

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

Université de Ghardaïa

كلية العلوم والتكنولوجيا

Faculté des Sciences et de la Technologie

قسم الآلية والإلكترونيكا

Département d'automatique et d'électromécanique

MEMOIRE

Présenté pour l'obtention du diplôme de MASTER

Domaine: Sciences et Technologies

Filière: Electrotechnique

Spécialité: Energies Renouvelables en Electrotechnique

Thème :

Analyse Comparative des Techniques de Décomposition pour
la Prévision d'Énergie Photovoltaïque

Présenté par :

Oulad Tayeb Mohamed Ikbal

Lahachami Moulay Abdellah

Soutenue publiquement le : .././2024

Devant le jury composé de:

BENHALIMA Ouissam

MCB

Univ. Ghardaïa

Présidente

BOUCHELGA Fatma

MCA

Univ. Ghardaïa

Examinatrice

BELGHERRAS Sifia

MCA

Univ. Ghardaïa

Examinatrice

FERKOUS Khaled

MCA

Univ. Ghardaïa

Encadreur

Année universitaire 2023/2024

اهداء

بسم الله الرحمن الرحيم

الحمد لله الذي بنعمته تتم الصالحات، وبفضله تُرفع الغايات

أولاً، أتوجه بقلبي وروحي إلى والديّ الكريمين، اللذين كانا نور حياتي ومصدر قوتي،
فبدعمهما المتواصل، وتشجيعهما اللامحدود، وصلواتهما التي لا تنقطع، تمكنت من اجتياز كل
العقبات وتحقيق هذا الإنجاز. كانا لي دائماً السند والملاذ، فلهما مني أصدق آيات الشكر وأعمق

مشاعر الامتنان.

ثم، أخص بالشكر أستاذي الفاضل خالد فركوس، الذي لولا إرشاده الحكيم وتوجيهاته السديدة لما
أبصرت هذه المذكرة النور. لقد كان لي معلماً حقيقياً، ملهماً وداعماً، إذ منحني من وقته وعلمه
بسخاء لا يُضاهى. فله مني خالص التقدير وأسمى آيات العرفان

وأخيراً، أوجه عميق الشكر والامتنان لكل أحبتي، ولكل من تمنى لي الخير وساندني بدعواته
وكلماته الطيبة. لقد كنتم جميعاً شعلة الأمل في مسيرتي، ودعمتني محبتكم في أوقات الصعاب

جزاكم الله خير الجزاء، وبارك فيكم، وجعل ما قدمتم في ميزان حسناتكم

محمد اقبال

Remerciements

Nous souhaitons exprimer notre sincère gratitude envers notre estimé encadrant, Dr. FERKOUS Khaled, pour sa guidance attentive et son soutien inestimable tout au long de notre mémoire. Nous sommes profondément reconnaissants pour ses conseils précieux et sa disponibilité constante.

Nos chaleureux remerciements s'adressent également aux membres bienveillants du jury qui ont accepté d'examiner et d'évaluer notre travail.

Nous saisissons cette occasion pour exprimer notre profonde reconnaissance envers tous les enseignants et le personnel de l'université de Ghardaïa, notamment ceux de la section ENERGIES Renouvelables. Leur aide inestimable, leurs conseils précieux et leur intérêt pour notre formation ont été d'une importance capitale.

Enfin, nous souhaitons exprimer nos remerciements les plus sincères à tous ceux qui ont contribué, de près ou de loin, au bon déroulement de cette mémoire. Leur soutien et leur engagement ont joué un rôle essentiel dans notre réussite.

Nous tenons à exprimer notre gratitude profonde envers chacun d'entre vous.

Résumé

Dans cette recherche intitulée "analyse comparative de l'effet de trois méthodes de décomposition des données sur la prévision de l'énergie photovoltaïque à la station de Conte à Adrar, au sud de l'Algérie", nous avons analysé les performances de trois techniques de décomposition du signal (WD, WPD, CEEMDAN) couplées avec la méthode ELM (Extreme Learning Machine) pour la prévision de l'énergie photovoltaïque. Ces techniques ont été étudiées pour déterminer leur efficacité à améliorer la précision des prévisions en tenant compte des variations environnementales et climatiques dans la région d'Adrar. Les modèles ont été évalués en utilisant des critères statistiques tels que le coefficient de détermination (R^2), la racine carrée de l'erreur quadratique moyenne (RMSE) et l'erreur quadratique moyenne normalisée (nRMSE). Les résultats ont montré que le modèle WP-ELM était le meilleur pour les prévisions à pas arrière, tandis que le modèle CEEMDAN-ELM excellait dans les prévisions multi-horizon. Cette étude met en évidence l'importance de choisir les techniques appropriées de décomposition du signal pour améliorer la précision des prévisions dans les applications pratiques. Elle souligne également la nécessité d'adopter des méthodologies de prévision avancées capables de gérer les variations environnementales pour garantir la stabilité et l'efficacité des systèmes photovoltaïques.

MOTS CLES : énergie photovoltaïque, prévision, ELM, décomposition du signal, WD, WPD, CEEMDAN

ملخص

تسلط هذه الدراسة الضوء على أهمية اختيار تقنيات تحليل الإشارة المناسبة لتحسين دقة التنبؤات في التطبيقات العملية. كما توضح ضرورة اعتماد منهجيات تنبؤ متقدمة قادرة على التعامل مع التغيرات البيئية لضمان استقرار وفعالية نظم الطاقة الكهروضوئية. من خلال هذا البحث الموسوم بـ " تحليل مقارن لتقنيات التحليل لتنبؤ الطاقة الكهروضوئية"، تم تحليل أداء ثلاث تقنيات تحليل للإشارة (CEEMDAN، WPD، WD) عند استخدامها مع تقنية التعلم الآلي القصوى (ELM) للتنبؤ بالطاقة الكهروضوئية. تمت دراسة هذه التقنيات لتحديد مدى فعاليتها في تحسين دقة التنبؤات بالنظر إلى التغيرات البيئية والمناخية في منطقة أدرار.

تم تقييم النماذج باستخدام معايير إحصائية مثل معامل التحديد (R^2)، الجذر التربيعي لمتوسط مربع الخطأ (RMSE)، والنسبة المعيارية للجذر التربيعي لمتوسط مربع الخطأ (nRMSE). أظهرت النتائج أن نموذج WPD-ELM كان الأفضل في التنبؤ بحالات التأخير، وكذلك في التنبؤ بالأفق المتعدد.

كلمات مفتاحية: الطاقة الكهروضوئية، التنبؤ، ELM، تحليل الإشارة، WPD، WD، CEEMDAN.

Summary:

In this research entitled "comparative analysis of the effect of three data decomposition methods on the forecast of photovoltaic energy at the Conte station in Adrar, southern Algeria", we analyzed the performance of three signal decomposition techniques (WD, WPD, CEEMDAN) coupled with the ELM (Extreme Learning Machine) method for photovoltaic energy forecasting. These techniques were studied to determine their effectiveness in improving forecast accuracy by taking into account environmental and climatic variations in the Adrar region. Models were evaluated using statistical criteria such as coefficient of determination (R^2), root mean square error (RMSE), and normalized root mean square error (nRMSE). The results showed that the WP-ELM model performed best in backward-step forecasting, while the CEEMDAN-ELM model outperformed in multi-horizon forecasting. This study highlights the importance of choosing appropriate signal decomposition techniques to improve forecast accuracy in practical applications. It also highlights the need to adopt advanced forecasting methodologies that can manage environmental variations to ensure the stability and efficiency of PV systems.

KEY WORDS: photovoltaic energy, forecast, ELM, signal decomposition, WD, WPD, CEEMDAN

Table des matières

Remerciements	1
Résumé	2
Table des matières	4
Liste des figures.....	7
Liste des tableaux	8
Liste des abréviations	9
Introduction générale.....	9
Chapitre I : Modélisation de la connaissance	
I.1 Introduction	11
I.2 État de l’art sur l’énergie photovoltaïque	11
I.2.1 Conversion énergétique du rayonnement solaire	11
I.2.2 Conversion énergétique du rayonnement solaire	12
I.2.3 L’effet photovoltaïque.....	12
I.2.4 Technologie de fabrication des cellules PV	14
I.2.5 Courbe I-V d’un module PV	15
I.2.6 Systèmes photovoltaïques	16
I.3 Définitions	18
I.3.1 Qu’est-ce qu’une « prévision » ?.....	18
I.3.2 Horizons temporels de prévision.....	18
I.4 Méthodes de prévision	19
I.4.1 Modèles linéaires.....	19
I.4.2 Les Méthodes non-linéaires	21
I.4.3 Les Méthodes hybrides.....	25
I.5 Conclusion.....	26

Chapitre II : Techniques de Décomposition pour la prévision d'énergie Photovoltaïque....	27
II.1 Introduction.....	27
II.2 Complète Décomposition Empirique en Modes avec Bruit Adaptatif	27
II.3 Développement chronologique de la méthode CEEMDAN.....	28
II.3.1 Principe de la décomposition	29
II.3.2 Processus de tamisage.....	30
II.3.3 Calculer le signal de différence.....	31
II.4 Ondelette	32
II.4.1 Principe de fonctionnement de la décomposition ondelette.....	32
II.4.2 Décomposition ondelettes en paquets	34
II.4.2 Ondelette mère	35
II.4 Conclusion	35
Chapitre III : Comparaison des méthodes de dé-composition.....	36
III.1 Introduction	36
III.2 Situation géographique de la centrale PV Zaouiet Kounta.....	37
III.3 Présentation de la centrale PV Zaouiet Kounta	37
III.4 Extrême Learning Machine (ELM)	43
III.4.1 Architecture du réseau « Extrême Learning machine ».....	43
III.4.2 Fonctionnement du réseau ELM.....	45
III.4.3 Caractéristiques d'ELM.....	45
III.5 Méthodologie de création d'un modèle ELM	46
III.6 Description de la méthode proposée pour la prédiction PV	39
III.6 Evaluation statistique.....	46
III.7 Conclusion	58
Conclusion générale	60
Bibliographies.....	

Liste des figures

Figure I-1 Principe de fonctionnement d'une cellule Photovoltaïque [5]	14
Figure I-2 : Cellule photovoltaïque[5]	14
Figure I-3 : Caractéristique courant-tension et puissance-tension d'un module PV	7
Figure I-4 : Types des Systèmes photovoltaïques autonomes [6].....	15
Figure I-5 : Représentation schématique du neurone artificiel [1].....	24
Figure II-1 : Principe de tamisage pour l'estimation de la 1ère IMF du signal $x(t)$	32
Figure II-2 : Processus de décomposition ondelette.	35
Figure II-3 : Processus de décomposition ondelettes en paquets.....	35
Figure II-4 : . ondelet paquets arber	37
Figure III-1 : Entrée de la centrale photovoltaïque de ZAOUJET EL-KOUNTA.....	37
Figure III-2 : La situation géographique du central solaire de zawiya konta	40
Figure III-3 : la Série temporelle PV avan la normalisation.....	42
Figure III-4 : Schéma du processus de prédiction proposé.....	43
Figure III-5 : la Série temporelle PV après la normalisation	44
Figure III-6 : L'architecteur de réseau ELM	47
Figure III-7 : Comparaison des Meilleurs Modèles de Prédiction via <i>Scatter Plot</i>	53
Figure III-8 : Performance de modèle hybride M7 dans la prévision de l'énergie photovoltaïque	52
Figure III-9 : Comparaison des Meilleurs Modèles de Prédiction multi horizon.....	58
Figure III-10 : Performance de modèle hybride M7 dans la prévision.....	60

Liste des tableaux

Nombre	Nom	Page
1	Table III -1 : Caractéristiques électriques des panneaux	38
2	Table III-2 : Présentation des Modèles	48
3	Tableau III-3 : Évaluation des performances des modèles hybrides de prévision de l'énergie photovoltaïque	49
4	Tableau III-4 : Présentation des Modèles (cas Multi horizon)	53
5	Tableau III-5 : Évaluation des performances des modèles hybrides de prévision de l'énergie photovoltaïque en cas de multi horizon	54

Liste des abréviations

Abréviation	La Définition
ARMA	Moyenne mobile autorégressive
ARIMA	Moyenne mobile intégrée autorégressive
AR	Autorégressif
AI	Intelligence artificielle
. Bil STM	Mémoire à long court terme bidirectionnelle
GRU	Unités récurrentes fermées
ELM	Extrême Learning Machine (Machine d'apprentissage extrême)
LS	Moindres carrés
LSTM	Mémoire longue à court terme
WD	Wavelet Décomposition (Décomposition Ondelettes)
WPD	Wavelet Packet Décomposition (décomposition de paquets d'ondelettes)
DL	Deep Learning (L'apprentissage en profondeur)
SVM	Support Vector Machines Machine à vecteurs support
IMFs	Fonctions du mode intrinsèque

Introduction générale

Dans ce mémoire de master, nous avons exploré divers aspects fondamentaux et techniques liés à la prévision de l'énergie photovoltaïque à la station de KOUNTA à Adrar, au sud de l'Algérie, en nous concentrant sur l'effet de trois méthodes de décomposition des données. Nous avons commencé par définir les concepts et les bases de l'énergie photovoltaïque, en détaillant les principes sous-jacents et l'importance croissante de cette source d'énergie renouvelable. Par la suite, nous avons examiné les différentes techniques de prévision employées dans ce domaine, en les classant en trois grandes catégories : les techniques statistiques, les techniques d'apprentissage automatique et les techniques d'apprentissage profond. De plus, nous avons présenté les techniques hybrides, qui constituent le principal sujet de notre étude.

Dans le troisième chapitre, nous avons décrit certains des modèles de prévision utilisés, en les catégorisant selon les trois sections mentionnées ci-dessus. Enfin, dans le dernier chapitre, nous avons exposé la méthodologie suivie pour la prévision en utilisant la technique ELM (Extrême Learning Machine) couplée à trois méthodes de décomposition du signal : WD (Discrète Wavelet Décomposition), WPD (Wavelet Packet Décomposition) et CEEMDAN (Décomposition complète du mode empirique d'un ensemble avec bruit adaptatif).

