



الجمهورية الجزائرية الديمقراطية الشعبية  
République Algérienne Démocratique et Populaire  
وزارة التعليم العالي والبحث العلمي  
Ministère de l'Enseignement Supérieure et de la Recherche Scientifique

جامعة وهران 2 أحمد بن أحمد  
Université d'Oran 2 Mohamed Ben Ahmed

معهد الصيانة والأمن الصناعي  
Institut de Maintenance et de Sécurité Industrielle

Département de Maintenance en Instrumentation

## MÉMOIRE

Pour obtenir du diplôme de Master

Filière : Génie Industriel

Spécialité : Maintenance de l'Automatisme et de l'Instrumentation

### Thème

Application de l'intelligence artificielle pour la gestion de  
l'énergie solaire photovoltaïque

Présenté et soutenu publiquement par :

**BENKACI AMINA & TASSOURIT AMIRA**

Devant le jury composé de

| Nom et Prénom            | Grade      | Etablissement         | Qualité   |
|--------------------------|------------|-----------------------|-----------|
| M. Hassini Abdelatif     | Professeur | IMSI - Univ. d'Oran 2 | Président |
| M. chennoufi<br>Mohammed | Professeur | IMSI - Univ. d'Oran 2 | Encadrant |
| Mme. Moufek Souad        | MCB        | IMSI - Univ. d'Oran 2 | Examineur |

Année : 2025-2026

## **Remerciements**

*Avant tout, nous remercions Allah, le Tout-Puissant, pour Son aide, Sa guidance et pour nous avoir accordé la santé, la patience et la détermination nécessaires à l'accomplissement de ce modeste travail.*

*Nous exprimons notre profonde gratitude à notre encadreur, **M. CHENOUFI Mohammed**, pour son accompagnement tout au long de ce projet, sa disponibilité, sa compréhension, ses précieux conseils et ses orientations pertinentes. Nous lui adressons nos sincères remerciements pour son écoute, sa patience et son soutien constant, qui ont grandement contribué à l'aboutissement de ce mémoire.*

*Nous tenons également à remercier l'ensemble des enseignants de l'**Institut de Maintenance et de Sécurité Industrielle (IMSI)** pour la qualité de la formation qu'ils nous ont dispensée ainsi que pour les connaissances et les compétences qu'ils nous ont transmises durant notre parcours universitaire.*

*Nous adressons également nos sincères remerciements à toutes les personnes qui nous ont aidés, de près ou de loin, et qui ont contribué, directement ou indirectement, à la réalisation de ce travail.*

*Enfin, nous remercions chaleureusement les membres du jury pour l'honneur qu'ils nous font en acceptant d'évaluer ce mémoire et pour l'intérêt qu'ils portent à notre travail.*

*Nous gardons une profonde reconnaissance envers toutes les personnes qui nous ont accompagnés, soutenus et encouragés tout au long de cette expérience académique.*

## ***Dédicaces***

*Je dédie ce modeste travail, avant tout, à Allah, le Tout-Puissant, qui m'a guidé, protégé et accordé la force, la patience et la persévérance nécessaires pour surmonter les difficultés et atteindre cet objectif.*

*À mes très chers parents,*

*Aucune parole ne saurait exprimer pleinement ma gratitude et mon affection envers vous. Merci pour votre amour inconditionnel, vos sacrifices, votre soutien constant et votre confiance en moi. Tout ce que je suis aujourd'hui, je le dois en grande partie à votre dévouement et à vos encouragements. Que ce travail soit le témoignage de mon profond respect et de ma reconnaissance infinie.*

*À toute ma famille,*

*Pour votre présence, votre soutien et vos encouragements tout au long de mon parcours. Votre affection a toujours été une source de motivation et de réconfort.*

*À moi-même,*

*Pour les efforts accomplis, les défis surmontés, les moments de doute dépassés et la détermination dont j'ai fait preuve pour mener ce travail à son terme.*

*Une dédicace particulière à mon amie **HAMDİ BASMALA**,*

*Pour sa présence, sa bienveillance, son soutien moral et ses encouragements qui m'ont accompagné durant cette aventure. Je lui adresse toute ma gratitude et ma sincère reconnaissance.*

*Enfin, à toutes les personnes qui ont cru en moi et qui m'ont soutenu de près ou de loin durant mon parcours universitaire.*

*Avec tout mon respect, ma reconnaissance et mon affection.*

**BENKACI AMINA**

## ***Dédicaces***

*Je dédie ce modeste travail à ma très chère mère.*

*Aucune expression ne saurait traduire toute ma gratitude pour son amour inconditionnel, ses sacrifices, sa patience et son soutien constant tout au long de mon parcours. Elle a toujours cru en moi, m'a encouragée dans les moments de doute et a consacré une grande partie de sa vie à mon bonheur et à ma réussite. Que ce travail soit le témoignage de mon profond respect, de mon affection et de ma reconnaissance infinie.*

*Une pensée pleine d'amour et d'émotion pour mon père, qui n'est malheureusement plus parmi nous pour partager ce moment si important de ma vie. Son souvenir demeure une source de force et d'inspiration au quotidien. J'aurais tant souhaité qu'il soit présent aujourd'hui pour voir l'aboutissement de ce parcours.*

*Je lui dédie cette réussite avec une profonde émotion, en espérant qu'il soit fier du chemin parcouru.*

*À ma famille, à mes proches et à toutes les personnes qui m'ont soutenue et encouragée durant cette aventure universitaire.*

**TASSOURIT AMIRA**

## Résumé

Ce travail s'inscrit dans le contexte de la transition énergétique et de l'optimisation des systèmes photovoltaïques. Il propose une approche basée sur l'intelligence artificielle pour la prévision de la puissance solaire et la gestion intelligente de l'énergie avec stockage par batterie. L'étude exploite les données PVGIS-SARAH2 de la région de Ouargla sur la période 2015–2020. Plusieurs modèles de Machine Learning et de Deep Learning sont développés et comparés afin d'identifier la meilleure performance de prévision. Les résultats obtenus montrent que l'utilisation de l'intelligence artificielle améliore la précision des prévisions et permet une optimisation efficace de la gestion énergétique.

**Mots-clés :** Intelligence artificielle, énergie photovoltaïque, prévision, Machine Learning, Deep Learning, batterie, gestion énergétique.

## Abstract

This work is situated in the context of the energy transition and the improvement of photovoltaic energy systems. It proposes an artificial intelligence-based approach for forecasting photovoltaic power production and optimizing energy management in a battery storage system. The study uses PVGIS-SARAH2 data from the Ouargla region over the period 2015–2020. Several Machine Learning and Deep Learning models are developed and compared in order to identify the most accurate forecasting approach. The results show that artificial intelligence techniques improve prediction accuracy and enable more efficient energy management, leading to better utilization of solar energy resources.

**Keywords:** Artificial intelligence, photovoltaic energy, forecasting, Machine Learning, Deep Learning, battery, energy management.

## ملخص

يأتي هذا العمل في إطار التحول الطاقوي وتحسين أداء أنظمة الطاقة الشمسية الكهروضوئية. يقترح هذا البحث مقارنة تعتمد على الذكاء الاصطناعي من أجل التنبؤ بقدرة الإنتاج الكهروضوئي وتحسين تسيير الطاقة في نظام مزود بتخزين عبر البطاريات. تم استخدام بيانات PVGIS-SARAH2 الخاصة بمنطقة ورقلة خلال الفترة 2015–2020. تم تطوير ومقارنة عدة نماذج من التعلم الآلي والتعلم العميق من أجل تحديد النموذج الأكثر دقة في التنبؤ. أظهرت النتائج أن تقنيات الذكاء الاصطناعي تساهم في تحسين دقة التنبؤ وتسمح بتسيير أمثل للطاقة، مما يعزز كفاءة استغلال الطاقة الشمسية.

**الكلمات المفتاحية:** الذكاء الاصطناعي، الطاقة الكهروضوئية، التنبؤ، التعلم الآلي، التعلم العميق، البطارية، تسيير الطاقة.

## *Table des matières*

|                                                                       |    |
|-----------------------------------------------------------------------|----|
| Introduction générale .....                                           | 1  |
| I. Chapitre I Généralités sur les systèmes photovoltaïques .....      | 2  |
| I.1 Introduction .....                                                | 2  |
| I.2 Définition de l'énergie solaire .....                             | 2  |
| I.2.1 Types d'exploitation de l'énergie solaire .....                 | 2  |
| I.2.2 Le rayonnement solaire .....                                    | 2  |
| I.2.3 Potentiel d'énergie solaire en Algérie .....                    | 4  |
| I.3 Conversion photovoltaïque .....                                   | 4  |
| I.3.1 Principe de conversion photovoltaïque .....                     | 4  |
| I.3.2 L'effet photovoltaïque .....                                    | 5  |
| I.4 La cellule photovoltaïque .....                                   | 5  |
| I.4.1 Structure et fonctionnement .....                               | 5  |
| I.4.2 Types de cellules photovoltaïques .....                         | 6  |
| I.4.2.1 Cellules monocristallines .....                               | 6  |
| I.4.2.2 Cellules polycristallines .....                               | 6  |
| I.4.2.3 Cellules amorphes .....                                       | 6  |
| I.4.3 Caractéristiques électriques d'une cellule photovoltaïque ..... | 7  |
| I.5 Module et panneau photovoltaïque .....                            | 8  |
| I.6 Architecture d'un Système Photovoltaïque .....                    | 9  |
| I.6.1 Système autonome (off-grid) .....                               | 9  |
| I.6.2 Système raccordé au réseau (grid-connected) .....               | 10 |
| I.6.3 Système hybride .....                                           | 11 |
| I.7 Composants d'un Système Photovoltaïque .....                      | 11 |
| I.7.1 L'onduleur .....                                                | 12 |
| I.7.2 Le régulateur de charge .....                                   | 12 |
| I.7.3 La batterie solaire .....                                       | 13 |
| I.8 Facteurs Influençant la Production Photovoltaïque .....           | 13 |
| I.9 Conclusion .....                                                  | 14 |
| II. Chapitre II État de l'art de l'Intelligence Artificielle .....    | 15 |
| II.1 Introduction .....                                               | 15 |
| II.2 Intelligence artificielle .....                                  | 15 |
| II.3 Apprentissage automatique (Machine Learning) .....               | 16 |
| II.3.1 Définition et principe .....                                   | 16 |
| II.3.2 Types d'apprentissage automatique .....                        | 17 |

|           |                                                                                                                            |    |
|-----------|----------------------------------------------------------------------------------------------------------------------------|----|
| II.3.2.1  | Apprentissage supervisé (Supervised Learning)                                                                              | 17 |
| II.3.2.2  | Apprentissage non supervisé                                                                                                | 18 |
| II.3.2.3  | Apprentissage semi-supervisé                                                                                               | 18 |
| II.3.2.4  | Apprentissage par renforcement                                                                                             | 19 |
| II.3.3    | Modèles de Machine Learning sélectionnés                                                                                   | 19 |
| II.3.3.1  | Random Forest                                                                                                              | 19 |
| II.3.3.2  | XGBoost (Extreme Gradient Boosting)                                                                                        | 21 |
| II.3.4    | Apprentissage profond (Deep Learning)                                                                                      | 22 |
| II.3.4.1  | Définition du Deep Learning                                                                                                | 22 |
| II.3.4.2  | Réseaux de neurones artificiels (RNA)                                                                                      | 22 |
| II.3.5    | Modèles de Deep Learning sélectionnés                                                                                      | 23 |
| II.3.5.1  | Long Short-Term Memory (LSTM)                                                                                              | 23 |
| II.3.5.2  | Gâte Récurrent Unit (GRU)                                                                                                  | 25 |
| II.4      | Revue de la littérature relative à la prévision de la puissance photovoltaïque et à l'optimisation du stockage énergétique | 27 |
| II.4.1    | Prévision de la puissance photovoltaïque                                                                                   | 27 |
| II.4.2    | Optimisation de la gestion du stockage énergétique                                                                         | 28 |
| II.4.3    | Synthèse et positionnement de l'étude                                                                                      | 28 |
| II.5      | Conclusion                                                                                                                 | 29 |
| III.      | Chapitre III Méthodologie de travail                                                                                       | 30 |
| III.1     | Introduction                                                                                                               | 30 |
| III.2     | Architecture globale du système proposé                                                                                    | 30 |
| III.3     | Collecte et description des données                                                                                        | 31 |
| III.4     | Prétraitement des données                                                                                                  | 32 |
| III.4.1   | Nettoyage des données                                                                                                      | 32 |
| III.4.2   | Construction des features                                                                                                  | 32 |
| III.4.3   | Normalisation des données                                                                                                  | 33 |
| III.4.4   | Séparation des données                                                                                                     | 33 |
| III.4.5   | Préparation des séquences temporelles pour les modèles de Deep Learning                                                    | 34 |
| III.5     | Environnement de développement                                                                                             | 34 |
| III.5.1   | Google Colab                                                                                                               | 34 |
| III.5.2   | Python                                                                                                                     | 35 |
| III.5.3   | Bibliothèques utilisées                                                                                                    | 35 |
| III.5.4   | Modèles d'apprentissage utilisés                                                                                           | 35 |
| III.5.4.1 | Random Forest                                                                                                              | 35 |
| III.5.4.2 | XGBoost                                                                                                                    | 36 |
| III.5.4.3 | LSTM & GRU                                                                                                                 | 36 |

---

|           |                                                               |    |
|-----------|---------------------------------------------------------------|----|
| III.5.4.4 | Modèle hybride (GRU et RF) .....                              | 37 |
| III.6     | Métriques d'évaluation des modèles .....                      | 38 |
| III.7     | Optimisation du système de stockage par batterie .....        | 39 |
| III.7.1   | Présentation et modélisation du système.....                  | 39 |
| III.7.2   | Contraintes et Paramètres de Simulation .....                 | 40 |
| III.7.3   | Stratégies de Gestion Comparées .....                         | 40 |
| III.7.4   | Indicateurs de Performance (KPIs) .....                       | 41 |
| III.8     | Conclusion.....                                               | 42 |
| IV.       | Chapitre IV Résultats et Discussion.....                      | 43 |
| IV.1      | Introduction .....                                            | 43 |
| IV.2      | Analyse exploratoire des données PV .....                     | 43 |
| IV.3      | Résultats de la Prédiction de la Puissance PV.....            | 45 |
| IV.3.1    | Résultats des Modèles Machine Learning.....                   | 45 |
| IV.3.2    | Résultats des Modèles Deep Learning .....                     | 46 |
| IV.3.3    | Résultats du Modèle Hybride RF+GRU .....                      | 48 |
| IV.3.4    | Comparaison Globale de Tous les Modèles .....                 | 49 |
| IV.4      | Résultats de l'Optimisation Intelligente de la Batterie ..... | 51 |
| IV.4.1    | Évolution du SoC .....                                        | 51 |
| IV.4.2    | Décisions de Charge et Décharge.....                          | 51 |
| IV.4.3    | Bilan Énergétique et Énergie Cumulative .....                 | 52 |
| IV.4.4    | Comparaison des Indicateurs de Performance (KPIs).....        | 54 |
| IV.5      | Discussion et Analyse.....                                    | 55 |
| IV.6      | Conclusion.....                                               | 55 |
|           | Conclusion Générale.....                                      | 57 |
|           | Références bibliographiques.....                              | 58 |
|           | Annexes .....                                                 | 62 |

## *Table des figures*

|                                                                                                                                                                     |    |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figure I-1 : Normes de mesures du spectre d'énergie lumineuse émis par le soleil, notion de la convention AM .....                                                  | 3  |
| Figure I-2: Composantes du rayonnement solaire .....                                                                                                                | 3  |
| Figure I-3 : Carte du gisements solaires en Algerie.....                                                                                                            | 4  |
| Figure I-4 : Principe de fonctionnement d'une cellule photovoltaïque sous éclairement .                                                                             | 5  |
| Figure I-5 : Formation de la jonction P-N et de la zone de charge d'espace.....                                                                                     | 6  |
| Figure I-6 : Types de cellules photovoltaïques .....                                                                                                                | 7  |
| Figure I-7 : Courbes caractéristiques I–V et P–V d’une cellule photovoltaïque .....                                                                                 | 7  |
| Figure I-8 : Module PV.....                                                                                                                                         | 9  |
| Figure I-9 : Schéma système off-grid .....                                                                                                                          | 10 |
| Figure I-10 : Schéma système grid-connected.....                                                                                                                    | 10 |
| Figure I-11 : Architecture d'un système de production hybride multi sources .....                                                                                   | 11 |
| Figure I-12 : Onduleur solaire photovoltaïque .....                                                                                                                 | 12 |
| Figure I-13 : Régulateur de charge .....                                                                                                                            | 12 |
| Figure I-14 : Trois types de batteries .....                                                                                                                        | 13 |
| Figure II-1 : Différences fondamentales entre l'IA, le ML et le DL .....                                                                                            | 15 |
| Figure II-2 : Un modèle de ML qui essaye d'obtenir la meilleure approximation possible de F .....                                                                   | 16 |
| Figure II-3 : classification les types de Machine Learning.....                                                                                                     | 17 |
| Figure II-4 : Schéma explicatif d’apprentissage automatique supervisé .....                                                                                         | 18 |
| Figure II-5 : Composants importants de la méthode d'apprentissage par renforcement profond .....                                                                    | 19 |
| Figure II-6 : schéma de la forêt aléatoire .....                                                                                                                    | 20 |
| Figure II-7 : Architecture et principe de fonctionnement de XGBoost .....                                                                                           | 21 |
| Figure II-8 : Architecture générale d’un réseau de neurones profond .....                                                                                           | 23 |
| Figure II-9 : : Architecture d’une cellule LSTM montrant la porte d’oubli, la porte d’entrée, la porte de sortie et le mécanisme de mise à jour de la mémoire. .... | 25 |
| Figure II-10 : Architecture des GRU .....                                                                                                                           | 26 |
| Figure III-1 : illustre l'architecture globale du système proposé .....                                                                                             | 30 |
| Figure III-2 : Google (Colab) Logo .....                                                                                                                            | 34 |
| Figure III-3 : Langage de programmation python .....                                                                                                                | 35 |
| Figure IV-1 : Extrait du dataset.....                                                                                                                               | 43 |
| Figure IV-2: Production PV horaire complète de (2015-2020) .....                                                                                                    | 43 |
| Figure IV-3: Influence de l'irradiance, de la température et du vent sur la production PV (1 semaine).....                                                          | 44 |
| Figure IV-4 : Découpage chronologique.....                                                                                                                          | 45 |
| Figure IV-5 : Prédiction vs Réel : RF (série temporelle + zoom 3 jours + scatter plot) .                                                                            | 45 |
| Figure IV-6 : Prédiction vs Réel : XGBoost (série temporelle + zoom 3 jours + scatter plot) .....                                                                   | 46 |
| Figure IV-7 : Courbes de Loss - Train vs Validation (LSTM   GRU).....                                                                                               | 47 |
| Figure IV-8 : Prédiction vs Réel : LSTM (série temporelle + zoom 3 jours + scatter plot) .....                                                                      | 47 |
| Figure IV-9 : Prédiction vs Réel : GRU (série temporelle + zoom 3 jours + scatter plot) .....                                                                       | 48 |
| Figure IV-10 : Prédiction vs Réel : Hybride RF+GRU (série temporelle + zoom 3 jours + scatter plot).....                                                            | 49 |

|                                                                                        |    |
|----------------------------------------------------------------------------------------|----|
| Figure IV-11 : Comparaison des 4 métriques pour tous les modèles (graphes barres)...   | 50 |
| Figure IV-12 : Comparaison globale : tous les modèles vs PV réel (zoom 3 jours).....   | 50 |
| Figure IV-13 : Évolution du SoC :Stratégie Baseline vs Stratégie Optimisée (IRBPC).    | 51 |
| Figure IV-14 : Décisions Charge/Décharge : Baseline (a) vs Stratégie Optimisée IRBPC   |    |
| (b) .....                                                                              | 52 |
| Figure IV-15 : Bilan Énergétique Global : PV prédit   Charge   Batterie   Réseau ..... | 53 |
| Figure IV-16 : Énergie Cumulée Importée du Réseau : Baseline vs Stratégie Optimisée    |    |
| .....                                                                                  | 53 |
| Figure IV-17 : KPIs comparatifs en barres groupées : Baseline vs Stratégie Optimisée   | 54 |

