



الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي والبحث العلمي



Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

جامعة غرداية

N°d'enregistrement

Université de Ghardaïa

.../.../...

كلية العلوم والتكنولوجيا

Faculté des Sciences et de la Technologie

قسم الآلية والكهروميكانيك

Département de d'automatique et d'électromécanique

Mémoire de fin d'étude, envue de l'obtention du diplôme

Master

Domaine: Sciences et Technologies

Filière : Automatique et électromécanique

Spécialité: Énergies Renouvelables en mécanique

Thème

Prévision de la production d'énergie photovoltaïque à l'aide d'un
modèle hybride SD-LSTM basé sur les données météorologiques

Present par:

AZZAOUI Anfal

BEN DJADOU Kaouter

Soutenue publiquement le : 13/06/2026

Devant le jury composé de :

Mr.BELKACEM Bekar	MCA	Univ. Ghardaïa	Président
Mr.MESBAH Cherif Abdelkrim	MCB	Univ. Ghardaïa	Examineur
Mr.KIFOUCH Abdelsalam	MCA	Univ. Ghardaïa	Examineur
Mr.FERKOUS Khaled	MCA	Univ. Ghardaïa	Encadreur
Mme. SEKAYAR Soundous	MCA	Univ. Ghardaïa	Co-encadreuse

Année universitaire 2026/2027

Remerciements

Je remercie Dieu le Tout-Puissant de m'avoir donné le courage, la volonté et la patience de mener à terme le présent mémoire.

J'adresse mes sincères remerciements à Monsieur le Docteur Ferkous Khaled, pour avoir accepté d'encadrer et de diriger ce travail. Je le remercie pour ses précieux conseils, son aide et sa grande patience. Qu'il trouve ici l'expression de ma profonde gratitude et de ma sincère considération.

Je tiens également à remercier Mademoiselle Sghir Sondes, assistante de l'encadreur, pour son aide, ses orientations et son soutien durant la réalisation de ce travail.

J'adresse aussi mes remerciements à Monsieur le Président du jury ainsi qu'aux membres du jury pour l'honneur qu'ils m'ont fait en acceptant d'évaluer ce mémoire.

Enfin, je remercie toute personne ayant contribué de près ou de loin à l'élaboration de ce travail.

Dédicaces

Dédicace Anfai

Alhamdulillah, louange à Dieu qui m'a accordé la réussite dans l'accomplissement de ce travail, et m'a donné la force et la patience pour atteindre ce beau moment.

Je dédie ce travail de fin d'études aux personnes les plus chères à mon cœur, à mes très chers parents, que Dieu les protège, qui ont été mon soutien et ma force tout au long de mon parcours scolaire.

À mes frères et sœurs, ainsi qu'à mon neveu Arkan et ma nièce Lina, qui ont été pour moi une source de joie et d'encouragement permanent.

À mes chères amies Hadjer et Safaa, merci pour votre présence constante à mes côtés et pour tous les moments de soutien et de bonheur partagés.

Enfin, à toutes les personnes qui m'ont soutenue et aidée, même par un simple mot bienveillant, je dédie ce modeste travail, en espérant davantage de succès et de réussite.

AZZAOUI Anfai

Dédicace Kaouter

Je dédie ce modeste travail à mes très chers parents.

À ma mère, pour son amour infini, sa tendresse, ses sacrifices et ses prières qui m'ont toujours accompagnée.

À mon père, pour son soutien, ses encouragements et sa confiance qui m'ont permis d'avancer et de réussir.

Aucun mot ne saurait exprimer toute ma gratitude et mon affection envers vous.

Que Dieu vous protège et vous accorde santé, bonheur et longue vie.

À vous deux, je dédie le fruit de mes efforts.



BEN DJADDOU Kaouter

تتناول هذه الدراسة موضوع التنبؤ بإنتاج الطاقة الكهروضوئية باستعمال نموذج هجين يجمع بين تقنية تحليل السرب وشبكات الذاكرة طويلة قصيرة المدى. في البداية، تم عرض المفاهيم الأساسية المرتبطة بالطاقة الشمسية والأنظمة الكهروضوئية، مع توضيح أهم العوامل التي تؤثر في إنتاج الطاقة، مثل الإشعاع الشمسي، درجة الحرارة، الظروف المناخية، واتجاه وميلان الألواح الشمسية. بعد ذلك، تم التطرق إلى مختلف طرق التنبؤ، بدءاً من الطرق الإحصائية التقليدية وصولاً إلى تقنيات الذكاء الاصطناعي والتعلم العميق، مع التركيز على النماذج الهجينة لقدرتها على تحسين دقة التنبؤ. اعتمدت الدراسة التطبيقية على بيانات إنتاج محطة كهروضوئية بولاية الأغواط، شملت القدرة المنتجة، الإشعاع الشمسي ودرجة الحرارة. بعد تنظيف البيانات ومعالجتها، تم بناء نموذج SD-LSTM واختبار عدة حالات باستعمال متغيرات داخلية وخارجية مع تأخيرات زمنية مختلفة. أظهرت النتائج أن استعمال تقنية التفكيك ساهم بشكل واضح في تحسين أداء النموذج، حيث ارتفعت دقة التنبؤ وانخفضت الأخطاء بشكل ملحوظ. كما بينت النتائج أن المتغيرات الداخلية أعطت أداءً أكثر استقراراً، خاصة عند التأخير الزمني الثاني، مما يؤكد فعالية النموذج المقترح في التنبؤ قصير المدى بإنتاج الطاقة الكهروضوئية.

الكلمات المفتاحية: الطاقة الشمسية، الأنظمة الكهروضوئية، التنبؤ، LSTM، تحليل السرب، SD-LSTM.

Abstract

This study focuses on forecasting photovoltaic energy production using a hybrid model that combines Swarm Decomposition with Long Short-Term Memory networks (LSTM). The work first presents the general concepts related to solar energy and photovoltaic systems, including the main factors affecting solar power generation such as solar irradiance, temperature, weather conditions, panel orientation, and tilt angle. It then reviews several forecasting approaches, ranging from classical statistical methods to artificial intelligence and deep learning techniques, with particular attention to hybrid models due to their ability to improve prediction accuracy. The experimental part of this research is based on data collected from the photovoltaic power plant of Laghouat, including PV power output, solar radiation, and temperature. After data cleaning and normalization, the proposed SD-LSTM model was developed and tested under different configurations using endogenous and exogenous variables with several time lags. The results show that Swarm Decomposition significantly improves the forecasting performance by reducing the complexity and non-stationarity of the photovoltaic signal. The best performance was obtained with endogenous variables and a time lag of 2, indicating that past PV production values are highly effective for short-term forecasting. Overall, the proposed hybrid model provides accurate, stable, and reliable predictions for photovoltaic power generation.

Keywords: solar energy, photovoltaic systems, forecasting, LSTM, Swarm Decomposition, SD-LSTM.

Résumé

Cette étude porte sur la prévision de la production d'énergie photovoltaïque à l'aide d'un modèle hybride combinant la technique de Swarm Decomposition et le réseau de neurones récurrent LSTM. Dans un premier temps, le travail présente les notions générales liées à l'énergie solaire et aux systèmes photovoltaïques, en mettant en évidence les principaux facteurs influençant la production d'énergie, tels que l'irradiation solaire, la température, les conditions météorologiques ainsi que l'orientation et l'inclinaison des panneaux. Ensuite, différentes méthodes de prévision sont étudiées, allant des approches statistiques classiques aux techniques basées sur l'intelligence artificielle et l'apprentissage profond. La partie expérimentale repose sur des données issues de la centrale photovoltaïque de Laghouat, comprenant la puissance produite, le rayonnement solaire et la température. Après une étape de nettoyage et de normalisation des données, le modèle SD-LSTM a été construit et évalué selon plusieurs configurations, en utilisant des variables endogènes et exogènes avec différents délais temporels. Les résultats obtenus montrent que l'intégration de la décomposition par essaim améliore nettement les performances de prévision, en réduisant la complexité du signal et en facilitant son apprentissage par le modèle LSTM. Les meilleures performances ont été obtenues avec les variables endogènes et un délai égal à 2, ce qui confirme l'efficacité du modèle proposé pour la prévision à court terme de la production photovoltaïque.

Mots-clés : *énergie solaire, systèmes photovoltaïques, prévision, LSTM, Swarm Decomposition, SD-LSTM.*

Table des matières

Remerciements	Erreur ! Signet non défini.
Dédicace	II
Remerciements	iii
Dédicace	iv
ملخص	v
Abstract	v
Résumé	vi
Introduction générale.....	1
Chapitre I : Généralités sur les systèmes photovoltaïques et la production d'énergie solaire..	2
1.1 Introduction	4
1.2 Energie solaire.....	4
1.2.1Le rayonnement solaire	5
1.2.2Composantes du rayonnement solaire	5
a) Rayonnement direct.....	5
b) Rayonnement diffus	5
c) Albédo (réfléchi)	5
d) Rayonnement global.....	5
1.2.3Facteurs influençant le rayonnement solaire	6
a) La position du soleil (angle d'incidence)	6
b) La durée d'ensoleillement	6
c) Les conditions atmosphériques	6
d) La latitude géographique	7
e) L'altitude	7
f) La nature de la surface terrestre (albédo)	7
g) Les saisons.....	7
h) L'orientation et l'inclinaison des surfaces.....	8
1.3 Technologie photovoltaïque	8
1.3.1Principe de fonctionnement d'une cellule photovoltaïque	8
1.3.2Types de cellules photovoltaïques.....	9
1.3.2.1 Les cellules en monocristallin	9

1.3.2.2	Les cellules photovoltaïques Poly-cristallines.....	9
1.3.2.3	Les cellules amorphes	10
1.3.3	Caractéristiques électriques des panneaux photovoltaïques.....	10
1.4	Systèmes photovoltaïques	11
1.4.1	Systèmes photovoltaïques connectés au réseau.....	12
1.4.2	Systèmes photovoltaïques autonomes	12
1.4.3	Composants d'une centrale photovoltaïque.....	13
1.4.3.1	Générateur	14
	Figure I- 9.....	14
1.4.3.2	Les batteries.....	14
1.4.3.3	Onduleur.....	15
1.4.3.4	Régulateur	15
1.4.3.5	Câblage.....	16
1.5	Facteurs influençant la production photovoltaïque	16
1.5.1	Irradiation solaire	17
1.5.2	Température des panneaux.....	17
1.5.3	Conditions météorologiques.....	17
1.5.4	Orientation et inclinaison des panneaux.....	17
1.6	Conclusion.....	18
	Chapitre II : Méthodes de prévision de la production photovoltaïque.	19
2.1.	Introduction	21
2.2.	Importance de la prévision dans les systèmes énergétiques.....	21
2.3.	Types de prévision	21
2.3.1.	Prévision à court terme.....	21
2.3.2.	Prévision à moyen terme	22
2.3.3.	Prévision à long terme	22
2.4	Méthodes classiques de prévision	22
2.4.1	Méthodes statistiques	24
2.4.2.	Régression linéaire	24
2.5.	Méthodes basées sur l'intelligence artificielle	24
2.5.1.	Réseaux de neurones artificiels (ANN).....	25
2.5.1.1.	Principes généraux	25
2.5.2.	Support Vector Machines (SVM).....	26
2.6.	Deep Learning pour la prévision énergétique	26
2.6.1.	Long Short-Term Memory (LSTM).....	27

2.7.	Modèles hybrides de prévision.....	28
2.7.1.	Principe des modèles hybrides	29
2.7.2.	Techniques de décomposition utilisées dans les modèles hybrides	30
	a) Décomposition en ondelettes (Wavelet Transform – WT).....	30
	b) Décomposition modale empirique (EMD).....	30
	c) Ensemble Empirical Mode Decomposition (EEMD).....	30
	d) Variational Mode Decomposition (VMD).....	31
	e) Iterative Filtering (IF).....	31
2.7.3.	Hybridation avec les algorithmes d’optimisation.....	31
2.7.4.	Avantages et limites des modèles hybrides	31
	Avantages	31
	Limites.....	32
2.8.	Conclusion.....	32
Chapitre III :Modélisation, résultats et discussion.		21
3.1.	Introduction	36
3.2.	Description des données utilisées.....	36
3.3.	Prétraitement des données	39
	3.3.1.Nettoyage	39
	3.3.2.Normalisation.....	39
	3.3.3.Délai	40
3.4.	Construction du modèle hybride SD-LSTM	40
	Étape 1 : Prétraitement des données.....	40
	Étape 2 : Décomposition du signal par Swarm Decomposition (SD)	41
	Étape 3 : Construction des séquences temporelles	41
	Étape 4 : Apprentissage du réseau LSTM	41
	Étape 5 : Prévision directe de la série temporelle.....	42
3.5.	Proposition de méthodologie.....	42
3.6.	Méthodes d’évaluation (R² , RMSE, nRMSE).....	44
3.7.	Résultats de la prévision :.....	45
	3.7.1Impact de la décomposition sur les performances de prévision	45
	3.7.2.Résultats avec les variables endogènes	47
	3.7.3.Résultats avec les variables exogènes :	50
	3.7.4.Analyse comparative des modèles à variables endogènes et exogènes.....	51
3.8.	Conclusion.....	53