À chaque étape, nous avons évalué les performances des modèles en utilisant des critères statistiques tels que le coefficient de détermination (R^2), la racine carrée de l'erreur quadratique moyenne (RMSE) et l'erreur quadratique moyenne normalisée (nRMSE). Les modèles ont été évalués selon deux scénarios : prévision à pas arrière (délai) et prévision multi-horizon (multi-horizon). Les résultats ont montré que le modèle WP-ELM se distingue pour les prévisions à pas arrière, tandis que le modèle CEEMDAN-ELM excelle dans les prévisions multi-horizon.

Chapitre I : Méthode de prévision

I.1 Introduction

Ce chapitre explore les diverses méthodologies utilisées dans le domaine des prévisions de l'énergie solaire. La prise de décision en matière de prévision solaire nécessite de choisir parmi une gamme de méthodologies en fonction de l'horizon temporel prévu et des besoins spécifiques de l'utilisateur final. Il est important de noter que tous les modèles ne fournissent pas le même niveau de précision. L'exactitude des prévisions est influencée par plusieurs facteurs, notamment le type spécifique de prévisions requis, la localisation géographique, l'horizon temporel, ainsi que la quantité et la qualité des données disponibles. Cette exploration s'inscrit dans un contexte où l'adoption croissante des énergies renouvelables, et notamment de l'énergie solaire, met en évidence la nécessité de développer des outils de prévision précis pour optimiser l'utilisation de ces ressources. Les progrès dans ce domaine sont essentiels pour garantir une transition énergétique réussie vers un avenir plus durable et écologique.

I.2 État de l'art sur l'énergie photovoltaïque

I.2.1 Conversion énergétique du rayonnement solaire

L'énergie solaire est actuellement exploitée par deux principales techniques : la conversion du rayonnement solaire en chaleur via des capteurs thermiques (conversion héliothermique) et sa transformation en électricité à l'aide de panneaux photovoltaïques (conversion électrique). Ces méthodes de conversion ont conduit au développement de trois filières d'exploitation : l'une dédiée à la production de chaleur (solaire thermique) et les deux autres à la génération d'électricité (solaire photovoltaïque et solaire thermodynamique) [1]

I.2.2 L'Histoire et les Applications de l'Énergie Solaire Photovoltaïque :

L'énergie solaire photovoltaïque désigne l'électricité produite par la conversion d'une partie du rayonnement solaire grâce à une cellule photovoltaïque. Plusieurs cellules connectées entre elles forment un panneau solaire (ou module photovoltaïque), et plusieurs modules regroupés dans une centrale solaire photovoltaïque constituent des champs photovoltaïques. Le terme photovoltaïque peut faire référence soit au phénomène physique connu sous le nom "effet photovoltaïque", soit à la technologie associée [2]

L'effet photovoltaïque a été observé pour la première fois en 1839 par le physicien français Edmond Becquerel. Cependant, ce n'est qu'au cours des années 1950 que des chercheurs des laboratoires Bell aux États-Unis ont réussi à fabriquer la première cellule en silicium, l'élément fondamental d'un système photovoltaïque, atteignant un rendement de conversion énergétique de 6 % [3] . Ils ont également découvert que la photosensibilité du silicium pouvait être augmentée par l'ajout d'"impuretés", une technique appelée "dopage", qui est utilisée pour tous les semi-conducteurs constituant les cellules photovoltaïques.

Malgré l'intérêt scientifique croissant au fil des ans, ce n'est que durant la course à l'espace que les cellules photovoltaïques ont quitté les laboratoires. En effet, les photopiles représentent la solution idéale pour satisfaire les besoins en électricité à bord des satellites, ainsi que dans tout site isolé. [3]

I.2.3 Principe de fonctionnement de la cellule photovoltaïque :

L'effet photovoltaïque utilisé dans les cellules solaires permet de convertir directement l'énergie lumineuse des rayons solaires en électricité par la production et le transport de charges électriques positives et négatives dans un matériau semi-conducteur sous l'effet de la lumière. Ce matériau comporte deux parties : l'une présentant un excès d'électrons (dopée de type N) et l'autre un déficit en électrons (dopée de type P). Lorsque ces deux parties sont mises en contact,

les électrons en excès dans le matériau N diffusent vers le matériau P. La zone initialement dopée N devient alors chargée positivement, tandis que la zone initialement dopée P devient chargée négativement, créant ainsi un champ électrique qui tend à repousser les électrons vers la zone N et les trous vers la zone P. Une jonction dite P-N est ainsi formée [4]

Lorsque cette jonction est exposée à la lumière, les photons dont l'énergie est égale ou supérieure à la largeur de la bande interdite transfèrent leur énergie aux atomes, faisant passer un électron de la bande de valence à la bande de conduction et laissant un trou mobile, créant ainsi une paire électron-trou. Si une charge est placée aux bornes de la cellule, les électrons de la zone N rejoignent les trous de la zone P via la connexion extérieure, générant une différence de potentiel et permettant au courant électrique de circuler (voir Figure (I.1) et Figure (I.2)). L'effet photovoltaïque repose donc sur les propriétés semi-conductrices du matériau et sur son dopage pour améliorer la conductivité.




Figure I-1 Principe de fonctionnement d'une cellule Photovoltaïque [5]




Figure I-2 : Anatomie d'un panneau solaire [5]

I.2.4 Technologie de fabrication des cellules PV

Le silicium est actuellement le matériau le plus couramment utilisé pour fabriquer les cellules photovoltaïques disponibles à l'échelle industrielle. Il est produit à partir de sable quartz (dioxyde de silicium), qui est chauffé dans un four électrique à une température de 1700 °C [2]. Divers traitements du sable permettent de purifier le silicium, produisant du silicium dit métallurgique, pur à seulement 98 %. Ce silicium est ensuite purifié chimiquement pour obtenir un produit de qualité électronique. Sous forme liquide, il est coulé en lingots, puis cristallisé et découpé en fines plaquettes (wafers).

Le matériau obtenu dans cet état pur est ensuite enrichi en éléments dopants (tels que le phosphore, l'arsenic, l'antimoine ou le bore) lors de l'étape de dopage, pour le transformer en semi-conducteur de type P ou N. La diffusion de ces éléments dopants (bore, phosphore) modifie l'équilibre électronique des plaquettes, les rendant sensibles à la lumière et permettant ainsi leur transformation en cellules photovoltaïques.

Selon la technologie de fabrication employée, on peut distinguer plusieurs types de modules photovoltaïques.

- Les modules solaires monocristallins : ils possèdent un très bon rendement ($\eta_{PV} \approx 15\%$) et sont essentiellement utilisés lorsque l'espace est restreint. Leur coût, plus élevé que celui d'autres installations de même puissance, freine toutefois le développement de cette technique [6].

-Les modules solaires poly cristallins : ils offrent actuellement le meilleur rapport qualité-prix et sont les plus utilisés. Ils ont un bon rendement ($\eta_{PV} \approx 12\%$) et une durée de vie supérieure à 35 ans [7].

-Les modules solaires amorphes : ils sont très intéressants car ils peuvent être souples et ont une meilleure production par faible lumière. Le silicium amorphe possède un rendement environ deux fois inférieur à celui du silicium cristallin ($\eta_{PV} \approx 7\%$), ce qui nécessite plus de surface pour la même puissance installée. Cependant, leur prix au m^2 étant plus faible, ils restent très compétitifs [8].

I.2.5 Courbe I-V d'un module PV

Les modules photovoltaïques fonctionnent entre deux états extrêmes : le court-circuit (I_{sc}), où il n'y a pas de tension ni de charge, et le circuit ouvert (V_{oc}), où il n'y a pas de courant et la charge est infinie. La courbe courant-tension, communément appelée courbe I-V, est une représentation graphique de la puissance d'un module en fonction de conditions spécifiques d'ensoleillement et de température (Figure I.3). Il est important de noter que les paramètres de la courbe I-V n'ont de sens que lorsque ces conditions sont spécifiées. Le point où le produit du courant et de la tension est le plus élevé représente le point de puissance maximale (MPP) [9].

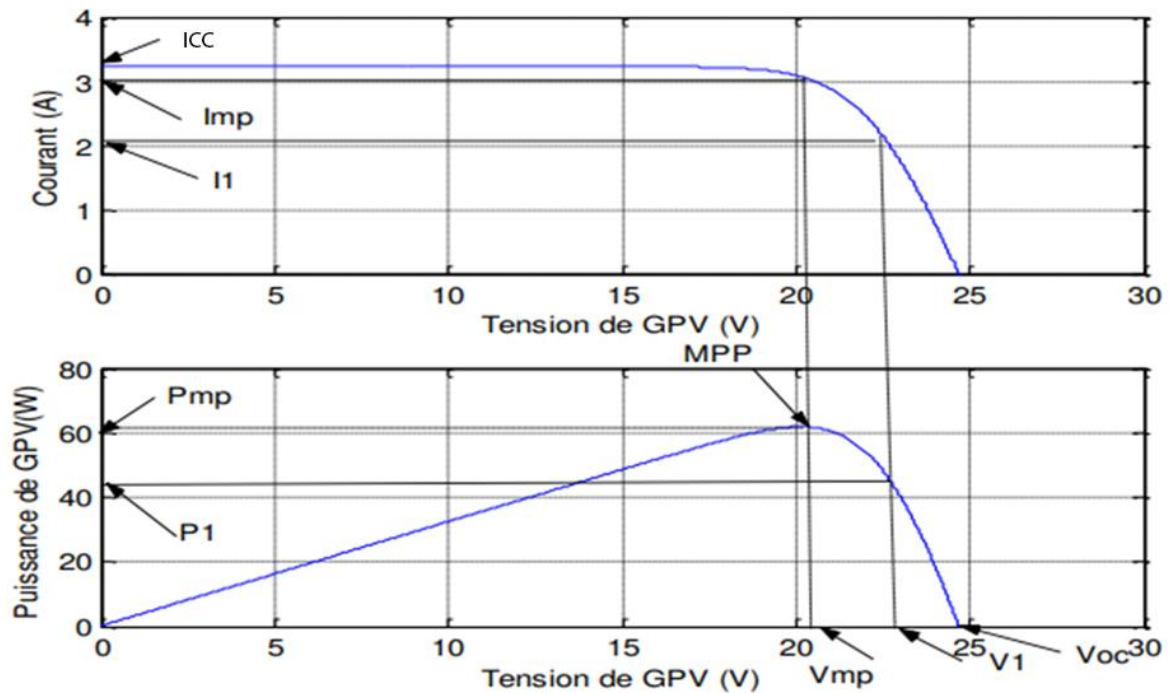


Figure I-3 : Caractéristique courant-tension et puissance-tension d'un module PV

I.2.6 Systèmes photovoltaïques

Pour produire de l'électricité à grande échelle, un module photovoltaïque seul n'est pas suffisant. Il doit être intégré à un système complet adapté à une application spécifique. On distingue principalement deux types d'utilisations selon que l'installation photovoltaïque est connectée ou non à un réseau de distribution d'électricité

Les installations non connectées peuvent consommer directement l'électricité produite. Elles représentent souvent le seul moyen de s'électrifier lorsque le courant du réseau n'est pas disponible, comme pour les maisons en site isolé, sur des îles ou en montagne. Ce type de système nécessite l'utilisation de batteries pour stocker l'électricité et d'un contrôleur de charge pour assurer la durabilité des batteries.

Un système photovoltaïque connecté au réseau est couplé directement au réseau électrique à l'aide d'un onduleur. Ce type de système offre de nombreuses facilités pour le producteur/consommateur, car c'est le réseau qui équilibre la production et la consommation d'électricité. Dans

ce cas, il est impératif de convertir le courant continu produit par le système photovoltaïque en courant alternatif synchronisé avec le réseau [10]. Pour effectuer cette conversion, un onduleur est utilisé. Cet appareil sophistiqué, fonctionnant grâce à un microprocesseur, est soumis à des normes réglementaires. En transformant la nature du courant, l'onduleur permet d'utiliser l'électricité produite par le module photovoltaïque. Pour un site isolé (non raccordé au réseau), l'onduleur sert à transférer l'électricité photovoltaïque des modules de production aux appareils à alimenter. Dans le cas d'un site connecté au réseau, l'onduleur transfère l'électricité photovoltaïque du site de production au réseau. La Figure (I.4) illustre le principe de fonctionnement d'un système photovoltaïque autonome et d'un système connecté au réseau électrique.

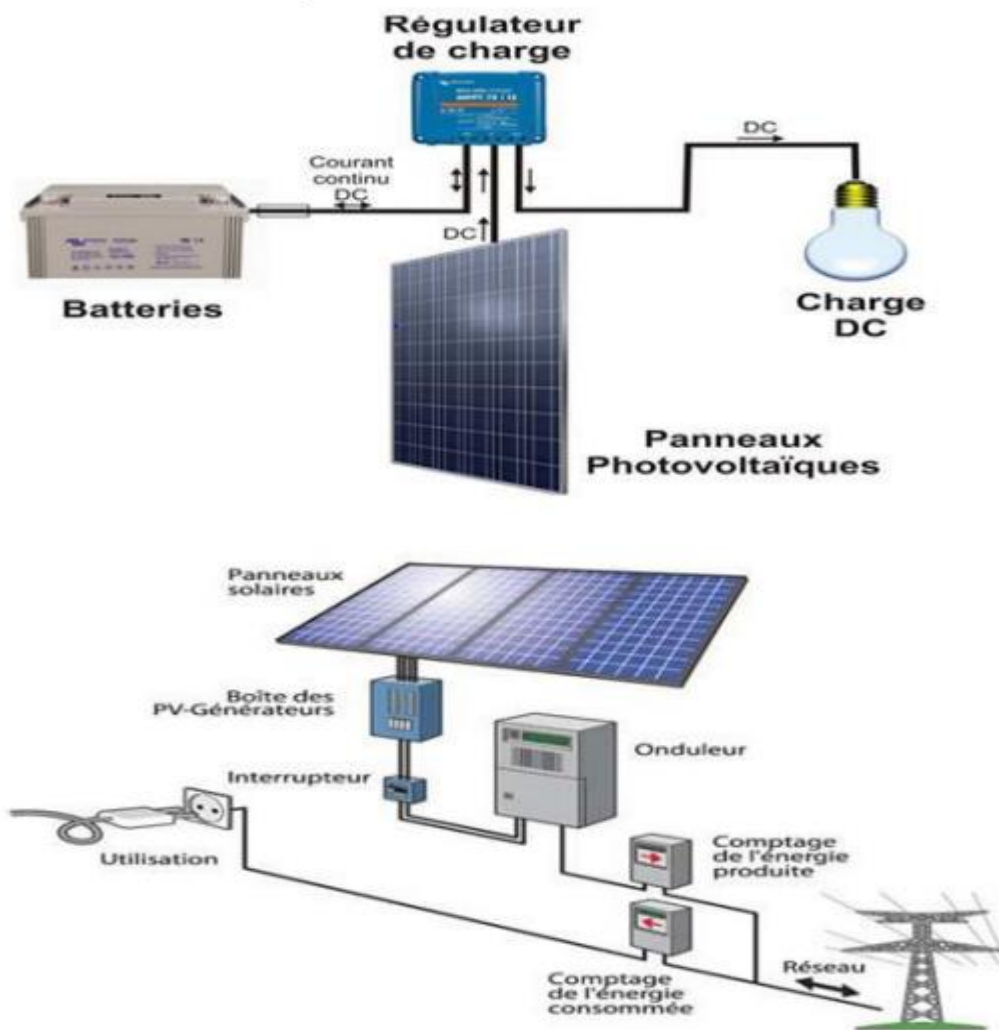


Figure I-4 : Types des Systèmes photovoltaïques [11].