## *Liste des tableaux*

|                                                                                                     |    |
|-----------------------------------------------------------------------------------------------------|----|
| Tableau II-1 : L'apprentissage supervisé et non supervisé .....                                     | 18 |
| Tableau III-1 : Description des variables du dataset .....                                          | 31 |
| Tableau III-2 : Variables temporelles générées à partir de l'index temporel .....                   | 32 |
| Tableau III-3 : Variables temporelles générées à partir de l'index temporel .....                   | 33 |
| Tableau III-4 : Répartition du dataset en ensembles d'apprentissage, de validation et de test ..... | 34 |
| Tableau III-5 : Bibliothèques Python utilisées.....                                                 | 35 |
| Tableau III-6 : Hyperparamètres du modèle Random Forest.....                                        | 36 |
| Tableau III-7 : Hyperparamètres du modèle XGBoost .....                                             | 36 |
| Tableau III-8 : Hyperparamètres communs des modèles LSTM et GRU.....                                | 36 |
| Tableau III-9 : Règles de décision de la stratégie IRBPC.....                                       | 41 |
| Tableau IV-1 : Métriques des modèles ML.....                                                        | 46 |
| Tableau IV-2 : Métriques des modèles DL .....                                                       | 48 |
| Tableau IV-3 : Poids du modèle hybride RF+GRU .....                                                 | 48 |
| Tableau IV-4 : Métriques du modèle hybride RF+GRU.....                                              | 49 |
| Tableau IV-5 : Classement final de tous les modèles.....                                            | 49 |
| Tableau IV-6 : Comparaison des KPIs : Baseline vs Stratégie Optimisée IRBPC .....                   | 54 |

### ***Liste des abréviations***

|                |                                                                                                                        |
|----------------|------------------------------------------------------------------------------------------------------------------------|
| <b>AC</b>      | : Alternating Current (Courant Alternatif)                                                                             |
| <b>AI / IA</b> | : Artificial Intelligence (Intelligence Artificielle)                                                                  |
| <b>AM</b>      | : Air Mass (Masse d'Air)                                                                                               |
| <b>BESS</b>    | : Battery Energy Storage System (Système de Stockage d'Énergie par Batterie)                                           |
| <b>BiLSTM</b>  | : Bidirectional Long Short-Term Memory (Mémoire à Court et Long Terme Bidirectionnelle)                                |
| <b>CA</b>      | : Courant Alternatif (Alternating Current)                                                                             |
| <b>CC</b>      | : Courant Continu (Direct Current)                                                                                     |
| <b>CNN</b>     | : Convolutional Neural Network (Réseau de Neurones Convolutif)                                                         |
| <b>CPU</b>     | : Central Processing Unit (Unité Centrale de Traitement)                                                               |
| <b>CSV</b>     | : Comma-Separated Values (Valeurs Séparées par des Virgules)                                                           |
| <b>DBSCAN</b>  | : Density-Based Spatial Clustering of Applications with Noise (Partitionnement Spatial de Données basé sur la Densité) |
| <b>DC</b>      | : Direct Current (Courant Continu)                                                                                     |
| <b>DC-DC</b>   | : Direct Current to Direct Current (convertisseur Courant Continu - Courant Continu)                                   |
| <b>DL</b>      | : Deep Learning (Apprentissage Profond)                                                                                |
| <b>FF</b>      | : Fill Factor (Facteur de Forme)                                                                                       |
| <b>GPU</b>     | : Graphics Processing Unit (Unité de Traitement Graphique)                                                             |
| <b>GRU</b>     | : Gated Recurrent Unit (Unité Récurrente à Portes)                                                                     |
| <b>GTI</b>     | : Global Tilted Irradiance (Irradiance Globale Inclinée)                                                               |
| <b>ICOA</b>    | : Improved Coot Optimization Algorithm (Algorithme d'Optimisation Coot Amélioré)                                       |
| <b>IRBPC</b>   | : Intelligent Rule-Based Predictive Control (Contrôle Prédicatif Intelligent à Base de Règles)                         |
| <b>K-NN</b>    | : K-Nearest Neighbors (K Plus Proches Voisins)                                                                         |
| <b>KPI</b>     | : Key Performance Indicator (Indicateur Clé de Performance)                                                            |
| <b>kWh</b>     | : Kilowatt-hour (Kilowattheure)                                                                                        |
| <b>LR</b>      | : Linear Regression (Régression Linéaire) / Learning Rate (Taux d'Apprentissage)                                       |
| <b>LSTM</b>    | : Long Short-Term Memory (Mémoire à Court et Long Terme)                                                               |
| <b>MAE</b>     | : Mean Absolute Error (Erreur Absolue Moyenne)                                                                         |
| <b>MAPE</b>    | : Mean Absolute Percentage Error (Erreur Absolue Moyenne en Pourcentage)                                               |
| <b>ML</b>      | : Machine Learning (Apprentissage Automatique)                                                                         |
| <b>MLP</b>     | : Multi-Layer Perceptron (Perceptron Multicouche)                                                                      |
| <b>MPP</b>     | : Maximum Power Point (Point de Puissance Maximale)                                                                    |

**MPPT** : Maximum Power Point Tracking (Recherche du Point de Puissance Maximale)

**MSE** : Mean Squared Error (Erreur Quadratique Moyenne)

**NN** : Neural Network (Réseau de Neurones)

**PCA** : Principal Component Analysis (Analyse en Composantes Principales)

**PPO** : Proximal Policy Optimization (Optimisation de Politique Proximale)

**PV** : Photovoltaic (Photovoltaïque)

**PVGIS-SARAH2** : Photovoltaic Geographical Information System - Surface Solar Radiation Data Set - Heliosat (Système d'Information Géographique Photovoltaïque - base de données d'irradiation solaire)

**PWM** : Pulse Width Modulation (Modulation de Largeur d'Impulsion)

**R<sup>2</sup>** : Coefficient of Determination (Coefficient de Détermination)

**RF** : Random Forest (Forêt Aléatoire)

**RMSE** : Root Mean Square Error (Racine de l'Erreur Quadratique Moyenne)

**RNA** : Réseau de Neurones Artificiels (Artificial Neural Network)

**RNN** : Recurrent Neural Network (Réseau de Neurones Récurrent)

**SoC** : State of Charge (État de Charge)

**SOH** : State of Health (État de Santé)

**STC** : Standard Test Conditions (Conditions Standards de Test)

**SVM** : Support Vector Machine (Machine à Vecteurs de Support)

**SVR** : Support Vector Regression (Régression par Vecteurs de Support)

**TWh** : Terawatt-hour (Térawattheure)

**XGBoost** : Extreme Gradient Boosting (Boosting de Gradient Extrême)

## *Introduction générale*

Face à l'augmentation continue de la demande énergétique mondiale et aux préoccupations environnementales liées à l'utilisation des combustibles fossiles, le développement des énergies renouvelables est devenu une nécessité. Parmi ces sources d'énergie, l'énergie solaire photovoltaïque occupe une place importante grâce à son caractère propre, durable et largement disponible, en particulier dans les régions à fort ensoleillement telles que l'Algérie.

Cependant, malgré ses nombreux avantages, la production d'énergie photovoltaïque reste fortement dépendante de plusieurs facteurs météorologiques et environnementaux, notamment l'irradiance solaire, la température ambiante, la vitesse du vent, la couverture nuageuse ainsi que les variations saisonnières. Cette dépendance entraîne une production variable et intermittente, ce qui représente un défi majeur pour l'intégration de cette énergie dans les réseaux électriques ainsi que pour la gestion des systèmes autonomes intégrant des dispositifs de stockage par batterie.

Dans ce contexte, la maîtrise de la variabilité de la production photovoltaïque devient essentielle afin d'assurer une exploitation optimale de l'énergie produite. Cela nécessite le développement de méthodes de prévision précises permettant d'anticiper la production future et d'adapter en conséquence les stratégies de gestion énergétique, notamment en ce qui concerne la charge et la décharge des batteries.

L'intelligence artificielle, et plus particulièrement les techniques de Machine Learning et de Deep Learning, constitue aujourd'hui un outil puissant pour l'analyse des données, la modélisation des systèmes complexes et la prise de décision intelligente. Ces méthodes permettent d'extraire des relations non linéaires à partir de grandes quantités de données et d'améliorer significativement la précision des modèles de prévision.

Ce mémoire s'intéresse à l'application de l'intelligence artificielle pour la prévision de la puissance photovoltaïque et l'optimisation de la gestion énergétique d'un système équipé de stockage par batterie. L'objectif principal est de développer et de comparer plusieurs modèles de prédiction afin d'identifier l'approche la plus performante, puis d'exploiter les résultats obtenus pour améliorer la stratégie de gestion énergétique du système.

Pour atteindre cet objectif, des données météorologiques et de production photovoltaïque issues de la base PVGIS-SARAH2 de la région de Ouargla (2015–2020) sont utilisées. Plusieurs modèles d'intelligence artificielle, notamment Random Forest, XGBoost, LSTM et GRU, sont développés et évalués à l'aide de différents indicateurs de performance afin de comparer leurs capacités de prévision. Les résultats obtenus sont ensuite intégrés dans une stratégie de gestion énergétique permettant d'optimiser l'utilisation du système de stockage.

Le présent mémoire est organisé en quatre chapitres. Le premier chapitre présente les généralités sur les systèmes photovoltaïques ainsi que leurs principaux composants et facteurs d'influence. Le deuxième chapitre est consacré à l'état de l'art des méthodes d'intelligence artificielle et leurs applications dans le domaine de l'énergie solaire. Le troisième chapitre décrit la méthodologie adoptée, incluant la collecte, le prétraitement des données ainsi que le développement des modèles de prédiction. Enfin, le quatrième chapitre présente les résultats obtenus, leur analyse et l'application des prévisions à l'optimisation de la gestion énergétique du système de stockage.

## I. Chapitre I Généralités sur les systèmes photovoltaïques

### I.1 Introduction

L'énergie solaire constitue l'une des sources d'énergies renouvelables les plus prometteuses dans le contexte actuel de la transition énergétique mondiale, elle joue un rôle essentiel dans la transition vers des systèmes énergétiques durables. Ce chapitre présente les notions fondamentales relatives aux systèmes photovoltaïques, leurs composants ainsi que les facteurs influençant leur production. Ces éléments sont essentiels pour comprendre le fonctionnement du système étudié dans ce mémoire.

### I.2 Définition de l'énergie solaire

L'énergie solaire représente l'énergie émise par le Soleil et reçue sur la Terre sous forme de rayonnements électromagnétiques. Elle provient des réactions de fusion nucléaire qui se produisent au cœur du Soleil. Cette énergie est diffusée sous différentes formes de rayonnements, de la lumière visible aux rayons invisibles (ultraviolets et infrarouges). Tous ces rayonnements sont composés de photons, qui constituent les particules fondamentales de la lumière et les vecteurs de l'énergie solaire [1].

#### I.2.1 Types d'exploitation de l'énergie solaire

Aujourd'hui, l'exploitation de l'énergie solaire se fait principalement selon trois méthodes [1]:

Le solaire photovoltaïque : il permet de transformer directement la lumière du Soleil en énergie électrique grâce aux panneaux photovoltaïques.

Le solaire thermique : il consiste à convertir le rayonnement solaire en chaleur utilisée pour le chauffage ou la production d'eau chaude.

Le solaire thermodynamique : il concentre le rayonnement solaire à l'aide de miroirs pour produire de la chaleur à haute température. Celle-ci génère de la vapeur qui entraîne une turbine pour produire de l'électricité.

Enfin, de nombreux programmes de recherche sont actuellement menés afin d'améliorer les performances et le rendement des technologies liées à l'exploitation de l'énergie solaire.

#### I.2.2 Le rayonnement solaire

Le rayonnement solaire est la forme sous laquelle l'énergie solaire parvient à la surface de la Terre. Il est composé de « grains » de lumière appelés photons, dont les longueurs d'onde couvrent un large spectre allant de l'ultraviolet (0,2  $\mu\text{m}$ ) au proche infrarouge (2,5  $\mu\text{m}$ ) [2]. Ce spectre se répartit en trois domaines : le rayonnement ultraviolet (0,2 – 0,4  $\mu\text{m}$ ) qui représente 5% de l'énergie totale, la lumière visible (0,4 – 0,7  $\mu\text{m}$ ) qui en constitue 43%, et le rayonnement infrarouge (0,7 – 2,5  $\mu\text{m}$ ) qui représente 52%, avec un éclaircissement maximal situé entre 450 nm et 700 nm. En traversant les différentes couches de l'atmosphère, certaines longueurs d'onde sont absorbées par des composants atmosphériques, notamment l'ozone qui absorbe les rayons ultraviolets, et la vapeur d'eau qui absorbe le rayonnement infrarouge.

Pour quantifier cette traversée, on utilise la notion de masse d'air (AM, Air Mass), dont la valeur est donnée par la relation [3]

$$AM = \left( \frac{P}{P_0} \right) \frac{1}{\sin \theta} \quad (1)$$

Où

- $P$  est la pression totale de l'air,
- $P_0 = 1,013 \times 10^5$  Pa (pression standard au niveau de la mer),
- $\theta$  est l'angle d'élévation solaire par rapport au plan horizontal.

On distingue trois cas de référence : **AM0** correspond au spectre hors atmosphère, très proche du rayonnement d'un corps noir à 5760 K ; **AM1** est obtenue pour un soleil à la verticale avec un ciel sans nuage ; et **AM1,5** représente la condition standard de mesure, avec une surface inclinée à  $37^\circ$  et un éclairement de  $100 \text{ mW/cm}^2$ . La figure I-1 illustre ces trois conditions de référence ainsi que le principe de la masse d'air (AM) lors de la traversée du rayonnement solaire à travers l'atmosphère terrestre.




Figure I-1 : Normes de mesures du spectre d'énergie lumineuse émis par le soleil, notion de la convention AM

En traversant l'atmosphère, le rayonnement global reçu au sol se divise en [4]:

- Rayonnement direct : le plus puissant, qui provient directement du soleil sans subir d'obstacles sur sa trajectoire (nuage, immeubles...).
- Rayonnement diffus : il provient des multiples diffractions et réflexions du rayonnement direct par les nuages. C'est à lui que nous devons la "lumière du jour" qui nous permet d'y voir clair même quand le temps est couvert.
- Rayonnement réfléchi (albédo) : il résulte de la réflexion du rayonnement solaire direct par le sol, qui est d'autant plus important que la surface est claire et réfléchissante (neige, étendue d'eau, ...).




Figure I-2: Composantes du rayonnement solaire

### I.2.3 Potentiel d'énergie solaire en Algérie

L'Algérie dispose de l'un des gisements solaires les plus élevés au monde grâce à sa localisation géographique au cœur de la « ceinture du soleil ». Avec environ 80 à 85% de territoire désertique dans le Sahara, le pays bénéficie d'un ensoleillement exceptionnel de 2500 à 3500 heures par an en moyenne selon les régions, pouvant atteindre 3500 heures dans le Grand Sud. L'irradiation annuelle varie de 1700 à 2650 kWh/m<sup>2</sup>, avec une durée d'insolation moyenne quotidienne d'environ 6 à 8 heures selon les saisons et les zones. Le potentiel solaire total est estimé à environ 169 000 TWh/an pour le solaire thermique (potentiel théorique) et à plusieurs dizaines de TWh/an pour le photovoltaïque selon les scénarios d'exploitation. Cette ressource considérable constitue un atout stratégique majeur pour la transition énergétique et le développement durable de l'Algérie [5].




Figure I-3 : Carte du gisements solaires en Algerie

## I.3 Conversion photovoltaïque

### I.3.1 Principe de conversion photovoltaïque

La conversion photovoltaïque est le processus par lequel l'énergie du rayonnement solaire est transformée directement en énergie électrique. Cette technologie repose sur l'utilisation de cellules photovoltaïques capables de produire un courant continu à partir de la lumière solaire. Contrairement aux méthodes conventionnelles de production d'électricité, la conversion photovoltaïque ne nécessite ni combustion de combustible ni dispositif mécanique en mouvement. L'énergie produite peut être utilisée directement, stockée dans des batteries ou convertie en courant alternatif pour alimenter divers équipements électriques. Ce processus repose sur les propriétés des matériaux semi-conducteurs, dont la structure atomique permet d'absorber les photons et de générer des paires de porteurs de charges. La chaîne de conversion comporte trois étapes : l'absorption du rayonnement, la génération de paires électron-trou sous l'effet photovoltaïque, puis la séparation et la collecte de ces charges grâce à la jonction P-N.

interne. Le rendement de cette conversion dépend de la qualité du matériau semi-conducteur, de l'intensité du rayonnement incident et de la température de fonctionnement [6].