Conclusion générale	36
Bibliographie.....	57

Liste des figures

Figure I- 2 : Composante du rayonnement global sur un plan horizontal.	6
Figure I- 3 : Cellule PV monocristalline.	9
Figure I- 4: Cellule PV polycristalline.	10
Figure I- 5: Cellule PV amorphe.	10
Figure I- 6: Caractéristiques I(V) et P(V) d'un module solaire.	11
Figure I- 7 : Schéma d'un système photovoltaïque connecté au réseau de distribution électrique.	12
Figure I- 8 : Schéma d'un système photovoltaïque autonome.	13
Figure I- 9 : Générateur photovoltaïque.	14
Figure I- 10 : Batterie solaire photovoltaïque.	15
Figure I- 11 : Les onduleurs solaires photovoltaïques.	15
Figure I- 12: Régulateur solaires photovoltaïques.	16
Figure I- 13 : câbles solaire photovoltaïque.	16
Figure II- 1: Classification des méthodes de prévision de la puissance de sortie photovoltaïque	23
Figure II- 2 : Représentation schématique du neurone artificiel.	26
Figure II- 3 : L'architecture des réseaux LSTM	27
Figure II- 4 : General Architecture of a Hybrid Model for Solar Energy Prediction.	32
Figure III- 1 : Localisation de la centrale photovoltaïque de Laghouat.	36
Figure III- 2 : Puissance PV (kW)	37
Figure III- 3 : Radiation solaire (W/m ²).	38
Figure III- 4 : Température (°C)	38
Figure III- 5 : Structure des entrées avec différents délais.	40
Figure III- 6 : Architecture générale du modèle hybride SD-LSTM	44
Figure III- 7 : Nuages de points (Scatter plots) avec et sans décomposition	46
Figure III- 8 : Courbes de suivi des prévisions avec et sans décomposition	47
Figure III- 9 : Nuages de points (configuration endogène)	48
Figure III- 10 : Comparaison du R ² et du nRMSE	49
Figure III- 11 : Courbes de suivi des prévisions des différents délais	49
Figure III- 12 : Nuages de points (configuration exogène)	50
Figure III- 13 : boxplots des erreurs	51
Figure III- 14 : Histogrammes des erreurs	52
Figure III- 15 : Erreurs résiduelles	53

Liste des tableaux

Table III. 1: Statistiques de Puissance PV (kW).....	37
Table III. 2: Statistiques de Radiation solaire (W/m^2).....	38
Table III. 3: Statistiques de Température ($^{\circ}\text{C}$).....	39
Table III. 4 : Statistiques de donne après le Nettoyage.....	39
Table III. 5 : Les hyperparamètres d'entraînement du modèle LSTM.....	42
Table III. 6 : Comparaison des performances de prévision avec et sans décomposition	45
Table III. 7 : Performances de prévision des variables endogènes avec différents délais	48
Table III. 8 : Performances de prévision des variables endogènes avec différents délais	50

Nomenclature

Symbole	Signification
PV	Photovoltaic
DC	Direct Current
AC	Alternating Current
ARMA	AutoRegressive Moving Average
ARIMA	AutoRegressive Integrated Moving Average
SARIMA	AutoRegressive Integrated Moving Average Seasonal
ANN	Artificial Neural Network
SVM	Support Vector Machine
CNN	Convolutional Neural Network
RNN	Recurrent Neural Network
LSTM	Long Short-Term Memory
BiLSTM	Bidirectional Long Short-Term Memory
GRU	GatedRecurrent Unit
WT	Wavelet Transform
EMD	Empirical Mode Decomposition
EEMD	Ensemble Empirical Mode Decomposition
VMD	Variational Mode Decomposition
IF	IterativeFiltering
SD	Swarm Decomposition
GA	GeneticAlgorithm
PSO	Particle Swarm Optimization
GWO	Grey Wolf Optimizer
WOA	Whale OptimizationAlgorithm
ACO	Ant Colony Optimization
ABC	Artificial Bee Colony

Introduction générale

Introduction générale

L'énergie constitue aujourd'hui l'un des piliers essentiels du développement économique, social et technologique. Cependant, la dépendance aux énergies fossiles pose de nombreux problèmes liés à l'épuisement des ressources naturelles, à la pollution environnementale et aux émissions de gaz à effet de serre. Face à ces défis, les énergies renouvelables occupent une place de plus en plus importante dans les stratégies énergétiques modernes. Parmi elles, l'énergie solaire photovoltaïque se distingue par son abondance, sa disponibilité et son caractère propre.

La production photovoltaïque repose sur la conversion directe du rayonnement solaire en énergie électrique à l'aide de cellules photovoltaïques. Toutefois, cette production reste fortement variable, car elle dépend de plusieurs facteurs environnementaux tels que l'irradiation solaire, la température, la nébulosité, l'humidité, la poussière, ainsi que l'orientation et l'inclinaison des panneaux. Cette variabilité rend la gestion des systèmes photovoltaïques plus complexe, notamment lorsqu'ils sont intégrés aux réseaux électriques.

Dans ce contexte, la prévision de la production photovoltaïque devient une étape essentielle pour assurer une meilleure planification énergétique, améliorer la stabilité du réseau et optimiser l'exploitation des ressources solaires. Plusieurs méthodes ont été proposées dans la littérature, allant des modèles statistiques classiques aux techniques d'intelligence artificielle. Parmi ces dernières, les réseaux de neurones récurrents, notamment les modèles LSTM, ont montré une grande capacité à traiter les séries temporelles et à apprendre les dépendances entre les valeurs passées et futures.

Cependant, les données photovoltaïques présentent souvent un comportement non linéaire, non stationnaire et bruité. Pour faire face à cette difficulté, les modèles hybrides constituent une solution intéressante. Dans ce travail, nous proposons un modèle hybride basé sur la combinaison de la SwarmDecomposition et du modèle LSTM afin d'améliorer la précision de la prévision de la production photovoltaïque.

Ce mémoire est organisé en trois chapitres. Le premier chapitre présente les généralités sur l'énergie solaire, les systèmes photovoltaïques et les facteurs influençant leur production. Le deuxième chapitre expose les différentes méthodes de prévision, en particulier les méthodes basées sur l'intelligence artificielle et les modèles hybrides. Le troisième chapitre est consacré à la méthodologie adoptée, au traitement des données, à la construction du modèle proposé ainsi qu'à l'analyse et la discussion des résultats obtenus.

Chapitre I: Généralités sur les systèmes photovoltaïques et la production d'énergie solaire.

1.1 Introduction

L'énergie solaire figure parmi les sources d'énergie renouvelable les plus cruciales. Cela nous offre la possibilité de générer de l'électricité de façon écologique, éloignée des sources conventionnelles. Grâce aux cellules photovoltaïques, on peut convertir directement la lumière solaire en électricité. Les installations photovoltaïques sont déployées dans divers lieux en raison de leur praticité et de l'accessibilité à l'énergie solaire. Cependant, la production d'électricité peut fluctuer en fonction de l'intensité solaire, des températures et des conditions climatiques. Ce chapitre nous amènera à explorer l'énergie solaire, le rayonnement solaire, la technologie des cellules photovoltaïques et les diverses configurations de systèmes, sans oublier les éléments qui affectent la production d'électricité.

1.2 Energie solaire

Le rayonnement solaire qui atteint la Terre est une source d'énergie quasi infinie. On estime que la quantité de rayonnement solaire atteignant la surface terrestre chaque année est plus de 8400 fois supérieures à la consommation énergétique annuelle de la planète. L'intensité maximale instantanée moyenne du rayonnement solaire sur Terre est d'environ 1 kilowatt par mètre carré (KWc/m^2), sur l'ensemble du spectre électromagnétique, incluant les rayonnements ultraviolet et infrarouge (la densité optique). Ce rayonnement maximal est réparti uniformément sur les surfaces terrestres et océaniques. Par exemple, les zones désertiques reçoivent en six heures cinq à six fois plus d'énergie solaire que l'humanité entière en une année civile, toutes sources de consommation d'énergie confondues (combustibles fossiles et énergie solaire). Plusieurs technologies permettent de produire et d'utiliser l'énergie solaire :

- L'énergie solaire thermique utilise des panneaux solaires pour produire de la chaleur. Après avoir transformé cette chaleur en vapeur, celle-ci peut être convertie en électricité.
- L'énergie solaire photovoltaïque produit de l'électricité à partir de la lumière du soleil grâce à des panneaux solaires. Elle est déjà disponible comme source d'énergie. exploitée dans de nombreux pays, en particulier dans les pays ou régions qui ne disposent pas de ressources énergétiques conventionnelles telles que les hydrocarbures ou le charbon[1].

1.2.1 Le rayonnement solaire

Le rayonnement solaire est composé de photons dont la longueur d'onde varie de du rayonnement ultraviolet($0.2\mu\text{m}$) à l'infrarouge éloigné ($2.5\mu\text{m}$). On fait appel au concept d'AM pour Air Mass pour décrire le spectre solaire en termes d'énergie émise [2]. Afin de prendre en considération la distance parcourue par les rayons, il est indispensable d'intégrer le concept de masse d'air (AM). Cette dernière fait référence à la longueur proportionnelle du trajet à travers l'atmosphère terrestre que traverse le rayonnement solaire direct. La masse d'air est définie comme un multiple de la distance parcourue à un endroit précis au niveau de la mer, le soleil étant positionné directement au-dessus [3].

1.2.2 Composantes du rayonnement solaire

Au niveau du sol le rayonnement global reçu par une surface plane d'inclinaison quelconque est constitué de quatre composantes principales [4] :

a) Rayonnement direct

L'irradiation directe désigne l'énergie solaire reçue directement de la part du Soleil. On peut le quantifier à l'aide d'un pyrhéliomètre [5].

b) Rayonnement diffus

Il s'agit de la portion du rayonnement solaire qui a subi plusieurs réflexions (dispersions) dans l'atmosphère [4].

c) Albédo (réfléchi)

Il s'agit de la portion du rayonnement solaire réfléchi par le sol, cette radiation dépend directement de la composition du sol (terre nue, sable, etc.). Il se distingue par un coefficient spécifique lié à la nature du lien, appelé Albédo (ϵ), avec $0 \leq \epsilon \leq 1$ [4].

d) Rayonnement global

L'ensoleillement global sur une surface quelconque près du sol est la combinaison vectorielle des composantes directe et diffusée. On opte généralement pour une référence. On fait référence au rayonnement global en fonction de la verticale de l'emplacement sur une surface horizontale[6].




Figure I- 1 : Composante du rayonnement global sur un plan horizontal.

1.2.3 Facteurs influençant le rayonnement solaire

Le rayonnement solaire reçu à la surface de la Terre est influencé par plusieurs facteurs d'ordre astronomique, géographique et atmosphérique. Ces facteurs déterminent l'intensité, la répartition spatiale et temporelle de l'énergie solaire. Ils sont présentés ci-dessous :

a) La position du soleil (angle d'incidence)

L'angle d'incidence des rayons solaires joue un rôle fondamental dans la quantité d'énergie reçue à la surface terrestre. Lorsque les rayons solaires arrivent perpendiculairement à la surface, l'énergie est concentrée et donc maximale. En revanche, lorsque les rayons sont inclinés, l'énergie se répartit sur une surface plus grande, ce qui diminue son intensité. Cet angle varie en fonction de l'heure de la journée, de la saison, de la latitude du lieu.

b) La durée d'ensoleillement

La durée d'exposition au soleil influe directement sur l'énergie totale reçue.

- En été, les journées sont plus longues $\Rightarrow$ énergie solaire plus élevée.
- En hiver, les journées sont plus courtes $\Rightarrow$ énergie plus faible.

Cette durée dépend principalement de la position géographique et de la période de l'année.

c) Les conditions atmosphériques

L'atmosphère modifie le rayonnement solaire par absorption, réflexion et diffusion.

Les nuages

- Ils réfléchissent et absorbent une partie du rayonnement solaire.
- Ils diminuent le rayonnement direct et augmentent le ray diffus.

Les aérosols (poussières, pollution)

- Ils absorbent et diffusent les rayons solaires.
- Leur effet est particulièrement important dans les régions désertiques.

L'humidité (vapeur d'eau)

- Elle absorbe une partie du rayonnement, surtout dans l'infrarouge.

d) La latitude géographique

La latitude influence l'angle d'incidence et la durée d'ensoleillement.