I.3 Définitions

I.3.1 Qu'est-ce qu'une « prévision » ?

Une prévision est une estimation ou une conjecture sur un événement futur basée sur des informations disponibles et des analyses. Les prévisions peuvent être utilisées dans de nombreux domaines, tels que la météorologie, l'économie, la finance, la politique, la science et bien d'autres. Elles sont souvent formulées en utilisant des modèles mathématiques, des données historiques, des tendances observées et parfois des jugements d'experts pour anticiper ce qui pourrait se produire dans le futur. Cependant, il est important de noter que les prévisions ne sont pas des certitudes et peuvent varier en précision en fonction de la fiabilité des données et des méthodes utilisées [12]

I.3.2 Horizons temporels de prévision

Un horizon temporel d'une prévision détermine la durée entre le moment de l'application de la prévision et l'instant futur à prédire. On distingue généralement trois types de prévisions : long terme, moyen terme et court terme. La signification de ces termes varie en fonction du contexte dans lequel ils sont utilisés [13]

La prévision à long terme : de l'énergie électrique est une estimation de la demande future d'électricité sur plusieurs années ou décennies. Elle repose sur des modèles prenant en compte la croissance démographique, les habitudes de consommation, les politiques énergétiques et d'autres facteurs. Ces prévisions aident à planifier les infrastructures énergétiques et à prendre des décisions d'investissement pour garantir un approvisionnement fiable, économique et durable en électricité [14]

La prévision à moyen terme de l'énergie électrique se concentre sur l'estimation de la demande électrique dans un avenir proche, généralement sur une période allant d'un an à quelques années. Elle repose sur l'analyse des tendances actuelles de la demande, des variations saisonnières et

des facteurs économiques, ainsi que sur la prise en compte des événements prévus tels que les projets de construction, les fermetures d'usines ou les changements réglementaires. Ces prévisions sont cruciales pour la gestion quotidienne du réseau électrique, la planification de la production et la sécurisation de l'approvisionnement en électricité à court et moyen terme [15]

La prévision à court terme de l'énergie électrique concerne l'estimation de la demande électrique dans un avenir immédiat, généralement sur une échelle de quelques heures à quelques jours. Elle utilise des techniques telles que la modélisation statistique, les données en temps réel sur la consommation d'électricité, les conditions météorologiques et les prévisions de charge pour prédire avec précision la demande électrique à court terme. Ces prévisions sont essentielles pour la gestion en temps réel du réseau électrique, permettant aux opérateurs de prendre des décisions rapides et efficaces pour garantir un approvisionnement stable et fiable en électricité [16].

I.4 Méthodes de prévision

I.4.1 Modèles linéaires

I.4.1.1 Modèle Autorégressif à Moyenne Mobile (ARMA)

Dans les années 1970, la méthodologie d'analyse des séries chronologiques a été définie par [17] ce qui a conduit au développement d'une série de modèles comprenant des modèles de moyennes mobiles autorégressifs. Il s'agit d'une méthode statistique pour analyser des séries chronologiques. La fusion d'un modèle autorégressif (AR) et d'un modèle de moyenne mobile (MA) donne naissance au modèle ARMA. Largement utilisé pour prévoir des séries chronologiques stationnaires, ce modèle trouve des applications dans divers domaines, notamment dans la prévision du rayonnement solaire dans le cadre du modèle linéaire

On définit les modèles AR et MA, respectivement d'ordre p et q , pour une série temporelle $x(t)$ et $t \in \mathbb{Z}$ par :

$$x(t) = \sum_{i=1}^p \varphi(i) \cdot x(t - i) + \varepsilon(t) \quad \text{I -1}$$

MA(q) :

$$X(t) = \sum_{i=1}^q \theta(i) \cdot \varepsilon(t - i) \quad \text{I -2}$$

La combinaison des deux modèles devient alors ARMA (p, q) :

$$x(t) = \varepsilon(t) + \sum_{i=1}^p \varphi(i) \cdot x(t - i) + \sum_{i=1}^q \theta(i) \cdot \varepsilon(t - i) \quad \text{I -3}$$

Où (φ) et (θ) sont les paramètres du modèle, p et q les ordres et ε Le résidu, souvent un bruit blanc, est fréquemment omis dans la littérature lorsqu'une série temporelle est stationnaire [18,19]. Le modèle ARMA, qui repose sur une combinaison de mesures et d'erreurs passées pour prédire les données actuelles, en est un exemple. Durant la phase d'optimisation de ce modèle, les ordres sont déterminés. Les paramètres du modèle (φ et θ) sont établis lors de la phase d'apprentissage [20]. Ce modèle est largement utilisé pour l'analyse des séries temporelles car il est peu exigeant en ressources et rapide à mettre en œuvre.

I.4.1.2 Modèle Autorégressif Intégrée Moyenne Mobile ARIMA

Les modèles ARIMA forment une catégorie générale de modèles statistiques qui peuvent être transformés en processus stationnaires grâce à "la différenciation". Par conséquent, les modèles ARIMA généralisent les modèles ARMA. Ils incluent une composante autorégressive (AR), une composante moyenne mobile (MA) et un terme de différenciation (d), et sont généralement notés ARIMA (p, d, q) selon l'expression mathématique suivante :

$$X(t) = (1 - B)^d x(t) \quad \text{I -4}$$

$$X(t) = \sum_{i=1}^p \varphi(i) \cdot x(t - i) + \sum_{i=1}^q \theta(i) \cdot \varepsilon(t - i) \quad \text{I -5}$$

Où B représente un opérateur de retard, les coefficients d'ajustement (i) et (i) sont estimés par une procédure de minimisation [21]

Il existe de nombreuses évolutions de ce type de modèle, telles qu'ARMAX, SARMA et SARIM. Les lecteurs intéressés peuvent consulter l'ouvrage de Box et Jenkins sur l'analyse des séries temporelles [17]

I.4.2 Les Méthodes non-linéaires

L'Intelligence Artificielle (IA) imite les quatre capacités cognitives humaines : percevoir, comprendre, agir et apprendre (Figure 1-1). Elle se divise principalement en deux domaines : l'apprentissage automatique (Machine Learning) et l'apprentissage profond « Dee Learning ». En plus de ces deux techniques, divers concepts gravitent autour, constituant les domaines de l'IA, qui englobent de nombreux processus et applications variées [22] [23]

Réseaux De Neurones Artificiels (ANN)

Les réseaux de neurones artificiels (ANN) sont une méthode qui s'inspire du fonctionnement du cerveau humain et qui offre de nouvelles perspectives pour résoudre des problèmes liés à la perception, la mémoire, l'apprentissage et le raisonnement [24] Les réseaux de neurones se sont imposés comme des alternatives très prometteuses pour constituer un modèle mathématique capable d'approximer des relations entre les variables. Contrairement aux méthodes traditionnelles, les réseaux de neurones sont réalisés sans faire aucune hypothèse sur la répartition des variables, et sans imposer aucune forme particulière aux données. Ils sont largement employés avec succès pour la prévision dans divers domaines [25]. Ces réseaux de neurones ont été considérés comme des outils utiles pour les problèmes de classification et de régression. Leur objectif initial était de mieux comprendre le fonctionnement du système nerveux en utilisant des éléments de base pour modéliser ses propriétés.

Principes généraux

Un neurone est une unité de traitement. Il peut avoir une ou plusieurs entrées et produit une sortie calculée en utilisant différentes caractéristiques :

- Des entrées (X ou E), avec la sortie appliquant le même principe ;
- Chaque entrée est associée à un poids (W), qui modifie l'importance relative de chaque entrée ;
- Une fonction d'agrégation qui calcule une valeur unique à partir des entrées et des poids associés ;
- Un seuil (ou biais), déterminant le moment où le neurone doit s'activer ;
- Une fonction d'activation, qui transforme la valeur agrégée en une sortie unique, en fonction du seuil.

Le résultat du calcul du neurone est donc la somme des produits des entrées et des poids, passée par une "fonction d'activation" (ou filtre) pour obtenir la sortie. Ainsi, le neurone formel peut être résumé comme illustré dans la Figure (I.5).

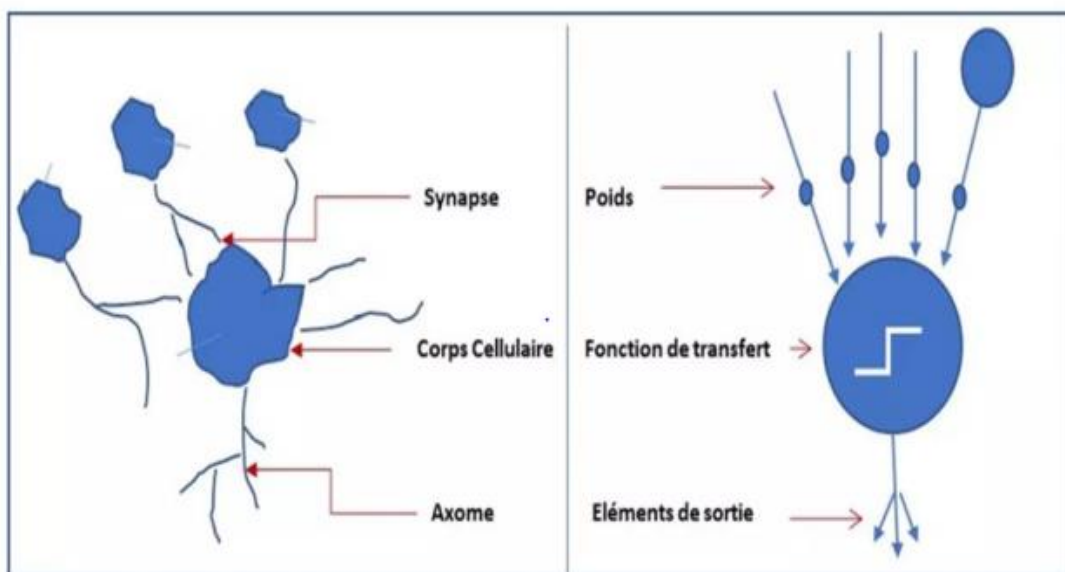


Figure I-5 : Représentation schématique du neurone artificiel [24].

I.4.2.1 L'Apprentissage automatique « Machine Learning »

Les modèles d'apprentissage automatique jouent un rôle crucial dans la prévision de l'énergie photovoltaïque, offrant une approche flexible et précise pour estimer la production d'électricité solaire. Parmi ces modèles, on trouve notamment les réseaux de neurones artificiels (RNA) et les machines à vecteurs de support (SVM) [26]. Les réseaux de neurones artificiels sont des structures computationnelles inspirées du fonctionnement du cerveau humain, composées de multiples couches de neurones interconnectés. Chaque neurone reçoit des signaux d'entrée, effectue une transformation non linéaire sur ces signaux, puis transmet le résultat aux neurones de la couche suivante. L'apprentissage se fait en ajustant les poids des connexions entre les neurones afin de minimiser une fonction de coût définie, généralement basée sur l'erreur de prédiction. Les réseaux de neurones sont capables d'apprendre à partir de données complexes et non linéaires, ce qui en fait des outils puissants pour la prévision de l'énergie solaire.

D'autre part, les machines à vecteurs de support sont des algorithmes d'apprentissage supervisé qui cherchent à trouver l'hyperplan optimal séparant les données en différentes classes. L'idée principale derrière les SVM est de maximiser la marge, c'est-à-dire la distance entre l'hyperplan de séparation et les points de données les plus proches de chaque classe. Cette approche vise à obtenir une généralisation maximale et à minimiser le risque de surajustement aux données d'entraînement. Les SVM sont particulièrement efficaces dans les cas où les données sont linéairement séparables ou peuvent être transformées pour le devenir [27].

Les différences entre ces deux approches résident notamment dans leurs architectures et leurs méthodes d'apprentissage. Les réseaux de neurones sont souvent plus adaptés aux données com-

plexes et non linéaires, tandis que les SVM excellent dans les cas où les données sont linéairement séparables ou lorsque les caractéristiques des données peuvent être transformées pour les rendre linéaires. Le choix entre ces modèles dépend donc de la nature des données, de la complexité du problème de prévision, et des performances recherchées dans un contexte spécifique.