### I.3.2 L'effet photovoltaïque

L'effet photovoltaïque est le phénomène physique à l'origine de la production d'électricité dans les cellules solaires. Lorsque les photons provenant du rayonnement solaire frappent un matériau semi-conducteur, ils transmettent leur énergie aux électrons. Si cette énergie est suffisante, les électrons sont libérés de leurs liaisons atomiques, créant ainsi des paires électron-trou. Sous l'action du champ électrique interne de la jonction P-N, ces charges sont séparées, ce qui entraîne l'apparition d'une tension électrique et la circulation d'un courant dans un circuit externe [7]. Le principe de fonctionnement d'une cellule photovoltaïque sous l'effet du rayonnement solaire est illustré par la Figure I-4.




Figure I-4 : Principe de fonctionnement d'une cellule photovoltaïque sous éclairage

## I.4 La cellule photovoltaïque

La cellule photovoltaïque, également appelée photopile, constitue l'élément de base d'un système photovoltaïque. Elle est capable de convertir directement l'énergie lumineuse en énergie électrique grâce à l'effet photovoltaïque. Plusieurs cellules sont assemblées et interconnectées afin de former un module photovoltaïque capable de fournir une puissance exploitable pour diverses applications. Une cellule photovoltaïque standard produit une tension de l'ordre de 0,5 à 0,6 V et un courant de quelques ampères selon sa surface active. Pour atteindre des niveaux de puissance significatifs, ces cellules sont assemblées en modules selon des associations série-parallèle adaptées aux besoins de l'installation. Leur matériau constitutif et leur qualité de fabrication déterminent directement le rendement global du système [8].

### I.4.1 Structure et fonctionnement

La cellule photovoltaïque est généralement fabriquée à partir de silicium, un matériau semi-conducteur largement utilisé en raison de ses propriétés électriques et de son abondance dans la nature. Afin d'améliorer sa conductivité, le silicium subit une opération appelée dopage, consistant à introduire de faibles quantités d'impuretés dans sa structure cristalline.

La couche supérieure de la cellule est dopée avec du phosphore, un élément possédant cinq électrons de valence. Ce dopage crée un excès d'électrons libres et forme une région dite de type N (négative). La couche inférieure est quant à elle dopée avec du bore, qui possède trois électrons de valence. Cette opération crée un déficit d'électrons, appelé « trou », et forme une région de type P (positive) [9].

À l'interface entre les régions P et N se forme une jonction P-N. Sous l'effet de la diffusion naturelle des porteurs de charge, une zone de déplétion apparaît autour de cette jonction. Cette zone est caractérisée par l'absence quasi totale de porteurs libres et par la présence d'un champ électrique interne orienté de la région N vers la région P.




Figure I-5 : Formation de la jonction P-N et de la zone de charge d'espace

Lorsque la cellule est exposée au rayonnement solaire, les charges électriques générées sont séparées par le champ électrique interne de la jonction P-N. Les électrons sont dirigés vers la couche N tandis que les trous migrent vers la couche P. Cette séparation permet la création d'un courant électrique continu dans le circuit extérieur.

Pour assurer la collecte du courant produit, des contacts métalliques sont déposés sur les faces avant et arrière de la cellule. Une couche antireflet est également ajoutée sur la surface exposée afin de réduire les pertes par réflexion et d'améliorer l'absorption du rayonnement solaire.

### I.4.2 Types de cellules photovoltaïques

#### I.4.2.1 Cellules monocristallines

Les cellules monocristallines sont fabriquées à partir d'un unique cristal de silicium. Elles présentent une structure homogène permettant d'obtenir des rendements élevés, généralement compris entre 18 % et 24 %. Elles sont reconnaissables à leur couleur noire uniforme et sont particulièrement adaptées lorsque la surface disponible est limitée [10].

#### I.4.2.2 Cellules polycristallines

Les cellules polycristallines sont obtenues à partir de plusieurs cristaux de silicium solidifiés ensemble. Leur procédé de fabrication est moins coûteux que celui des cellules monocristallines. Leur rendement est généralement compris entre 15 % et 18 % [10].

### I.4.2.3 Cellules amorphes

Les cellules amorphes appartiennent à la famille des technologies à couches minces. Elles utilisent du silicium non cristallisé déposé sur différents supports. Leur rendement est plus

faible, mais elles présentent une meilleure performance sous faible éclairement et une grande flexibilité d'utilisation [10].



Figure I-6 : Types de cellules photovoltaïques

### I.4.3 Caractéristiques électriques d'une cellule photovoltaïque

Le fonctionnement d'une cellule photovoltaïque est généralement décrit à l'aide de sa caractéristique courant-tension ( $I-V$ ), qui représente l'évolution du courant généré en fonction de la tension à ses bornes, depuis la condition de court-circuit jusqu'à la condition de circuit ouvert.

Contrairement à une source idéale, la cellule photovoltaïque ne fonctionne pas à un point fixe, mais à un point de fonctionnement unique qui dépend du circuit électrique auquel elle est connectée ainsi que des conditions d'ensoleillement et de température. Ce point est déterminé par l'intersection entre la caractéristique  $I-V$  de la cellule et celle de la charge électrique [11].

Ainsi, l'analyse de la courbe  $I-V$ , associée à la courbe de puissance  $P-V$ , permet de déterminer les principaux paramètres électriques caractérisant la cellule photovoltaïque et d'évaluer ses performances énergétiques.

La figure ci-dessous représente les courbes caractéristiques  $I-V$  et  $P-V$  d'une cellule photovoltaïque.




Figure I-7 : Courbes caractéristiques  $I-V$  et  $P-V$  d'une cellule photovoltaïque

### ➤ Paramètres caractéristiques

À partir des courbes caractéristiques I–V et P–V présentées à la figure I-7, plusieurs paramètres permettent de caractériser les performances électriques d'une cellule photovoltaïque :

- Courant de court-circuit ( $I_{sc}$ ) : courant maximal fourni par la cellule lorsque la tension est nulle ( $U = 0$ ).
- Tension de circuit ouvert ( $V_{oc}$ ) : tension maximale obtenue lorsque le courant est nul ( $I = 0$ ).
- Point de puissance maximale (MPP) : point de fonctionnement optimal correspondant à la puissance maximale délivrée, défini par la tension ( $V_{mp}$ ) et le courant ( $I_{mp}$ ).
- Facteur de forme (FF)

Le facteur de forme est un indicateur de la qualité électrique de la cellule photovoltaïque. Il est défini comme le rapport entre la puissance maximale et le produit du courant de court-circuit et de la tension de circuit ouvert :

$$FF = \frac{P_{max}}{I_{sc} \times V_{oc}} = \frac{V_{mp} \times I_{mp}}{V_{oc} \times I_{sc}} \quad (2)$$

Un facteur de forme élevé traduit une meilleure qualité de la cellule et de faibles pertes internes.

- Rendement énergétique ( $\eta$ )

Le rendement énergétique représente le rapport entre la puissance électrique maximale fournie par la cellule et la puissance du rayonnement solaire incident :

$$\eta = \frac{P_{max}}{P_{inc}} \quad (3)$$

avec

$P_{inc} = E \times S_a$

$E$  : éclairement solaire ( $W/m^2$ )

$S_a$  : surface active de la cellule ( $m^2$ )

$P_{max}$  : puissance maximale en conditions standards (STC :  $1000 W/m^2$ , AM1.5,  $25^\circ C$ )

## I.5 Module et panneau photovoltaïque

Un module photovoltaïque est constitué d'un ensemble de cellules photovoltaïques interconnectées électriquement et encapsulées dans une structure protectrice. Cette encapsulation assure l'isolation électrique des cellules et les protège contre les agressions extérieures telles que l'humidité, la poussière, la corrosion et les chocs mécaniques [12].

Afin d'adapter les niveaux de tension et de puissance aux applications pratiques, plusieurs cellules sont associées pour former un module selon différentes configurations électriques.

Dans une connexion en série, les tensions s'additionnent tandis que le courant reste identique :

$$U = N \times U_c \quad (4)$$

$$I = I_c \quad (5)$$

Dans une association en parallèle, les courants s'additionnent alors que la tension demeure constante :

$$U = U_c \quad (6)$$

$$I = N \times I_c \quad (7)$$

Où  $N$  représente le nombre de cellules associées.

Un panneau photovoltaïque est, quant à lui, constitué d'un ou de plusieurs modules assemblés sur une même structure mécanique. Il représente l'élément de base des installations photovoltaïques destinées à la production d'énergie électrique, permettant d'augmenter la puissance globale fournie par le système [13].




Figure I-8 : Module PV

## I.6 Architecture d'un Système Photovoltaïque

Un système photovoltaïque complet intègre un ensemble de composants permettant de convertir, stocker, réguler et distribuer l'énergie électrique produite. On distingue trois configurations principales selon le mode de raccordement au réseau électrique.

### I.6.1 Système autonome (off-grid)

Le système autonome, également appelé système off-grid, fonctionne indépendamment de tout réseau électrique public, ce qui le rend particulièrement adapté aux zones isolées et aux régions sahariennes éloignées des infrastructures [14].

Dans un système photovoltaïque autonome, le régulateur de charge a une fonction primordiale, il protège toute l'installation et notamment la batterie, qui constitue l'élément le plus sensible du système, influençant grandement la durée de vie du système. Il comprend obligatoirement un système de stockage par batteries pour assurer la continuité de l'alimentation en l'absence de soleil.




Figure I-9 : Schéma système off-grid

Ce schéma illustre les flux d'énergie dans un système autonome : le générateur photovoltaïque alimente directement la charge en journée et recharge simultanément la batterie via le régulateur de charge. En période d'absence d'ensoleillement, la batterie prend le relais pour assurer la continuité de l'alimentation. L'onduleur convertit ensuite cette énergie pour alimenter les charges en courant alternatif (AC), tandis que les équipements en courant continu (DC) sont alimentés directement.

### I.6.2 Système raccordé au réseau (grid-connected)

Dans un système photovoltaïque raccordé au réseau, le premier étage est composé d'un convertisseur DC-DC qui optimise la puissance tirée du panneau solaire, tandis que le second étage consiste en un onduleur qui convertit cette énergie pour l'injecter dans le réseau électrique. Ce dernier joue le rôle de tampon énergétique, compensant les déficits et absorbant les excédents de production.




Figure I-10 : Schéma système grid-connected

Ce schéma représente l'architecture d'un système raccordé au réseau. L'énergie photovoltaïque est d'abord optimisée par un convertisseur DC-DC (qui assure la poursuite du point de puissance maximale, ou MPPT), puis convertie en courant alternatif par un onduleur avant d'être injectée dans le réseau. Lorsque la production excède la consommation locale, l'excédent est exporté vers le réseau ; lorsque la production est insuffisante, le réseau compense le déficit. Ce mode de fonctionnement élimine le besoin de stockage par batteries, réduisant ainsi le coût d'installation.

### I.6.3 Système hybride

Un système hybride combine au moins deux sources d'énergie distinctes, intègre généralement une unité de stockage, et s'intègre à un réseau de distribution local (mini-réseau). Les panneaux photovoltaïques générant du courant continu (CC) et le réseau fonctionnant en courant alternatif (CA), le cœur du système repose sur un **onduleur multifonctionnel**. Cet équipement central assure la conversion entre CC et CA, pilote les flux de production et de stockage, et régule la tension ainsi que la fréquence du mini-réseau [14].




Figure I-11 : Architecture d'un système de production hybride multi sources

## I.7 Composants d'un Système Photovoltaïque

Une installation photovoltaïque repose sur l'association de plusieurs éléments fonctionnels destinés à produire, gérer et acheminer l'énergie électrique issue du rayonnement solaire. Le générateur photovoltaïque, composé des cellules, des modules, des panneaux et du champ solaire, a été présenté dans les sections précédentes. Outre ces éléments, une installation photovoltaïque comprend également d'autres composants essentiels tels que le régulateur de charge, les batteries de stockage, l'onduleur.

### I.7.1 L'onduleur

L'onduleur solaire est la pièce centrale entre les deux sources d'énergie auxquelles l'installation photovoltaïque est reliée les panneaux solaires qui produisent un courant continu et le réseau en courant alternatif. Son rendement de conversion est typiquement compris entre 95% et 98% pour les modèles modernes [15].



Figure I-12 : Onduleur solaire photovoltaïque

### I.7.2 Le régulateur de charge

Le régulateur gère la charge et la décharge du parc de batteries. D'une part, il limite la tension pour éviter toute surcharge ; d'autre part, il déconnecte la batterie de la charge (l'utilisation) via un système de protection automatique afin de prévenir une décharge profonde. Il existe deux technologies principales [16] :

- Le régulateur PWM (Pulse Width Modulation) : Économique et simple, il connecte directement les panneaux à la batterie, ce qui limite son efficacité énergétique.
- Le régulateur MPPT (Maximum Power Point Tracking) : Grâce à un algorithme de recherche du point de puissance maximale, il adapte en permanence la tension pour extraire le maximum d'énergie disponible des panneaux, offrant un gain d'efficacité pouvant atteindre jusqu'à 30 %.



Figure I-13 : Régulateur de charge

**I.7.3 La batterie solaire**

La batterie constitue un élément essentiel des systèmes photovoltaïques autonomes et hybrides. Elle permet de stocker l'énergie électrique produite par le générateur photovoltaïque afin de la restituer lorsque la production solaire est insuffisante ou inexistante. Toutefois, elle représente l'un des composants les plus sensibles du système, sa durée de vie étant fortement influencée par les cycles de charge et de décharge, ainsi que par les conditions de température [17] [18].

Les principales technologies de batteries utilisées dans les installations photovoltaïques sont :

a) Batteries Lithium-ion

Les batteries lithium-ion se distinguent par leur forte densité énergétique, leur rendement élevé et leur longue durée de vie. Grâce à leurs performances et à leur faible taux d'autodécharge, elles sont aujourd'hui largement utilisées dans les systèmes photovoltaïques modernes ainsi que dans les appareils électroniques portables [19].

b) Batteries Nickel-Cadmium (Ni-Cd)

Les batteries Nickel-Cadmium offrent une bonne résistance aux conditions climatiques sévères et aux décharges profondes. Elles présentent également une durée de vie relativement importante, mais leur utilisation tend à diminuer en raison de la présence de cadmium, un matériau toxique pour l'environnement.

c) Batteries Plomb-Acide

Les batteries plomb-acide sont les plus anciennes et les plus répandues dans les installations photovoltaïques en raison de leur faible coût. Cependant, elles nécessitent un entretien régulier et sont sensibles aux surcharges, aux décharges profondes ainsi qu'aux températures élevées, ce qui peut réduire leur durée de vie.



Figure I-14 : Trois types de batteries

**I.8 Facteurs Influençant la Production Photovoltaïque**

La puissance produite par un système PV dépend de plusieurs facteurs dont les principaux sont :

➤ **L'irradiance solaire**

C'est le facteur le plus déterminant. Une forte corrélation positive est généralement observée entre l'irradiance et la production photovoltaïque, confirmant la prédominance de ce paramètre sur les autres facteurs environnementaux. À température constante, la puissance générée évolue de manière quasi-linéaire avec l'intensité du rayonnement reçu [20].

➤ **La température**

Agit négativement sur le rendement. Le coefficient de température définit la perte de puissance du panneau pour chaque degré Celsius supplémentaire par rapport à la température optimale de 25°C. Les cellules silicium perdent entre 0.3% et 0.5% de puissance par degré supplémentaire, ce qui peut entraîner une diminution significative de la production d'énergie dans les environnements à températures élevées [21].

➤ **La vitesse du vent**

Elle joue un rôle double. D'un côté, un vent modéré favorise le refroidissement par convection des panneaux, ce qui abaisse leur température de fonctionnement et améliore leur rendement. D'un autre côté, un vent fort chargé de particules phénomène fréquent en milieu aride provoque un encrassement accéléré des cellules capable de réduire la production de 20% à 40%. De plus, les vents turbulents et à grande vitesse capturent les débris en suspension dans l'air, entraînant une augmentation des taux de dépôt et des risques de dommages structurels sur les installations [21].

➤ **L'ombrage et l'orientation**

Ce sont des facteurs géométriques et d'installation déterminants. L'ombre portée sur un seul module d'un champ photovoltaïque peut entraîner une diminution très marquée de la production du système tout entier ; il est donc essentiel de modéliser toutes les ombres, y compris celles générées par de petits obstacles. Pour optimiser la capture du gisement solaire, l'orientation optimale recommandée est plein Sud avec une inclinaison fixe d'environ 30° [22].

➤ **La poussière et l'encrassement**

Ils représentent un défi majeur en environnement désertique. Le dépôt continu de poussière et de particules fines sur la surface vitrée des modules réduit l'irradiance incidente atteignant les cellules actives. De plus, un dépôt hétérogène peut provoquer des déséquilibres électriques locaux et l'apparition de points chauds (*hot spots*), susceptibles de détériorer irrémédiablement les cellules en l'absence d'un entretien et d'un nettoyage réguliers [22].

Parmi ces facteurs, l'irradiance solaire, la température et la vitesse du vent constituent les variables retenues dans cette étude pour la prédiction de la puissance photovoltaïque.

## **I.9 Conclusion**

Dans ce chapitre, nous avons présenté les principes de base de l'énergie photovoltaïque, son architecture, ses composants ainsi que les facteurs influençant sa production. Cette présentation met en évidence la variabilité intrinsèque de cette source d'énergie, justifiant le recours à des techniques avancées de prédiction et d'optimisation. Le chapitre suivant est consacré à l'intelligence artificielle, outil central de ce travail.

## II. Chapitre II État de l'art de l'Intelligence Artificielle

### II.1 Introduction

Ce chapitre présente les notions fondamentales de l'intelligence artificielle, ainsi que les principes du Machine Learning et du Deep Learning. Il propose également une revue de la littérature portant sur les applications de l'IA à la prévision de la production photovoltaïque et à l'optimisation de la gestion des batteries.

### II.2 Intelligence artificielle

L'intelligence artificielle (IA) est un domaine de l'informatique qui vise à créer des systèmes capables de réaliser des tâches nécessitant l'intelligence humaine, telles que l'apprentissage, le raisonnement, la perception et la prise de décision [23].

Selon **John McCarthy**, pionnier qui a inventé ce terme en 1955 (officiellement adopté en 1956), l'IA est « la science et l'ingénierie de la fabrication de machines intelligentes » [24]. **Marvin Minsky**, autre cofondateur du domaine, précise qu'elle consiste en « la construction de programmes informatiques qui s'adonnent à des tâches accomplies de façon plus satisfaisante par des êtres humains, car elles demandent des processus mentaux de haut niveau : apprentissage perceptuel, organisation de la mémoire et raisonnement critique » [25].