- Les régions proches de l'équateur reçoivent un rayonnement élevé et relativement constant.
- Les régions proches des pôles reçoivent un rayonnement plus faible et très variable.

e) L'altitude

L'altitude a un impact direct sur la quantité de rayonnement solaire reçue.

- À haute altitude :
 - L'épaisseur de l'atmosphère traversée est plus faible,
 - Les pertes par absorption et diffusion sont réduites,
 - Le rayonnement solaire est plus intense.

f) La nature de la surface terrestre (albédo)

L'albédo représente la capacité d'une surface à réfléchir le rayonnement solaire.

- Les surfaces claires (neige, sable) ont un albédo élevé $\Rightarrow$ forte réflexion.
- Les surfaces sombres (sols, végétation) absorbent davantage le rayonnement.

g) Les saisons

Les saisons résultent de l'inclinaison de l'axe de la Terre.

- En été :
 - Les rayons sont plus perpendiculaires,
 - La durée d'ensoleillement est plus longue.
- En hiver :
 - Les rayons sont plus inclinés,
 - La durée d'ensoleillement est plus courte.

h) L'orientation et l'inclinaison des surfaces

Dans les applications énergétiques (panneaux photovoltaïques), l'orientation et l'inclinaison sont essentielles.

- Une surface orientée vers le soleil reçoit un maximum d'énergie.
- L'inclinaison optimale dépend de la latitude.

1.3 Technologie photovoltaïque

La conception des panneaux solaires à base de silicium repose sur une phase de chauffage puis de refroidissement. La manière dont est conduit ce dernier joue un rôle important dans la formation et les caractéristiques des cellules qui composent ces panneaux. Concrètement, le processus de refroidissement influence les propriétés finales des panneaux solaires. Pour faire le bon choix à l'installation photovoltaïque du système étudié, on a étudié les panneaux et cellules du même fabricant (JS Solar) qui sont disponibles au marché [7].

1.3.1 Principe de fonctionnement d'une cellule photovoltaïque

Le fonctionnement de cette cellule est basé sur l'effet photovoltaïque. En effet, une cellule est composée de deux couches fines d'un matériau semi-conducteur. Les couches sont dopées de manière différente :

- Pour la couche N, fourniture d'électrons périphériques.
- Pour la couche P, il y a un déficit en électrons.

Ainsi, ces deux couches montrent une différence de potentiel. L'énergie des photons .Les électrons périphériques (couche N) captent la lumière, ce qui leur permet de surmonter la barrière de potentiel et de produire un courant électrique constant. La collecte de ce courant est réalisée grâce à l'application d'électrodes par sérigraphie sur les deux couches de semi-conducteur[8].

1.3.2 Types de cellules photovoltaïques

Les divers types de cellules photovoltaïques. Il est possible de fabriquer des cellules photovoltaïques à partir de divers semi-conducteurs. À l'heure actuelle, le matériau semi-conducteur le plus couramment utilisé dans les cellules photovoltaïques. Le silicium, qui constitue la majeure partie de la production mondiale de cellules photovoltaïques, est un matériau stable et non toxique [8].

1.3.2.1 Les cellules en monocristallin

C'est la première cellule solaire réalisée à partir d'une seule pièce de silicium cristallin. Cristaux Ils apparaissent sous la forme de disques ronds, carrés ou pseudo-carrés. Leur performance est de 12 %[9].




Figure I- 2: Cellule PV monocristalline.

1.3.2.2 Les cellules photovoltaïques Poly-cristallines

Les panneaux solaires à cellules polycristallines sont composés d'un Le silicium se cristallise sous une forme polycristalline. En examinant attentivement, on peut observer la direction différente du cristal (votre ton différent).Ils affichent des performances de 13 % à 20 %, cependant leur Le coût de fabrication est inférieur à celui des cellules monocristallines [9].



Figure I- 3: Cellule PV polycristalline.

1.3.2.3 Les cellules amorphes

Ces cellules sont composées de substrats en verre ou en matière synthétique, sur lesquels est appliquée une mince couche de silicium (l'agencement des atomes ne se reflète plus dans le cristal). Ils ont une performance approximativement de 5 à 10% moins bonne que celle des cellules cristallines, mais sont actuellement proposés à un prix assez abordable. Elles sont mises en œuvre dans les produits de consommation de petite taille (figure I.4) [9].




Figure I- 4: Cellule PV amorphe

1.3.3 Caractéristiques électriques des panneaux photovoltaïques

Les panneaux solaires (PV) sont souvent des parallélépipèdes rectangles rigides et fins (de quelques centimètres d'épaisseur), dont les spécificités sont les suivantes :

- Puissance de crête (P_c) : La puissance électrique maximale que le module est en mesure de fournir dans les conditions normales sont de (25°C avec une exposition de 1000 W/m^2).
- Caractéristique $I=f(V)$: Graphique illustrant le courant I produit par le module en relation avec la tension aux bornes de ce dernier.
- Tension à vide, V_{co} : Il s'agit de la tension mesurée aux bornes du module lorsque aucun courant n'est présent, dans des conditions standardisées de température et d'ensoleillement.
- Courant de court-circuit, I_{cc} : Un courant est délivré par un module en situation de court-circuit pour une l'ensoleillement et une température normale.
- Point de fonctionnement optimal, $P_m (V_m, I_m)$: point déterminé par son courant et sa tension où le panneau fournit sa puissance maximale.
- Rendement : rapport entre la puissance électrique optimale et la puissance de rayonnement incident.
- Facteur de forme : Proportion entre la puissance optimale P_m et la puissance maximale que peut atteindre la cellule : V_{co}, I_{cc} [10].

La figure (1.16) illustre les courbes $I(V)$ et $P(V)$ d'un module sous un éclairage et une température spécifique.




Figure I- 5: Caractéristiques $I(V)$ et $P(V)$ d'un module solaire.

1.4 Systèmes photovoltaïques

Un module photovoltaïque est formé de plusieurs cellules photovoltaïques interconnectées. On assemble ensuite ces modules pour constituer un système photovoltaïque intégral. Dans le cas

échéant, En plus de fonctionner sur un site isolé, ce système comprend divers éléments tels que le contrôleur de charge, la batterie et l'onduleur. Cependant, quand un système photovoltaïque est relié au réseau électrique, l'usage d'une batterie n'est généralement pas indispensable, car l'énergie peut être directement fournie par le réseau en cas de besoin [11].

1.4.1 Systèmes photovoltaïques connectés au réseau

On peut utiliser un système photovoltaïque de manière non autonome en l'attachant au réseau public de distribution d'électricité. Dans cette disposition, l'énergie générée par les panneaux solaires en courant continu (CC) est transformée en courant alternatif (AC) grâce à un onduleur. Cette énergie peut être utilisée directement sur le site de production ou, si elle est produite en excès, être vendue au réseau électrique. Le principal atout de ce genre de dispositif est que, quand la production d'énergie solaire ne suffit pas à satisfaire les besoins du lieu, le réseau électrique peut suppléer à cette insuffisance. Par conséquent, le recours aux batteries pour conserver l'énergie n'est pas indispensable, ce qui facilite l'installation et diminue les frais liés aux systèmes indépendants. Toutefois, cette configuration dépend de la disponibilité du réseau électrique et peut requérir l'utilisation d'appareils de protection et de contrôle pour garantir une intégration efficace et sûre au réseau public[12].




Figure I- 6: Schéma d'un système photovoltaïque connecté au réseau de distribution électrique.

1.4.2 Systèmes photovoltaïques autonomes

Un système photovoltaïque hors réseau est élaboré pour alimenter un endroit isolé et comporte un dispositif de stockage d'énergie. Les panneaux solaires génèrent de l'électricité sous forme de courant continu (CC), cependant la majorité des dispositifs fonctionnent avec du courant

alternatif (AC), ce qui nécessite une transformation. La batterie, en tant que système de stockage, occupe une place cruciale : elle emmagasine l'énergie solaire collectée durant la journée. Cette énergie emmagasinée est par la suite utilisée pour fournir de l'énergie aux appareils grâce à un régulateur de charge, qui gère le chargement de la batterie afin d'éviter une surcharge.

Par la suite, un onduleur est mis en œuvre pour transformer le courant continu de la batterie en courant alternatif, requis pour les équipements domestiques ordinaires. Toutefois, ce système autonome comporte certains inconvénients :

- L'élévation du coût initial est due à l'exigence d'un système de stockage d'énergie (batterie), d'un régulateur de charge et d'un onduleur.
- L'installation prend beaucoup de place, surtout à cause de la batterie et du matériel qui y est lié.
- Diminution de l'efficacité énergétique en raison des pertes lors de la transformation du courant et du stockage de l'énergie [12].




Figure I- 7: Schéma d'un système photovoltaïque autonome.

1.4.3 Composants d'une centrale photovoltaïque

Les composants essentiels d'un système de production d'énergie solaire photovoltaïque sont les suivants :

- a) Un dispositif photovoltaïque destiné à recueillir la lumière solaire
- b) Un convertisseur pour changer le courant en courant alternatif (AC) à partir du courant continu (CC)
- c) Un groupe de batteries associé à un régulateur de charge pour les systèmes photovoltaïques autonomes. Composants supplémentaires du système.

On désigne sous le terme « composants du système » tous les éléments, à l'exception des modules photovoltaïques[13].

1.4.3.1 Générateur

Il s'agit du domaine du photovoltaïque, où les panneaux solaires sont formés de modules solaires interconnectés en série et/ou en parallèle afin de générer de l'électricité. Les modules sont installés sur des structures métalliques, ce qui permet à l'orientation et aux angles d'inclinaison spécifiques du champ solaire d'être maintenus [13].



Figure I- 8 : Générateur photovoltaïque.

1.4.3.2 Les batteries

La batterie conserve l'énergie électrique afin de fonctionner durant la nuit ou lors de longues périodes nuageuses ou couvertes lorsque le générateur photovoltaïque ne peut à lui seul produire assez d'énergie. Le nombre de jours durant lesquels la capacité de stockage de la batterie peut être utilisée pour alimenter des charges électriques directement à partir de la batterie, sans intervention du générateur photovoltaïque, pour les usages photovoltaïques standards et moins critiques, est généralement prévu entre deux et six jours. Dans le cas d'applications cruciales nécessitant des charges vitales ou de sécurité publique, les durées d'autonomie peuvent dépasser dix jours. a généralement recours à des batteries au plomb ou au lithium-ion[13].



Figure I- 9: Batterie solaire photovoltaïque.

1.4.3.3 Onduleur

La batterie et le générateur photovoltaïque génèrent de l'électricité et de la tension en courant continu. Un onduleur a pour fonction de transformer l'électricité en courant continu (CC) en électricité en courant alternatif (AC) qui alimente vos équipements électriques et/ou qui peut être exportée vers le réseau AC. On propose une vaste sélection d'onduleurs allant de quelques centaines de watts (habituellement pour les systèmes autonomes) à plusieurs kW (la gamme la plus couramment utilisée), et même jusqu'à 2 000 kW pour les installations de grande envergure[13].



Figure I- 10: Les onduleurs solaires photovoltaïques.

1.4.3.4 Régulateur

Un régulateur de charge assure la connexion entre les batteries et le générateur photovoltaïque. Le contrôleur de charge préserve la batterie d'une surcharge ou d'un déchargement excessif. On peut Aussi, il est possible de fournir des renseignements sur l'état du système ou d'effectuer le suivi et le règlement de la consommation d'électricité[13].



Figure I- 11: Régulateur solaires photovoltaïques.

1.4.3.5 Câblage

Chaque système solaire photovoltaïque intègre des câbles qui assurent le transfert de l'énergie des panneaux solaires vers les batteries, puis vers la charge. En règle générale, les câbles préconisés pour le courant continu sont en cuivre souple, ce matériau offrant le meilleur équilibre coût/conductivité. De plus, le fait qu'ils soient multibrins garantit une connexion optimale, réduisant ainsi les pertes d'énergie liées aux baisses de tension[13].



Figure I- 12: câbles solaire photovoltaïque.

1.5 Facteurs influençant la production photovoltaïque

La production d'énergie photovoltaïque dépend de plusieurs facteurs environnementaux et techniques qui influencent directement la performance des panneaux solaires et la quantité d'énergie électrique produite. Parmi les paramètres les plus importants figurent l'irradiation solaire, la température des panneaux, les conditions météorologiques ainsi que l'orientation et l'inclinaison des modules photovoltaïques [14].

1.5.1 Irradiation solaire

L'irradiation solaire constitue le facteur principal influençant la production d'énergie photovoltaïque. Elle représente la quantité d'énergie solaire reçue par unité de surface pendant une période donnée. Une augmentation de l'irradiation entraîne généralement une augmentation directe de la puissance produite par les panneaux photovoltaïques. Cette irradiation dépend de plusieurs paramètres tels que la position géographique, la saison, l'heure de la journée et la couverture nuageuse [15].