I.4.2.2 L'apprentissage profond « Deep Learning »

Le Deep Learning, ou apprentissage profond, est une branche avancée de l'apprentissage automatique qui utilise des architectures de réseaux de neurones artificiels composées de plusieurs couches de traitement pour apprendre des représentations de données complexes. Parmi les types de modèles de Deep Learning les plus utilisés, on trouve les réseaux de neurones convolutifs (CNN), les réseaux de neurones récurrents (RNN), y compris les LSTM (Long Short-Terme Memory), les Bil STM (Bidirectionnel Long Short-Terme Memory) et les GRU (Gâte Récurrent Unit), ainsi que les réseaux de neurones profonds entièrement connectés. Les réseaux de neurones convolutifs sont particulièrement efficaces pour l'analyse de données spatiales, telles que les images, en utilisant des filtres convolutifs pour extraire des caractéristiques locales. Les réseaux de neurones récurrents, tels que les LSTM, les Bil STM et les GRU, sont adaptés pour les données séquentielles, comme les séries temporelles, en utilisant des boucles de rétroaction pour traiter les dépendances temporelles. Les LSTM sont conçus pour capturer les dépendances à long terme dans les séquences [28], les Bil STM permettent de prendre en compte l'information contextuelle à la fois dans le passé et dans le futur [29], tandis que les GRU sont une alternative plus légère aux LSTM, avec des portes de mémoire simplifiées. Les réseaux de neurones profonds entièrement connectés sont des architectures génériques qui peuvent être utilisées pour un large éventail de tâches, en apprenant des représentations de données à partir de données non structurées. En utilisant des techniques telles que la rétro propagation et l'optimisation stochastique, les réseaux de neurones profonds peuvent être entraînés sur de grands ensembles de données pour résoudre une variété de tâches, y compris la prévision de l'énergie

solaire. Néanmoins, l'apprentissage profond nécessite souvent des ensembles de données massifs et des ressources de calcul considérables, ce qui peut limiter sa mise en œuvre dans certains contextes. Néanmoins, lorsque les données et les ressources sont disponibles, le Deep Learning peut offrir des performances de prévision exceptionnelles, complétant ainsi les méthodes traditionnelles d'apprentissage automatique.

I.4.3 Les Méthodes hybrides

Les modèles hybrides, combinant différentes techniques de modélisation, jouent un rôle essentiel dans l'amélioration des performances des modèles de prévision. Dans la littérature, diverses approches de fusion ont été explorées pour tirer parti des avantages de différentes méthodes de prédiction. Parmi les types de techniques de fusion les plus courants, on trouve l'intégration de modèles d'apprentissage automatique avec des méthodes de traitement du signal, telles que la transformation en ondelettes (Wavelete Transforme, WT) ou la décomposition empirique en modes d'ensemble (Complete Ensemble Empirical Mode Décomposition with Adaptive Noise, CEEMDAN). D'autres approches hybrides incluent la fusion de modèles statistiques avec des algorithmes évolutifs, la combinaison de méthodes basées sur les connaissances avec des techniques d'apprentissage automatique, ou encore l'utilisation de méthodes de pondération pour combiner les prédictions de différents modèles. Ces approches hybrides permettent de combiner les capacités de capture des tendances temporelles des modèles d'apprentissage automatique avec la capacité de décomposition des données des techniques de traitement du signal. Dans notre étude, nous avons adopté une approche hybride en combinant la méthode de prédiction Extrême Learning Machine (ELM) avec les techniques de décomposition du signal WP (Ondellet Packet), WD (Ondellet Décomposition), et CEEMDAN. Cette combinaison a permis de capturer efficacement les variations temporelles des données tout en gérant le bruit et les incertitudes, conduisant ainsi à des performances améliorées dans la prévision de l'énergie photovoltaïque.

I.5 Conclusion

Dans ce chapitre, nous avons exploré les méthodologies de prévision de l'énergie photovoltaïque, soulignant l'importance de choisir des approches adaptées en fonction de divers facteurs tels que l'horizon temporel et la qualité des données. Nous avons également examiné la conversion énergétique du rayonnement solaire, en mettant l'accent sur la technologie photovoltaïque et les avancées dans ce domaine. En ce qui concerne les méthodes de prévision, nous avons couvert à la fois les approches traditionnelles et non linéaires, ainsi que l'émergence des modèles hybrides. Enfin, nous avons présenté une approche hybride prometteuse pour la prévision de l'énergie photovoltaïque. Ce chapitre fournit ainsi une base essentielle pour comprendre les enjeux et les méthodes de prévision de l'énergie photovoltaïque, cruciales pour la transition vers une énergie durable.

Chapitre II : Techniques de Décomposition pour la prévision d'énergie Photovoltaïque

II.1 Introduction

La prédiction de l'énergie photovoltaïque (PV) est cruciale pour la gestion efficace des systèmes d'énergie renouvelable et la stabilité du réseau électrique. Parmi les nombreuses techniques de prévision disponibles, les méthodes de décomposition se distinguent par leur capacité à traiter la variabilité et la complexité des séries temporelles de l'énergie photovoltaïque. Deux techniques particulièrement prometteuses dans ce domaine sont la méthode de décomposition en modes empiriques améliorée par l'ensemble (CEEMDAN) et la méthode de décomposition par ondelettes.

II.2 Complète Décomposition Empirique en Modes avec Bruit Adaptatif

En Anglais CEEMDAN il s'agit d'une technique de traitement du signal utilisée pour décomposer les signaux non stationnaires en un nombre fini et souvent petit de fonctions de mode intrinsèques (IMF) ainsi qu'un composant résiduel. CEEMDAN est une extension de la méthode de décomposition en mode empirique (EMD), utilisée pour analyser des données non linéaires et non stationnaires. CEEMDAN améliore EMD en résolvant certaines de ses limites, telles que le mixage de modes et les effets finaux. Il y parvient en utilisant une approche d'ensemble et en ajoutant du bruit blanc au signal pendant le processus de décomposition. CEEMDAN a trouvé des applications dans divers domaines, notamment le traitement des signaux biomédicaux, l'analyse de séries chronologiques financières et l'analyse des signaux environnementaux, entre autres. Ceci est particulièrement utile lorsqu'il s'agit de signaux présentant un comportement non linéaire et non stationnaire [30]

II.3 Développement chronologique de la méthode CEEMDAN

Récemment, Wu et Huang [31] , ont développé une méthode appelée décomposition empirique Model (EMD) pour analyser les données provenant de systèmes non stationnaires et non Linéaires. Cet algorithme décompose le signal en une série de fonctions oscillatoires, connues Sous le nom de fonctions de mode intrinsèque (IMF). Le puissant outil EMD adaptatif se Comporte comme un banc de filtres dyadique et est utile pour filtrer le bruit dans les domaines De mesure. Cependant, l'EMD a des inconvénients, tels que le mélange de mode. Les Oscillations de différentes amplitudes se trouvent dans un mode ou des oscillations similaires Se rencontrent dans différents modes. Pour éviter ce problème, Wu et Huang [31] ont proposés Ensemble EMD, une méthode basée sur l'algorithme EMD. La méthode proposée Suit une étude des caractéristiques statistiques du bruit blanc, ce qui implique une analyse Assistée par un bruit. Cette dernière ajoute un bruit blanc d'une distribution de fréquence Uniforme dans EMD pour éviter le mélange en mode.

Actuellement, les méthodes de filtrage basées sur l'EEMD sont disponibles. Toutefois, L'EEMD introduit de nouveaux problèmes, le bruit blanc ajouté n'est pas Complètement éliminé, et différents modes peuvent être produits par l'interaction entre le Signal et le bruit. Pour résoudre ces problèmes, l'Ensemble Empirique Décomposition Modal Complémentaire (CEEMD) a été introduite, l'IMF final peut être obtenu en faisant la moyenne. Des IMF produits dans la décomposition des EEMD pour les signaux ayant des valeurs

Positive et négatives des bruits blancs. Néanmoins, cette méthode nécessite un coût de calcul Elevée ne résout pas les Modes. Ainsi, l'EEMD complet avec bruit adaptatif (CEEMDAN) a Été proposé. Cette méthode réduit la charge de calcul et surmonte les modes Supplémentaires [32] . Il est judicieux avant d'éclaircir la CEEMD de donner un panorama des Différentes méthodes qui ont précédé cette dernière.

II.3.1 Principe de la décomposition

Le signal $x(t)$ peut alors s'écrire :

$$x(t) = \sum_{j=1}^N IMF_j(t) + r(t) \quad \text{II -1}$$

Où la j -ème oscillation, $r(t)$ est le résidu de la décomposition et N est le nombre'. Même si la notion d' repose plus sur une intuition que sur une définition très rigoureuse, cette fonction doit respecter certains critères comme précisé ci-dessous. Une IMF (ou mode empirique) est une fonction telle que :

$$IMF: \begin{cases} R \rightarrow R \\ t \rightarrow IMF_j \end{cases} \quad \text{II -2}$$

Qui vérifie les conditions suivantes :

- De moyenne nulle.
- Les nombres d'extrema et de passages à zéro diffèrent au plus d'un (en d'autres Termes, cela signifie qu'entre un minimum et un maximum successif, une IMF passe par Zéro). Cette condition est nécessaire pour que la fréquence instantanée n'ait pas de Fluctuations Indésirables dues à l'asymétrie du signal. Les deux conditions précédentes Assurent l'unicité du mode oscillatoire de l'IMF à chaque instant.
- Une IMF suit une loi de modulation en amplitude et en fréquence (comportement oscillant) Naturellement de type mono-composant [33]

II.3.2.2 La méthode CEEMDAN

La méthode CEEMDAN améliore l'algorithme EEMD en décomposant un signal avec un nombre d'essais N inférieur à celui requis par la méthode EEMD. [34].

Algorithme de la méthode CEEMDAN

La méthode CEEMDAN résout le problème de la charge de calcul élevée associée à la décomposition CEEMD. Pour réduire le coût de calcul tout en conservant la capacité à éliminer le mélange de modes, un algorithme CEEMDAN est proposé [31]. Les étapes de décomposition du CEEMDAN sont les suivantes :

-Décomposer le signal $x(t) + W_0 \varepsilon^i(t)$ pour obtenir le premier mode en utilisant l'algorithme EMD

$$C_1(t) = \frac{1}{N} \sum_{i=1}^N C_1^i \quad I \in \{1, \dots, N\} \quad - \quad \text{II-4}$$

Où W_0 est l'amplitude du bruit blanc ajouté, et $\varepsilon(t)$ est le bruit blanc avec la variance unitaire.

II.3.3 Calculer le signal de différence

$$r_1(t) = X(t) - c(t)E \quad \text{II-5}$$

Décomposer $r_1(t) + W_1 \varepsilon^i(t)$ pour obtenir le premier mode et définir le second mode

$$C_2(t) = \frac{1}{N} \sum_{i=1}^N E_1(r_1(t) + W_1 \varepsilon^i(t)) \quad \text{II-6}$$

-Pour $k = 2, \dots, K$, calculez le K^{ieme} résidu et obtenez le premier mode.

-Définissez le $K + 1^{\text{ieme}}$ mode comme suit :

$$C_{k+1}(t) = \frac{1}{N} \sum_{i=1}^N E_1(r_k(t) + W_k \varepsilon^i(t)) \quad \text{II-7}$$

Où E_j est une fonction pour extraire le j ème IMF décomposé par EMD.

5) Répétez l'étape 4 jusqu'à ce que le résidu ne contienne pas plus de deux extrema. Le mode résidu est alors défini comme :

$$R(t) = X(t) - \sum_{i=1}^N C_K(t) \quad \text{II-8}$$

II.3.2.2 Précision des prévisions améliorées :

Dans les applications de prévision, CEEMDAN peut améliorer la précision des prévisions en décomposant les données de séries chronologiques en composants significatifs et en supprimant le bruit et les fluctuations non pertinentes. Cela peut conduire à des prévisions plus fiables et à une meilleure prise de décision dans divers domaines. Dans l'ensemble, les avantages du CEEMDAN, notamment sa gestion adaptative du bruit, sa capacité à analyser des données non linéaires et non stationnaires, son approche d'ensemble, sa flexibilité et sa précision de prévision améliorée, en font un outil précieux pour le traitement du signal, l'analyse des données et les tâches de prévision. dans des domaines divers [35].

II.4 Ondelette

La technique des ondelettes, ou ondelette en anglais, est une méthode utilisée dans le domaine du traitement du signal et de l'analyse des données. Elle repose sur l'utilisation de petites fonctions d'ondelettes, qui sont des impulsions courtes et répétitives. Ces ondes sont utilisées pour analyser les données afin de détecter de petites variations dans les signaux à travers le temps et la fréquence. La technique des ondelettes peut être utilisée dans de nombreux domaines d'application, notamment la compression de données, le filtrage de signaux, l'analyse d'images [36] ,

II.4.1 Principe de fonctionnement de la décomposition ondelette

La principale motivation pour utiliser la décomposition en ondelettes (WT) réside dans la simplicité d'analyse de la série obtenue. Pendant de nombreuses années, la WT (ou transformée

en ondelettes) a été combinée avec des modèles de séries chronologiques en tant que technique de prétraitement. La WT utilise un ensemble de filtres pour décomposer la série chronologique d'origine de manière itérative, permettant ainsi l'application de modèles de prévision distincts à chaque composante. La transformée en ondelettes continue (CWT) d'une fonction $f(t)$ par rapport à l'ondelette mère $\psi(t)$ peut s'exprimer par l'intégrale suivante [36] :

$$F_W(a, \tau) = |a|^{-\frac{1}{2}} \int_{-\infty}^{+\infty} f(t) * \left(\frac{1 - \tau}{a}\right) dt \quad \text{II-9}$$

Où (*) représente l'opération de la conjugaison complexe, $\tau \in R$ est la valeur de translation

Contrairement à la transformation de Fourier, la CWT a été discrétisée et est connue sous le nom de transformée en ondelettes discrète (DWT). Cette approche consiste en une implémentation de la transformée en ondelettes par la mise à l'échelle et la translation des ondelettes en temps discret. Dans ce cas, les ondelettes sont définies par :

$$\psi_{n,k(t)} = |a_0^N|^{-\frac{1}{2}} \psi\left(\frac{1 - k\tau_0 a_0^n}{a_0^n}\right) \quad \text{II-10}$$

Où n et k sont des entiers ($a = a_0^n$)

Plus de détails sur la transformée en ondelettes peuvent être trouvés dans la littérature [37,38] , Le principal avantage de l'utilisation de la méthode des ondelettes réside dans sa robustesse, car elle ne repose sur aucune hypothèse paramétrique ni sur des procédures de test potentiellement défectueuses. Un autre avantage de la méthode par ondelettes est que la décomposition du signal permet d'étudier indépendamment le comportement du signal à différentes échelles de temps. Les résultats de la décomposition par ondelettes de la série chronologique de rayonnement solaire sont illustrés à la figure II-2.