L'histoire de l'IA remonte à l'Antiquité avec les premiers automates, avant de se structurer au XX<sup>e</sup> siècle. En 1950, Alan Turing propose son célèbre test pour évaluer l'intelligence des machines, mais c'est en 1956, lors de la conférence de Dartmouth, que la discipline naît officiellement. Après avoir traversé des cycles de succès et de ralentissements appelés « hivers de l'IA », le domaine connaît une renaissance majeure dans les années 1990, illustrée par la victoire de Deep Blue contre Kasparov en 1997. Depuis 2010, l'apprentissage profond (*Deep Learning*) révolutionne les technologies (AlphaGo en 2016) et s'impose dans tous les secteurs [23], une importance couronnée en 2024 par le prix Nobel de physique attribué aux pionniers des réseaux de neurones artificiels.

Pour bien appréhender ce domaine, il est indispensable de comprendre comment l'IA englobe des sous-champs plus spécifiques, notamment le Machine Learning (Apprentissage Automatique) et le Deep Learning (Apprentissage Profond), qui sont au cœur de notre étude. L'imbrication de ces technologies est illustrée par la figure suivante :




Figure II-1 : Différences fondamentales entre l'IA, le ML et le DL

## II.3 Apprentissage automatique (Machine Learning)

### II.3.1 Définition et principe

L'apprentissage automatique est un domaine dont la définition a évolué progressivement au fil des années, au rythme des nouvelles découvertes scientifiques.

En 1959, l'informaticien américain Arthur Samuel introduit pour la première fois ce concept, en développant un programme capable d'apprendre à jouer aux dames sans être explicitement programmé. Il définit alors l'apprentissage automatique comme « le domaine d'étude qui donne aux ordinateurs la capacité d'apprendre sans être explicitement programmés » [26].

En 1997, le professeur Tom Mitchell propose une définition plus rigoureuse et formelle : un programme informatique est dit apprenant lorsqu'il améliore ses performances  $P$  sur une classe de tâches  $T$ , grâce à l'accumulation de l'expérience  $E$  [27].

Par la suite, la définition évolue vers une dimension mathématique et statistique : l'apprentissage automatique est désormais vu comme une forme de statistiques appliquées, visant à estimer des fonctions complexes à partir des données, plutôt qu'à démontrer des intervalles de confiance [28].

Sur le plan formel, comme illustré dans la Figure II-2 [29], la variable cible dépend d'une fonction  $F(x)$  et d'un terme de bruit  $\varepsilon(x)$  ; l'objectif d'un modèle ML est alors de construire la meilleure fonction de prédiction  $f$  possible à partir des observations disponibles.





Figure II-2 : Un modèle de ML qui essaye d'obtenir la meilleure approximation possible de  $F$

En définitive, l'apprentissage automatique est la science qui consiste à programmer les ordinateurs pour qu'ils optimisent automatiquement leurs performances à partir des données et de l'expérience passée, à des fins de prédiction ou de description [30].

### II.3.2 Types d'apprentissage automatique

Le Machine Learning comprend plusieurs approches d'apprentissage qui se distinguent par la nature des données utilisées et la manière dont le modèle est entraîné. Il existe principalement quatre types d'apprentissage automatique comme illustré dans la figure II-3 .

Figure II-3 : classification les types de Machine Learning



#### II.3.2.1 Apprentissage supervisé (Supervised Learning)

L'apprentissage supervisé est une méthode d'apprentissage automatique dans laquelle le modèle est entraîné à partir de données étiquetées, c'est-à-dire que chaque donnée d'entrée est associée à une sortie connue. L'objectif est d'apprendre la relation existante entre les variables d'entrée et les variables de sortie afin de pouvoir prédire correctement les résultats pour de nouvelles données non observées auparavant [31].

Durant la phase d'entraînement, l'algorithme analyse les exemples fournis et ajuste progressivement ses paramètres internes pour minimiser l'erreur entre les valeurs prédites et les valeurs réelles. Une fois l'apprentissage terminé, le modèle est évalué sur un ensemble de données de test afin de vérifier sa capacité de généralisation et ses performances [28].

L'apprentissage supervisé est principalement utilisé pour résoudre des problèmes de classification et de régression.

##### ➤ Classification :

La classification est une tâche d'apprentissage supervisé dont l'objectif est d'attribuer une observation à une classe prédéfinie. Elle peut être **binaire**, lorsque deux classes seulement sont possibles, ou **multi classe**, lorsqu'il existe plusieurs catégories. Dans les deux cas, le modèle apprend à prédire la classe à laquelle appartient une nouvelle donnée à partir de ses caractéristiques [32].

##### ➤ Régression :

La régression est une tâche d'apprentissage supervisé dans laquelle la variable de sortie est une valeur continue. Son objectif est de prédire une valeur numérique aussi proche que possible de la valeur réelle. Les performances du modèle sont évaluées à l'aide d'une mesure d'erreur ; plus cette erreur est faible, plus le modèle est précis [32].




Figure II-4 : Schéma explicatif d'apprentissage automatique supervisé

### II.3.2.2 Apprentissage non supervisé

L'apprentissage non supervisé est une technique de Machine Learning qui analyse des données non étiquetées pour découvrir des motifs et structures cachés sans supervision humaine. Ses types principaux sont : le **clustering** (K-Means, DBSCAN, classification hiérarchique), la **réduction de dimensionnalité** (PCA, auto encodeurs), la **détection d'anomalies** (Isolation Forest) et les **règles d'association** [33].

Contrairement à l'apprentissage supervisé, il ne nécessite pas de données étiquetées, ce qui le rend utile quand le coût de labélisation est trop élevé. Il s'applique à la segmentation client, détection de fraude, cybersécurité et traitement du langage naturel.

Ce tableau résume la différence entre apprentissage supervisé et non supervisé :

Tableau II-1 : L'apprentissage supervisé et non supervisé

| Critère                       | Apprentissage supervisé                            | Apprentissage non Supervisé     |
|-------------------------------|----------------------------------------------------|---------------------------------|
| Les données d'entrée          | Données étiquetées<br>(Entrées et sorties connues) | Données non étiquetées          |
| Nombre de Classes             | Connu à l'avance                                   | Inconnu à l'avance              |
| Précision du résultat         | Résultats précis et fiables                        | Précision et fiabilité Modérées |
| Présence d'une variable Cible | Oui                                                | Non                             |

### II.3.2.3 Apprentissage semi-supervisé

L'apprentissage semi-supervisé est une technique d'apprentissage automatique qui combine à la fois des données étiquetées et non étiquetées pour entraîner des modèles d'IA. Il se situe à l'intersection entre l'apprentissage supervisé et non supervisé, offrant un compromis optimal qui permet de traiter un grand nombre de données sans avoir besoin de toutes les étiqueter, réduisant ainsi considérablement le coût d'annotation. Cette méthode se caractérise par la présence de quelques informations disponibles sur l'ensemble des données, soit sous forme de quelques données labellisées, soit sous forme de ressemblance ou dissemblance entre

couples de données. Le but fondamental est d'améliorer l'efficacité de l'apprentissage supervisé en utilisant des données non-étiquetées pour obtenir de meilleures performances de classifieur tout en profitant des avantages des deux autres types d'apprentissage [34].

#### II.3.2.4 Apprentissage par renforcement

Entraînement par renforcement est une technique dans laquelle on immerge un agent dans un environnement où celui-ci interagit avec son environnement dans le but d'apprendre. Le principe est illustré dans la figure II-5 un agent dans un environnement est muni de senseurs pour capter les informations de son environnement, ainsi que d'actionneurs qui lui permettront d'agir dans son environnement. Les agents observent l'entrée, puis il effectue une action en prenant des décisions. Une fois l'action réalisée, l'agent reçoit des récompenses en conséquence, ce qui renforce le modèle en stockant ses informations dans une base de données [32].

La récompense peut être positive, négative ou nulle selon les actions effectuées.




Figure II-5 : Composants importants de la méthode d'apprentissage par renforcement profond

### II.3.3 Modèles de Machine Learning sélectionnés

L'apprentissage automatique regroupe plusieurs algorithmes tels que la régression linéaire, les machines à vecteurs de support (SVM) et les k plus proches voisins (K-NN). Dans le cadre de ce travail, deux modèles d'ensemble ont été retenus, à savoir la Forêt Aléatoire (Random Forest) et XGBoost. Ces deux modèles d'ensemble sont les plus robustes et performants pour modéliser nos données.

#### II.3.3.1 Random Forest

Random Forest est un algorithme d'apprentissage automatique qui utilise de nombreux arbres de décision pour faire de meilleures prédictions. Chaque arbre examine différentes parties aléatoires des données et leurs résultats sont combinés en votant pour la classification ou en moyennant pour la régression, ce qui en fait une technique d'apprentissage en ensemble. Cela aide à améliorer la précision et à réduire les erreurs [35].




Figure II-6 : schéma de la forêt aléatoire

L'algorithme fonctionne en quatre étapes principales basées sur la combinaison de plusieurs modèles :

### 1- Création d'un ensemble d'arbres :

L'algorithme génère plusieurs arbres de décision entraînés sur des échantillons aléatoires des données d'apprentissage, selon la méthode du *bagging* (Bootstrap Aggregating). Cette approche permet de diversifier les modèles et de réduire la corrélation entre les arbres.

### 2- Sélection aléatoire des caractéristiques :

Lors de la construction de chaque nœud d'un arbre, l'algorithme ne regarde pas toutes les variables en même temps. Il en choisit un sous-ensemble au hasard pour diviser les données, garantissant la diversité des arbres.

### 3- Prédiction individuelle :

Chaque arbre de la forêt génère sa propre prédiction en fonction des données qu'il a reçues.

### 4- Agrégation des résultats :

**En classification :** La réponse finale est déterminée par un vote majoritaire (la classe la plus prédite).

**En régression (notre cas) :** la prédiction finale correspond à la moyenne des sorties de tous les arbres :

$$y_{final} = \frac{1}{T} \sum_{t=1}^T h_t(x) \quad (8)$$

Où

$y_{final}$  : La prédiction finale de la production solaire.

$T$  : Le nombre total d'arbres dans la forêt.

$\sum$ : Le symbole de la somme (addition de toutes les prédictions).

$h_t(x)$ : La prédiction individuelle donnée par le  $t$ -1 arbre.

Cette méthode d'agrégation confère à l'algorithme une excellente capacité de généralisation, car elle permet de réduire drastiquement la variance globale du système sans pour autant augmenter son biais, limitant ainsi le risque de surapprentissage (*overfitting*) face aux fortes fluctuations des variables climatiques.

### II.3.3.2 XGBoost (Extreme Gradient Boosting)

XGBoost (eXtreme Gradient Boosting) est une bibliothèque de Machine Learning open source et distribuée développée par Tianqi Chen de l'Université de Washington, qui combine des arbres de décision avec le boosting de gradient. Ce dernier est un algorithme d'apprentissage supervisé qui repose sur la descente de gradient pour optimiser les prédictions. XGBoost est réputé pour sa vitesse, son efficacité et sa capacité à traiter de grands volumes de données [36].




Figure II-7 : Architecture et principe de fonctionnement de XGBoost

#### ➤ Principe de fonctionnement

L'algorithme XGBoost repose sur la construction séquentielle d'arbres de décision afin d'améliorer progressivement la qualité des prédictions. Son fonctionnement peut être résumé selon les étapes suivantes :

##### 1- Initialisation du modèle :

L'algorithme commence par générer une première prédiction à partir d'une valeur initiale, généralement la moyenne des valeurs de la variable cible dans le cas d'un problème de régression.

##### 2- Calcul des erreurs :

Les écarts entre les valeurs réelles et les valeurs prédites sont calculés. Ces erreurs, appelées résidus, représentent les informations que le modèle n'a pas encore apprises.

##### 3- Construction d'un nouvel arbre :

Un arbre de décision est ensuite entraîné pour prédire ces résidus. Son objectif est de corriger les erreurs produites par le modèle précédent.

#### 4- Mise à jour du modèle :

Les prédictions du nouvel arbre sont ajoutées aux prédictions précédentes afin d'améliorer progressivement les résultats. Ce processus est répété plusieurs fois jusqu'à obtenir un modèle suffisamment précis.

#### 5- Prédiction finale :

La prédiction finale est obtenue par la somme pondérée des contributions de tous les arbres construits.

Dans le cas d'un problème de régression, la prédiction finale peut être exprimée par la relation suivante :

$$y_{(x)} = \sum_{k=1}^k f_k(x) \quad (9)$$

Où

$y(x)$  : la valeur prédite par le modèle ;

$f_k(x)$  : la prédiction fournie par le k-ième arbre ;

$K$  : le nombre total d'arbres construits.

L'une des principales forces de XGBoost réside dans l'intégration de mécanismes de régularisation permettant de réduire le surapprentissage. De plus, l'algorithme est capable de gérer efficacement les valeurs manquantes, d'exploiter le calcul parallèle et d'optimiser l'utilisation des ressources mémoire, ce qui en fait l'une des méthodes les plus performantes pour les tâches de prédiction [36].

### II.3.4 Apprentissage profond (Deep Learning)

#### II.3.4.1 Définition du Deep Learning

Le Deep Learning (apprentissage profond) est une branche avancée du Machine Learning qui repose sur l'utilisation de réseaux de neurones artificiels composés de plusieurs couches de traitement. Inspiré du fonctionnement du cerveau humain, il permet d'apprendre automatiquement des représentations complexes à partir de grandes quantités de données.

Le principe du Deep Learning consiste à entraîner un réseau de neurones sur un ensemble de données afin qu'il puisse réaliser différentes tâches telles que la classification, la reconnaissance d'images, le traitement du langage naturel ou la prédiction de séries temporelles. L'apprentissage est réalisé à l'aide d'algorithmes d'optimisation qui minimisent une fonction de coût afin d'améliorer progressivement les performances du modèle [37].

Contrairement aux méthodes traditionnelles de Machine Learning, le Deep Learning est capable d'extraire automatiquement les caractéristiques pertinentes des données grâce à sa structure multicouche, ce qui lui permet d'obtenir de meilleures performances pour les problèmes complexes.

#### II.3.4.2 Réseaux de neurones artificiels (RNA)

Les réseaux de neurones artificiels (RNA) sont des modèles d'apprentissage inspirés du fonctionnement du cerveau humain. Ils sont constitués d'un ensemble de neurones artificiels interconnectés organisés en plusieurs couches permettant de traiter et d'analyser les données [15].

- Un réseau de neurones se compose généralement de trois types de couches :

**Couche d'entrée :** reçoit les données initiales et les transmet au réseau.

**Couches cachées :** réalisent différentes transformations et extractions de caractéristiques à partir des données d'entrée.

**Couche de sortie :** fournit le résultat final sous forme de prédiction ou de classification.

Grâce à leur capacité à apprendre des relations complexes et non linéaires, les réseaux de neurones constituent l'une des technologies fondamentales de l'intelligence artificielle moderne. Ils sont largement utilisés dans de nombreux domaines tels que la reconnaissance d'images, le traitement du langage naturel, la prévision et l'analyse de données.

Plusieurs architectures de réseaux de neurones ont été développées pour répondre à différents types de problèmes, parmi lesquelles :

**Perceptron Multicouche (MLP) :** réseau entièrement connecté utilisé pour les tâches de classification et de régression.

**Convolutional Neural Networks (CNN) :** architecture principalement utilisée pour le traitement d'images et la vision par ordinateur.

**Recurrent Neural Networks (RNN) :** architecture conçue pour le traitement des données séquentielles et des séries temporelles.

Les RNN occupent une place importante dans les applications de prévision, notamment dans le domaine de l'énergie photovoltaïque. Ils constituent la base de modèles plus avancés tels que les réseaux Long Short-Term Memory (LSTM) et Gated Recurrent Unit (GRU), qui seront présentés dans les sections suivantes.




Figure II-8 : Architecture générale d'un réseau de neurones profond

## II.3.5 Modèles de Deep Learning sélectionnés

### II.3.5.1 Long Short-Term Memory (LSTM)

Le Long Short-Term Memory (LSTM) est un type de réseau de neurones récurrents (RNN) conçu pour apprendre les dépendances à long terme dans les données séquentielles. Il a été développé pour résoudre le problème de disparition du gradient rencontré dans les RNN traditionnels [38].

## ➤ Principe de fonctionnement

Le LSTM est constitué d'une cellule mémoire permettant de stocker les informations importantes au cours du temps. Le flux d'information est contrôlé par trois portes : la porte d'oubli, la porte d'entrée et la porte de sortie. Ces portes permettent respectivement de supprimer les informations inutiles, d'ajouter de nouvelles informations à la mémoire et de produire la sortie du réseau.

**1- Porte d'oubli (Forget Gate)**

La première étape consiste à déterminer quelles informations de l'état précédent doivent être conservées ou supprimées. Cette décision est prise par la porte d'oubli :

$$ft = \sigma(Wf \cdot [h_{t-1}, xt] + bf) \quad (10)$$

Où

$Wf$  représente la matrice de poids associée à la porte d'oubli.

$h_{t-1}, xt$  désigne la concaténation de l'entrée courante et de l'état caché précédent.

$bf$  c'est le biais avec la porte d'oubli.

$\sigma$  est la fonction d'activation sigmoïde.

La fonction sigmoïde produit des valeurs comprises entre 0 et 1. Une valeur proche de 0 signifie que l'information sera oubliée, tandis qu'une valeur proche de 1 signifie qu'elle sera conservée.

**2- Porte d'entrée (Input Gate)**

La porte d'entrée détermine quelles nouvelles informations doivent être ajoutées à la mémoire.

$$it = \sigma(Wi \cdot [h_{t-1}, xt] + bi) \quad (11)$$

Cette équation génère un vecteur de sélection indiquant quelles informations doivent être mises à jour.

Ensuite, un vecteur candidat contenant les nouvelles informations est calculé :

$$\hat{c}_t = \tanh(Wc \cdot [h_{t-1}, xt] + bc) \quad (12)$$

fonction tangente hyperbolique produit des valeurs comprises entre -1 et 1. Ces valeurs représentent les nouvelles informations susceptibles d'être stockées dans la mémoire.

L'état de la cellule est ensuite mis à jour selon :

$$C_t = ft \odot c_{t-1} + it \odot \hat{c}_t \quad (13)$$

Où

$c_{t-1}$  représente l'état mémoire précédent ;

$C_t$  représente le nouvel état mémoire ;

( $\odot$ ) désigne la multiplication élément par élément.

Cette équation combine les informations conservées de l'ancien état mémoire avec les nouvelles informations sélectionnées par la porte d'entrée.

### 3- Porte de sortie (Output Gate)

La porte de sortie détermine quelles informations de la mémoire seront transmises à la sortie du réseau.

$$ot = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (14)$$

Le vecteur obtenu agit comme un filtre sur l'état mémoire mis à jour.