1.5.2 Température des panneaux

La température des panneaux photovoltaïques influence fortement leur rendement électrique. En effet, une augmentation de la température provoque généralement une diminution de la tension de sortie des cellules photovoltaïques, ce qui entraîne une baisse de la puissance produite. Par conséquent, même sous une forte irradiation solaire, une température élevée peut réduire les performances globales du système photovoltaïque[16].

1.5.3 Conditions météorologiques

Les conditions météorologiques telles que la nébulosité, l'humidité, la vitesse du vent et la présence de poussière affectent directement la quantité d'énergie solaire reçue par les panneaux photovoltaïques. Par exemple, une couverture nuageuse importante diminue l'irradiation incidente, tandis que le vent peut contribuer à refroidir les panneaux et améliorer légèrement leur rendement énergétique [17].

1.5.4 Orientation et inclinaison des panneaux

L'orientation et l'inclinaison des panneaux photovoltaïques jouent un rôle essentiel dans l'optimisation de la production d'énergie. Une orientation vers le sud dans l'hémisphère nord, associée à un angle d'inclinaison adapté à la latitude du site d'installation, permet généralement de maximiser la quantité d'énergie solaire reçue et d'améliorer la production annuelle du système photovoltaïque [18].

1.6 Conclusion

Ce chapitre a permis de présenter le cadre général de l'étude à travers les notions fondamentales liées à l'énergie solaire et aux systèmes photovoltaïques, en mettant en évidence les principaux facteurs climatiques et techniques influençant la production d'énergie photovoltaïque. Il a également permis d'identifier les données essentielles utilisées dans l'analyse et l'évaluation des performances de ces systèmes. Ces éléments constituent une base indispensable pour comprendre et appliquer les méthodes de prévision de la production photovoltaïque, qui feront l'objet du chapitre suivant intitulé Méthodes de prévision de la production photovoltaïque.

Chapitre II : Méthodes de prévision de la production photovoltaïque.

2.1. Introduction

La prévision de la production d'énergie solaire est cruciale pour l'organisation et la gestion des systèmes énergétiques contemporains, compte tenu de l'irrégularité de l'énergie solaire due à des facteurs météorologiques comme le rayonnement solaire et la température. Il est donc indispensable de recourir à des techniques de prévision précises pour renforcer la stabilité du réseau électrique et optimiser la gestion de la production d'énergie. De nombreuses techniques de prévision ont vu le jour, allant des approches statistiques traditionnelles aux méthodes reposant sur l'intelligence artificielle et l'apprentissage profond, sans oublier les modèles mixtes qui contribuent à améliorer la précision des résultats.

Dans ce chapitre, nous exposons diverses techniques de prévision de la production photovoltaïque. Nous débutons par une classification selon l'horizon temporel, puis nous abordons les méthodes traditionnelles, celles basées sur l'intelligence artificielle et enfin les modèles mixtes que nous avons utilisés dans le cadre de notre recherche.

2.2. Importance de la prévision dans les systèmes énergétiques

La prévision de la production énergétique joue un rôle essentiel dans la gestion efficace des systèmes électriques modernes. Elle permet d'assurer une meilleure planification et exploitation des ressources énergétiques, notamment dans le contexte des énergies renouvelables comme le photovoltaïque, caractérisées par leur variabilité. En effet, la prévision contribue à réduire les erreurs de production, à maintenir l'équilibre entre l'offre et la demande d'électricité, et à améliorer la stabilité du réseau électrique. De plus, elle aide les opérateurs et les entreprises énergétiques à prendre des décisions optimales en matière de planification et de gestion des systèmes énergétiques. Ainsi, l'absence de prévision fiable peut entraîner des déséquilibres importants et perturber le fonctionnement global du système énergétique [19].

2.3. Types de prévision

L'horizon temporel d'une prévision spécifie la période qui s'étend entre le moment où la prévision est faite et le futur à anticiper. On fait généralement la distinction entre trois catégories de prévisions : à long terme, à moyen terme et à court terme. Le sens de ces termes peut changer en fonction du contexte dans lequel ils sont employés [20].

2.3.1. Prévision à court terme

L'estimation à court terme de l'énergie électrique vise à prédire la consommation d'électricité dans un avenir proche, habituellement sur une période allant de quelques heures à quelques

jours. Elle emploie des méthodes comme la modélisation statistique, les informations en temps réel concernant la consommation d'énergie, les conditions climatiques et les prévisions de charge afin de prévoir avec exactitude la demande d'électricité à court terme. Ces prédictions sont cruciales pour l'administration en direct du réseau électrique, offrant aux opérateurs la possibilité d'effectuer des choix prompte et efficaces afin d'assurer un approvisionnement constant et sûr en électricité [21].

2.3.2. Prévision à moyen terme

L'estimation de la demande future en électricité sur une période généralement comprise entre un an et quelques années est au cœur de la prévision à moyen terme. Elle s'appuie sur l'évaluation des tendances de demande actuelles, les fluctuations saisonnières et les éléments économiques, tout en tenant compte des événements à venir tels que les projets de construction, les arrêts d'usines ou les modifications réglementaires. Ces prévisions sont essentielles pour l'administration quotidienne du réseau électrique, l'organisation de la production et l'assurance de la fourniture d'électricité à court et moyen terme [22].

2.3.3. Prévision à long terme

L'estimation de la demande d'électricité sur plusieurs années ou décennies. Elle se base sur des modèles qui intègrent la croissance démographique, les comportements de consommation, les politiques énergétiques et divers autres éléments. Ces projections soutiennent la planification des infrastructures énergétiques et les choix d'investissement pour assurer une fourniture d'électricité fiable, abordable et durable [23].

2.4. Méthodes classiques de prévision

La prévision de l'énergie solaire constitue un élément essentiel pour assurer une intégration optimale des sources renouvelables dans les réseaux électriques intelligents. En raison de la variabilité intrinsèque du rayonnement solaire influencée par la couverture nuageuse, la poussière atmosphérique, l'humidité ou encore les changements rapides des conditions locales, il devient indispensable de disposer de méthodes de prévision fiables capables d'anticiper avec précision la production photovoltaïque. Cette capacité d'anticipation permet non seulement d'améliorer la stabilité du réseau, mais aussi d'optimiser la planification, le stockage et la gestion de la demande énergétique.

Dans la littérature, les méthodes traditionnelles suggérées tendent à se classer en trois catégories majeures. Les modèles physiques reposent sur une représentation précise de la météorologie et utilisent des équations radiatives ainsi que des données de l'atmosphère, mais

ils requièrent des informations complexes et engendrent un coût computationnel important. Les modèles statistiques, de leur côté, tentent de saisir les liens entre les données passées et les paramètres solaires, mais ils se heurtent à des difficultés face aux comportements non linéaires et non stationnaires des signaux photovoltaïques. Finalement, les modèles hybrides fusionnent les atouts des deux premières catégories ou incorporent l'intelligence artificielle pour optimiser la précision, tout en demeurant tributaires de la qualité des données et de la sélection des paramètres[24].




Figure II- 1: Classification des méthodes de prévision de la puissance de sortie photovoltaïque

2.4.1. Méthodes statistiques

On utilise des modèles statistiques afin d'extraire des motifs à partir des données et de prévoir les valeurs pour de nouveaux points de données. Voici quelques-uns des modèles statistiques fréquemment employés en lien avec notre problématique :

➤ **ARMA/ARIMA/SARIMA**

Les modèles ARMA (Moyenne Mobile Autorégressive), ARIMA (Moyenne Mobile Autorégressive Intégrée) et SARIMA (Moyenne Mobile Autorégressive Saisonnière Intégrée) sont fréquemment employés dans le domaine de l'apprentissage automatique pour les missions de prévision. Ces modèles sont aptes à anticiper les valeurs futures d'une série temporelle en se basant sur leurs observations passées. Ils évaluent les paramètres qui s'adaptent le mieux aux données de la série temporelle et les exploitent pour réaliser des prédictions [25].

2.4.2. Régression linéaire

La régression linéaire est l'une des méthodes statistiques les plus simples utilisées pour la prévision de la production photovoltaïque. Elle consiste à modéliser la relation entre une variable dépendante, telle que la puissance produite, et une ou plusieurs variables indépendantes, comme l'irradiation solaire et la température ambiante. Cette approche repose sur l'hypothèse d'une relation linéaire entre les variables. Bien qu'elle soit facile à mettre en œuvre et à interpréter, la régression linéaire présente des limites importantes, notamment son incapacité à capturer les relations non linéaires et les dynamiques complexes présentes dans les systèmes photovoltaïques [26].

2.5. Méthodes basées sur l'intelligence artificielle

L'apprentissage automatique et l'apprentissage profond se sont imposés comme des outils puissants pour modéliser la variabilité des ressources en énergie solaire, qui dépendent de nombreux facteurs tels que les conditions météorologiques, le rayonnement solaire, la température et l'environnement atmosphérique. Ces techniques analysent de vastes ensembles de données historiques afin d'apprendre des modèles complexes et de produire des prévisions précises. Contrairement aux méthodes traditionnelles, souvent basées sur des modèles physiques ou statistiques simplifiés, les approches fondées sur l'apprentissage automatique et profond sont capables de capturer efficacement les relations non linéaires et les dynamiques saisonnières.

Les méthodes d'apprentissage automatique, comme les réseaux de neurones, les forêts aléatoires et les SVM, ont été largement exploitées pour la prévision de la puissance

photovoltaïque. L'émergence du DeepLearning, avec des architectures avancées telles que les CNN, LSTM et GRU, a renforcé cette capacité en modélisant plus efficacement les dépendances temporelles et spatiales. Ces approches ont significativement amélioré la précision des prévisions, facilitant une meilleure intégration de l'énergie solaire dans les smart grids. Ainsi, la synergie entre Machine Learning et DeepLearning marque une avancée clé vers une gestion plus intelligente et durable des ressources solaires [27].

2.5.1. Réseaux de neurones artificiels (ANN)

Les réseaux de neurones artificiels (ANN), une méthode inspirée du processus de pensée humain, offre une nouvelle perspective sur des problématiques liées à la perception, la mémorisation, l'apprentissage et le raisonnement [28]. Les réseaux de neurones se sont révélés être des options très prometteuses agissant comme un modèle mathématique capable d'approcher les relations entre les variables. À la différence des techniques traditionnelles, les réseaux de neurones sont conçus sans présumer de la distribution des variables, et sans imposer une structure spécifique aux données. Ils sont couramment utilisés avec succès pour les prévisions dans divers secteurs [29],[30]. Ces réseaux de neurones ont été perçus comme des instruments précieux pour les problèmes de classification et de régression. Ils visaient à saisir les caractéristiques du système nerveux en se basant sur les éléments fondamentaux.

1.5.1.1. Principes généraux

Un neurone représente une unité de traitement. Elle peut inclure une ou plusieurs entrées et une sortie déterminée par diverses caractéristiques :

La sortie suit le même processus, que les entrées soient X ou E ;

- Chaque entrée se voit attribuer un poids (W) qui permet d'ajuster la valeur de certaines par rapport aux autres ;
- Une fonction d'agrégation est utilisée pour générer une seule valeur à partir des entrées et des poids associés ;
- Un seuil (ou biais) est défini pour indiquer quand le neurone doit intervenir ;
- Une fonction d'activation attribue à chaque valeur agrégée une sortie unique dépendante du seuil.

Le neurone produit un résultat qui est simplement la somme des produits de toutes les entrées et des poids, le tout étant traversé par une « filtration » que l'on désigne sous le terme de fonction d'activation (sortie). On peut donc représenter le neurone formel de la manière suivante, comme illustré à la Figure (2.1) :




Figure II- 2 : Représentation schématique du neurone artificiel.

2.5.2. Support Vector Machines (SVM)

Les Machines à Vecteurs de Support (SVM) représentent une catégorie d'algorithme supervisé d'apprentissage automatique employé pour les missions de prédiction. Les SVMs reposent sur le concept de dénicher un hyperplan qui distingue les données en diverses catégories. L'hyperplan est sélectionné dans le but d'optimiser la marge, qui représente l'écart entre l'hyperplan et les points de données les plus près de chaque classe [31].

2.6. Deep Learning pour la prévision énergétique

Le Deep Learning (apprentissage profond) est une branche avancée de l'apprentissage automatique basée sur des réseaux de neurones artificiels multicouches capables d'extraire automatiquement des caractéristiques complexes à partir des données. Parmi les architectures les plus utilisées figurent les réseaux convolutifs (CNN), adaptés aux données spatiales, ainsi que les réseaux récurrents (RNN) et leurs variantes LSTM, BiLSTM et GRU, particulièrement efficaces pour le traitement des séries temporelles grâce à leur capacité à modéliser les dépendances temporelles. Les réseaux de neurones profonds permettent de capturer des relations non linéaires complexes entre les variables d'entrée et de sortie, améliorant ainsi la précision des prévisions énergétiques, notamment pour la production photovoltaïque. Malgré leurs besoins élevés en données et en ressources de calcul, ces modèles offrent généralement des performances supérieures aux méthodes traditionnelles d'apprentissage automatique dans les problèmes de prévision complexes [32].