Figure II-2 : Processus de décomposition par Ondelettes

II.4.2 Décomposition ondelettes en paquets

La décomposition par paquets d'ondelettes (WPD) est une transformation en ondelettes spéciale. Contrairement à la WT, la WPD traite à la fois les composantes approximatives et détaillées lors du processus de décomposition [39], comme le montre dans la figure II-3 et II-4..

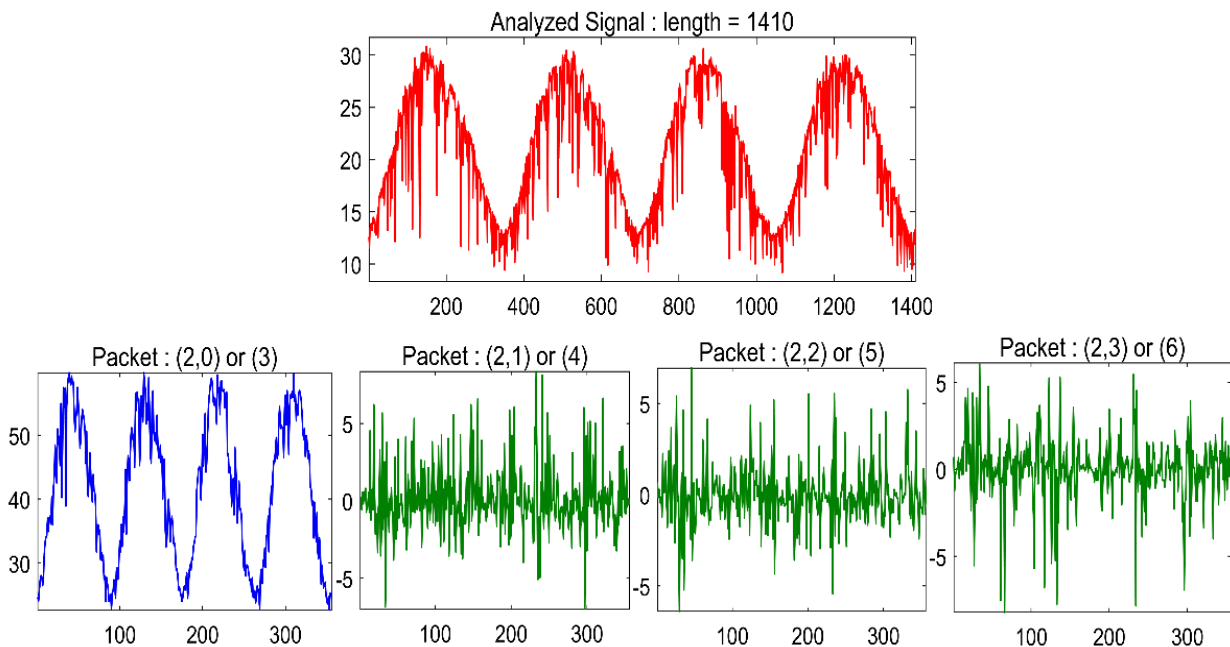


Figure II-3 : Représentation des Séries Temporelles Après Analyse par la Technique des Ondelettes




Figure II-4 : Processus de décomposition par Ondelettes Packet.

II.4.2 Ondelette mère

Une ondelette mère est une fonction de base qui peut être traduite et dilatée, permettant d'analyser un signal en suivant le plan temps-fréquence [40].

II.4 Conclusion

Dans ce chapitre, nous avons étudié deux techniques importantes pour l'analyse des séries temporelles : la méthode améliorée de décomposition en composantes empiriques (CEEMDAN) et la technique d'analyse par ondelettes. La CEEMDAN étend la méthode de décomposition empirique (EMD) en ajoutant du bruit blanc au signal lors de la décomposition, ce qui améliore la précision de l'analyse en réduisant les interférences entre les composantes. En ce qui concerne l'analyse par ondelettes, elle repose sur l'utilisation d'ondes courtes et répétitives pour détecter les variations dans les signaux à travers le temps et la fréquence. Ces techniques ont des applications diverses dans des domaines tels que l'énergie solaire, le traitement des signaux médicaux et l'analyse des données financières, où elles sont des outils puissants pour comprendre et interpréter les séries temporelles.

Chapitre III : Résultats es Discussion

III.1 Introduction

Dans ce chapitre nous commençons par décrire la zone d'étude, mettant en lumière la région d'Adrar où nous avons collecté nos données météorologiques de la station d'observation de la ZAOUJET EL-KOUNTA, ADRAR. Ensuite, nous abordons les techniques de tri, de normalisation et de division des données que nous avons appliquées à ces ensembles de données. Nous expliquons également les critères statistiques que nous avons utilisés pour évaluer et comparer les performances de nos modèles de prévision. Par la suite, nous décrivons en détail la méthode que nous avons suivie pour la prédiction, en mettant particulièrement en évidence le modèle ELM (Extrême Learning Machine) que nous avons utilisé. Nous présentons également un aperçu du modèle hybride que nous avons développé pour améliorer la précision de nos prévisions.

Enfin, nous discutons et comparons les résultats obtenus en utilisant différentes approches, notamment en analysant les performances selon les délais et les horizons multiples. Nous utilisons des critères statistiques pour évaluer la pertinence et la fiabilité de nos résultats.

III.2 Situation géographique de la centrale PV ZAOUJET EL-KOUNTA

La centrale photovoltaïque de PV Zaouïa Kounta 06 MW illustrée sur la Figure (III-1) est située dans la Wilaya d'Adrar à une distance 70 km de la capitale de wilaya et à 80 km au nord de la daïra de Reggan. Ce projet couvre une superficie de 12 ha pour un coût de réalisation estimée à 11 millions d'euro, La centrale photovoltaïque de Zaouïa Kounta a été installée en 2015 par production d'électricité Sharikate Kahraba Wa Taket Moutadjadida (SKTM).Elle s'inscrit dans le cadre du programme national des énergies renouvelables, Cette centrale injecte sa puissance produite directement dans le réseau PIAT (Pôle de In Saleh, Adrar et Timimoune) 30KV[41].



Figure III-1 : Entrée de la centrale photovoltaïque de ZAOUJET EL-KOUNTA.

III.3 Présentation de la centrale PV Zaouïa El-Kounta

Le parc solaires de la centrale PV Zaouïa El-Kounta occupe une superficie de 12 ha avec 24552 panneaux photovoltaïques (YL245P-29b-silicium poly cristallin) installés (Figure III-2) .Tous les sous-champs sont identiques (chacun avec une puissance crête de 1MWc), chaque

sous-champ est composé de deux onduleurs, deux boîtes générales et un transformateur, Chaque onduleur est alimenté par une boîte générale avec un sortie positif et autre négatif, Chaque boîte générale rassemble un total de 04 boites parallèles avec des fusibles de protection, Chaque boîte parallèle rassemble un total de 03 boites jonctions avec des fusibles de protection, Chaque boîte jonction rassemble un total de 08 string, avec des fusibles de protection et une carte de communication transférée tous les donne des strings (courant, tension, défaut de terre, température, l'état de fusible et parafoudre qui permet de supervision très précise pour l'intervention rapide et efficace), et ressemble deux strings en parallèle, chaque string se compose a 22 panneaux en séries, chaque panneaux de 245wc, avec les caractéristiques électriques regroupées dans la tableau(Tableau III -1) Donc chaque onduleur rassemble 4092 panneaux, Ces panneaux photo-voltaïques sont dirigés vers le sud et ils sont inclinés d'un angle de 26° [41]




Figure III-2 : La situation géographique du central solaire de zawiya konta

Tableau III -1 : Caractéristiques électriques des panneaux

Marque	YINGLI SOLAR
Type de module	YL245P-29b
Classe d'application (w)	A
Puissance mesurée (W)	245
Courant mesure (A)	8.28
Fusible série Max (A)	15
Tension a circuit ouvert (V)	37.5
Courant de court-circuit (A)	8.83
Tension système max (V)	1000
Tension mesurée (V)	29.6

Le tableau1 présente les caractéristiques techniques du module photovoltaïque YINGLI SOLAR de type YL245P-29b, classé en application A. Ce module a une puissance nominale de 245 watts et un courant mesuré de 8,28 ampères. Il supporte un courant de court-circuit de 8,83 ampères et une tension à circuit ouvert de 37,5 volts. La tension mesurée est de 29,6 volts, tandis que la tension maximale du système atteint 1000 volts. Le module est conçu pour fonctionner avec un fusible série maximum de 15 ampères. Ces spécifications indiquent que le module YINGLI SOLAR est performant et robuste, capable de fonctionner efficacement dans des systèmes photovoltaïques de grande envergure tout en offrant une sécurité adéquate grâce à ses paramètres de tension et de courant bien définis, La Figure III- 3 illustre la variation de la production d'énergie photovoltaïque de la centrale d'Adrar sur une période de deux ans. La fluctuation de la production reflète les changements saisonniers ainsi que d'autres facteurs environnementaux. Cette visualisation met en évidence l'importance de la surveillance continue de la production d'énergie

solaire pour mieux comprendre ses variations et optimiser son utilisation dans le cadre de la transition vers les énergies renouvelables."




Figure III-3 : la Série temporelle PV avant la normalisation

III.6 Description de la méthode proposée pour la prédiction PV

Cette étude vise à améliorer la précision de la prévision de la puissance photovoltaïque à intervalles de demi-heure. Prédire avec précision la caractéristique aléatoire de la puissance photovoltaïque horaire représente un défi majeur. Pour relever ce défi, un nouveau modèle hybride de prévision a été développé, comme illustré dans la Figure (III.4) Ce modèle combine principalement l'Extrême Learning Machine (ELM) en tant que prédicteur principal et l'utilisation de méthodes de décomposition telles que WD (décomposition en ondelettes), WP (décomposition en paquets d'ondelettes) et CEEMDAN (Décomposition en Mode Empirique Complète avec Bruit Adaptatif) comme techniques de prétraitement des données. Dans la suite de ce mémoire, ces modèles seront désignés respectivement sous les noms de WD-ELM, WPD-ELM et CEEMDAN-ELM pour simplification. Le processus de prédiction de notre modèle repose sur quatre étapes principales représentées dans la figure III-4.

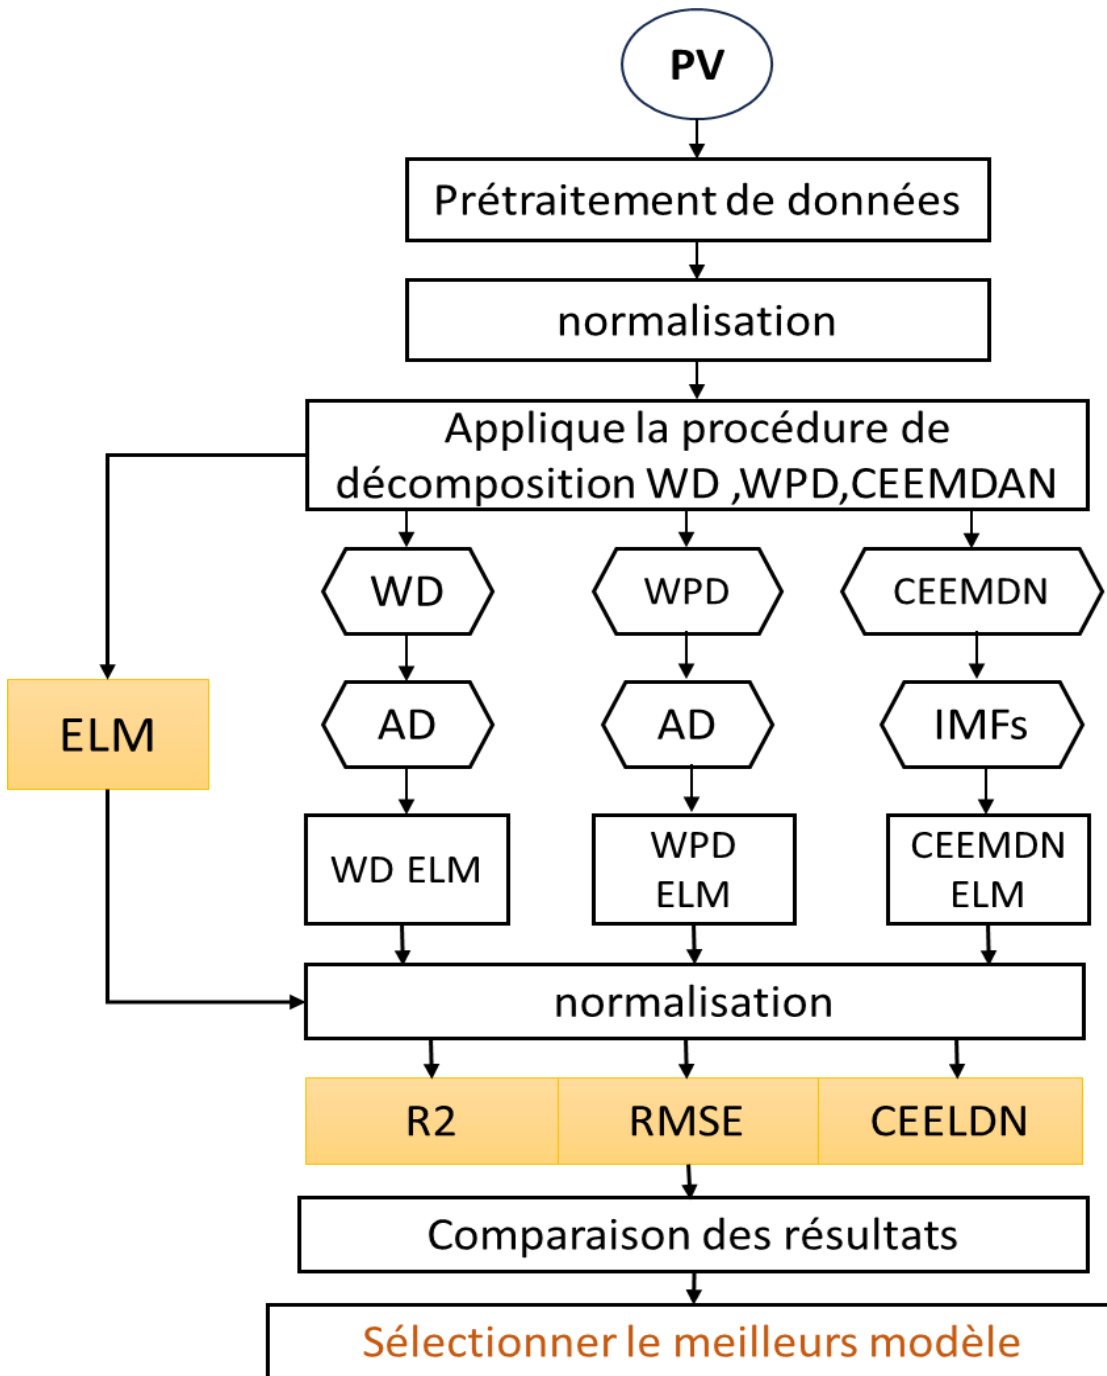


Figure III-4 : Schéma du processus de prédiction proposé.