L'état caché de sortie est alors calculé par :

$$ht = ot \odot \tanh(C_t) \quad (15)$$

$ot$  est l'activation de la porte de sortie.

$C_t$  est l'état cellulaire actuel.

$\odot$  représente la multiplication élément par élément.

$\sigma$  est la fonction d'activation sigmoïde.

Cette équation produit la sortie finale du bloc LSTM. La mémoire ( $C_t$ ) est d'abord transformée par la fonction ( $\tanh$ ), puis filtrée par la porte de sortie ( $ot$ ). Le résultat ( $ht$ ) est transmis à l'étape suivante du réseau et peut également être utilisé comme sortie du modèle.




Figure II-9 : : Architecture d'une cellule LSTM montrant la porte d'oubli, la porte d'entrée, la porte de sortie et le mécanisme de mise à jour de la mémoire.

#### II.3.5.2 Gâte Récurrent Unit (GRU)

Le Gated Recurrent Unit (GRU) est une variante simplifiée des réseaux de neurones récurrents (RNN), proposée pour résoudre le problème de disparition du gradient tout en réduisant la complexité de calcul par rapport au LSTM. Contrairement au LSTM, le GRU utilise uniquement deux portes : la porte de mise à jour (*Update Gate*) et la porte de réinitialisation (*Reset Gate*) [39].

#### ➤ Principe de fonctionnement

Le GRU combine directement la mémoire et l'état caché dans une seule représentation. Son fonctionnement repose sur deux mécanismes principaux : la porte de mise à jour, qui contrôle la quantité d'informations conservées du passé, et la porte de réinitialisation, qui détermine la quantité d'informations passées à oublier lors du calcul du nouvel état caché.

- Équations pour les opérations du GRU

Le fonctionnement interne d'un GRU peut être décrit à l'aide des équations suivantes

1. Réinitialisation de la porte :

$$r_t = \sigma(w_r \cdot [h_{t-1}, x_t] + b_r) \quad (16)$$

La porte de réinitialisation contrôle combien de l'état caché précédent est utilisé lors du calcul de l'état caché candidat.

2. Porte de mise à jour :

$$z_t = \sigma(w_z \cdot [h_{t-1}, x_t] + b_z) \quad (17)$$

La porte de mise à jour contrôle l'équilibre entre le maintien de l'état caché précédent et l'intégration de l'état caché candidat.

Architecture des GRU

3. État caché du candidat :

$$h'_t = \tanh(w_h \cdot [r_t \cdot h_{t-1}, x_t] + b_h) \quad (18)$$

est le nouvel état caché potentiel calculé en fonction de l'entrée actuelle et de l'état caché précédent.

4. État caché :

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot h'_t \quad (19)$$

L'état caché final est une moyenne pondérée de l'état caché précédent  $h_{t-1}$  et de l'état caché candidat  $h'_t$  basé sur la porte de mise à jour  $z_t$ .

Le GRU permet ainsi de mémoriser les informations importantes sur de longues séquences tout en réduisant le nombre de paramètres par rapport au LSTM.




Figure II-10 : Architecture des GRU

## II.4 Revue de la littérature relative à la prévision de la puissance photovoltaïque et à l'optimisation du stockage énergétique

L'intelligence artificielle (IA) joue un rôle essentiel dans l'optimisation des systèmes photovoltaïques, contribuant à améliorer leur performance, leur fiabilité et leur efficacité énergétique. Parmi les applications les plus notables, on trouve la prévision de la production d'énergie solaire, l'optimisation du suivi du point de puissance maximale (MPPT), ainsi que la détection et le diagnostic des défauts. De plus, l'IA permet une maintenance prédictive et une gestion intelligente des systèmes de stockage d'énergie. En particulier, la prévision de la puissance photovoltaïque et l'optimisation de la gestion des batteries sont cruciales, car elles permettent d'améliorer l'exploitation des installations solaires et de garantir une continuité optimale de l'alimentation électrique. Cette section présente les principaux travaux de recherche réalisés dans ces deux domaines.

### II.4.1 Prévision de la puissance photovoltaïque

La prévision de la production d'énergie solaire constitue un enjeu majeur pour les gestionnaires de réseaux électriques et les exploitants de centrales. Étant donné que cette production dépend fortement des conditions météorologiques, plusieurs chercheurs ont développé des modèles utilisant l'intelligence artificielle pour en améliorer la précision.

Dans une étude publiée dans la revue *Energy*, plusieurs algorithmes de Machine Learning ont été comparés pour la prévision de la production photovoltaïque, notamment Random Forest (RF), Support Vector Machine (SVM), Neural Network (NN) et Linear Regression (LR). Les auteurs ont développé 64 modèles de prévision et les ont validés à partir de données réelles de production solaire. Les résultats ont montré que le modèle Random Forest obtenait les meilleures performances avec un RMSE moyen de 32, contre 32,3 pour le SVM, 36,5 pour la régression linéaire et 38,9 pour les réseaux de neurones. Les auteurs concluent que Random Forest représente l'une des approches les plus robustes pour la prévision photovoltaïque [40].

Faris et Chouder ont évalué les performances de plusieurs algorithmes de Machine Learning pour la prévision de la puissance photovoltaïque, notamment Random Forest (RF), Support Vector Regression (SVR) et eXtreme Gradient Boosting (XGBoost). Les auteurs ont utilisé des données météorologiques ainsi que des données historiques de production photovoltaïque afin d'entraîner et de tester les différents modèles. Les résultats obtenus ont montré que le modèle XGBoost offrait une précision supérieure à celle des modèles RF et SVR grâce à sa capacité à capturer les relations non linéaires entre les variables d'entrée et la puissance produite. Les auteurs concluent que XGBoost constitue une solution efficace pour la prévision photovoltaïque et peut être utilisé comme alternative performante aux méthodes traditionnelles de Machine Learning [41].

Par ailleurs en 2024, Jiang et ses collègues ont développé un modèle hybride qui combine un réseau de neurones bidirectionnel à mémoire longue (BiLSTM) avec un algorithme d'optimisation connu sous le nom d'Improved Coot Optimization Algorithm (ICOA). Pour mener à bien leur recherche, ils ont utilisé des données météorologiques, incluant l'irradiance solaire, la température et l'humidité, ainsi que des données historiques relatives à la production photovoltaïque. Les résultats expérimentaux obtenus révèlent un coefficient de détermination  $R^2$  de 99,898 %, une erreur quadratique moyenne (RMSE) de 0,02081 kW et une erreur absolue moyenne (MAE) de 0,01473 kW, attestant ainsi de l'excellente précision du modèle proposé [42].

Dans une autre étude, Wang et ses collaborateurs ont conçu un modèle reposant sur des réseaux LSTM pour effectuer des prévisions à court terme de la production d'énergie

photovoltaïque. Ils ont comparé les performances d'un modèle qui se basait uniquement sur les données historiques de production avec celles d'un modèle qui intégrait également des paramètres météorologiques. Les résultats ont montré une diminution du RMSE de 34,87 % lorsque les données météorologiques étaient incluses, soulignant ainsi l'importance cruciale de ces variables dans le processus de prévision [43].

#### II.4.2 Optimisation de la gestion du stockage énergétique

Le stockage de l'énergie constitue un élément fondamental dans les systèmes photovoltaïques, en raison de l'intermittence de la production solaire. Les batteries stockent l'énergie excédentaire pour l'utiliser lorsque la production est faible. Une gestion inefficace peut dégrader les batteries et augmenter les coûts. Des recherches récentes suggèrent d'utiliser l'intelligence artificielle pour optimiser cette gestion.

Dans ce cadre, une approche basée sur l'apprentissage par renforcement a été proposée par Kofinas (2021) pour optimiser la gestion énergétique d'un système photovoltaïque avec batterie. Cette méthode permet d'apprendre automatiquement les stratégies optimales de charge et de décharge en fonction de la production solaire et de la demande énergétique. Les résultats obtenus montrent une réduction des coûts énergétiques et une amélioration de l'autoconsommation du système [44].

Hosseini et autres chercheurs (2023) aussi ont proposé une approche basée sur l'apprentissage par renforcement (*Reinforcement Learning*) utilisant l'algorithme Proximal Policy Optimization (PPO) pour optimiser la gestion énergétique d'un micro-réseau intégrant des panneaux photovoltaïques, une batterie de stockage et une charge électrique. Le modèle développé apprend automatiquement les stratégies optimales de gestion des flux d'énergie entre les différentes composantes du système sans recourir à un modèle physique complexe. Les résultats obtenus ont montré une amélioration de l'efficacité énergétique globale ainsi qu'une meilleure répartition de l'énergie entre la production photovoltaïque, le stockage et la consommation. Les auteurs concluent que l'apprentissage par renforcement constitue une solution efficace pour la gestion intelligente des systèmes photovoltaïques avec stockage énergétique [45].

Enfin, Wang et (2020) ont utilisé des réseaux de neurones artificiels pour estimer l'état de santé (State of Health – SOH) des batteries lithium-ion. Les résultats obtenus montrent une précision supérieure à 95 %, permettant une meilleure anticipation du vieillissement des batteries et une optimisation de leur durée de vie [46].

#### II.4.3 Synthèse et positionnement de l'étude

L'analyse des travaux présentés met en évidence l'apport significatif de l'intelligence artificielle dans le domaine photovoltaïque. Les modèles de Machine Learning et de Deep Learning ont démontré leur efficacité pour améliorer la précision des prévisions de production solaire, tandis que les approches intelligentes de gestion énergétique permettent d'optimiser l'utilisation des batteries et d'améliorer les performances des systèmes de stockage.

Cependant, les études existantes abordent généralement ces problématiques de manière indépendante. Dans ce contexte, la présente étude propose une approche combinant la prévision de la puissance photovoltaïque et la gestion intelligente du stockage énergétique. L'objectif est d'exploiter les prévisions de production pour orienter les décisions de charge et de décharge des batteries, afin d'améliorer l'exploitation de l'énergie solaire et les performances globales du système.

**II.5 Conclusion**

Ce chapitre nous a permis de présenter les bases théoriques de l'intelligence artificielle ainsi que les modèles retenus pour ce travail. Nous avons examiné les techniques de Machine Learning et de Deep Learning, en mettant l'accent sur les modèles Random Forest, XGBoost, LSTM et GRU. La revue de littérature a confirmé l'efficacité de ces approches pour la prédiction photovoltaïque et l'optimisation du stockage. Dans le chapitre suivant, nous détaillons la méthodologie mise en œuvre pour appliquer ces techniques au site de Ouargla.

### III. Chapitre III Méthodologie de travail

#### III.1 Introduction

Dans les systèmes photovoltaïques, la puissance produite est fortement influencée par plusieurs paramètres météorologiques tels que l'irradiance solaire, la température ambiante et la vitesse du vent. Cette variabilité rend la gestion énergétique plus complexe, ce qui nécessite des méthodes de prédiction précises et fiables.

Ce chapitre présente la méthodologie adoptée dans ce travail. Nous décrivons la démarche suivie pour la prédiction de la puissance photovoltaïque à partir des données PVGIS-SARAH2, ainsi que l'optimisation d'un système de stockage par batterie (BESS) basée sur ces prévisions, afin d'améliorer la gestion et la performance du système énergétique.

#### III.2 Architecture globale du système proposé

L'architecture proposée décrit un système photovoltaïque intelligent intégrant des capteurs météorologiques, un panneau PV, un système de stockage par batterie et un module d'intelligence artificielle. Les données météorologiques et de production sont d'abord collectées puis prétraitées avant d'être exploitées par les modèles de Machine Learning pour la prévision de la puissance PV.

La puissance prédite est ensuite utilisée par un algorithme d'optimisation pour gérer la batterie en temps réel (charge/décharge). Enfin, l'énergie est distribuée vers la charge ou le réseau via le bus AC. Cette architecture permet d'optimiser la gestion énergétique globale en améliorant la prévision, la décision et l'utilisation de l'énergie solaire (figure III-1).




Figure III-1 : illustre l'architecture globale du système proposé

**Remarque : Choix du couplage AC**

Le système adopte un **couplage AC** (batterie reliée au bus alternatif via un convertisseur bidirectionnel) plutôt qu'un couplage DC direct après les panneaux pour deux raisons :

1. **Meilleur rendement** : L'électricité solaire alimente directement la maison en journée après une seule conversion (DC  $\rightarrow$  AC), évitant les pertes d'un passage systématique par la batterie.
2. **Flexibilité de contrôle** : Cela permet à l'algorithme d'optimisation (IRBPC) de gérer intelligemment la batterie en l'interfaçant à la fois avec la production solaire locale, les besoins de la maison et le réseau électrique externe.

**III.3 Collecte et description des données**

Les données utilisées dans cette étude proviennent de la base PVGIS-SARAH2 (Photovoltaic Geographical Information System), élaborée par le Centre commun de recherche de la Commission européenne, et disponible au format CSV.

La zone étudiée est Ouargla, située au sud de l'Algérie (31,95°N, 5,32°E), que nous avons sélectionnée en raison de son fort potentiel solaire et de son importance stratégique dans le développement des projets photovoltaïques en Algérie. Cette région bénéficie d'un des plus forts ensoleillements annuels du pays, ce qui la rend particulièrement adaptée aux installations photovoltaïques.

Le jeu de données couvre une période de six ans, de 2015 à 2020, avec une résolution horaire. Il contient environ 52 560 observations et plusieurs paramètres météorologiques influençant la production photovoltaïque.

Ces données sont utilisées comme variables d'entrée et sortie pour les modèles de Machine et Deep Learning afin de prédire la puissance photovoltaïque produite.

(Des autres features temporelles et de lag sont ensuite construites à partir de ces variables lors de l'étape de prétraitement).

Tableau III-1 : Description des variables du dataset

| Variable                   | Description                                                        | Unité            | Rôle   |
|----------------------------|--------------------------------------------------------------------|------------------|--------|
| Irradiance globale incliné | Irradiation solaire totale sur panneau incliné                     | W/m <sup>2</sup> | Entrée |
| Température de l'Air à 2 m | Température ambiante                                               | °C               | Entrée |
| Vitesse du vent            | Vitesse de vent local, influençant Le refroidissement des panneaux | m/s              | Entrée |
| P_pv (puissance PV)        | Puissance électrique produite                                      | kW/kWp           | Sortie |

### III.4 Prétraitement des données

Le prétraitement des données constitue une étape indispensable dans tout projet de modélisation basé sur le Machine Learning, le Deep Learning ou les approches hybrides. Il consiste à transformer les données brutes en un format exploitable par les algorithmes d'apprentissage, tout en améliorant leur qualité et leur cohérence. Nous décomposons cette étape en cinq parties principales : le nettoyage des données, la construction des features et la normalisation.

#### III.4.1 Nettoyage des données

Nous commençons par détecter et traiter les anomalies présentes dans les données brutes. Les valeurs manquantes étant très peu nombreuses, leur suppression n'a pas affecté significativement la taille du jeu de données. Les doublons éventuels sont également éliminés pour assurer la cohérence et l'intégrité du jeu de données.

Par ailleurs, les valeurs physiquement incohérentes sont identifiées et supprimées, notamment les valeurs de production photovoltaïque négatives, qui sont impossibles d'un point de vue physique.

#### III.4.2 Construction des features

À partir des variables météorologiques et de l'index temporel, nous construisons des features supplémentaires afin d'enrichir l'information fournie aux modèles et de capturer les patterns cycliques et la mémoire temporelle de la production solaire.

##### a) Features temporelles

L'index temporel horaire est décomposé en plusieurs variables numériques permettant aux modèles de capturer la saisonnalité et les cycles journaliers :

Tableau III-2 : Variables temporelles générées à partir de l'index temporel

| Feature   | Description         | valeurs                      |
|-----------|---------------------|------------------------------|
| Hour      | Heure de la journée | 0-23                         |
| Month     | Mois de l'Année     | 1-12                         |
| Day       | Jour du mois        | 1-31                         |
| Dayofweek | Jour de la semaine  | 0-6                          |
| Season    | Saison              | 0=hiver,1=print,2=été,3=auto |

##### b) Encodage cyclique

Les variables temporelles sont naturellement cycliques (par exemple l'heure 23 est proche de l'heure 0), Une représentation numérique directe ne capture pas cette continuité. Pour remédier à ce problème, un encodage trigonométrique est appliqué :

$$\sin_{hour} = \sin\left(\frac{2\pi \times hour}{24}\right) \quad (20)$$

$$\cos_{hour} = \cos\left(\frac{2\pi \times hour}{24}\right) \quad (21)$$

$$\sin_{month} = \sin\left(\frac{2\pi \times month}{12}\right) \quad (22)$$

$$\cos_{month} = \cos\left(\frac{2\pi \times month}{12}\right) \quad (23)$$

Cette transformation représente le temps sur un cercle continu, évitant toute discontinuité artificielle entre la fin et le début d'un cycle.

### c) Features de lag (valeurs décalées)

Les modèles ML classiques traitent chaque instant de manière indépendante et ne disposent d'aucune mémoire temporelle. Les features de **lag** permettent d'introduire cette dimension temporelle :

Tableau III-3 : Variables temporelles générées à partir de l'index temporel

| Feature | Formule        | Justification           |
|---------|----------------|-------------------------|
| Pv-lag1 | Pv-real(t-1h)  | Continuite temporelle   |
| Pv-lag2 | Pv-real(t-24h) | Périodicité journalière |

### III.4.3 Normalisation des données

Les variables utilisées dans les modèles présentent des unités et des échelles différentes. Cette disparité peut avoir un impact défavorable sur l'efficacité des algorithmes, notamment les modèles de Deep Learning et certains algorithmes de Machine Learning qui sont sensibles à l'échelle.

Pour traiter ce problème, une normalisation est appliquée afin de ramener toutes les variables dans un intervalle de valeurs commun. La technique appliquée est la normalisation Min-Max, définie par :

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (24)$$

Cette transformation permet de ramener les données dans l'intervalle [0,1]. Il est important de souligner que cette transformation est ajustée uniquement sur l'ensemble d'entraînement afin d'éviter toute fuite d'information.

### III.4.4 Séparation des données

Nous divisons le dataset en trois ensembles. Cette séparation permet de :

- Évaluer correctement les modèles : Permet d'évaluer les performances des modèles sur des données non vues, assurant ainsi une évaluation impartiale de leur capacité de généralisation.

- Éviter le surapprentissage (overfitting) : Détecter si le modèle mémorise les données d'entraînement au lieu d'apprendre les relations générales entre les variables.
- Améliorer la fiabilité du modèle : l'utilisation d'ensembles distincts rend les résultats plus réalistes et garantit de meilleures performances sur de nouvelles données.

