recherches. L'enrichissement de la base de données sur une période plus longue et sous des conditions climatiques plus variées permettrait d'améliorer significativement la généralisation des modèles neuronaux profonds. Le remplacement du capteur de luminosité par un pyranomètre calibré et l'intégration de variables météorologiques supplémentaires renforceraient la qualité des entrées et, par conséquent, la précision des prédictions. Enfin, l'extension de la plateforme vers des architectures de smart grid, combinant les prévisions de plusieurs générateurs distribués avec des algorithmes de gestion énergétique centralisés, constitue la perspective la plus ambitieuse et la plus porteuse pour les travaux futurs.

BIBLIOGRAPHY

- [1] Reda Mohamed Nezzar. Approches multi-modèle pour la prévision de la charge électrique à moyen long terme. *Mémoire de fin d'études*, 2020.
- [2] Abderrahim Hadjiat and Lynda Bemmerzouk. Optimisation du transfert d'énergie d'un panneau solaire à l'aide d'outils de l'intelligence artificielle. Master's thesis, École Supérieure en Sciences Appliquées de Tlemcen, 2024.
- [3] Debeche Mehdi, Babouri Abdesselam, and Boucerredj Leila. Classification des données basée sur les réseaux de neurones récurrents. *Mémoire de fin d'études*, 2022.
- [4] YACINE AKROUR. prévision de la demande d'électricité par régression linéaire et réseau de neurones artificiels : Application au réseau de la ville de baie-comeau. 2022.
- [5] Chen Luo, Naji Al-Messabi, Zhaoqi Kuang, Changjiang Ma, Ibrahim El-Amin, Hui Deng, and Yun Li. Photovoltaic system modeling and forecasting techniques: A survey. *Engineering Applications of Artificial Intelligence*, 162:112516, 2025.
- [6] 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.
- [7] Musaed Alrashidi and Saifur Rahman. Short-term photovoltaic power production forecasting based on novel hybrid data-driven models. *Journal of Big Data*, 10(1):26, 2023.
- [8] 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. *Energies*, 17(16), 2024.
- [9] 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).
- [10] Hosna Khajeh and Hannu Laaksonen. Applications of probabilistic forecasting in smart grids: A review. *Applied Sciences*, 12(4):1823, 2022.
 - [11] Mondher Ouari and Yakoub Zine. Étude des commandes mppt d'un système photovoltaïque. Master's thesis, École Nationale Polytechnique, 2020.
 - [12] Sahour Dounia and Guessab Borhane. Etude et modélisation d'un panneau photovoltaïque. Master's thesis, Université 8 Mai 1945 Guelma, 2021.
 - [13] 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).
 - [14] Bilel Ben Nasser. Etude et modelisation de la commande mppt avec matlab. *Mémoire présenté dans le cadre du programme de maîtrise en ingénierie en vue de l'obtention du grade de maître en sciences appliquées (M. Sc. A.)*, 2021.
 - [15] Abdelouadoud Loukriz. Optimisation de la modélisation et de la commande d'un système photovoltaïque par les techniques d'intelligence artificielle. Master's thesis, Université, 2014.
 - [16] Leo Breiman. Random forests. *Machine Learning*, 45(1):5–32, 2001.
 - [17] alldatasheet.com. Esp-wroom-32 datasheet, pdf. <http://www.alldatasheet.com/view.jsp>. Consulté le 09/05/2026.
 - [18] Dht22 datasheet, pdf - alldatasheet. <https://www.alldatasheet.com/view.jsp>. Consulté le 09/05/2026.
 - [19] alldatasheet.com. Ina219 datasheet, pdf. <http://www.alldatasheet.com/view.jsp>. Consulté le 09/05/2026.
 - [20] Ldr sensor module datasheet. <https://fr.scribd.com/doc/128939598/LDR-Datasheet>. Consulté le 09/05/2026.
 - [21] Module adaptateur pour carte micro sd : Brochage, spécifications, fiche technique, fonctionnement, applications, alternatives. <https://components101.com/modules/micro-sd-card-module-pinout-features-datasheet-alternatives>. Consulté le 10/05/2026.

- [22] Meryem Khelil and Walid Sahel. *Estimation de l'irradiation solaire basée sur l'intelligence artificielle*. PhD thesis, ESSA Tlemcen, 2025. (accès : 2026-02-22).
- [23] BOUKHETTA OMAR ELFAROUK. Identification paramétrique d'une machine asynchrone. 2015.
- [24] 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. 7:e623.
- [25] Augustin-Louis Cauchy. Méthode générale pour la résolution des systèmes d'équations simultanées. *Comptes Rendus de l'Académie des Sciences*, 25:536–538, 1847.
- [26] Diederik P. Kingma and Jimmy Ba. Adam: A method for stochastic optimization. <http://arxiv.org/abs/1412.6980>, 2017. Consulté le 12/05/2026.
- [27] Reza Moradi, Reza Berangi, and Behrouz Minaei. A survey of regularization strategies for deep models. *Artificial Intelligence Review*, 53(6):3947–3986, 8 2020. Consulté le 13/05/2026.