Normalisation et filtrage des données PV :

La normalisation par score z rapproche toutes les données de la distribution normale standard. La distribution résultante possède une moyenne de 0 et un écart-type de 1. En utilisant la formule suivante (N étant le nombre d'observations) :

$$X_{\text{normalisé}} = \frac{X - \mu(x_i)_{i=1,\dots,N}}{\varepsilon(x_i)_{i=1,\dots,N}}$$

III-1

$$\mu = \text{moy}(x_i), \quad \varepsilon = \text{std}(x_i)$$




Figure III- 5 : la Série temporelle PV après la normalisation

La figure III-5 représente série chronologique de puissance PV sur une période de 2 ans. La série est divisée en trois sections pour différentes étapes de développement du modèle d'apprentissage automatique :

Données d'apprentissage (65 %) : utilisée pour former le modèle d'apprentissage automatique, cette section contient la majorité des données pour aider le modèle à apprendre des modèles et des relations.

Données de validation (10 %) : utilisées pour régler les hyperparamètres du modèle et valider ses performances pendant l'entraînement. Cela garantit que le modèle ne surajoute pas les données d'entraînement.

Données de test (25 %) : utilisées pour évaluer les performances du modèle final sur des données invisibles. Cela donne une indication de la manière dont le modèle fonctionnera dans des scénarios réels.

Dans l'ensemble,

III.4 Extrême Learning Machine (ELM)

L'Extrême Learning Machine (ELM) représente une approche rapide et innovante de l'apprentissage au sein de réseaux de neurones comportant une couche cachée unique. Contrairement aux techniques classiques, l'ELM ne modifie pas les poids de la couche cachée ; au lieu de cela, il se concentre exclusivement sur l'acquisition de connaissances sur les poids de sortie au cours d'une seule itération. Cette caractéristique permet d'atténuer les problèmes liés à la lenteur des processus de formation et à des ajustements excessifs. L'ELM repose sur la minimisation du risque empirique et intègre une initialisation aléatoire des poids des couches cachées, offrant ainsi des avantages notables en termes de vitesse d'apprentissage et de résolution des problèmes. Par conséquent, l'ELM apparaît comme une méthodologie prometteuse dans le domaine de l'apprentissage automatique [42]

III.4.1 Architecture du réseau « Extrême Learning machine »

Le modèle ELM (Extrême Learning Machine) est un modèle prédictif multicouche comprenant une couche d'entrée, une couche cachée, et une couche de sortie, comme illustré dans la figure (III -6). La couche d'entrée sert à introduire les données dans le réseau, tandis que la couche de sortie contient un nombre de neurones correspondant au nombre de classes dans un

contexte de classification (Figure III-6). La couche cachée joue un rôle crucial en extrayant les caractéristiques pertinentes des données d'entrée à travers une combinaison linéaire pondérée des valeurs d'entrée suivie par l'application d'une fonction d'activation non linéaire. La détermination du nombre de neurones dans la couche cachée est essentielle, car un nombre insuffisant ou excessif peut affecter négativement les performances de classification. Par conséquent, il est nécessaire d'optimiser ce hyperparamètre en prenant en compte la complexité des données, la taille de l'ensemble d'apprentissage, et les performances souhaitées pour obtenir des résultats de classification optimaux. Voici quelques définitions spécifiques :

α_i : C'est Vecteur de poids pour l'entrée dans le nœud caché.

Rôle : il détermine la manière dont les entités en entrée sont combinées linéairement pour former l'entrée du

β_i : C'est le Vecteur de poids du nœud caché au nœud de sortie

Rôle : Il détermine comment la sortie Le i -ème nœud caché est combiné linéairement pour contribuer à chaque nœud de sortie.

b_i : C'est le Biais pour le nœud caché

Rôle : il déplace la fonction d'activation du nœud caché, permettant au modèle de s'adapter aux données de manière plus flexible.




Figure III-6 : L'architecteur de réseau ELM

III.4.2 Fonctionnement du réseau ELM

Pour N échantillons (x_i, t_i) , où $x_i = [x_{i1} \ x_{i2} \ x_{in}]^T \in R^n$ représente le vecteur de caractéristiques du $i^{ème}$ échantillon de dimension n, et $t_i = [t_{i1}, t_{i2}, t_{im}]^T \in R^m$ est le vecteur des valeurs d'apprentissage de l' $i^{ème}$ échantillon pour m classes. Ainsi, (x_i, t_i)

$\in R^n \times R^m$ ($i = 1, 2, N$). Un réseau multicouche à propagation avant avec une seule couche cachée standard comportant \tilde{N} neurones cachés et une fonction d'activation $f(x)$ peut être modélisé mathématiquement comme suit

$$\sum_{i=1}^{\tilde{N}} B_i f_i(x_i) = \sum_{i=1}^{\tilde{N}} B_i f(a_i \cdot x_i + b_i) = t_j, j = 1 \dots N \quad \text{III-2}$$

Avec :

$a_i = [a_{i1}, a_{i2}, \dots, a_{in}]^T$ est le vecteur de poids qui relie le i ème nœud caché et les nœuds d'entrée, et b_i est le seuil du $i^{ème}$ nœud caché et $B_i = [B_{i1}, B_{i2}, \dots, B_{in}]^T$ est le vecteur de poids reliant le $i^{ème}$ nœud caché et les nœuds de sortie. $a_i \cdot x_j$ Représente le produit scalaire de a_i et x_j , et la fonction d'activation choisit généralement est une sigmoïde

III.4.3 Caractéristiques d'ELM

Les principales caractéristiques d'une Machine à Vecteurs Support Extrême (ELM, Extrême Learning Machine) sont les suivantes

- Apprentissage rapide
- Fonctions d'activation simples : Les fonctions d'activation utilisées dans l'ELM sont généralement des fonctions simples, telles que la fonction sigmoïde, la fonction tangente hyperbolique ou des fonctions Relu (Rectified Linear Unit). Ces fonctions sont choisies pour leur simplicité et leur efficacité.
- Généralisation performante : L'ELM est réputée pour sa bonne capacité de généralisation.

- Adaptabilité aux grands ensembles de données : L'ELM est bien adaptée pour traiter des ensembles de données volumineux et complexes, grâce à son temps d'apprentissage rapide et à sa capacité de généralisation efficace.

Il est important de noter que l'ELM est un domaine de recherche dynamique, et de nouvelles variantes et améliorations peuvent être développées par les chercheurs. Les caractéristiques mentionnées ci-dessus sont générales et reflètent les principes fondamentaux de l'ELM.

III.5 Méthodologie de création d'un modèle ELM

Les méthodes de prédiction traditionnelles se déroulent en deux phases principales : la phase d'apprentissage et la phase de test. Durant la phase d'apprentissage, l'estimateur utilise les données d'apprentissage pour construire le modèle. Ensuite, lors de la phase de test, il utilise les données de test pour prédire de nouvelles valeurs en se basant sur le modèle généré précédemment. Une fois le processus terminé, les données de test et les prédictions sont comparées afin d'estimer le taux d'erreur. Pour notre étude, nous avons utilisé deux années de données (2019 et 2021) pour entraîner et évaluer notre modèle.

La Figure (III.5) illustre l'évolution de la puissance photovoltaïque tout au long de l'année 2019 -2021 pour le site d'étude. On n'observe que le comportement de la sortie du système photovoltaïque présente des similitudes avec celui des signaux périodiques bruités. Ce bruit, généré par la couverture nuageuse, est plus prononcé pendant les mois d'hiver.

III.6 Evaluation statistique

Les performances des modèles ont été évaluées en utilisant l'erreur quadratique moyenne (RMSE en kW) et son équivalent normalisé (nRMSE en %), ainsi que le coefficient de détermination (R^2). Ces mesures sont largement adoptées dans la littérature lors de la comparaison de

différents modèles. Idéalement, des valeurs faibles de RMSE indiquent une meilleure adéquation aux données observées, tandis que des valeurs proches de 1 pour le coefficient de détermination (R^2) sont privilégiées

Coefficient de détermination (R^2)

Le coefficient de détermination (R^2 , soit le carré du coefficient de corrélation linéaire r) est un indicateur qui permet de juger de la qualité d'une régression linéaire simple. Il mesure l'adéquation entre le modèle et les données observées (Ce coefficient varie entre 0 et 1, soit entre un pouvoir de prédiction faible et un pouvoir de prédiction fort) [43]

$$R^2 = \frac{(\sum_{n=1}^N (H_{n,obs} - \bar{H}_{n,obs})(H_{n,Pred} - \bar{H}_{n,Pred}))^2}{\sum_{n=1}^N (H_{n,obs} - \bar{H}_{n,obs})^2 \sum_{n=1}^N (H_{n,Pred} - \bar{H}_{n,Pred})^2} \quad \text{III-3}$$

Ou:

$H_{n,obs}, \bar{H}_{n,obs}$: Valeur observées et moyenne des observations respectivement.

$H_{n,Pred}, \bar{H}_{n,Pred}$: Valeurs prédites et moyenne des prédictions respectivement.

Erreur Quadratique Moyenne Relative (nRMSE)

Le nRMSE est calculé en divisant le RMSE par la moyenne des données mesurées comme suit [44] :

$$rRMSE = \frac{\sqrt{\frac{1}{N} \sum_{n=1}^N (H_{n,obs} - H_{n,Pred})^2}}{\frac{1}{N} \sum_{n=1}^N (H_{n,obs})^2} * 100 \quad \text{III-4}$$

Selon [45] la performance du modèle en considérant nRMSE est définie comme:

$nRMSE < 10\%$, la performance est excellente.

$10\% < nRMSE < 20\%$, la performance est bonne.

$20\% < nRMSE < 30\%$, la performance est correcte.

$nRMSE > 30\%$, la performance est médiocre

Racine De l'Erreur Quadratique Moyenne (RMSE)

Le RMSE représente la différence entre les valeurs prédites estimées par le modèle et les valeurs mesurées. En fait, RMSE identifie la précision du modèle calculée par [46]

$$\text{RMSE} = \sqrt{\frac{\sum_{n=1}^N (H_{n,obs} - H_{n,pred})^2}{N}} \quad \text{III-5}$$

Prédiction de la Production d'Énergie Photovoltaïque

Le tableau III-2 présent la construction des différents modèles utilisés pour la prédiction de l'énergie photovoltaïque, en comparant les méthodes Originale, W-ELM, WP-ELM et CEEM-DAN-ELM. Chaque méthode est testée avec des entrées temporelles décalées, allant de H-2 à H-3, où "H-1" représente l'heure précédente. Pour chaque combinaison d'entrées, des modèles spécifiques sont construits : M1 à M3 pour le modèle ELM, M4 à M6 pour le modèle W-ELM, M7 à M9 pour le modèle WP-ELM, et M10 à M12 pour le modèle CEEMDAN-ELM.

Tableau III-2 : Présentation des Modèles

Entrées	ELM	W-ELM	WP-ELM	CEEMDAN-ELM
H-1	M1	M4	M7	M10
H-2, H-1	M2	M5	M8	M11
H-3, H-2, H-1	M3	M6	M9	M12

Ce tableau permet de visualiser clairement l'approche multi-délai adoptée pour la prédiction, où les modèles utilisent une ou plusieurs heures précédentes comme entrées pour améliorer la précision des prévisions. En comparant les performances de ces modèles, il est possible d'évaluer l'impact des techniques de décomposition avancées sur la qualité des prédictions.

Tableau III-3 : Évaluation des performances des modèles hybrides de prévision de l'énergie photovoltaïque

	Modèles											
	ELM			WD-ELM			WPD-ELM			CEEMDN-ELM		
	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	M11	M12
R ² (%)	90.163	91.568	92.598	98.123	98.599	99.021	99.607	99.583	99.603	98.937	99.058	98.977
RMSE (kW)	371.953	344.314	322.573	162.784	140.32	117.462	74.729	76.722	75.793	124.67	115.511	119.882
nRMSE (%)	14.667	13.577	12.72	6.419	5.533	4.631	2.946	3.025	2.988	4.916	4.555	4.727

Le tableau ci-dessus résume les résultats obtenus à partir des différents modèles de prédiction de l'énergie photovoltaïque, en utilisant les techniques sans décomposition, WD, WPD et CEEMDAN, selon plusieurs indicateurs de performance : le coefficient de détermination (R^2), la racine carrée de l'erreur quadratique moyenne (RMSE) et le RMSE normalisé (nRMSE).

Les résultats de la figure III-7 montrent que les modèles utilisant des techniques de décomposition (WD, WPD, CEEMDAN) surpassent systématiquement le modèle sans décomposition (SANS DECOMP) en termes de R^2 , RMSE et nRMSE. Par exemple, le modèle CEEMDAN-ELM (M7-M9) atteint les meilleures performances avec un R^2 de 99.607 pour M7, indiquant une très forte corrélation entre les valeurs prédites et réelles. De même, les valeurs de RMSE et nRMSE les plus faibles pour M7 (74.729 et 2.946, respectivement) montrent que ce modèle offre la meilleure précision de prédiction et la plus faible erreur par rapport aux autres.