Tableau III-4 : Répartition du dataset en ensembles d'apprentissage, de validation et de test

| Ensemble de données             | Proportion | Nombre d'échantillons |
|---------------------------------|------------|-----------------------|
| Ensemble d'entraînement (Train) | 70 %       | 36 792                |
| Ensemble de Validation          | 15 %       | 7 884                 |
| Ensemble de Test                | 15 %       | 7 884                 |

### III.4.5 Préparation des séquences temporelles pour les modèles de Deep Learning

Les modèles de Deep Learning séquentiels tels que LSTM et GRU ne traitent pas les données de manière indépendante comme les modèles ML classiques. Ils nécessitent une restructuration des données sous forme de **séquences temporelles glissantes**.

Dans ce travail, une fenêtre temporelle de **24 heures** est adoptée. Ainsi, pour chaque instant  $t$ , le modèle reçoit en entrée les 24 heures précédentes et prédit la puissance PV à l'instant  $t+1$ .

## III.5 Environnement de développement

Dans cette étude, l'implémentation des modèles d'intelligence artificielle et le traitement des données PV ont été réalisés en utilisant l'environnement de développement Google Colab et le langage de programmation Python.

### III.5.1 Google Colab

Google Colab est un environnement de développement dans le cloud qui permet d'exécuter des programmes Python directement via un navigateur internet. Cette plateforme offre plusieurs avantages, dont l'accès aux ressources de calcul GPU, ce qui facilite l'entraînement des modèles de Deep Learning, ainsi qu'une intégration facile avec les bibliothèques d'intelligence artificielle et d'analyse de données.

Dans ce projet, Google Colab a été utilisé pour développer, entraîner et tester les différents modèles de prévision solaire.



Figure III-2 : Google (Colab) Logo

### III.5.2 Python

Python est l'un des langages de programmation les plus populaires et largement utilisés dans le secteur de Machine Learning et du Deep Learning. Nous utilisons le langage Python pour sa simplicité et sa flexibilité et la disponibilité de de plusieurs bibliothèques spécialisées dans l'analyse des données et l'intelligence artificielle.



Figure III-3 : Langage de programmation python

### III.5.3 Bibliothèques utilisées

Les principales bibliothèques utilisées dans ce travail sont regroupées dans le tableau suivant :

Tableau III-5 : Bibliothèques Python utilisées

| Bibliothèque        | Rôle principal                                                              |
|---------------------|-----------------------------------------------------------------------------|
| Pandas              | Chargement, manipulation et prétraitement du dataset                        |
| NumPy               | Réalisation des calculs matriciels et numériques                            |
| Scikit-learn        | Implémentation des modèles de Machine Learning et normalisation des données |
| TensorFlow<br>Keras | Développement et entraînement de modèles de Deep Learning                   |
| XGBoost             | Implémentation de l'algorithme XGBoost pour la prédiction photovoltaïque    |
| Matplotlib          | Visualisation des résultats expérimentaux et tracé des courbes              |
| Seaborn             | Visualisation statistique                                                   |
| Joblib              | Sauvegarde et chargement des modèles entraînés                              |

### III.5.4 Modèles d'apprentissage utilisés

#### III.5.4.1 Random Forest

Nous avons choisi le modèle **Random Forest** pour la prédiction de la puissance photovoltaïque grâce à sa capacité à modéliser les relations non linéaires entre les variables d'entrée et la sortie.

Tableau III-6 : Hyperparamètres du modèle Random Forest

| Hyperparamètre | Valeur | Rôle                                |
|----------------|--------|-------------------------------------|
| n_estimators   | 300    | Nombre d'arbres dans la forêt       |
| max_depth      | 15     | Profondeur maximale de chaque arbre |
| random_state   | 42     | Reproductibilité des résultats      |
| n_jobs         | -1     | Utilisation de tous les cœurs CPU   |

#### III.5.4.2 XGBoost

Nous avons opté pour le modèle XGBoost (eXtreme Gradient Boosting) pour prédire la production d'énergie solaire, en raison de son efficacité supérieure dans les problèmes de régression et de sa capacité à capturer des relations non linéaires complexes.

Tableau III-7 : Hyperparamètres du modèle XGBoost

| Hyperparamètre   | Valeur | Rôle                       |
|------------------|--------|----------------------------|
| n_estimators     | 500    | Nombre d'arbres boostés    |
| learning_rate    | 0.05   | Vitesse d'apprentissage    |
| max_depth        | 8      | Profondeur maximale        |
| subsample        | 0.8    | 80% des données par arbre  |
| colsample_bytree | 0.8    | 80% des features par arbre |

#### III.5.4.3 LSTM & GRU

##### ➤ LSTM

Nous avons choisi le modèle LSTM pour la prévision de la production photovoltaïque car il permet de prendre en compte les dépendances entre les observations horaires. Grâce à ses mécanismes de portes (entrée, oubli et sortie), il conserve les informations importantes sur plusieurs pas de temps, ce qui améliore la précision des prédictions.

##### ➤ GRU

Dans cette étude, nous avons retenu le modèle GRU pour sa structure plus simple que celle du LSTM, ce qui permet de réduire le temps d'entraînement et le nombre de paramètres à apprendre, tout en conservant de bonnes performances pour la prédiction de la production photovoltaïque.

Les hyperparamètres communs utilisés pour l'entraînement des modèles LSTM et GRU sont présentés dans le tableau suivant :

Tableau III-8 : Hyperparamètres communs des modèles LSTM et GRU

| Hyperparamètre                 | Valeur          | Rôle                                        |
|--------------------------------|-----------------|---------------------------------------------|
| Longueur de séquence (SEQ_LEN) | 24 heures       | Fenêtre d'historique fournie au modèle      |
| Optimizer                      | Adam (lr=0.001) | Ajustement adaptatif des poids              |
| Fonction de perte              | MSE             | Pénalise les grandes erreurs plus fortement |
| Batch size                     | 64              | Nombre d'exemples par mise à jour           |
| Epochs max                     | 100             | Nombre maximum d'itérations                 |

|                   |              |                                                           |
|-------------------|--------------|-----------------------------------------------------------|
| EarlyStopping     | Patience =10 | Arrêt si pas d'amélioration sur 10 époques                |
| ReduceLROnPlateau | Factor = 0.5 | Divise le learning rate par 2 si stagnation               |
| Dropout           | 20%          | Désactivation aléatoire de neurones (évite L'overfitting) |

#### III.5.4.4 Modèle hybride (GRU et RF)

Afin de combiner les avantages complémentaires des approches ML et DL, nous avons développé un modèle hybride associant le modèle GRU et le modèle Random Forest. Le GRU excelle dans la capture des dépendances temporelles grâce à sa mémoire séquentielle, tandis que le Random Forest capture efficacement les relations non linéaires entre les features météorologiques.

La combinaison des deux modèles est réalisée par une moyenne pondérée, où les poids sont déterminés à partir des performances individuelles des modèles évaluées par le RMSE.

Le poids associé au modèle GRU est calculé par :

$$w_{GRU} = \frac{\frac{1}{RMSE_{GRU}}}{\frac{1}{RMSE_{GRU}} + \frac{1}{RMSE_{RF}}} \quad (25)$$

Le poids associé au modèle Random Forest est calculé par :

$$w_{RF} = \frac{\frac{1}{RMSE_{RF}}}{\frac{1}{RMSE_{GRU}} + \frac{1}{RMSE_{RF}}} \quad (26)$$

La prédiction finale du modèle hybride est obtenue par :

$$\hat{Y}_{hybride}(t) = w_{GRU}\hat{Y}_{GRU}(t) + w_{RF}\hat{Y}_{RF}(t) \quad (27)$$

Où

$w_{GRU}$  : poids attribué au modèle GRU ;

$w_{RF}$  : poids attribué au modèle Random Forest ;

$RMSE_{GRU}$  : erreur quadratique moyenne du modèle GRU ;

$RMSE_{RF}$  : erreur quadratique moyenne du modèle Random Forest ;

$\hat{Y}_{GRU}(t)$  : puissance photovoltaïque prédite par le modèle GRU à l'instant t ;

$\hat{Y}_{RF}(t)$  : puissance photovoltaïque prédite par le modèle Random Forest à l'instant t ;

$\hat{Y}_{hybride}(t)$  : prédiction finale du modèle hybride.

### III.6 Métriques d'évaluation des modèles

Pour comparer objectivement les performances des modèles développés et sélectionner le plus performant, quatre métriques statistiques classiquement utilisées dans les travaux de prédiction énergétique sont adoptées dans cette étude.

- MAE (Mean Absolute Error)

MAE est une métrique qui représente la moyenne des erreurs absolues entre les valeurs réelles et prédites, utilisée pour évaluer la performance d'un modèle de prédiction.

Son calcul consiste à déterminer la différence absolue entre chaque valeur prédite et la valeur réelle, puis à faire la moyenne de ces écarts sur l'ensemble des données. La formule est donnée par :

$$MAE = \frac{1}{n} \sum |y_{réel} - y_{prédit}| \quad (28)$$

Où  $n$  représente le nombre total d'observations.

- RMSE (Root Mean Squared Error)

Le RMSE, ou *racine de l'erreur quadratique moyenne*, mesure l'écart quadratique moyen entre les valeurs réelles et les valeurs prédites. Cette métrique permet de mesurer la dispersion des erreurs et indique à quel point les prédictions s'écartent des valeurs réelles. Une valeur faible de RMSE traduit une meilleure précision du modèle.

La formule est donnée par :

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (29)$$

- $R^2$  (Coefficient de détermination)

Le coefficient de détermination, noté  $R^2$  est une métrique statistique indique la qualité d'ajustement du modèle aux données observées. Une valeur proche de 1 signifie que le modèle explique une grande partie de la variation des données, tandis qu'une valeur proche de 0 indique une faible capacité de prédiction.

La formule est donnée par :

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (30)$$

Où

$y_i$  représente les valeurs réelles,

$\hat{y}_i$  Représente les valeurs prédites,

$\bar{y}$  représente la moyenne des valeurs réelle.

- MAPE (Mean Absolute Percentage Error)

Le MAPE (Mean Absolute Percentage Error), ou erreur absolue moyenne en pourcentage, mesure l'écart moyen entre les valeurs réelles et les valeurs prédites en pourcentage. Cette métrique permet d'évaluer la précision relative du modèle en exprimant l'erreur par rapport aux valeurs réelles. Plus la valeur du MAPE est faible, plus les prédictions du modèle sont précises.

La formule est donnée par :

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (31)$$

Où

$n$  représente le nombre total d'observations ;

$y_i$  représente la valeur réelle ;

$\hat{y}_i$  représente la valeur prédite.

### III.7 Optimisation du système de stockage par batterie

#### III.7.1 Présentation et modélisation du système

Dans ce travail, un système de stockage par batterie (BESS - *Battery Energy Storage System*) est intégré au système photovoltaïque afin d'optimiser la gestion de l'énergie produite. Le système proposé est composé de quatre éléments principaux : les panneaux photovoltaïques, une batterie lithium-ion, une charge locale et une connexion au réseau électrique utilisée comme source d'appoint.

La puissance photovoltaïque est fournie sous forme horaire et estimée à l'aide d'un modèle d'apprentissage automatique. Elle est notée  $\hat{P}_{pv}(t)$ , où  $t$  représente l'instant horaire. Cette grandeur correspond à la puissance photovoltaïque prédite (en kW) à partir des données météorologiques et temporelles.

La technologie Li-ion, avec une capacité nominale  $E_{bat} = 10 \text{ KWh}$ , est retenue en raison de son rendement élevé (95%), de sa profondeur de décharge admissible de 80% et de sa durée de vie supérieure à 2000 cycles, ce qui en fait la référence pour les systèmes PV résidentiels.

À chaque instant  $t$ , le bilan énergétique du système est régi par l'équation de conservation de puissance suivante :

$$\hat{P}_{pv}(t) + P_{dch}(t) + P_{grid}(t) = P_{load}(t) + P_{ch}(t) \quad (32)$$

Où

$\hat{P}_{pv}(t)$  désigne la puissance PV prédite,

$P_{ch}(t)$  la puissance de charge de la batterie,

$P_{dch}(t)$  la puissance de décharge,

$P_{grid}(t)$  la puissance importée du réseau électrique,

$P_{load}(t)$  la charge locale consommée.

- L'état de charge de la batterie (SoC *State of Charge*), exprimé en pourcentage de sa capacité nominale, évolue selon l'équation dynamique discrète suivante :

$$SoC(t+1) = SoC(t) + \frac{\eta_{ch} P_{ch}(t) - \frac{P_{dch}(t)}{\eta_{dch}}}{E_{bat}} \times \Delta t \quad (33)$$

Où

$\eta_{ch} = 0.95$  est le rendement de charge,

$\eta_{dch} = 0.95$  le rendement de décharge,

$E_{bat} = 10$  kWh la capacité nominale de la batterie et  $\Delta t = 1$  heure le pas de temps de simulation.

### III.7.2 Contraintes et Paramètres de Simulation

Afin de garantir la longévité et la sécurité de la batterie, les contraintes opérationnelles suivantes sont imposées :

$$SoC_{min} \leq SoC(t) \leq SoC_{max}, 0 \leq P_{ch}(t) \leq P_{ch,max}, 0 \leq P_{dch}(t) \leq P_{dch,max}$$

$$P_{ch}(t) \times P_{dch}(t) = 0, \quad \forall t$$

Les limites  $SoC_{min} = 20\%$  et  $SoC_{max} = 90\%$  protègent la batterie contre la surcharge et la décharge profonde.

La contrainte de non-simultanéité empêche la charge et la décharge de se produire au même instant.

En l'absence de données de consommation réelles pour le site de Ouargla, la charge locale est modélisée par un profil synthétique sinusoïdal défini par :

$$P_{load}(t) = 0.35 - 0.2 \times \sin\left(\frac{2\pi \times h}{24} - \frac{\pi}{3}\right) + \varepsilon(t) \quad (38)$$

cette formulation génère une charge variante entre 0.1 et 0.66 kW, comparable à la puissance PV maximale disponible (0.941 kW/kWp), condition nécessaire pour que l'algorithme d'optimisation puisse démontrer son efficacité.

### III.7.3 Stratégies de Gestion Comparées

Deux stratégies de gestion de la batterie sont développées et comparées afin d'évaluer l'apport de la prédiction par apprentissage automatique dans la prise de décision énergétique.

- Stratégie Baseline (Gestion réactive classique)

La stratégie Baseline est une stratégie à seuil classique qui réagit uniquement à l'état énergétique instantané, sans anticipation des conditions futures. La batterie se charge dès qu'un surplus PV est disponible et se décharge dès qu'un déficit apparaît, dans les limites des contraintes définies. Cette stratégie constitue la référence de comparaison.

- Stratégie Optimisée (Contrôle prédictif intelligent)

La stratégie Optimisée, dénommée IRBPC (Intelligent Rule-Based Predictive Control), utilise la puissance photovoltaïque prédite  $\hat{P}_{pv}(t+1)$ . Cette valeur prédite est utilisée comme signal décisionnel afin d'anticiper l'évolution de la production solaire.

Lorsqu'une augmentation de la production est anticipée, c'est-à-dire si :

$$\hat{P}_{pv}(t+1) > 1.1\hat{P}_{pv}(t) \quad (39)$$

La décision de charge de la batterie peut être différée afin de profiter d'un surplus photovoltaïque plus important à l'instant suivant. Cette approche combine la prédiction par apprentissage automatique et un contrôle basé sur des règles afin d'améliorer la gestion énergétique globale.

La stratégie repose sur un ensemble de règles de décision synthétisées dans le tableau suivant :

Tableau III-9 : Règles de décision de la stratégie IRBPC

| Condition                                               | Décision           | Justification                            |
|---------------------------------------------------------|--------------------|------------------------------------------|
| $SoC(t) \leq 20\%$                                      | CHARGE prioritaire | Protection contre la décharge profonde   |
| $SoC(t) \geq 90\%$                                      | REPOS              | Protection contre la surcharge           |
| Surplus > 0 et $\hat{P}_{pv}(t+1) > 1.1\hat{P}_{pv}(t)$ | ATTENTE            | Anticipation d'un surplus plus important |
| Surplus > 0                                             | CHARGE             | Utilisation de l'énergie disponible      |
| Surplus < 0                                             | DECHARGE           | Couverture du déficit énergétique        |

#### III.7.4 Indicateurs de Performance (KPIs)

Les performances des deux stratégies sont évaluées à l'aide des indicateurs suivants :

**Taux d'autonomie (%) :**

$$\left(1 - \frac{E_{grid}}{E_{load}}\right) \times 100 \quad (40)$$

**Énergie importée du réseau (kWh) :**

$$\sum P_{grid}(t) \Delta t \quad (41)$$

**Énergie chargée dans la batterie (kWh) :**

$$\sum P_{ch}(t) \Delta t \quad (42)$$

**Énergie déchargée (kWh) :**

$$\sum P_{dch}(t)\Delta t \quad (43)$$

**Violations du SoC (Sécurité de la batterie) :**

Nombre de cas où  $SoC(t) < SoC_{min}$  ou  $SoC(t) > SoC_{max}$

**Pertes énergétiques du stockage :**

$$E_{loss} = E_{ch}(1 - \eta_{ch}) + E_{dch}(1 - \eta_{dch}) \quad (44)$$

Une amélioration du taux d'autonomie, une réduction de l'énergie importée du réseau et une absence totale de violations SoC constituent les critères principaux de validation de la stratégie optimisée par rapport à la stratégie Baseline.

### III.8 Conclusion

Nous avons présenté dans ce chapitre l'ensemble de la méthodologie adoptée, depuis l'acquisition des données PVGIS-SARAH2 jusqu'au développement de l'algorithme de gestion énergétique IRBPC, en passant par le prétraitement des données et la mise en œuvre des modèles de prédiction. Le chapitre suivant présente les résultats obtenus ainsi que leur analyse et leur discussion.

## IV. Chapitre IV Résultats et Discussion

### IV.1 Introduction

Ce chapitre présente les résultats obtenus lors de l'application du pipeline méthodologique décrit au chapitre précédent. L'implémentation a été réalisée en Python sous l'environnement Google Colaboratory avec activation de l'accélérateur GPU. Les résultats sont organisés en deux parties : les résultats de prédiction de la puissance PV pour les cinq modèles développés, puis les résultats de l'optimisation intelligente du système de stockage par batterie basée sur la production PV prédite par le meilleur modèle identifié.