2.6.1. Long Short-Term Memory (LSTM)

Le LSTM (Long Short-Term Memory) est une version spécifique des réseaux de neurones récurrents. Pour résoudre les problèmes du gradient qui disparaît et de la dépendance à long terme, qui rendent le modèle inadapté à l'apprentissage des données séquentielles, on peut insérer une cellule de mémoire dans chaque neurone de la couche cachée et utiliser des portes d'entrée, de sortie et d'oubli pour réguler l'état de cette cellule de mémoire [33]. La figure présente une illustration de l'architecture du neurone LSTM.




Figure II- 3: L'architecture des réseaux LSTM

La cellule de mémoire et l'état caché sont capables de stocker les informations historiques des données séquentielles. Trois unités de porte supervisent les données stockées dans la mémoire cellulaire. En se basant sur l'état caché précédent h_{t-1} et l'entrée actuelle x_t , la porte d'oubli (forget gate) efface les informations présentes dans la cellule de mémoire. La porte d'oubli est déterminée de la manière suivante :

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

En se basant sur l'état masqué précédent h_{t-1} à l'instant précédent et l'entrée actuelle x_t à l'instant présent, la porte d'entrée (input gate) intègre des données supplémentaires dans la cellule de mémoire. Elle constitue le point d'accès. C'est l'état de la cellule et $\tilde{C}_t$ est la valeur qui sert à déterminer l'état courant de la cellule C_t . La porte d'entrée gère la régulation des informations à incorporer dans la cellule de mémoire en se basant sur l'état caché précédent et l'entrée courante.

La mise à jour de l'état de la cellule est calculée en utilisant la valeur $\tilde{C}_t$, qui sera par la suite employée dans les calculs suivants. Après le calcul de la porte d'oubli (forget gate) et de la

porte de sortie (output gate), l'équation ci-dessous est employée pour actualiser la cellule de mémoire :

$$C_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{C}_t \quad (2)$$

Cette équation actualise la valeur de la cellule de mémoire en se basant sur les données précédemment déterminées à partir de la porte d'oubli et de la porte de sortie. Elle a pour fonction de réguler le flux d'informations dans la cellule de mémoire, selon les décisions déterminées par les portes d'oubli et de sortie. L'état caché actuel h_t est défini par la porte de sortie (output gate) en tenant compte de l'état caché précédent h_{t-1} , de l'entrée actuelle x_t et de la mise à jour de la cellule de mémoire C_t .

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (4)$$

La porte de sortie a une importance capitale dans le calcul de l'état actuel caché. Elle intègre les informations de l'état caché précédent, de l'entrée actuelle et de la cellule de mémoire actualisée pour évaluer la participation de chaque composant à la génération de l'état caché actuel. Cette phase permet de maîtriser et de gérer le flux d'informations afin de produire l'état caché approprié en fonction des données contextuelles antérieures et de la saisie présente. W_f Symbolise le poids de la porte d'oubli (forget gate), W_i et W_c correspondent aux poids de la porte d'entrée (input gate), tandis que W_o représente le poids de la porte de sortie (output gate). En outre, b_f , b_i , b_c et b_o symbolisent les biais associés à chaque porte.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (5)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (6)$$

La fonction σ correspond à la fonction sigmoïde, qui sert à convertir les valeurs en une échelle allant de 0 à 1. Ces poids et biais sont employés dans les formules de traitement des diverses portes du réseau LSTM pour moduler l'effet de chaque entrée et orienter le courant d'informations au sein de la cellule de mémoire et de l'état caché.

2.7. Modèles hybrides de prévision

L'association de diverses sortes de modèles et méthodes est une approche visant à élaborer et à développer un modèle innovant aux performances supérieures ; ce sont des modèles hybrides. Par exemple, un modèle hybride pourrait associer un réseau de neurones profonds à l'apprentissage par renforcement, ou fusionner un réseau neuronal convolutif et un réseau neuronal récurrent [34]. On est fréquemment confronté à des enjeux complexes demandant plusieurs méthodes pour leur résolution, c'est dans ce contexte que les modèles hybrides peuvent être mis en œuvre. La distinction entre les modèles hybrides et les modèles d'ensemble

réside dans le fait que les modèles hybrides fusionnent divers types de modèles ou techniques pour concevoir un modèle inédit avec des performances supérieures, tandis que les modèles d'ensemble assemblent plusieurs modèles individuels afin de constituer un modèle plus solide et précis. Ces modèles peuvent être bénéfiques pour optimiser les performances des modèles d'apprentissage automatique, en se référant aux données analysées et au problème particulier [35].

2.7.1. Principe des modèles hybrides

Les modèles hybrides de prévision constituent une approche avancée visant à améliorer les performances des modèles prédictifs en combinant plusieurs techniques complémentaires. L'idée principale consiste à exploiter les avantages de différentes méthodes afin de compenser leurs limites respectives. Dans le domaine de la prévision énergétique, notamment pour les systèmes photovoltaïques, les données présentent généralement un comportement fortement non linéaire, non stationnaire et influencé par plusieurs facteurs météorologiques. Les modèles hybrides permettent ainsi de mieux représenter cette complexité et d'obtenir des prévisions plus précises que celles fournies par les modèles individuels [36]. Le principe général d'un modèle hybride repose sur une succession d'étapes comprenant généralement le prétraitement des données, la décomposition des séries temporelles, l'apprentissage des composantes obtenues puis la reconstruction du signal final. Cette approche permet de séparer les différentes structures contenues dans le signal, telles que les tendances, les fluctuations saisonnières et les composantes aléatoires, avant leur modélisation par des algorithmes adaptés. La structure générale d'un modèle hybride peut être représentée par l'équation suivante [37]:

$$Y(t) = \sum_{i=1}^n C_i(t) + R(t) \quad (7)$$

où :

- $Y(t)$ Représente la série temporelle originale ;
- $C_i(t)$ Désigne la i ème composante issue de la décomposition ;
- $R(t)$ Représente le résidu ou la composante résiduelle ;
- n est le nombre total de composantes extraites.

Chaque composante est ensuite prédite individuellement à l'aide d'un modèle d'apprentissage automatique ou d'apprentissage profond avant d'être recombinaée pour produire la prévision finale.

2.7.2. Techniques de décomposition utilisées dans les modèles hybrides

Les techniques de décomposition constituent souvent la première étape des modèles hybrides. Elles permettent de transformer un signal complexe en plusieurs sous-signaux plus simples et plus faciles à modéliser.

a) Décomposition en ondelettes (Wavelet Transform – WT)

La transformation en ondelettes est une méthode largement utilisée pour l'analyse des signaux non stationnaires. Elle permet de décomposer une série temporelle en composantes de différentes fréquences correspondant aux variations lentes et rapides du signal. La transformée en ondelettes continue est définie par [38]:

$$W(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \psi^* \left(\frac{t - b}{a} \right) dt \quad (8)$$

Où :

- a Est le facteur d'échelle ;
- b Représente la translation temporelle ;
- ψ Est l'ondelette mère.

Cette technique est fréquemment combinée avec des réseaux de neurones artificiels (WT-ANN), des modèles LSTM (WT-LSTM) ou des machines à vecteurs de support (WT-SVM).

b) Décomposition modale empirique (EMD)

L'Empirical Mode Decomposition (EMD) est une méthode adaptative permettant de décomposer un signal en plusieurs fonctions appelées Intrinsic Mode Functions (IMF)[39]. Cette approche est particulièrement adaptée aux signaux photovoltaïques caractérisés par une forte variabilité due aux nuages et aux conditions météorologiques.

c) Ensemble Empirical Mode Decomposition (EEMD)

L'EEMD constitue une amélioration de l'EMD classique. Elle consiste à ajouter un bruit blanc au signal avant décomposition afin de réduire le phénomène de mélange modal (Mode

Mixing). Cette méthode offre une meilleure stabilité et est largement utilisée dans les applications de prévision solaire à court terme.

d) Variational Mode Decomposition (VMD)

La Variational Mode Decomposition est l'une des techniques de décomposition les plus performantes actuellement utilisées dans les travaux de prévision énergétique. Son principe consiste à rechercher un ensemble de modes $u_{k=1}^K$ ayant chacun une fréquence centrale propre et une bande passante minimale. La VMD présente généralement de meilleures performances que l'EMD en termes de robustesse au bruit et de stabilité numérique[40].

e) Iterative Filtering (IF)

L'Iterative Filtering est une technique récente de décomposition adaptative reposant sur un filtrage itératif du signal. Elle permet d'extraire progressivement différentes composantes fréquentielles tout en conservant une bonne stabilité numérique. Cette méthode est particulièrement adaptée aux séries temporelles fortement non stationnaires[41].

2.7.3. Hybridation avec les algorithmes d'optimisation

Une autre forme d'hybridation consiste à utiliser des algorithmes d'optimisation pour ajuster automatiquement les hyperparamètres des modèles prédictifs. Les algorithmes les plus employés sont :

- Genetic Algorithm (GA)
- Particle Swarm Optimization (PSO)
- Grey Wolf Optimizer (GWO)
- Whale Optimization Algorithm (WOA)
- Ant Colony Optimization (ACO)
- Artificial Bee Colony (ABC)

Ces techniques permettent d'optimiser le nombre de neurones, le taux d'apprentissage, le nombre de couches cachées et d'autres paramètres influençant directement la précision des prévisions.

2.7.4. Avantages et limites des modèles hybrides

Avantages

- Réduction du bruit contenu dans les données.
- Amélioration de la précision des prévisions.
- Meilleure modélisation des comportements non linéaires.
- Gestion efficace des séries temporelles non stationnaires.
- Robustesse accrue face aux variations météorologiques.

Limites

- Complexité de mise en œuvre plus élevée.
- Temps de calcul important.
- Difficulté de sélection des paramètres optimaux.
- Besoin de ressources informatiques plus importantes.




Figure II- 4 : General Architecture of a Hybrid Model for Solar Energy Prediction.

2.8. Conclusion

Ce chapitre a présenté les différentes méthodes de prévision de la production d'énergie photovoltaïque, allant des approches traditionnelles jusqu'aux techniques modernes basées sur l'intelligence artificielle et le DeepLearning. Il a été montré que les méthodes classiques, bien qu'elles soient simples, présentent des limites dans la gestion des complexités et de la non-linéarité des données réelles. En revanche, les techniques de DeepLearning offrent une meilleure capacité d'extraction des motifs complexes et améliorent la précision des prévisions. Dans ce contexte, les modèles hybrides, en particulier le modèle basé sur la combinaison SD-LSTM, sont considérés comme l'une des solutions les plus efficaces, car ils permettent d'améliorer significativement les performances de prévision en combinant la puissance de la décomposition et le traitement des séries temporelles.

Chapitre III :Modélisation, résultats et discussion.

3.1. Introduction

Dans ce chapitre, nous présentons la méthodologie adoptée pour la réalisation de cette étude. Il décrit les différentes étapes de traitement des données, depuis la collecte des données météorologiques et de production photovoltaïque jusqu'au prétraitement et à la normalisation afin de les rendre exploitables par les modèles de prédiction. Ensuite, nous définissons les variables utilisées, notamment les variables exogènes et endogènes, ainsi que leur rôle dans le modèle. Par la suite, nous présentons les méthodes de décomposition des signaux, notamment la Swarm Decomposition, utilisée pour analyser et décomposer les séries temporelles en composantes plus simples, ainsi que les modèles d'apprentissage profond, en particulier le modèle LSTM utilisé pour la prévision de la production photovoltaïque.

Enfin, nous exposons les différents scénarios expérimentaux et les hyperparamètres optimisés afin d'obtenir les meilleures performances possibles du modèle

3.2. Description des données utilisées

Les données utilisées dans cette étude proviennent de la société nationale Sonelgaz (Société Nationale de l'Électricité et du Gaz). Elles ont été collectées à partir de la centrale photovoltaïque de Laghouat (Fig.III.1). Les données indiquent qu'en 2016, la puissance produite par cette centrale a atteint environ 60 MW. Cependant, cette production peut varier ou diminuer au fil du temps en raison de facteurs environnementaux et opérationnels. Les données sont enregistrées avec un pas de temps de 30 minutes, ce qui permet de suivre avec précision l'évolution temporelle de la production photovoltaïque.




Figure III- 1: Localisation de la centrale photovoltaïque de Laghouat.