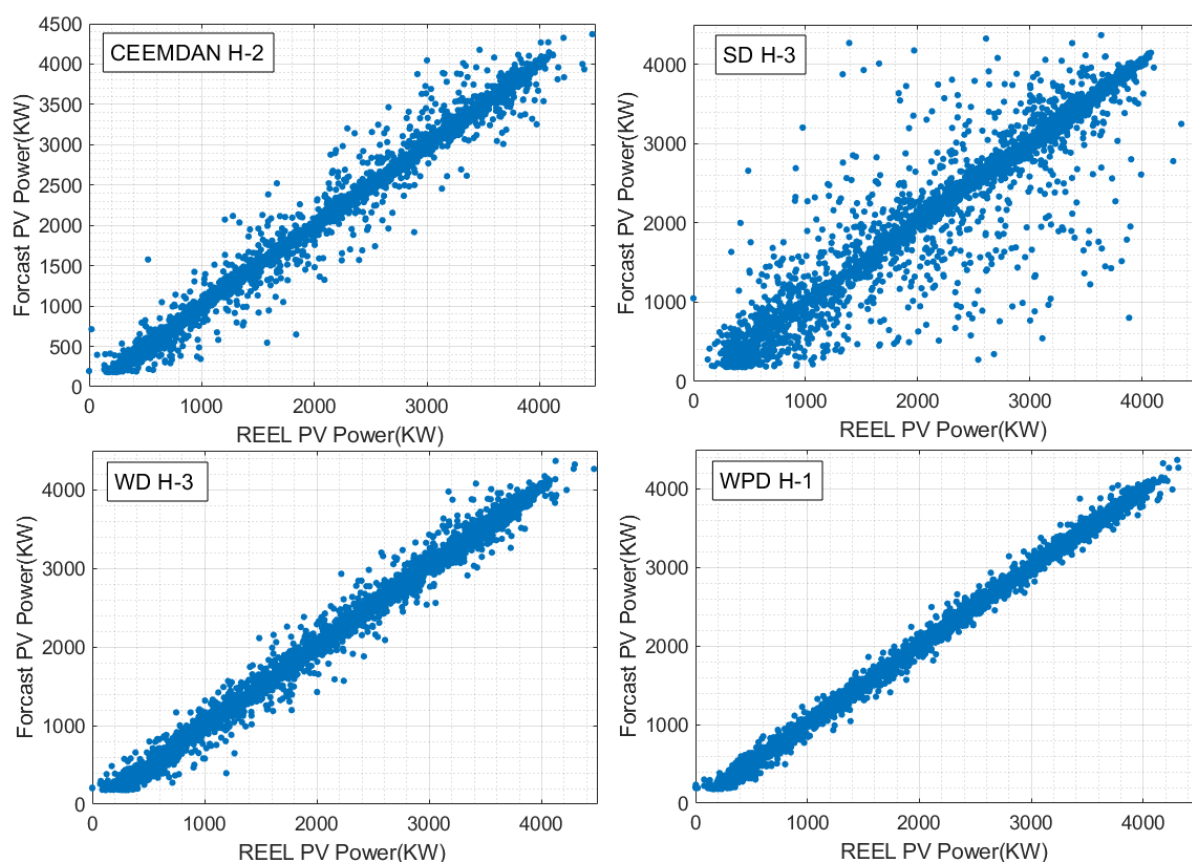


Figure III-7 Comparaison des Meilleurs Modèles de Prédiction via Scatter Plot

L'analyse du (scatter plot) démontre une amélioration significative des performances de prédiction lorsque des techniques de décomposition plus avancées sont utilisées. Le modèle WP (M9) surpasse nettement les autres, suivi par CEEM-DAN (M11) et WD (M6), tandis que le modèle sans décomposition (M3) affiche les performances les plus faibles. Cette progression est en accord avec les résultats statistiques, soulignant l'importance des techniques de décomposition pour améliorer la précision des prédictions dans le domaine de l'énergie photovoltaïque




Figure III- 8 : Performance de modèle hybride M7 dans la prévision de l'énergie photovoltaïque

La figure III-8 présente les résultats obtenus en utilisant le modèle WP-ELM, identifié comme le modèle M7, qui a fourni la prédiction la plus précise du rayonnement solaire. Les valeurs réelles expérimentales sont représentées en bleu, tandis que les valeurs prédites par le modèle sont représentées en rouge.

On observe que le modèle WP-ELM suit de près les valeurs réelles, bien que certaines variations rapides ne soient pas capturées avec une précision parfaite. Les valeurs prédictives (rouge) oscillent autour des valeurs expérimentales (bleu), indiquant que le modèle parvient globalement

à estimer le comportement du rayonnement solaire, malgré la présence de fluctuations significatives. Cette performance souligne l'efficacité du modèle WP-ELM dans la tâche de prédiction du rayonnement solaire, faisant de lui un choix pertinent pour des applications nécessitant des prévisions précises dans ce domaine.

Étude de la Prédiction Multi-Horizon de la Production d'Énergie Photovoltaïque

La prédiction multi-horizon de l'énergie solaire revêt une importance cruciale dans le domaine de l'énergie renouvelable, notamment pour l'optimisation des systèmes de production d'énergie solaire et la gestion des réseaux électriques. Cette étude permet de prévoir le comportement du rayonnement solaire à différents intervalles de temps futurs, offrant ainsi une vision plus complète et stratégique des variations potentielles.

Le tableau (III-3) présente la construction des modèles utilisés pour l'étude de la prédiction multi-horizon. Les entrées indiquent les délais de prédiction, H+1, H+5 et H+6, associés à quatre types de modèles différents : ELM, W-ELM, WP-ELM et CEEMDAN-ELM. Chaque type de modèle est appliqué à différents horizons temporels, permettant ainsi d'évaluer leur performance respective. Par exemple, m1, m4, m7 et m10 sont les modèles appliqués à un horizon de prédiction de H+1, tandis que m2, m5, m8 et m11 sont utilisés pour H+5. Enfin, m3, m6, m9 et m12 sont les modèles correspondant à H+6. Cette structure permet une comparaison détaillée de l'efficacité de chaque méthode de décomposition et de chaque modèle à différents horizons de temps, fournissant ainsi une analyse complète de leurs performances prédictives.

Tableau (III-3) : Présentation des Modèles (cas Multi horizon)

Entrées	ELM	W-ELM	WP-ELM	CEEMDAN-ELM
H+3	m1	m4	m7	m10
H+5	m2	m5	m8	m11
H+6	m3	m6	m9	m12

D'après le tableau III-4 Le coefficient de détermination R^2 indique la force de la relation entre les valeurs prédites et les valeurs réelles. Des valeurs élevées indiquent que le modèle a une bonne capacité à prédire l'énergie photovoltaïque. Le RMSE mesure l'erreur moyenne entre les valeurs prédites et les valeurs réelles. Des valeurs basses indiquent que le modèle prédit bien les données. Le nRMSE mesure l'erreur en pourcentage par rapport à la moyenne des valeurs réelles. Il peut être utilisé pour comparer les performances des modèles entre eux. Des valeurs basses indiquent une performance exceptionnelle.

En examinant le tableau, on remarque que les coefficients de détermination (R^2) pour tous les modèles indiquent une excellente performance dans la prédiction de l'énergie photovoltaïque. Cependant, les valeurs de RMSE et de nRMSE varient d'un modèle à l'autre. Par exemple, le modèle m7 montre le RMSE et le nRMSE les plus bas, ce qui suggère qu'il prédit les données avec une grande précision. En revanche, le modèle m3 affiche les valeurs les plus élevées pour RMSE et nRMSE, indiquant une précision relativement inférieure dans ses prédictions

Tableau III-4 : Évaluation des performances des modèles hybrides de prévision de l'énergie photovoltaïque en cas de multi horizon

	Models											
	ELM			WD-ELM			WPD-ELM			CEEMDN-ELM		
	m1	m2	m3	m4	m5	m6	m7	m8	m9	m10	m11	m12
R² (%)	88.011	74.662	71.273	96.558	86.428	84.911	98.974	94.689	92.951	98.042	94.034	92.957
RMSE (kW)	411.09	598.886	641.424	225.145	440.817	468.819	120.347	282.769	325.711	165.83	291.475	314.609
nRMSE (%)	16.21	23.616	25.293	8.878	17.383	18.487	4.745	11.15	12.844	6.539	11.493	12.406

La figure III-9 présente quatre nuages de points montrant les performances prédictives des meilleurs modèles de prévision multi-horizons à H+3. Chaque nuage de points compare la puissance PV prévue (axe Y) à la puissance PV réelle (axe X).

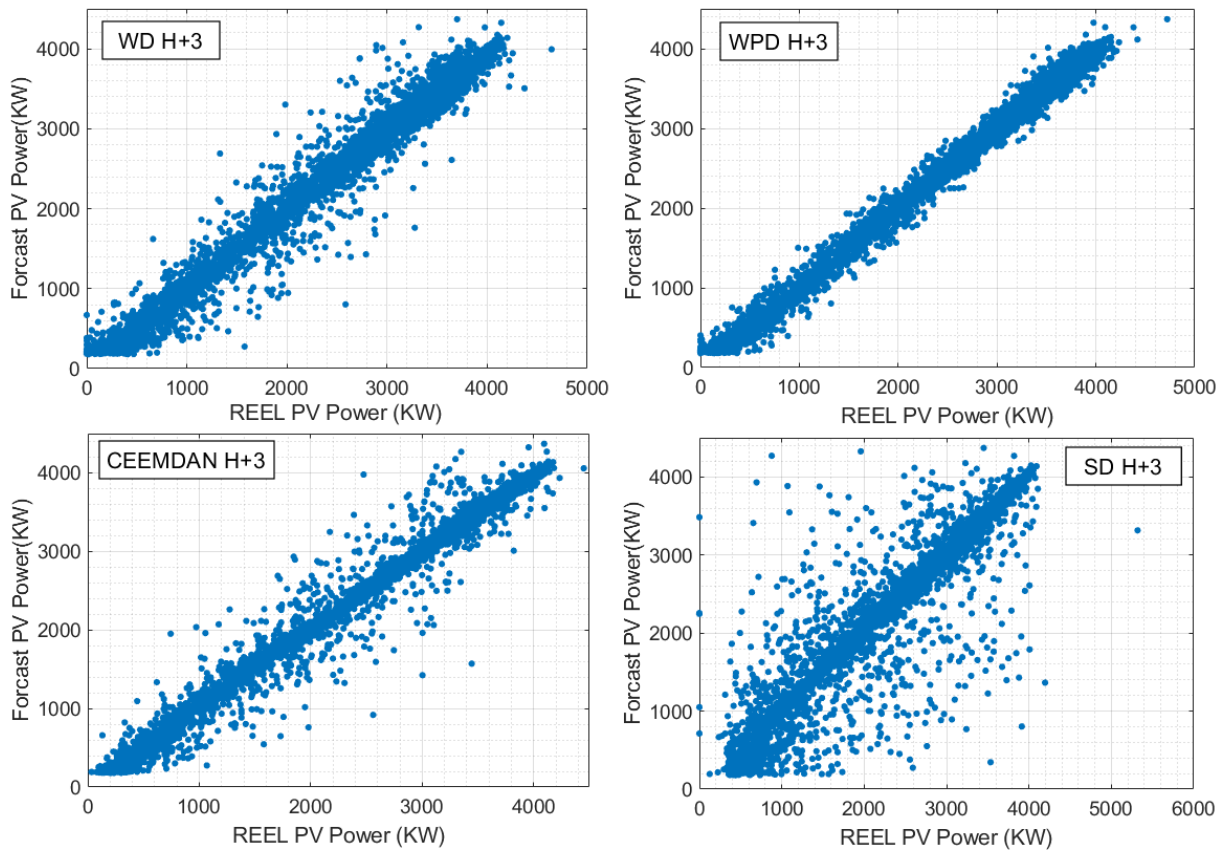


Figure III- 9 : Comparaison des Meilleurs Modèles de Prédiction multi horizon.

SD H+3 (Modèle m3 - ELM) :

Le scatter plot pour le modèle m3 utilisant la série originale montre une bonne corrélation entre les valeurs réelles et prédites, mais avec une dispersion notable. Cela indique que le modèle peut prédire les tendances générales, mais avec une variabilité significative dans les prédictions individuelles.

WD H+3 (Modèle m6 – W-ELM) :

Le scatter plot pour le modèle m6 utilisant la décomposition par ondelettes (WD) présente une amélioration par rapport à la série originale. La dispersion des points est réduite, suggérant

que la décomposition par ondelettes a aidé à capturer plus précisément les variations de la série temporelle, réduisant ainsi les erreurs de prédiction.

WPD H+3 (Modèle m9 – WP-ELM) :

Le scatter plot pour le modèle M7 utilisant la décomposition (WPD) montre la meilleure performance parmi les modèles évalués. Les points sont fortement concentrés le long de la ligne de 45 degrés, indiquant une excellente corrélation entre les prédictions et les valeurs réelles. Cela confirme que (WPD) est particulièrement efficace pour traiter les séries temporelles non linéaires et non stationnaires, offrant ainsi les prédictions les plus précises. L'analyse des scatter plots révèle que les techniques de décomposition améliorent significativement la précision des prédictions de la puissance photovoltaïque. Parmi les modèles étudiés, WPD-ELM (m7) offre les meilleures performances, suivi par CEEMDAN -ELM (m11) et WD-ELM (m6). Le modèle utilisant la série originale (m3) montre des performances acceptables, mais nettement inférieures à celles des modèles utilisant des techniques de décomposition. Ces résultats soulignent l'importance de choisir des méthodes appropriées de décomposition pour améliorer la qualité des prédictions dans les études multi-horizon.

CEEMDAN H+3 (Modèle m11 – CEEMDAN-ELM) :

Le scatter plot pour le modèle m9 utilisant la décomposition par paquets d'ondelettes CEEMDAN montre une amélioration encore plus marquée. Les points sont plus proches de la ligne de 45 degrés, indiquant une correspondance plus étroite entre les valeurs prédites et réelles. Cela suggère que la décomposition par paquets d'ondelettes est très efficace pour améliorer la précision des prédictions.