### IV.2 Analyse exploratoire des données PV

La figure IV-1 présente un extrait du dataset utilise dans cette étude avant l'ajoute des 14 explicatives (features) construites lors du prétraitement.

```
=====
Max P_pv CORRIGE : 0.9448 kW/kWp
Max irradiance GLOBAL: 1159.8 W/m2
Nb enregistrements : 52608
=====
```

|                     | P_pv    | temperature | wind_speed | irradiance |
|---------------------|---------|-------------|------------|------------|
| datetime            |         |             |            |            |
| 2015-01-01 00:00:00 | 0.00000 | 6.32        | 4.90       | 0.00       |
| 2015-01-01 01:00:00 | 0.00000 | 6.05        | 5.10       | 0.00       |
| 2015-01-01 02:00:00 | 0.00000 | 5.81        | 5.31       | 0.00       |
| 2015-01-01 03:00:00 | 0.00000 | 5.64        | 5.72       | 0.00       |
| 2015-01-01 04:00:00 | 0.00000 | 5.52        | 6.00       | 0.00       |
| 2015-01-01 05:00:00 | 0.00000 | 5.32        | 5.79       | 0.00       |
| 2015-01-01 06:00:00 | 0.00000 | 5.16        | 5.52       | 0.00       |

Figure IV-1 : Extrait du dataset

Comme on peut l'observer sur cette figure, les données contiennent les principaux facteurs météorologiques influençant la production d'énergie ainsi que la puissance photovoltaïque utilisée comme variable cible.

La figure IV-2 présente la production photovoltaïque horaire enregistrée entre 2015 et 2020. Malgré la forte densité des données qui masque les détails locaux, elle permet d'observer une répartition homogène des mesures et une enveloppe de production globalement stable. Cette représentation confirme la cohérence du jeu de données sur l'ensemble de la période étudiée et l'absence d'anomalies majeures susceptibles d'affecter l'analyse ultérieure.




Figure IV-2: Production PV horaire complète de (2015-2020)

Là la figure IV-3 illustre la relation entre la production photovoltaïque et les principales variables météorologiques utilisées comme variables d'entrée du modèle.




Figure IV-3: Influence de l'irradiance, de la température et du vent sur la production PV (1 semaine)

On observe que l'irradiance solaire présente la corrélation visuelle la plus forte avec la puissance produite : les pics de production coïncident directement avec les pics d'irradiance, ce qui confirme son rôle prépondérant dans le processus de conversion photovoltaïque.

La température suit également une évolution journalière similaire à celle de la production PV, mais avec un léger décalage temporel, indiquant une influence indirecte liée au cycle solaire. En revanche, la vitesse du vent présente des fluctuations plus irrégulières et ne montre pas de relation visuelle évidente avec la puissance produite. Ces observations confirment empiriquement l'ordre d'importance des variables météorologiques sur la production photovoltaïque : irradiance, température puis vitesse du vent.

La figure IV-4 montre le découpage chronologique des données en trois ensembles distincts selon la répartition de 70 % pour l'entraînement, 15 % pour la validation et 15 % pour le test. Cette organisation garantit que le modèle est évalué sur des données strictement postérieures à celles utilisées pour l'apprentissage, condition indispensable pour une évaluation non biaisée.




Figure IV-4 : Découpage chronologique

### IV.3 Résultats de la Prédiction de la Puissance PV

#### IV.3.1 Résultats des Modèles Machine Learning

La figure VI.5 présente deux représentations complémentaires permettant d'évaluer les performances du modèle Random Forest.




Figure IV-5 : Prédiction vs Réel : RF (série temporelle + zoom 3 jours + scatter plot)

Le graphique de gauche montre un zoom sur trois jours du jeu de test, où les courbes de puissance photovoltaïque réelle et prédite sont pratiquement confondues. L'écart maximal observé entre les deux courbes est de seulement 0,0105 kW/kWp, ce qui témoigne d'une excellente précision de prédiction. Les faibles erreurs résiduelles restent négligeables par rapport à l'amplitude de la production photovoltaïque.

Le graphique de droite représente le nuage de points des valeurs prédites en fonction des valeurs réelles. La quasi-totalité des points est alignée sur la droite idéale  $y = x$ , indiquant une très forte corrélation entre les valeurs observées et estimées. Cette observation est confirmée par le coefficient de détermination  $R^2 = 0,9999$ , traduisant une capacité exceptionnelle du modèle à reproduire le comportement réel du système photovoltaïque.

La structure de cette figure est identique à la précédente. Le zoom sur trois jours met en évidence une très bonne concordance entre les valeurs réelles et les valeurs prédites par le modèle XGBoost.




Figure IV-6 : Prédiction vs Réel : XGBoost (série temporelle + zoom 3 jours + scatter plot)

Les deux courbes restent pratiquement superposées sur l'ensemble de la période considérée, avec une erreur maximale de 0,0293 kW/kWp, légèrement supérieure à celle obtenue avec Random Forest mais restant très faible en valeur absolue.

Le nuage de points confirme cette excellente qualité de prédiction, les observations étant fortement regroupées autour de la droite idéale  $y = x$ . Les performances du modèle sont corroborées par un coefficient de détermination très élevé ( $R^2 = 0,9998$ ).

Les deux modèles ML (Random Forest et XGBoost) ont été entraînés sur 36 792 enregistrements et évalués sur le jeu de test de 7 884 enregistrements. Le tableau IV-1 présente les métriques obtenues :

Tableau IV-1 : Métriques des modèles ML

| Modèle        | MAE    | RMSE   | $R^2$  | MAPE  |
|---------------|--------|--------|--------|-------|
| Random Forest | 0.0012 | 0.0025 | 0.9999 | 0.93% |
| XGBoost       | 0.0016 | 0.0035 | 0.9998 | 1.27% |

Les résultats montrent que Random Forest et XGBoost présentent des performances très proches avec des coefficients de détermination supérieurs à 0,999. Random Forest obtient les meilleures métriques, mais l'écart observé reste faible, ce qui confirme l'efficacité des deux approches pour la prédiction de la puissance photovoltaïque.

### IV.3.2 Résultats des Modèles Deep Learning

Les deux modèles DL (LSTM et GRU) ont été entraînés sur des séquences de 24 heures avec les mêmes ensembles de données. La figure IV-7 présente les courbes de loss Train vs Validation, montrant une convergence stable pour les deux modèles grâce aux callbacks EarlyStopping et ReduceLROnPlateau.

La Figure IV-7 présente l'évolution des pertes d'entraînement et de validation pour les modèles LSTM et GRU.




Figure IV-7 : Courbes de Loss - Train vs Validation (LSTM | GRU)

Dans les deux cas, la perte d'entraînement diminue progressivement au cours de l'apprentissage, tandis que la perte de validation atteint son minimum à l'époque 6 pour le LSTM et à l'époque 9 pour le GRU. La proximité entre les courbes d'entraînement et de validation traduit une convergence satisfaisante et une bonne capacité de généralisation. Ces résultats indiquent que les deux modèles ont été correctement entraînés, sans signe notable de surapprentissage.

Les performances du modèle LSTM sont présentées à la figure IV-8.




Figure IV-8 : Prédiction vs Réel : LSTM (série temporelle + zoom 3 jours + scatter plot)

La série temporelle montre que le modèle LSTM suit globalement la forme de la courbe réelle, mais avec une difficulté à capter les variations brusques et une sous-estimation visible des pics de production. Le zoom sur trois jours révèle une erreur maximale de 0.4998 kW/kWp, localisée précisément lors d'une chute soudaine au premier pic et au sommet des productions journalières. Le scatter plot montre un nuage de points qui commence à se disperser autour de la diagonale, en particulier pour les valeurs élevées de PV (au-dessus de 0.6 kW/kWp), où le modèle sous-prédit de façon répétée. La métrique globale de corrélation obtenue est de  $R^2 = 0.9629$ .

Les résultats du modèle GRU sont illustrés par la figure IV-9.




Figure IV-9 : Prédiction vs Réel : GRU (série temporelle + zoom 3 jours + scatter plot)

La structure de cette figure est identique aux précédentes. Le modèle GRU présente des écarts plus marqués entre les valeurs réelles et prédites, particulièrement lors des phases de montée et de descente de la production photovoltaïque. Le zoom sur trois jours met en évidence une erreur maximale de 0,4875 kW/kWp, traduisant une difficulté à reproduire fidèlement certains pics de production. Le nuage de points apparaît également plus dispersé autour de la droite idéale  $y = x$ , avec un coefficient de détermination de  $R^2 = 0,9581$ , révélant une précision inférieure à celle des modèles précédemment étudiés. Ces résultats confirment que le modèle GRU présente les performances les plus limitées parmi les approches évaluées.

Contrairement aux modèles Machine Learning, les modèles Deep Learning obtiennent des performances légèrement inférieures.

Tableau IV-2 : Métriques des modèles DL

| Modèle | MAE    | RMSE   | $R^2$  | MAPE   |
|--------|--------|--------|--------|--------|
| LSTM   | 0.0257 | 0.0505 | 0.9629 | 17.36% |
| GRU    | 0.0300 | 0.0570 | 0.9581 | 21.36% |

### IV.3.3 Résultats du Modèle Hybride RF+GRU

Le modèle hybride RF+GRU combine les prédictions du Random Forest et du GRU selon une moyenne pondérée dont les poids sont calculés automatiquement en fonction des performances individuelles. Les résultats obtenus sont présentés ci-dessous :

Tableau IV-3 : Poids du modèle hybride RF+GRU

| Paramètre | Valeur |
|-----------|--------|
| RMSE RF   | 0.0025 |
| RMSE GRU  | 0.0570 |
| Poids RF  | 95.7%  |
| Poids GRU | 4.3%   |

Le Random Forest reçoit un poids très supérieur (95.7%) par rapport au GRU en raison de son RMSE nettement plus faible .

La structure de cette figure IV-10 est identique aux précédentes.




Figure IV-10 : Prédiction vs Réel : Hybride RF+GRU (série temporelle + zoom 3 jours + scatter plot)

Le modèle hybride RF+GRU reproduit avec une très grande précision l'évolution de la puissance photovoltaïque, les courbes réelle et prédite étant pratiquement confondues sur le zoom de trois jours. L'erreur maximale observée est de 0,0189 kW/kWp, nettement inférieure à celle obtenue avec le modèle GRU seul. Le nuage de points est fortement concentré autour de la droite idéale  $y = x$ , avec un coefficient de détermination de  $R^2 = 0,9998$ , témoignant d'une excellente qualité de prédiction.

Le modèle hybride obtient  $R^2 = 0.9998$  et  $MAPE = 1.36\%$ . Ces résultats montrent que l'hybridation permet d'améliorer considérablement les performances du GRU. Toutefois, le modèle hybride ne dépasse pas les performances du modèle Random Forest utilisé seul, qui demeure le modèle le plus précis de cette étude.

Tableau IV-4 : Métriques du modèle hybride RF+GRU

| Modèle | MAE    | RMSE   | $R^2$  | MAPE  |
|--------|--------|--------|--------|-------|
| RF+GRU | 0.0019 | 0.0034 | 0.9998 | 1.36% |

#### IV.3.4 Comparaison Globale de Tous les Modèles

Tableau IV-5 : Classement final de tous les modèles

| Rang | Modèle        | MAE    | Type    | RMSE   | $R^2$  | MAPE   |
|------|---------------|--------|---------|--------|--------|--------|
| 1    | Random Forest | 0.0012 | ML      | 0.0025 | 0.9999 | 0.93%  |
| 2    | RF+GRU        | 0.0019 | Hybride | 0.0034 | 0.9998 | 1.36%  |
| 3    | XGBoost       | 0.0016 | ML      | 0.0035 | 0.9998 | 1.27%  |
| 4    | LSTM          | 0.0257 | DL      | 0.0521 | 0.9629 | 17.36% |
| 5    | GRU           | 0.0300 | DL      | 0.0554 | 0.9581 | 21.36% |

Le tableau IV-5 présente le classement final de tous les modèles développés selon le critère RMSE sur le jeu de test.

Les résultats démontrent la nette supériorité des modèles ML sur les modèles DL pour ce jeu de données. Random Forest se positionne en tête avec  $R^2 = 0.9999$  et  $MAPE = 0.93\%$ , soit une précision quasi parfaite sur le jeu de test. Les autres modèles présentent également des performances satisfaisantes ( $R^2 > 0,95$ ), mais demeurent moins précis que les approches basées sur les arbres de décision pour une utilisation opérationnelle dans l'algorithme d'optimisation de la batterie.

La figure IV-11 compare visuellement les quatre métriques pour tous les modèles.




Figure IV-11 : Comparaison des 4 métriques pour tous les modèles (graphes barres)

À travers ces quatre histogrammes, on met clairement en évidence la supériorité des modèles Random Forest, RF+GRU Hybride et XGBoost par rapport aux modèles LSTM et GRU. Les écarts observés sur les métriques d'erreur et sur le coefficient de détermination montrent que les approches basées sur les arbres de décision sont mieux adaptées aux caractéristiques du jeu de données étudié, Random Forest obtenant les meilleures performances globales. Tandis que la figure IV-12 superpose les prédictions de tous les modèles face à la production réelle.




Figure IV-12 : Comparaison globale : tous les modèles vs PV réel (zoom 3 jours)

## IV.4 Résultats de l'Optimisation Intelligente de la Batterie

Le modèle Random Forest, identifié comme le modèle le plus performant pour la prédiction de la puissance ( $R^2 = 0.9999$ ), est utilisé pour générer les prévisions de production PV  $P_{pv}(t+1)$  qui alimentent l'algorithme IRBPC. La charge locale simulée varie entre 0.1 et 0.60 kW, comparable à la puissance PV disponible (max 0.941 kW/kWp), garantissant l'existence de surplus suffisants pour démontrer l'efficacité de l'optimisation.

### IV.4.1 Évolution du SoC

Afin d'évaluer l'impact de la stratégie proposée sur le comportement du système de stockage, l'évolution de l'état de charge (SoC) de la batterie est analysée pour les stratégies Baseline et Optimisée.




Figure IV-13 : Évolution du SoC : Stratégie Baseline vs Stratégie Optimisée (IRBPC)

La figure IV-13 présente l'évolution de l'état de charge (SoC) de la batterie pour les stratégies Baseline et Optimisée. Les deux méthodes respectent intégralement les contraintes opérationnelles en maintenant le SoC dans la plage de sécurité comprise entre 20 % et 90 %, sans aucune violation.

Sur la majeure partie de la période étudiée, les courbes sont presque superposées et présentent un comportement cyclique journalier similaire, caractérisé par des phases successives de charge et de décharge liées à l'alternance entre la production photovoltaïque et la demande énergétique.

Quelques écarts apparaissent néanmoins autour des heures 120–150, puis de manière plus prononcée entre les heures 260 et 340. Dans cette dernière zone, la stratégie Baseline atteint des niveaux de charge plus élevés, avec des pics proches de 78 %, tandis que la stratégie Optimisée limite le SoC à environ 55–60 %. Ce comportement traduit l'action du contrôleur prédictif IRBPC qui, grâce aux prévisions fournies par le modèle Random Forest, adapte la gestion de la batterie afin d'éviter certaines charges excessives et de conserver une marge de stockage disponible pour les périodes futures.

### IV.4.2 Décisions de Charge et Décharge

L'analyse des commandes de charge et de décharge permet de mieux comprendre le comportement de l'algorithme de gestion énergétique.




Figure IV-14 : Décisions Charge/Décharge : Baseline (a) vs Stratégie Optimisée IRBP (b)

La figure IV-14 illustre les décisions de charge et de décharge pour les deux stratégies. Dans les deux cas, la batterie se charge durant les périodes de production photovoltaïque et se décharge lorsque la production est insuffisante. Les pics de charge à 3 kW correspondent aux recharges prioritaires déclenchées lorsque le SoC atteint sa limite minimale. La stratégie Optimisée ajuste légèrement le moment de certaines opérations de charge grâce aux prévisions Random Forest, permettant une gestion plus anticipative de l'énergie et expliquant les écarts de SoC observés sur la figure VI-13.

#### IV.4.3 Bilan Énergétique et Énergie Cumulative

Cette figure IV-15 superpose, pour chaque stratégie, la production photovoltaïque prédite, la charge consommée, la puissance de charge et de décharge de la batterie ainsi que la puissance importée du réseau. On observe un cycle journalier régulier caractérisé par des pics récurrents de puissance de charge d'environ 3 kW et de puissance réseau compris entre 3,2 et 3,6 kW. La production photovoltaïque atteint près de 0,8 kW, tandis que la charge varie globalement entre 0,1 et 0,6 kW.

Bien que les deux stratégies présentent des profils énergétiques proches, la stratégie optimisée répartit plus efficacement les phases de charge et de décharge grâce à l'utilisation des prévisions photovoltaïques. Cette anticipation permet de limiter certains appels au réseau et d'améliorer l'exploitation de l'énergie solaire disponible, ce qui se traduit par une diminution de l'énergie importée du réseau et de l'énergie gaspillée par rapport à la stratégie Baseline.




Figure IV-15 : Bilan Énergétique Global : PV prédit | Charge | Batterie | Réseau

L'impact de l'optimisation sur la dépendance énergétique vis-à-vis du réseau électrique est étudié à travers l'évolution de l'énergie importée.




Figure IV-16 : Énergie Cumulée Importée du Réseau : Baseline vs Stratégie Optimisée

La figure IV-16 présente l'évolution cumulative de l'énergie importée du réseau pour les stratégies Baseline et Optimisée. Les deux courbes suivent une progression en escalier similaire, traduisant les appels successifs au réseau au cours de la période étudiée. Elles restent presque confondues sur la majeure partie de l'horizon, avec un léger écart apparaissant entre les heures 280 et 330, où la stratégie Optimisée importe moins d'énergie que la stratégie Baseline. Cet écart traduit la capacité de l'algorithme IRBPC à mieux exploiter les prévisions photovoltaïques fournies par le modèle Random Forest, permettant de retarder certains appels au réseau et de réduire la dépendance énergétique globale du système.

#### IV.4.4 Comparaison des Indicateurs de Performance (KPIs)

Afin d'évaluer quantitativement l'apport de la stratégie prédictive IRBPC, plusieurs indicateurs de performance ont été calculés sur l'ensemble de la période de test. Ces indicateurs permettent d'analyser l'impact de l'optimisation sur l'autonomie énergétique du système, les échanges avec le réseau, l'utilisation de la batterie ainsi que le respect des contraintes opérationnelles. Le tableau IV-6 présente la comparaison des principaux KPIs obtenus avec les stratégies Baseline et Optimisée.