La période d'étude s'étend de (à compléter : de 01/01/2024 à 31/12/2024). Ces données sont considérées comme fiables puisqu'elles proviennent d'une source officielle. Les principales variables utilisées dans ce travail sont :

- **La puissance produite (énergie photovoltaïque)**

Afin de mieux caractériser la série de données utilisée dans cette étude, une analyse statistique descriptive a été réalisée (Fig 3.2). Cette analyse permet d'obtenir une vue d'ensemble sur la distribution des valeurs, leur dispersion ainsi que la qualité des données disponibles. Les principaux indicateurs statistiques calculés comprennent la moyenne, la médiane, l'écart-type, les valeurs extrêmes (minimum et maximum), ainsi que le nombre de valeurs nulles et manquantes.




Figure III- 2: Puissance PV (KW)

Les résultats obtenus sont présentés dans le Tableau 3.1. Ils montrent une forte variabilité des données, illustrée par un écart-type élevé, ainsi que la présence d'un nombre non négligeable de valeurs nulles correspondant aux périodes sans production énergétique, notamment durant la nuit. Par ailleurs, seules deux valeurs manquantes ont été identifiées, ce qui témoigne d'une bonne qualité globale de la base de données.

Table III. 1: Statistiques de Puissance PV (KW)

Paramètre	Valeur
Moyenne (Mean)	18226
Median (Mediane)	16163
Ecart-type (Std)	15982
Maximum	52101
Minimum	0
Valeurs Nulles (Zeros)	2099
Valeurs Manquantes (NaN)	2

Parmi les variables explicatives utilisées pour la prévision de la puissance photovoltaïque, le rayonnement solaire représente le facteur le plus déterminant, puisqu'il est directement lié au processus de conversion de l'énergie solaire en énergie électrique. L'analyse de cette variable

permet d'évaluer sa variabilité et son comportement au cours de la période étudiée. La Figure 3.3 illustre l'évolution du rayonnement solaire exprimé en W/m^2 , alors que le Tableau 3.2 présente les statistiques descriptives correspondantes. Cette variable sera utilisée comme entrée principale des modèles de prévision développés dans cette étude




Figure III- 3: Radiation solaire (W/m^2).

Table III. 2: Statistiques de Radiation solaire (W/m^2)

Paramètre	Valeur
Irradiance Moyenne	386.88
Pic de Radiation (Max)	1307.6
Somme des NaNs	0

La température constitue l'un des principaux facteurs environnementaux affectant le fonctionnement des panneaux photovoltaïques. Son analyse est essentielle pour comprendre les variations de la production électrique et améliorer les performances des modèles de prévision. La Figure III.4 illustre l'évolution de la température au cours de la période étudiée, tandis que le Tableau 3.3 présente les statistiques descriptives correspondantes. Cette variable sera utilisée comme donnée d'entrée dans les modèles de prévision développés dans ce travail.




Figure III- 4: Température ($^{\circ}C$)

Table III. 3: Statistiques de Température (°C)

Paramètre	Valeur
Température Moyenne	22.713
Température Max	45.6
Température Min	0
Nombre de NaNs	0

Ces variables sont utilisées comme entrées dans le modèle SD–LSTM afin de réaliser les prévisions. Il est à noter que la production est nulle durant les périodes nocturnes en raison de l’absence de rayonnement solaire.

3.3. Prétraitement des données

3.3.1. Nettoyage

Avant la modélisation, les données ont été nettoyées afin d’améliorer leur qualité. Les valeurs nulles liées aux périodes nocturnes ont été supprimées, et les valeurs manquantes ont été traitées par suppression, Le tableau III.4 présente les statistiques des données après le nettoyage.

Table III. 4: Statistiques de donne après le Nettoyage

	Paramètre	Valeur
Puissance	Moyenne (Mean)	22720
	Median (Mediane)	23722
	Ecart-type (Std)	14707
	Maximum	52101
	Minimum	0.93
	Valeurs Nulles (Zeros)	0
	Valeurs Manquantes	0
Radiation solaire	Irradiance Moyenne	480.44
	Pic de Radiation (Max)	1307.6
	Somme des NaNs	0
Température	Temperature Moyenne	24.362
	Temperature Max	45.6
	Température Min	0
	Nombre de NaNs	0

3.3.2. Normalisation

Après le nettoyage des données, une étape de normalisation a été appliquée afin de mettre toutes les variables sur la même échelle et d’améliorer les performances des modèles de prédiction. Dans ce travail, la méthode de normalisation **Z-score** a été utilisée, selon la relation suivante :

$$X_{\text{Norm}} = \frac{X - \mu}{\delta} \quad (1)$$

Que :

μ : moyenne σ : écart-type

3.3.3. Délai

Dans cette étude, nous avons choisi d'introduire différents délais (2, 4 et 6) afin d'analyser l'influence des valeurs passées des variables exogènes sur la puissance produite. L'objectif est d'identifier le délai qui fournit les meilleures performances de prédiction. Cette approche permet de comparer plusieurs configurations temporelles et de sélectionner celle qui minimise l'erreur et améliore la précision du modèle (Fig III.5).




Figure III- 5: Structure des entrées avec différents délais.

3.4. Construction du modèle hybride SD-LSTM

Le modèle hybride SD-LSTM proposé dans cette étude combine la technique de décomposition Swarm Decomposition (SD) avec le réseau de neurones récurrent Long Short-Term Memory (LSTM) afin d'améliorer la précision de la prévision de la production photovoltaïque. L'objectif principal de cette hybridation est de réduire la complexité du signal original en le décomposant en plusieurs composantes plus simples avant leur modélisation par le réseau LSTM. La méthodologie adoptée comprend cinq étapes principales : le prétraitement des données, la décomposition du signal par SD, la préparation des séquences temporelles, l'apprentissage du modèle LSTM et enfin la reconstruction de la prévision finale.

Étape 1 : Prétraitement des données

Les données météorologiques et la production photovoltaïque ont d'abord été soumises à une phase de prétraitement comprenant :

- La suppression ou le traitement des valeurs manquantes ;

- La vérification des valeurs aberrantes ;
- La normalisation des variables dans l'intervalle [0,1] afin d'améliorer la convergence du réseau de neurones ;
- La division des données en ensembles d'apprentissage (65 %), de validation (15 %) et de test (20 %).

Cette étape permet d'assurer la qualité des données utilisées durant l'entraînement du modèle.

Étape 2 : Décomposition du signal par Swarm Decomposition (SD)

La technique Swarm Decomposition est ensuite appliquée à la série temporelle de production photovoltaïque. Cette méthode, inspirée des comportements collectifs observés dans les systèmes biologiques, décompose le signal initial en plusieurs composantes représentant différentes fréquences et dynamiques temporelles. Le signal original ($X(t)$) est représenté sous la forme :

$$X(t) = \sum_{i=1}^N SD_i(t) + R(t) \quad (2)$$

$SD_i(t)$ Représente la i ème composante extraite ;

- $R(t)$ Correspond au résidu final ;
- N Désigne le nombre total de composantes obtenues.

Étape 3 : Construction des séquences temporelles

Après décomposition, chaque composante SD est transformée en séquences temporelles adaptées à l'apprentissage supervisé.

Pour chaque instant (t), les observations précédentes sont utilisées pour prédire la valeur future selon :

$$Y_t = f(X_{t-1}, X_{t-2}, \dots, X_{t-n}) \quad (3)$$

où (n) représente la taille de la fenêtre temporelle utilisée comme entrée du réseau. Cette étape permet au modèle de capturer les dépendances temporelles présentes dans les données photovoltaïques.

Étape 4 : Apprentissage du réseau LSTM

Chaque composante obtenue par SD est ensuite utilisée pour entraîner le réseau LSTM.

L'architecture retenue comprend :

- une couche d'entrée séquentielle ;
- une couche LSTM de 10 neurones cachés ;
- une couche Dropout avec un taux de 0,3 afin de limiter le surapprentissage
- une couche FullyConnected ;
- une couche de régression pour produire la sortie finale.

L'entraînement est réalisé à l'aide de l'optimiseur Adam avec les paramètres suivants :

Table III. 5:Les hyperparamètres d'entrainement du modèle LSTM.

Paramètre	Valeur
Learning Rate	0.05
Mini Batch Size	8
Nombre d'Epochs	60
Hidden Units	10
Dropout	0.3

Le fonctionnement interne du LSTM repose sur trois portes principales : la porte d'oubli, la porte d'entrée et la porte de sortie permettant la gestion de la mémoire à long terme.

Étape 5 : Prédiction directe de la série temporelle

Dans cette approche, contrairement aux modèles hybrides classiques basés sur la reconstruction des composantes, la prédiction est réalisée directement sur la série temporelle globale après traitement par le modèle LSTM. En effet, les composantes issues de la Swarm Decomposition (SD) ne sont pas modélisées séparément puis recombinaées, mais elles sont utilisées conjointement comme entrées enrichies afin d'améliorer la capacité du modèle à apprendre les dynamiques complexes du signal. Ainsi, le modèle LSTM apprend directement la relation entre les variables d'entrée et la production photovoltaïque future, ce qui permet d'obtenir une prévision finale sans étape de recomposition explicite.

La prédiction finale est donc exprimée par :

$$\hat{X}(t) = f(\text{features SD-LSTM}(t))$$

- $\hat{X}(t)$ Représente la production photovoltaïque prédite ;
- $\text{features SD-LSTM}(t)$ Correspond aux entrées enrichies issues de la décomposition SD.

3.5. Proposition de méthodologie

Dans cette étude, la mise en œuvre du modèle LSTM a été précédée par une phase de sélection et d'optimisation des paramètres afin d'assurer des performances optimales de prédiction. Dans un premier temps, les hyperparamètres du réseau LSTM ont été définis, notamment le nombre d'unités cachées, le taux de régularisation (Dropout), ainsi que les paramètres d'entraînement tels que le taux d'apprentissage et la taille des mini-batches. Par la suite, une étape d'analyse de dépendance temporelle a été réalisée afin de déterminer le meilleur décalage temporel (*time lag*) permettant d'améliorer la qualité des prévisions. Cette étape est essentielle car elle permet d'identifier la quantité d'information historique la plus pertinente à intégrer dans le modèle.

Deux configurations d'entrée ont été étudiées :

- **Cas 1 : Entrées endogènes (univariées)**

Dans ce cas, le modèle utilise uniquement les valeurs passées de la variable cible (production photovoltaïque) pour prédire les valeurs futures. Différents lags ont été testés afin de déterminer celui offrant la meilleure performance.

- **Cas 2 : Entrées exogènes (multivariées)**

Dans cette configuration, le modèle intègre en plus des variables météorologiques telles que le rayonnement solaire et la température. Là encore, plusieurs combinaisons de lags ont été évaluées afin d'identifier la structure optimale du modèle. Cette démarche comparative a permis de sélectionner la structure d'entrée la plus performante, en fonction de l'information temporelle disponible et de l'influence des variables exogènes sur la production photovoltaïque.




Figure III- 6: Architecture générale du modèle hybride SD-LSTM

3.6. Méthodes d'évaluation (R^2 , RMSE, nRMSE)

Dans cette étude, plusieurs métriques sont utilisées pour évaluer la performance du modèle SD-LSTM. Le coefficient de détermination (R^2) permet de mesurer la qualité de l'ajustement entre les valeurs réelles et les valeurs prédites.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

Une valeur de R^2 proche de 1 indique un bon modèle.

Le RMSE (Root Mean Square Error) représente l'erreur quadratique moyenne entre les valeurs réelles et prédites. Il permet de mesurer l'écart global des prédictions, où une valeur faible indique une meilleure précision du modèle.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

Le nRMSE (Normalized Root Mean Square Error) est une version normalisée du RMSE, exprimée en pourcentage, ce qui permet de comparer les performances indépendamment de l'échelle des données.

$$nRMSE = \frac{RMSE}{y_{max} - y_{min}} \times 100 \quad (6)$$

Ainsi, ces indicateurs permettent d'évaluer la précision et la fiabilité du modèle SD-LSTM.

3.7. Résultats de la prévision :

3.7.1. Impact de la décomposition sur les performances de prévision

La comparaison des résultats avec et sans décomposition par essaim (SWARM Decomposition) montre une amélioration significative des performances de prévision de la puissance photovoltaïque. Après l'application de cette méthode, le coefficient de détermination R^2 est passé de 83.57 % à 98.79 %, tandis que les valeurs du RMSE et du nRMSE ont fortement diminué. Ces résultats indiquent que la décomposition par essaim permet de mieux représenter les variations du signal PV en réduisant sa complexité et sa non-stationnarité. Ainsi, le modèle devient plus capable de suivre les fluctuations de la production photovoltaïque et d'améliorer la précision globale des prévisions.