La figure III-10 présente les résultats de la prédiction de la puissance photovoltaïque (PV) obtenue avec le modèle WPD-ELM (M7), qui a montré les meilleures performances parmi les modèles testés. Voici une analyse détaillée de cette figure :

- L'axe des abscisses (X) représente le temps en heures (h), couvrant une période d'environ 4000 heures. Cela montre que le modèle a été testé sur une longue période, offrant ainsi une vue complète de ses performances à travers différentes conditions temporelles et météorologiques.
- L'axe des ordonnées (Y) représente la puissance photovoltaïque en kilowatts (kW). Les valeurs varient de 0 à 5000 kW, couvrant une large gamme de production d'énergie solaire.
- Les lignes bleues représentent les valeurs réelles de la puissance photovoltaïque mesurée.
- Les lignes rouges représentent les valeurs prédites par le modèle WPD-ELM (M7).
- Une correspondance étroite entre les deux lignes indique une haute précision du modèle.




Figure III- 10 : Performance de modèle hybride M7 dans la prévision de l'énergie photovoltaïque

Globalement, les lignes rouge et bleue se chevauchent bien, indiquant que le modèle prédit avec précision la puissance PV à la plupart des points temporels. Il y a quelques fluctuations et

écarts visibles entre les lignes bleues et rouges, mais ces écarts semblent relativement faibles, ce qui montre que le modèle est capable de capturer les tendances majeures et les variations de la production d'énergie solaire avec une bonne précision.

Le modèle WPD-ELM (M7) semble stable sur toute la période de 4000 heures, sans déviation significative ni dégradation des performances. Cela suggère que le modèle peut être utilisé de manière fiable pour des prévisions à long terme.

La figure démontre l'efficacité du modèle WPD-ELM (M7) pour prédire la puissance photovoltaïque. La correspondance étroite entre les valeurs réelles et prédites sur une longue période indique que ce modèle est bien adapté pour des applications de prévision à long terme, aidant ainsi à la gestion et à la planification des systèmes d'énergie renouvelable.

III.7 Conclusion

Dans ce chapitre, nous avons mené une étude approfondie sur la prédiction de l'énergie solaire à partir des données endogènes. Nous avons décrit notre méthodologie de manière exhaustive, mettant en évidence l'utilisation de la Machine d'Apprentissage Extrême (ELM) et d'autres techniques de prétraitement des données telles que la décomposition en ondelettes et la décomposition en paquets d'ondelettes. Nous avons effectué une étude approfondie, en tenant compte de différentes approches de modélisation et en évaluant les performances de chaque modèle à l'aide de critères statistiques pertinents tels que le coefficient de détermination (R^2), la racine carrée de l'erreur quadratique moyenne (RMSE) et le RMSE normalisé (nRMSE). Cette approche nous a permis de comparer les performances des différents modèles et d'identifier ceux qui offraient les meilleures prédictions pour l'énergie solaire. De plus, nous avons exploré la prédiction multi-horizon de l'énergie solaire, ce qui est crucial pour optimiser les systèmes de production d'énergie solaire et la gestion des réseaux électriques. Nous avons également utilisé

des graphiques de dispersion pour illustrer visuellement les performances prédictives des différents modèles à différents horizons temporels, facilitant ainsi la compréhension des résultats.

Conclusion générale

Ce mémoire a permis de mettre en lumière les avantages et les performances des techniques hybrides de prévision de l'énergie photovoltaïque. L'analyse comparative des trois méthodes de décomposition des données a révélé que l'intégration de la technique ELM avec différentes méthodes de décomposition du signal peut améliorer significativement la précision des prévisions. Nos résultats montrent que le modèle WP-ELM est le plus performant pour les prévisions à pas arrière, grâce à sa capacité à capturer efficacement les variations temporelles des données. En revanche, pour les prévisions multi-horizon, le modèle WPD-ELM a démontré une supériorité notable, en raison de sa robustesse et de sa capacité à gérer le bruit et les incertitudes des données. Ces conclusions soulignent l'importance de choisir des méthodes adaptées de décomposition du signal et de prévision en fonction du contexte et des exigences spécifiques de chaque application. En outre, elles ouvrent la voie à de futures recherches visant à explorer davantage les combinaisons optimales de techniques d'apprentissage automatique et de décomposition du signal pour améliorer encore la précision des prévisions énergétiques.

Pour compléter, il est pertinent de discuter des implications pratiques de ces résultats. En effet, ces techniques pourraient être mises en œuvre dans des systèmes de gestion de l'énergie photovoltaïque existants pour optimiser l'utilisation des ressources énergétiques renouvelables. De plus, une amélioration de la précision des prévisions énergétiques pourrait avoir des implications économiques significatives en permettant une meilleure planification des opérations et une optimisation des coûts. Cependant, il convient de reconnaître les défis potentiels à surmonter lors de la mise en œuvre de ces techniques à grande échelle, tels que la disponibilité de données de haute qualité et la nécessité de former le personnel pour utiliser ces nouveaux modèles de prévision. Des recherches futures pourraient se concentrer sur ces aspects pratiques et fournir

des solutions pour les adresser, contribuant ainsi à une adoption plus large et efficace de ces techniques innovantes dans le domaine de la gestion de l'énergie photovoltaïque.

En résumé, cette étude contribue à l'avancement des connaissances dans le domaine de la prévision de l'énergie photovoltaïque et propose des solutions pratiques pour optimiser l'exploitation des ressources énergétiques renouvelables dans des contextes variés.

Références

- [1]. Lincot, D., *la conversion photovoltaïque de l'énergie solaire*. Découverte2007, 2007: p. 47.
- [2]. Navarro, J.M., *Cellules photovoltaïques organiques transparentes dans le visible*. 2008.
- [3]. Quaschnig, V., *Understanding renewable energy systems*. 2014: Routledge.
- [4]. Lotsch, H.K.V., A. Goetzberger, and V.U. Hoffmann, *Photovoltaic solar energy generation*. 2005: Springer.
- [5]. Gairaa, K., *Prédiction du rayonnement solaire en Algérie à partir des modèles hybrides*. 2018.
- [6]. Edgar, N.F., et al., *Evaluation des performances d'un module solaire photovoltaïque monocristallin par système expert neuronal*. Synthèses de Résumés des Communications scientifiques: p. 15.
- [7]. Mansouri, M.M., *Étude, simulation et mesure du rendement des panneaux solaires de différentes technologies d'une centrale solaire*.
- [8]. Hadj Belkacemi, M., *Etude de la fiabilité des tests IV des modules solaire à base de silicium cristallin et amorphe sous les conditions réelle du climat saharien*.
- [9]. Merah, R., R. Chenni, and M. Houbes, *Modélisation et Simulation d'un Module PV par MatLab*. Journal of scientific Research, 2010(10).
- [10]. Labouret, A. and M. Viloz, *Energie solaire photovoltaïque*. Vol. 3. 2006: Dunod Paris.
- [11]. Voyant, C., *Prédiction de séries temporelles de rayonnement solaire global et de production d'énergie photovoltaïque à partir de réseaux de neurones artificiels*. 2011.
- [12]. Reikard, G., *Predicting solar radiation at high resolutions: A comparison of time series forecasts*. Solar energy, 2009. **83**(3): p. 342-349.
- [13]. Tatsa, S., *Modélisation et prévision de la consommation horaire d'électricité au Québec: comparaison de méthodes de séries temporelles*. 2014.
- [14]. Krakutovski, Z., *Amélioration de l'approche démographique pour la prévision à long terme de la mobilité urbaine*. 2004.
- [15]. Charpin, J.-M., et al., *DMS, modèle de prévision à moyen terme*. Économie et statistique, 1976. **79**(1): p. 33-48.
- [16]. Lewandowski, R., *La prévision à court terme: présentation des techniques, organisation et mise en place des systèmes de prévisions*. 1979: FeniXX.
- [17]. Anderson, O.D., *The Box-Jenkins approach to time series analysis*. RAIRO-Operations Research, 1977. **11**(1): p. 3-29.
- [18]. Delignières, D., *Séries temporelles–Modèles ARIMA*. Séminaire EA" Sport–Performance–Santé, 2000.
- [19]. Box, G.E.P., et al., *Time series analysis: forecasting and control*. 2015: John Wiley & Sons.

- [20]. Ghimire, S., et al., *Deep solar radiation forecasting with convolutional neural network and long short-term memory network algorithms*. Applied Energy, 2019. **253**: p. 113541.
- [21]. Colak, I., et al. *Multi-period prediction of solar radiation using ARMA and ARIMA models*. IEEE.
- [22]. Greenspan, R.J. and B.J. Baars, *Consciousness eclipsed: Jacques Loeb, Ivan P. Pavlov, and the rise of reductionistic biology after 1900*. Consciousness and cognition, 2005. **14**(1): p. 219-230.
- [23]. Cyr, A., *Intelligence artificielle et robotique bio-inspirée: modélisation de fonctions d'apprentissage par réseaux de neurones à impulsions*. 2016.
- [24]. Crone, S.F., *Stepwise selection of artificial neural network models for time series prediction*. Journal of Intelligent Systems, 2005. **14**(2-3): p. 99-122.
- [25]. Bishop, C.M., *Neural networks for pattern recognition*. 1995: Oxford university press.
- [26]. Vapnik, V., *The nature of statistical learning theory*. 2013: Springer science & business media.
- [27]. Lauret, P., et al., *A benchmarking of machine learning techniques for solar radiation forecasting in an insular context*. Solar energy, 2015. **112**: p. 446-457.
- [28]. Ouyang, Z., P. Ravier, and M. Jabloun, *Une comparaison des modèles d'apprentissage profond combinés avec des différentes stratégies pour la prédiction multi-étape des séries temporelles*.
- [29]. Richard, S., *Le Nanomonde des chercheurs Analyse sociologique des pratiques et des discours sur l'instrumentation en nanotechnologies*. 2013: Université de Montreal (Canada).
- [30]. Djebablia, H. and R.E. Yacef, *Prévision de l'irradiation solaire globale à l'aide des méthodes d'apprentissage automatique*. 2023.
- [31]. Li, C., L. Zhan, and L. Shen, *Friction signal denoising using complete ensemble EMD with adaptive noise and mutual information*. Entropy, 2015. **17**(9): p. 5965-5979.
- [32]. Zhang, G.P., *Time series forecasting using a hybrid ARIMA and neural network model*. Neurocomputing, 2003. **50**: p. 159-175.
- [33]. Aimene, M.A., *L'impact de fuite et échappement de gaz sur l'environnement*.
- [34]. Boudjerda, S., et al., *La décomposition modale empirique (EMD) et ses variantes pour le traitement des signaux ultrasonores: Application au contrôle non destructif (CND)*. 2016.
- [35]. Zhang, W., et al., *A combined model based on CEEMDAN and modified flower pollination algorithm for wind speed forecasting*. Energy Conversion and Management, 2017. **136**: p. 439-451.
- [36]. Addison, P.S., *The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance*. 2017: CRC press.
- [37]. Daubechies, I., *Ten lectures on wavelets*. 1992: SIAM.
- [38]. Mallat, S.G., *Multifrequency channel decompositions of images and wavelet models*. IEEE Transactions on Acoustics, speech, and signal processing, 1989. **37**(12): p. 2091-2110.

- [39]. Zhou, X., C. Zhou, and B.G. Stewart. *Zhou, X., Zhou, C. and Stewart, B. Comparisons of discrete wavelet transform, wavelet packet transform and stationary wavelet transform in denoising PD measurement data. Conference record of the 2006 IEEE international symposium on electrical insulation, IEEE. Vol. no., pp. 237-240, (2006). IEEE.*
- [40]. Ngui, W.K., et al., *Wavelet analysis: mother wavelet selection methods. Applied mechanics and materials, 2013. 393: p. 953-958.*
- [41]. Salemi, A., B. Ghoulam, and S. Chabachi, *Etude Techno-Economique D'une Centrale Photovoltaïque Raccordée au Réseau Installé Dans le Sud de l'Algérie. 2022.*
- [42]. Huang, G.-B., Q.-Y. Zhu, and C.-K. Siew, *Extreme learning machine: theory and applications. Neurocomputing, 2006. 70(1-3): p. 489-501.*
- [43]. Farkous, K., *Caractérisation et évaluation du rayonnement solaire pour le site de Ghardaïa.*
- [44]. Khelifi, R., et al., *Multi-step-ahead forecasting of daily solar radiation components in the Saharan climate. International Journal of Ambient Energy, 2020. 41(6): p. 707-715.*
- [45]. Ertekin, C. and O. Yaldiz, *Comparison of some existing models for estimating global solar radiation for Antalya (Turkey). Energy Conversion and Management, 2000. 41(4): p. 311-330.*
- [46]. Rabehi, A., et al., *Decomposing global solar radiation into its diffuse and direct normal radiation. International Journal of Ambient Energy, 2020. 41(7): p. 738-743.*

annexe :

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي والبحث العلمي
Ministère de L'enseignement Supérieur et de La recherche Scientifique

Faculté de sciences et technologie
Département autonome



جامعة غرداية
كلية العلوم والتكنولوجيا
قسم الآلية والكهروميكانيك
Université de Ghardaïa
Electromécanique

إذن بالطباعة (مذكرة ماستر)

بعد الاطلاع على التصحيحات المطلوبة على محتوى المذكرة المنجزة من طرف الطلبة التالية أسمائهم:

1. الطالب (ة): أولاد الطيب محمد اقبال

2. الطالب (ة): الهاشمي مولاي عبد الله

تخصص: طاقات متجددة في الكهرو تقني

نمنح نحن الأساتذة:

الاسم و اللقب	الرتبة - الجامعة الأصلية	الصفة	الامضاء
بن حليلة وسام	MCA - جامعة غرداية	مصصح (1)	
بلغراسيافية	MCA - جامعة غرداية	مصصح (2)	
بوشلقةفاطمة	MCA - جامعة غرداية	مصصح (3)	
خالد فركوس	MCA - جامعة غرداية	مؤطر	

الإذن بالطباعة النسخة النهائية لمذكرة ماستر الموسومة بعنوان:

Analyse Comparative des Techniques de Decomposition pour la Prevision d'Énergie
Photovoltaïque

إمضاء رئيس القسم

جامعة غرداية
قسم الآلية
والكهروميكانيك
كلية العلوم والتكنولوجيا
رئيس قسم الآلية
والكهروميكانيك
عبد اللطيف