Tableau IV-6 : Comparaison des KPIs : Baseline vs Stratégie Optimisée IRBPC

| Indicateur              | Baseline | Optimise | Variation          |
|-------------------------|----------|----------|--------------------|
| Autonomie               | 46.21    | 46.31    | +0.10              |
| Energie réseau (KWh)    | 1484.32  | 1481.62  | -2.70 kWh (-0.18%) |
| Energie stockée (KWh)   | 2066.32  | 2064.49  | -1.83 kWh (-0.09%) |
| Energie déchargée (KWh) | 1864.94  | 1864.71  | -0.23 kWh          |
| Violations Soc          | 0        | 0        | Stable             |
| Energie gaspille (KWh)  | 201.38   | 199.79   | -1.59 kWh (-0.79%) |

Les résultats montrent une amélioration globale des performances avec la stratégie Optimisée. L'énergie importée du réseau diminue de 2,70 kWh (-0,18 %), tandis que l'autonomie augmente légèrement de 46,21 % à 46,31 %. L'énergie gaspillée est également réduite de 1,59 kWh (-0,79 %), traduisant une meilleure valorisation de l'énergie photovoltaïque disponible. Les énergies stockée et déchargée restent très proches entre les deux stratégies, ce qui indique que les gains observés proviennent principalement d'une meilleure gestion temporelle des opérations de charge et de décharge. Enfin, aucune violation des limites de SoC n'est enregistrée, confirmant la robustesse et la sécurité du système de gestion proposé.




Figure IV-17 : KPIs comparatifs en barres groupées : Baseline vs Stratégie Optimisée

La figure IV-17 illustre graphiquement les résultats du tableau IV-6. Elle confirme les gains obtenus avec la stratégie Optimisée, notamment la réduction de l'énergie importée du réseau et de l'énergie gaspillée, ainsi que la légère amélioration de l'autonomie du système, tout en maintenant un fonctionnement sûr de la batterie sans violation des contraintes de SoC.

## IV.5 Discussion et Analyse

Les résultats obtenus permettent de dégager plusieurs observations importantes.

Les modèles Random Forest, XGBoost et RF+GRU ont tous obtenu des performances très élevées pour la prédiction de la puissance photovoltaïque, avec des coefficients de détermination supérieurs à 0,999. Le modèle Random Forest présente les meilleures métriques ( $R^2 = 0,9999$  et  $MAPE = 0,93 \%$ ), bien que l'écart observé avec XGBoost et le modèle hybride demeure relativement faible. Ces résultats montrent que les approches basées sur les arbres de décision sont particulièrement adaptées à la modélisation de la production photovoltaïque lorsque les variables météorologiques, temporelles et les variables de retard sont correctement exploitées.

Les modèles de Deep Learning, LSTM et GRU, affichent également des performances satisfaisantes, mais restent inférieurs aux modèles de Machine Learning dans le cadre de cette étude. Cet écart peut s'expliquer par le fait que les quatorze variables construites lors du prétraitement, notamment les variables de retard et l'encodage cyclique du temps, capturent déjà une grande partie de l'information temporelle nécessaire à la prédiction. Dans ces conditions, l'avantage généralement associé aux architectures récurrentes devient moins marqué.

Concernant le modèle hybride RF+GRU, les résultats montrent qu'il n'apporte pas d'amélioration significative par rapport au modèle Random Forest utilisé seul. Le poids attribué au Random Forest (95,7 %) confirme que la contribution du GRU reste limitée, ce qui est cohérent avec les performances déjà très élevées du modèle principal.

L'intégration du modèle de prédiction dans la stratégie de gestion énergétique IRBPC a permis d'améliorer globalement les performances du système. Le taux d'autonomie énergétique passe de 46,21 % à 46,31 %, tandis que l'énergie importée depuis le réseau diminue de 1484,32 kWh à 1481,62 kWh. De plus, l'énergie gaspillée est réduite de 201,38 kWh à 199,79 kWh, soit une diminution relative de 0,79 %. Bien que ces gains demeurent modestes, ils sont observés de manière cohérente sur les principaux indicateurs énergétiques.

Cette amélioration s'explique par la capacité de la stratégie IRBPC à exploiter les prévisions de production photovoltaïque afin d'anticiper les décisions de charge et de décharge de la batterie. Lorsque l'état de charge approche des limites de fonctionnement, l'algorithme adapte son comportement en fonction de la production future estimée, ce qui permet de mieux valoriser l'énergie solaire disponible, de limiter les pertes liées à la saturation de la batterie et de réduire le recours au réseau électrique. Enfin, l'absence de violations des contraintes de SoC confirme que ces améliorations sont obtenues tout en préservant la sécurité et la durée de vie du système de stockage.

## IV.6 Conclusion

Ce chapitre a présenté les résultats de l'implémentation des modèles de prédiction de la puissance photovoltaïque ainsi que leur intégration dans une stratégie de gestion intelligente du stockage. L'évaluation des différentes approches a montré que les modèles basés sur le Machine Learning fournissent les meilleures performances de prédiction, tandis que les modèles de Deep Learning obtiennent des résultats satisfaisants mais légèrement inférieurs dans le contexte étudié.

L'exploitation des prévisions dans la stratégie IRBPC a permis d'améliorer les performances énergétiques du système tout en respectant les contraintes de fonctionnement de la batterie. Les résultats obtenus mettent ainsi en évidence l'intérêt d'une gestion anticipative

fondée sur les prévisions de production photovoltaïque pour une meilleure valorisation de l'énergie disponible.

Ces travaux confirment le potentiel des techniques d'intelligence artificielle pour le pilotage des systèmes photovoltaïques avec stockage et constituent une base prometteuse pour le développement de stratégies de gestion énergétique plus avancées.

## Conclusion Générale

Ce mémoire a porté sur l'application de l'intelligence artificielle à la prédiction de la puissance photovoltaïque et à l'optimisation de la gestion énergétique d'un système de stockage par batterie. À partir des données PVGIS-SARAH2 du site de Ouargla, plusieurs modèles de prédiction ont été développés et comparés, notamment Random Forest, XGBoost, LSTM, GRU et un modèle hybride RF+GRU.

Les résultats obtenus ont montré la supériorité des modèles de Machine Learning, en particulier Random Forest, qui a atteint les meilleures performances avec un coefficient de détermination de 0,9999 et une erreur MAPE de 0,93 %. Ce modèle a ensuite été intégré dans une stratégie intelligente de gestion de batterie afin d'améliorer l'exploitation de l'énergie photovoltaïque produite.

L'optimisation réalisée a permis de maintenir un fonctionnement sûr de la batterie tout en réduisant légèrement la dépendance au réseau électrique. Malgré des gains modestes, les résultats obtenus confirment l'intérêt de combiner les techniques de prédiction basées sur l'intelligence artificielle avec les stratégies de gestion énergétique des systèmes photovoltaïques.

Enfin, ce travail ouvre plusieurs perspectives, notamment l'utilisation de données météorologiques en temps réel, l'adoption d'horizons de prédiction plus longs et l'intégration d'approches avancées telles que l'apprentissage par renforcement pour améliorer davantage les performances des systèmes énergétiques intelligents.

## Références bibliographiques

- [1] C. d. Énergies, «Énergie solaire : exploitation photovoltaïque et thermique,» 25 06 2024. [En ligne]. Available: [www.connaissancedesenergies.org/fiche-pedagogique/energie-solaire](http://www.connaissancedesenergies.org/fiche-pedagogique/energie-solaire).
- [2] M. Mechalikh et C. Hamada, «Modélisation et simulation d'un système photovoltaïque en fonctionnement autonome et connecté au réseau,» Mémoire de Maste ,Ouargla, Algérie, 2013.
- [3] M. Noura, «Élaboration de molécules  $\pi$ -conjuguées à base de triphénylamine pour la réalisation de dispositifs photovoltaïques hybrides sensibilisés,» Thèse de doctorat , Cergy-Pontoise, France, 2011.
- [4] Z. Bouzid, «Contribution à l'optimisation d'un système de conversion éolien photovoltaïque : application pour un site isolé,» Thèse de doctorat ,Tlemcen, Algérie, 2016.
- [5] Horizons, «Énergie solaire, cap sur une production de 15 gigawatts en 2035,» 2024. [En ligne]. Available: [www.horizons.dz/2024/12/horizons-dz-dossiers-energie-solaire-cap-sur-une-production-de-15-gigawatts-en-2035](http://www.horizons.dz/2024/12/horizons-dz-dossiers-energie-solaire-cap-sur-une-production-de-15-gigawatts-en-2035).
- [6] A. Labouret et M. Viloz, Énergie solaire photovoltaïque : le manuel de référence, Paris, France: 5e édition (ouvrage issu de la série Installations photovoltaïques), 2012.
- [7] S. William et H. J. Queisser, «Detailed Balance Limit of Efficiency of P-N Junction Solar Cells,» *Journal of Applied Physics*, vol. 32, n° 13, pp. 510-519, 1961.
- [8] R. A. Messenger et J. Ventre, Photovoltaic Systems Engineering, Boca Raton, Florida, USA: CRC Press, 2010.
- [9] S. M. Sze et K. K. Ng, Physics of Semiconductor Devices, Hoboken, New Jersey, USA: John Wiley & Sons , 3rd Edition, 2006.
- [10] M. A. Green, Third Generation Photovoltaics: Advanced Solar Energy Conversion, Berlin, Heidelberg, Allemagne: Springer-Verlag, 2003.
- [11] Y. Warda et A. Fatma, «Prédiction à Court Terme de la Production de l'Énergie Solaire avec des Modèles d'Apprentissage Automatique en utilisant des Séries Temporelles Météorologiques,» Mémoire de Master ,M'Sila, 2024.
- [12] A. ElAmran, A. Mahrane, M. F. M. Moussaet et Y. Boukennous, «Procédé d'encapsulation des modules photovoltaïques type mono-verre,» vol. 9, n° 11, pp. 37-42, 2006.
- [13] T. Markvart et C. Luis, Practical Handbook of Photovoltaics: Fundamentals and Applications, Oxford, Royaume-Uni, 2012.

- [14] L. Ayoub et B. Walid, «Etude et réalisation d'une installation PV,» blida, 2022.
- [15] T. Gharbi et M. Merabet, «Technique d'intelligence artificiel pour l'étude de l'état de santé des panneaux solaires,» Mémoire de Master, Guelma, 2025.
- [16] M. Hassan, «Artificial Intelligence Powered Intelligent Energy Management Framework for Hydrogen Storage and Dispatch in Smart Microgrids,» *Scientific Reports*, vol. 15, 2025.
- [17] M. Drif, A. Malek et F. Krim, « An Alternative Design of Microcontroller-Based Charge Controller for Stand-Alone Photovoltaic Systems,» 1999.
- [18] B. Multon et J.-M. Peter, «Le stockage de l'énergie électrique. Moyens et applications,» n° 16, p. 59–64, 1996.
- [19] G. Vallverdu, *Principe de fonctionnement des batteries au lithium*, Université de Pau et des Pays de l'Adour, 2020.
- [20] Y. Khawaja, N. Shankar, I. Qiqieh, J. Alzubi, O. Alzubi, M. K. Nallakaruppan et S. Padmanaban, «Battery management solutions for li-ion batteries based on artificial intelligence,» vol. 14, n° 112, 2023.
- [21] S. A. M. Said, G. Hassan, H. M. Walwil et N. Al-Aqeeli, «The effect of environmental factors and dust accumulation on photovoltaic modules and dust-accumulation mitigation strategies,» vol. 82, p. 743–760, 2018.
- [22] A. A. Babatunde, S. Abbasoglu et M. Şenol, «Analysis of the impact of dust, tilt angle and orientation on performance of PV Plants,» vol. 90, p. 1017–1026, 2018.
- [23] S. Russell et N. Peter, *Artificial Intelligence: A Modern Approach*, Harlow, England: Pearson, 2020.
- [24] J. McCarthy, «From Here to Human-Level AI,» *Article scientifique*, vol. 117, n° 118, p. 1174–1182, 2007.
- [25] L. M. Marvin, *Semantic Information Processing*, Cambridge, Massachusetts, USA: MIT Press, 1968.
- [26] «Introduction à l'apprentissage automatique en pharmacométrie : concepts et applications,» Mémoire de maîtrise, Montréal, 2021.
- [27] T. M. Mitchell, *Machine Learning*, New York, NY, USA: McGraw-Hill, 1997.
- [28] G. Ian, Y. Bengio et A. Courville, *Deep Learning*, Cambridge, MA, USA: MIT Press, 2016, p. 96–97.
- [29] M. Douaa et T. Wassila, «Optimisation des performances des systèmes photovoltaïques par l'utilisation de l'apprentissage automatique et du

- l'apprentissage profond pour la prédiction des irradiances et des températures,» Mémoire de Master,, 2023.
- [30] A. Ethem, Introduction to Machine Learning, Cambridge, MA, USA: MIT Press, 2004, p. 415.
- [31] C. M. Bishop, Pattern Recognition and Machine Learning, New York, USA: Springer, 2006, p. 738.
- [32] S. Senani, «Réseaux de neurones convolutionnels pour la détection précoce de la rétinopathie diabétique,» Mémoire, Tizi-Ouzou, 2019.
- [33] A. Géron, Machine Learning avec Scikit-Learn, Keras et TensorFlow : Concepts, outils et techniques pour construire des systèmes intelligents, Paris, France: Dunod, 2023.
- [34] R. Jérémy, «Liora institut,L'apprentissage semi-supervisé : Tout savoir ce qu'il faut savoir,» 2026. [En ligne]. Available: <https://liora.io/apprentissage-semi-supervise-tout-savoir>.
- [35] GeeksforGeeks, «Random Forest Algorithm in Machine Learning,» 2026. [En ligne]. Available: <https://www.geeksforgeeks.org/machine-learning/random-forest-algorithm-in-machine-learning/>.
- [36] IBM, «Qu'est-ce que XGBoost ?,» 2004. [En ligne]. Available: [www.ibm.com/fr-fr/think/topics/xgboost](http://www.ibm.com/fr-fr/think/topics/xgboost).
- [37] D. A. E. Nour, «Prédiction de la production d'énergie photovoltaïque par des techniques d'apprentissage automatique,» Mémoire de Master,Guelma, 2023.
- [38] GeeksforGeeks, «Deep Learning - Introduction to Long Short Term Memory,» [En ligne]. Available: <https://www.geeksforgeeks.org/deep-learning/deep-learning-introduction-to-long-short-term-memory/>.
- [39] GeeksforGeeks, «Réseaux d'unités récurrentes fermées,» 2026. [En ligne]. Available: <https://www.geeksforgeeks.org/machine-learning/gated-recurrent-unit-networks/>.
- [40] C. Scott et M. Ahsan, «Machine learning for forecasting a photovoltaic (PV) generation system,» *sciencedirect*, vol. 278, 2023.
- [41] A. Faris et A. Chouder, «Improving Photovoltaic Power Prediction: Insights through Computational Modeling and Feature Selection,» *MDPI*, 2024.
- [42] M. Jiang, K. Ding, Xiang et Chen, «Research on time-series based and similarity search based methods for PV power prediction,» *Elsevier*, vol. 308, 2024.
- [43] W. hui, H. Gao et S. Qiu, «Short-Term Prediction of PV Power Based on Combined Modal Decomposition and NARX-LSTM-LightGBM,» *MDPI*, vol. 13, n° %110, 2023.

- [44] Kofinas.P et Doltsinis.S, «A reinforcement learning approach for MPPT control method of photovoltaic sources,» *Elsevier*, vol. 108, pp. 461-473, 2017.
- [45] E. Hosseini et H.-Q. Pablo, «Reinforcement learning-based energy management system for lithium-ion battery storage in multilevel microgrid,» p. 2024.
- [46] S. Wang et D. L. a. b, «A novel physical extraction multi-step neural network algorithm for power lithium-ion battery state of charge and available capacity estimation,» vol. 177, 2026.
- [47] A. Benabou, *L'énergie solaire – Application au photovoltaïque*, Slideserve, 2012.

# Annexes

## Annexe A : Source des données photovoltaïques

Dans le cadre de cette étude, les données météorologiques et photovoltaïques ont été extraites à partir de la plateforme PVGIS (Photovoltaic Geographical Information System).




Figure A.1 : Interface de la plateforme PVGIS utilisée pour l'extraction des données photovoltaïques du site d'étude.

## Annexe B Environnement de développement sous Google Colab




Figure B.1 : Environnement Google Colab utilisé pour le développement et l'exécution des modèles de prédiction.

## Annexe C : Variation de la puissance photovoltaïque

Les figures suivantes présentent un exemple de l'évolution de la puissance photovoltaïque au cours d'une journée. On observe une production quasi nulle durant la nuit, une augmentation progressive après le lever du soleil, un maximum autour de midi, puis une diminution jusqu'au coucher du soleil. Cette évolution est conforme au comportement attendu d'un système photovoltaïque.

|                     | P_pv    | temperature | wind_speed | irradiance |
|---------------------|---------|-------------|------------|------------|
| datetime            |         |             |            |            |
| 2015-01-01 00:00:00 | 0.00000 | 6.32        | 4.90       | 0.00       |
| 2015-01-01 01:00:00 | 0.00000 | 6.05        | 5.10       | 0.00       |
| 2015-01-01 02:00:00 | 0.00000 | 5.81        | 5.31       | 0.00       |
| 2015-01-01 03:00:00 | 0.00000 | 5.64        | 5.72       | 0.00       |
| 2015-01-01 04:00:00 | 0.00000 | 5.52        | 6.00       | 0.00       |
| 2015-01-01 05:00:00 | 0.00000 | 5.32        | 5.79       | 0.00       |
| 2015-01-01 10:00:00 | 0.60923 | 9.00        | 7.72       | 705.51     |
| 2015-01-01 11:00:00 | 0.49673 | 9.20        | 7.17       | 577.38     |
| 2015-01-01 12:00:00 | 0.79394 | 9.98        | 6.41       | 940.30     |
| 2015-01-01 13:00:00 | 0.63221 | 10.83       | 6.69       | 742.50     |
| 2015-01-01 14:00:00 | 0.60480 | 11.34       | 7.03       | 708.98     |
| 2015-01-01 15:00:00 | 0.26701 | 11.29       | 6.90       | 320.62     |
| 2015-01-01 16:00:00 | 0.08826 | 10.84       | 5.66       | 124.16     |
| 2015-01-01 18:00:00 | 0.00000 | 8.25        | 2.90       | 0.00       |
| 2015-01-01 19:00:00 | 0.00000 | 7.10        | 2.83       | 0.00       |
| 2015-01-01 20:00:00 | 0.00000 | 6.02        | 2.76       | 0.00       |
| 2015-01-01 21:00:00 | 0.00000 | 4.94        | 2.76       | 0.00       |
| 2015-01-01 22:00:00 | 0.00000 | 3.97        | 2.90       | 0.00       |
| 2015-01-01 23:00:00 | 0.00000 | 3.06        | 3.03       | 0.00       |

Figure C.1 : Variation journalière de la puissance photovoltaïque.