Table III. 6: Comparaison des performances de prévision avec et sans décomposition

	<i>Sans Décomposition</i>	<i>Avec Décomposition</i>
R^2	83.5751	98.7903
RMSE	6019.6260	1753.3610
nRMSE	24.5905	7.1625

La figure III.6 présente les nuages de points (scatter plots) représentant la relation entre les valeurs réelles et les valeurs prédites avec et sans décomposition par essaim (SWARM Decomposition). Elle montre clairement l'effet positif de la décomposition sur la qualité des prévisions. Avec décomposition, les points sont fortement concentrés autour de la ligne idéale,

ce qui traduit une meilleure corrélation entre les valeurs prédites et les valeurs réelles. En revanche, sans décomposition, les points présentent une dispersion plus importante, indiquant une précision de prévision plus faible et une difficulté du modèle à suivre correctement les variations du signal photovoltaïque.




Figure III- 7: Nuages de points (Scatter plots) avec et sans décomposition

La figure 3.7 présente le suivi temporel des valeurs réelles et des valeurs prédites avec et sans décomposition par essaim (SWARM Decomposition). On remarque que le modèle sans décomposition a des difficultés à suivre les variations importantes du signal photovoltaïque, notamment dans les zones comprises entre les points 150 et 200 ainsi qu'autour du point 400, où plusieurs fluctuations rapides ne sont pas correctement reproduites.




Figure III- 8: Courbes de suivi des prévisions avec et sans décomposition

En revanche, avec la décomposition par essaim, le suivi devient nettement plus précis, même dans les zones critiques caractérisées par de fortes perturbations. Les courbes prédites restent très proches des valeurs réelles sur l'ensemble de la série temporelle. Cela montre que la décomposition a permis de rendre les patterns du signal PV plus clairs et mieux structurés dans les différentes composantes, ce qui a facilité leur apprentissage par le modèle de prévision.

3.7.2. Résultats avec les variables endogènes

Les résultats obtenus à partir des variables endogènes montrent globalement de bonnes performances de prévision pour les différents retards étudiés. Cependant, une comparaison entre les retards 2, 4 et 6 révèle des différences de précision selon la valeur du retard utilisée.

Le tableau 6 présente les résultats de prévision obtenus pour les retards 2, 4 et 6 en utilisant les variables endogènes. Les résultats montrent une supériorité du modèle avec le retard 2, qui a enregistré la plus faible valeur de nRMSE égale à 5,3212 ainsi que le coefficient de détermination le plus élevé, atteignant 99,5503. Le retard 6 occupe la deuxième position en termes de performance, suivi du retard 4 qui présente les résultats les moins performants parmi les trois configurations.

Table III. 7: Performances de prévision des variables endogènes avec différents délais

	<i>Lag 2</i>	<i>Lag 4</i>	<i>Lag 6</i>
R^2	99,5503	99,0423	99,0561
RMSE	1302,6001	1642,7488	1452,8
nRMSE	5,3212	6,7107	5,9339

Afin de mieux visualiser les performances obtenues pour les différents délais, plusieurs représentations graphiques sont présentées dans les figures suivantes, à commencer par les Nuages de points des valeurs prédites et réelles, Les Nuages de points présentés dans la figure 3.8 confirment les résultats obtenus dans le tableau des performances. Le délai 2 présente la meilleure distribution des points autour de la ligne idéale $y = x$, avec une dispersion plus faible et une meilleure concordance entre les valeurs réelles et les valeurs prédites. Cela traduit une précision de prévision plus élevée ainsi qu'une meilleure capacité du modèle à suivre le comportement réel de la production photovoltaïque.

Le délai 6 montre également de bonnes performances, mais avec une dispersion légèrement plus importante des points, tandis que le délai 4 présente la dispersion la plus élevée autour de la ligne idéale, indiquant une précision de prédiction relativement moins performante par rapport aux autres délais.




Figure III- 9: Nuages de points (configuration endogène)

La figure 3.9 présente une comparaison graphique des valeurs du coefficient de détermination R^2 et du nRMSE pour les différents délais étudiés. Les résultats montrent que le délai 2 obtient le meilleur compromis entre une valeur élevée de R^2 et une faible valeur de nRMSE, confirmant ainsi sa supériorité en termes de précision de prévision.




Figure III- 10: Comparaison du R^2 et du nRMSE

Le délai 6 présente des performances intermédiaires avec des résultats proches de ceux du délai 2, tandis que le délai 4 enregistre la valeur de nRMSE la plus élevée ainsi que le coefficient R^2 le plus faible, indiquant une diminution relative des performances du modèle pour cette configuration. Malgré les différences observées entre les différents délais en termes de performances, l'ensemble des modèles a présenté des résultats globalement excellents. En effet, tous les délais étudiés ont permis au modèle d'expliquer efficacement les variations de la production photovoltaïque et d'assurer un bon suivi des valeurs réelles, comme l'illustre la figure III.10.




Figure III- 11: Courbes de suivi des prévisions des différents délais

Le suivi des 600 premiers points montre une bonne concordance entre les valeurs prédites et les valeurs réelles pour les différents délais, confirmant ainsi la capacité des modèles à reproduire correctement le comportement dynamique de la série temporelle.

3.7.3. Résultats avec les variables exogènes :

Après avoir complété l'étude basée sur les variables endogènes, une seconde approche a été réalisée en intégrant des variables exogènes, notamment la température et l'irradiance, comme entrées supplémentaires avec la puissance photovoltaïque. Ces variables ont également subi une étape de normalisation avant l'entraînement des modèles. Les performances globales obtenues avec cette approche exogène sont présentées dans le tableau 8.

Table III. 8: Performances de prévision des variables endogènes avec différents délais

	Lag 2	Lag 4	Lag 6
R^2	99.2086	98.7536	98.6961
RMSE	1482.9991	1735.3158	1883.8083
nRMSE	6.0581	7.0888	7.6942

La figure III.11 présente les Nuages de points obtenus pour cette configuration exogène. Globalement, les résultats restent relativement proches de ceux obtenus avec les variables endogènes, bien qu'une légère diminution des performances ait été observée. Toutefois, la comparaison entre les différents délais montre que le délai 2 conserve les meilleures performances, avec une distribution des points plus proche de la ligne idéale et une dispersion relativement plus faible par rapport aux délais 4 et 6.




Figure III- 12: Nuages de points (configuration exogène)

3.7.4. Analyse comparative des modèles à variables endogènes et exogènes

Dans le but d'approfondir l'analyse comparative entre les configurations endogène et exogène, une étude plus détaillée du comportement statistique des erreurs de prédiction a été menée à travers plusieurs outils de visualisation et d'analyse. La figure 3.12 présente une comparaison des boxplots des erreurs de prédiction obtenues avec les approches endogène et exogène pour les différents délais étudiés. Globalement, les deux approches présentent des distributions d'erreurs relativement centrées autour de zéro, traduisant une bonne capacité générale des modèles à reproduire les variations de la puissance photovoltaïque.

Cependant, plusieurs différences significatives peuvent être observées entre les deux configurations. Dans le cas des variables exogènes, les médianes des erreurs apparaissent légèrement mieux centrées autour de zéro, notamment pour le délai 2, ce qui indique une réduction partielle du biais de prédiction. Néanmoins, cette amélioration du centrage s'accompagne d'une augmentation de la dispersion des erreurs ainsi que d'une présence plus importante des valeurs aberrantes (outliers), particulièrement pour les délais 4 et 6. À l'inverse, les modèles basés uniquement sur les variables endogènes présentent une distribution des erreurs plus compacte et globalement plus stable, avec une dispersion plus faible autour de la médiane. Cette stabilité plus élevée explique les meilleures performances obtenues précédemment en termes de R^2 , RMSE et nRMSE.




Figure III- 13: boxplots des erreurs

Pour analyser plus précisément la répartition des erreurs de prédiction ainsi que leur concentration autour de la valeur nulle, des histogrammes des erreurs ont été utilisés pour les configurations endogène et exogène figure 3.13. Les histogrammes obtenus montrent que les erreurs demeurent globalement distribuées autour de zéro pour l'ensemble des délais étudiés, confirmant les bonnes capacités de prévision des modèles. Les distributions associées aux variables exogènes présentent un centrage légèrement meilleur autour de la valeur nulle, notamment pour les délais 2 et 4, traduisant une réduction partielle du biais de prédiction. Cependant, cette amélioration du centrage s'accompagne également d'une dispersion plus large ainsi que de queues de distribution plus étendues, indiquant une augmentation de la variabilité des erreurs et de la présence des valeurs extrêmes.




Figure III- 14: Histogrammes des erreurs

Les graphiques des erreurs résiduelles (figure 3.14) permettent d'analyser le comportement temporel des erreurs de prédiction pour les configurations endogène et exogène. Les erreurs demeurent distribuées autour de zéro pour l'ensemble des délais étudiés, ce qui confirme la bonne capacité des modèles à suivre la dynamique de la production photovoltaïque. Cependant, les configurations exogènes présentent des fluctuations temporelles plus importantes ainsi qu'une variabilité plus élevée des erreurs résiduelles, particulièrement pour les délais 4 et 6. Les signaux d'erreur apparaissent plus bruités avec une présence plus

marquée des pics et des variations rapides, traduisant une augmentation du niveau de bruit introduit par les variables exogènes. À l'inverse, les configurations endogènes montrent des erreurs résiduelles relativement plus stables et plus homogènes au cours du temps, avec des fluctuations moins importantes autour de la valeur nulle. Ces observations confirment que l'ajout des variables exogènes a permis d'améliorer légèrement le centrage des erreurs, mais au prix d'une augmentation de la variabilité temporelle et du bruit dans les prédictions.




Figure III- 15: Erreurs résiduelles

3.8. Conclusion

Les résultats obtenus montrent que l'impact du choix du délai (Lag) sur les performances du modèle n'est pas linéaire et dépend fortement de la capacité du LSTM à exploiter l'information temporelle ainsi que de la nature des données. Dans les deux configurations étudiées, le Lag = 2 a fourni les meilleures performances en termes de précision et d'erreur. L'introduction des variables exogènes n'a pas systématiquement amélioré les résultats. Bien qu'elle ait permis une réduction du biais des prédictions, elle a également augmenté la variabilité des erreurs et introduit davantage de bruit, notamment dans un climat caractérisé par de fortes fluctuations comme celui de Laghouat. Ainsi, les résultats suggèrent que les variables endogènes suffisent à elles seules pour capturer efficacement la dynamique temporelle de la production photovoltaïque à court terme, offrant des performances plus stables et plus robustes.

Conclusion générale

Conclusion générale

Dans ce travail, nous nous sommes intéressés à la prévision de la production d'énergie photovoltaïque à l'aide d'un modèle hybride combinant la technique de Swarm Decomposition et le réseau LSTM. L'objectif principal était d'améliorer la précision des prévisions en tenant compte de la nature complexe, variable et non stationnaire des données photovoltaïques. Dans un premier temps, nous avons présenté les notions fondamentales liées à l'énergie solaire et aux systèmes photovoltaïques. Cette partie a permis de comprendre le principe de fonctionnement des cellules solaires, les différents types de systèmes photovoltaïques, ainsi que les facteurs qui influencent directement la production d'énergie, notamment l'irradiation solaire, la température et les conditions météorologiques. Ensuite, nous avons étudié les principales méthodes de prévision utilisées dans le domaine énergétique. Les méthodes classiques, bien qu'utiles et simples à mettre en œuvre, présentent certaines limites face aux comportements non linéaires des séries temporelles photovoltaïques. Les méthodes basées sur l'intelligence artificielle, en particulier les modèles de DeepLearning comme le LSTM, offrent une meilleure capacité d'apprentissage et permettent de modéliser plus efficacement les dépendances temporelles. La partie expérimentale a été réalisée à partir de données issues de la centrale photovoltaïque de Laghouat. Après le nettoyage et la normalisation des données, plusieurs configurations ont été testées en utilisant des variables endogènes et exogènes avec différents délais temporels. Les résultats obtenus ont montré que l'application de la Swarm Decomposition améliore nettement la qualité des prévisions, en réduisant la complexité du signal et en facilitant son apprentissage par le modèle LSTM. Les meilleures performances ont été obtenues avec les variables endogènes et un délai égal à 2, ce qui montre que les valeurs passées de la production photovoltaïque peuvent fournir une information suffisante et pertinente pour la prévision à court terme. En conclusion, le modèle hybride SD-LSTM proposé s'est révélé efficace, précis et stable pour la prévision de la production photovoltaïque. Comme perspective, il serait intéressant d'élargir cette étude à d'autres sites photovoltaïques, d'intégrer davantage de variables météorologiques et de comparer le modèle proposé avec d'autres approches hybrides ou architectures avancées de DeepLearning.

Bibliographie

- [1] S. Belakehal, « Conception & commande des machines à aimants permanents dédiées aux énergies renouvelables », *université costantine*, 2010.
- [2] M. N. MECHALIKH et C. E. HAMADA, « Modélisation et simulation d'un système photovoltaïque en fonctionnement autonome et connecté au réseau », PhD Thesis, 2013. Consulté le : 12 avril 2026. [En ligne]. Disponible sur : <https://dspace.univ-ouargla.dz/jspui/handle/123456789/1641>
- [3] N. Metri, « Elaboration de molécules pi-conjuguées à base de triphénylamine pour la réalisation de dispositifs photovoltaïques hybrides sensibilisés. », PhD Thesis, Cergy-Pontoise, 2011. Consulté le : 12 avril 2026. [En ligne]. Disponible sur : <https://theses.fr/2011CERG0521>
- [4] M. N. MECHALIKH et C. E. HAMADA, « Modélisation et simulation d'un système photovoltaïque en fonctionnement autonome et connecté au réseau », PhD Thesis, 2013. Consulté le : 12 avril 2026. [En ligne]. Disponible sur : <https://dspace.univ-ouargla.dz/jspui/handle/123456789/1641>
- [5] A. Moummi, N. Hamani, N. Moummi, et Z. Mokhtari, « Estimation du rayonnement solaire par deux approches semi empiriques dans le site de Biskra », *Une*, vol. 3, n° 4, 2006, Consulté le : 12 avril 2026. [En ligne]. Disponible sur : https://www.researchgate.net/profile/Abdelhafid-Moummi/publication/264781835_estimation_du_rayonnement_solaire_par_deux_approches_semi_empiriques_dans_le_site_de_biskra/links/53ee90890cf26b9b7dccf986/estimation-du-rayonnement-solaire-par-deux-approches-semi-empiriques-dans-le-site-de-biskra.pdf
- [6] S. BEDDIAR, S. DJEDDI, et D. Encadre par GUIZA, « Modélisation et simulation d'un système hybride photovoltaïque/thermique », PhD Thesis, 2021.
- [7] K. Bouziane, « contribution a l'optimisation des processus de production energetique photovoltaïque (application aux procedes d'epuration des eaux dans les zones rurales) », PhD Thesis, Université Kasdi Merbah Ouargla, 2013. Consulté le : 12 avril 2026. [En ligne]. Disponible sur : <https://dspace.univ-ouargla.dz/jspui/handle/123456789/27627>
- [8] A. Labouret et M. Villoz, *Energie solaire photovoltaïque*, vol. 3. Dunod Paris, 2006. Consulté le : 12 avril 2026. [En ligne]. Disponible sur : <https://pascal-francis.inist.fr/vibad/index.php?action=getRecordDetail&idt=22156282>

- [9] A. Labouret, P. Cumunel, J.-P. Braun, et B. Faraggi, *Cellules solaires-5e éd.: Les bases de l'énergie photovoltaïque*. Dunod, 2010.
- [10] A. C. Pastor, « Conception et réalisation de modules photovoltaïques électroniques », PhD Thesis, INSA de Toulouse, 2006. Consulté le : 12 avril 2026. [En ligne]. Disponible sur: <https://theses.hal.science/tel-00128644/>
- [11] R. A. Messenger, *Photovoltaic systems engineering*. CRC press, 2018. Consulté le : 12 avril 2026. [En ligne]. Disponible sur : <https://www.taylorfrancis.com/books/mono/10.1201/9781315218397/photovoltaic-systems-engineering-roger-messenger-homayoon-amir-abtahi>
- [12] Z. Saida, « Etude et analyses des performances d'une installation solaire photovoltaïque autonome », PhD Thesis, FGEI. UMMTO, 2024. Consulté le : 12 avril 2026. [En ligne]. Disponible sur : <https://dspace.ummtto.dz/items/0d2b3320-1586-4966-a9d3-85b4ce33a9df>
- [13] B. Hbibe et B. Mohamed Abdelaziz, « Étude Paramétrique de la Dégradation des Caractéristiques Électriques d'un Module PV et Pratiques de Maintenance », PhD Thesis, université Ibn Khaldoun, 2024. Consulté le: 12 avril 2026. [En ligne]. Disponible sur: <http://dspace.univ-tiaret.dz/handle/123456789/15532>
- [14] S. A. Kalogirou, *Solar energy engineering: processes and systems*. Elsevier, 2023. Consulté le : 14 avril 2026. [En ligne]. Disponible sur: <https://books.google.com/books?hl=en&lr=&id=8C2gEAAQBAJ&oi=fnd&pg=PP1&dq=Kalogirou,+S.A.,+Solar+Energy+Engineering:+Processes+and+Systems,+Academic+Press,+2014.&ots=2CNh6WUqhN&sig=JSVmTnhiwbjhQkGrWlbfJmbarg>
- [15] J. A. Duffie et W. A. Beckman, *Solar engineering of thermal processes*. John Wiley & Sons, 2013. Consulté le: 14 avril 2026. [En ligne]. Disponible sur: <https://books.google.com/books?hl=en&lr=&id=Q1tjDQAAQBAJ&oi=fnd&pg=PA19&dq=Duffie,+J.A.,+Beckman,+W.A.,+Solar+Engineering+of+Thermal+Processes,+Wiley,+2013.&ots=ZlfQdsjCNE&sig=ymmukmdicwycxaQCNz--Vq1Uelc>
- [16] E. Skoplaki et J. A. Palyvos, « On the temperature dependence of photovoltaic module electrical performance: A review of efficiency/power correlations », *Solar energy*, vol. 83, n° 5, p. 614-624, 2009.
- [17] A. Luque et S. Hegedus, *Handbook of photovoltaic science and engineering*. John Wiley & Sons, 2011. Consulté le : 14 avril 2026. [En ligne]. Disponible sur: <https://books.google.com/books?hl=en&lr=&id=sLMkCsde1u4C&oi=fnd&pg=PR23&dq>

- =+Luque,+A.,+Hegedus,+S.,+Handbook+of+Photovoltaic+Science+and+Engineering,+Wiley,+2011.&ots=INNHskQHfo&sig=R9b7P7h-hAzoPcS1L19asNQQ75k
- [18] D. Y. Goswami, *Principles of solar engineering*. CRC press, 2022. Consulté le : 14 avril 2026. [En ligne]. Disponible sur : <https://api.taylorfrancis.com/content/books/mono/download?identifieurName=doi&identifieurValue=10.1201/9781003244387&type=googlepdf>
- [19] J. Zhang, B.-M. Hodge, A. Florita, S. Lu, H. F. Hamann, et V. Banunarayanan, « Metrics for evaluating the accuracy of solar power forecasting », National Renewable Energy Laboratory (NREL), Golden, CO., 2013. Consulté le : 6 mai 2026. [En ligne]. Disponible sur : <https://docs.nrel.gov/docs/fy14osti/60142.pdf>
- [20] S. Tatsa, « Modélisation et prévision de la consommation horaire d'électricité au Québec : comparaison de méthodes de séries temporelles », 2014, Consulté le : 6 mai 2026. [En ligne]. Disponible sur : <https://corpus.ulaval.ca/entities/publication/cb8d9627-91b9-465b-8fe8-fl6c277bf374>
- [21] R. Lewandowski, *La prévision à court terme : présentation des techniques, organisation et mise en place des systèmes de prévisions*. FeniXX, 1979. Consulté le : 6 mai 2026. [En ligne]. Disponible sur : https://books.google.com/books?hl=ar&lr=&id=NKX_EAAAQBAJ&oi=fnd&pg=PP1&d
- [22] J.-M. Charpin, D. Fouquet, P.-A. Muet, H. Guillaume, et D. Vallet, « DMS, modèle de prévision à moyen terme », *Économie et statistique*, vol. 79, n° 1, p. 33-48, 1976.
- [23] Z. Krakutovski, « Amélioration de l'approche démographique pour la prévision à long terme de la mobilité urbaine », PhD Thesis, Paris 12, 2004. Consulté le: 6 mai 2026. [En ligne]. Disponible sur: <https://theses.fr/2004PA123012>
- [24] A. Mokhtar, « Modeling of photovoltaic energy systems », PhD Thesis, Ministry of Higher Education, 2016. Consulté le: 6 mai 2026. [En ligne]. Disponible sur: <https://www.researchgate.net/profile/Ali-Mokhtar->
- [25] A. SELEM, « IA dans le secteur d'Énergie—Cas d'étude «Prédiction de consommation d'Énergie» », PhD Thesis, Université Echahid Chikh Larbi Tébessi-Tébessa, 2023.
- [26] T. Hastie, J. Friedman, et R. Tibshirani, *The Elements of Statistical Learning*. in Springer Series in Statistics. New York, NY: Springer New York, 2001. doi: 10.1007/978-0-387-21606-5.
- [27] A. Mokhtar, « Modeling of photovoltaic energy systems », PhD Thesis, Ministry of Higher Education, 2016. Consulté le: 6 mai 2026. [En ligne]. Disponible sur: <https://www.researchgate.net/profile/Ali-Mokhtar->

- [28] A. Rabehi, M. Guermoui, R. Khelifi, et M. L. Mekhalfi, « Decomposing global solar radiation into its diffuse and direct normal radiation », *International Journal of Ambient Energy*, vol. 41, n° 7, p. 738-743, juin 2020, doi: 10.1080/01430750.2018.1492445.
- [29] R. Khelifi, M. Guermoui, A. Rabehi, et D. Lalmi, « Multi-step-ahead forecasting of daily solar radiation components in the Saharan climate », *International Journal of Ambient Energy*, vol. 41, n° 6, p. 707-715, mai 2020, doi: 10.1080/01430750.2018.1490349.
- [30] M. Guermoui, F. Melgani, et C. Danilo, « Multi-step ahead forecasting of daily global and direct solar radiation: a review and case study of Ghardaia region », *Journal of Cleaner Production*, vol. 201, p. 716-734, 2018.
- [31] Y. Wei *et al.*, « A review of data-driven approaches for prediction and classification of building energy consumption », *Renewable and Sustainable Energy Reviews*, vol. 82, p. 1027-1047, 2018.
- [32] Y. Wang, P. Yang, S. Zhao, J. Chevallier, et Q. Xiao, « A hybrid intelligent framework for forecasting short-term hourly wind speed based on machine learning », *Expert Systems with Applications*, vol. 213, p. 119223, 2023.
- [33] Y. Bengio, N. Boulanger-Lewandowski, et R. Pascanu, « Advances in optimizing recurrent networks », in *2013 IEEE international conference on acoustics, speech and signal processing*, IEEE, 2013, p. 8624-8628. Consulté le: 6 mai 2026. [En ligne]. Disponible sur: <https://ieeexplore.ieee.org/abstract/document/6639349/>
- [34] I. Ghalekhondabi, E. Ardjmand, G. R. Weckman, et W. A. Young, « An overview of energy demand forecasting methods published in 2005–2015 », *Energy Syst*, vol. 8, n° 2, p. 411-447, mai 2017, doi: 10.1007/s12667-016-0203-y.
- [35] J.-S. Chou et D.-S. Tran, « Forecasting energy consumption time series using machine learning techniques based on usage patterns of residential householders », *Energy*, vol. 165, p. 709-726, 2018.
- [36] K. Dragomiretskiy et D. Zosso, « Variational mode decomposition », *IEEE transactions on signal processing*, vol. 62, n° 3, p. 531-544, 2013.
- [37] N. E. Huang, « The empirical mode decomposition and », *Proceedings of the Royal Society of*, 2005.
- [38] M. E. Torres, M. A. Colominas, G. Schlotthauer, et P. Flandrin, « A complete ensemble empirical mode decomposition with adaptive noise », in *2011 IEEE international conference on acoustics, speech and signal processing (ICASSP)*, IEEE,

- 2011, p. 4144-4147. Consulté le: 29 mai 2026. [En ligne]. Disponible sur: <https://ieeexplore.ieee.org/abstract/document/5947265/>
- [39] A. Cicone et H. Zhou, « Numerical analysis for iterative filtering with new efficient implementations based on FFT », *Numer. Math.*, vol. 147, n° 1, p. 1-28, janv. 2021, doi: 10.1007/s00211-020-01165-5.
- [40] S. Hochreiter et J. Schmidhuber, « Long short-term memory », *Neural computation*, vol. 9, n° 8, p. 1735-1780, 1997.



غرداية في 2026/07/12

شعبة: هندسة ميكانيكية
تخصص: طاقات متجددة في الميكانيك

شهادة ترخيص بالتصحيح والايداء:

انا الاستاذ(ة): بكار بلقاسم
بصفتي المشرف المسؤول عن تصحيح مذكرة تخرج ماستر المعنونة بـ:

Prévision de la production d'énergie photovoltaïque à l'aide d'un modèle hybride SD-LSTM basé sur les
données météorologiques

من انجاز الطالب (الطالبة):

عزاوي انفال

بن جدو كوثر

التي نوقشت بتاريخ 2026/06/13

اشهد ان الطلبة قد قاموا بالتعديلات والتصحيحات المطلوبة من طرف لجنة المناقشة وقد تم التحقق من ذلك من طرفنا
وقد استوفت جميع الشروط المطلوبة.

مصادقة رئيس القسم

امضاء المسؤول عن التصحيح

