

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 عين تموشنت بلحاج بوشعيب  
Université –Ain Temouchent- Belhadj Bouchaib  
Faculté des Sciences et de Technologie  
Département d'Électronique et des Télécommunications



Projet de Fin d'Etudes  
Pour l'obtention du diplôme de Master en :  
Domaine : Sciences et Technologie  
Filière : Électronique  
Spécialité : Instrumentation  
Thème

**Système de Gestion Énergétique Intelligent par l'Intégration de  
Panneaux Solaires pour une Consommation Optimisée et  
Durable**

Présenté par :

- 1) Mr KAMLI Mounir Tewfik
- 2) Melle DJELLOUL BENCHERIF Amira Ahlem

Devant le jury composé de :

Dr MEKAMI Hayet	UAT.B.B (Ain Temouchent )	Présidente
Dr YAGOUB Réda	UAT.B.B (Ain Temouchent )	Examineur
Dr BENTAIEB Samia	UAT.B.B (Ain Temouchent )	Encadrante
Pr NEHARI Driss	UAT.B.B (Ain Temouchent )	Co-encadrant

*Année Universitaire 2024/2025*

*Je dédie ce travail à celles et ceux qui ont été les piliers de mon parcours académique.*

*À mes parents, dont la foi inébranlable en moi a constamment éclairé mon chemin, même dans les périodes les plus difficiles. Leurs sacrifices et leur soutien indéfectible ont nourri ma détermination et guidé ma quête de savoir.*

*À ma famille, tant paternelle que maternelle, pour leur affection, leurs encouragements et leur présence rassurante.*

*Enfin, je dédie ce travail à mes amis et collègues, dont le soutien constant et l'énergie positive ont accompagné chaque étape de ce parcours. Votre présence, dans les moments de doute comme dans ceux de joie, a été une véritable source d'inspiration et de force.*

*Ce travail représente le fruit d'un effort partagé, porté par l'amour, le soutien et la confiance de toutes les personnes auxquelles il est dédié. Merci d'avoir cru en moi et d'avoir été présentes tout au long de ce parcours.*

***Mounir***

*À mes parents: Ma mère, qui a sacrifié sa vie pour mon bien-être. Mon père, à qui je voue un profond respect pour tout le dévouement qu'il m'a consacré.*

*À ma famille , paternelle et maternelle, pour leur amour, leur bienveillance et leur présence rassurante, qui ont été une source précieuse de réconfort et de motivation.*

*À mes professeurs et encadrants, pour la richesse de leur enseignement, la justesse de leurs conseils et leur soutien constant tout au long de ce parcours.*

*À mes amis et camarades, pour les instants de partage, de joie et de soutien qui ont marqué ce parcours et l'ont rendu inoubliable.*

*À toutes celles et ceux qui ont croisé mon chemin durant cette période, merci du fond du cœur. Ce mémoire vous est dédié, car chacun d'entre vous a contribué, à sa manière, à cette belle aventure.*

**Ahlem**

# Remerciements

Avant toute chose, nous adressons nos louanges et notre gratitude à Dieu, le Tout-Puissant et le Miséricordieux, pour nous avoir accordé la santé, la persévérance et la force morale nécessaires à l'accomplissement de ce travail.

Nous exprimons notre profonde gratitude à notre encadrante, Dr BENTAIEB Samia, pour son encadrement, ses précieux conseils, sa disponibilité constante, ainsi que pour ses qualités humaines et scientifiques. Sa patience et son soutien tout au long de ce travail ont été d'une aide inestimable.

Nous adressons également nos sincères remerciements au Pr NEHARI Driss pour son aide précieuse et son accompagnement ainsi que pour sa confiance et les moyens qu'il nous a accordés.

Nous exprimons également notre gratitude à Dr MEKAMI Hayet pour avoir accepté de présider le jury de soutenance. Nos remerciements vont aussi à Dr Yagoub Réda, qui nous a fait l'honneur d'évaluer notre modeste travail.

Nous tenons également à exprimer notre profonde gratitude à Mr HAMZI Kheir Eddine Yassine et Mr BENMAROUF Mohamed Nabil, étudiants de la promotion précédente, dont le travail nous a servi de fondement et a constitué une base essentielle pour la continuité et le développement de notre projet.

Nous tenons également à remercier l'ensemble des enseignants qui ont contribué à notre formation tout au long de notre parcours universitaire à la Faculté des Sciences et Technologies, et plus particulièrement ceux du Département d'Électronique et des Télécommunications. Leur passion pour la discipline, leur encadrement, ainsi que les outils et données mis à notre disposition ont nourri notre curiosité scientifique et renforcé notre goût pour la recherche. Nous exprimons enfin notre profonde reconnaissance à nos familles, nos amis et nos collègues pour leur soutien indéfectible, leurs encouragements constants et leur présence bienveillante tout au long de cette aventure. Nos remerciements s'adressent également à toutes les personnes, citées ou non, qui nous ont aidés de près ou de loin dans l'élaboration de ce mémoire.

# Table des matières

<b>Table des figures</b>	<b>vii</b>
<b>Liste des tableaux</b>	<b>viii</b>
<b>Code Listings</b>	<b>i</b>
<b>Glossaire</b>	<b>ii</b>
<b>I Partie Théorique</b>	<b>5</b>
<b>1 Énergies Renouvelables et Hybridation des Sources d'Énergie en Algérie</b>	<b>6</b>
1.1 Introduction aux énergies renouvelables en Algérie . . . . .	7
1.1.1 Contexte énergétique en Algérie . . . . .	7
1.1.2 Besoin de transition énergétique . . . . .	7
1.1.3 Potentiel des énergies renouvelables . . . . .	8
1.2 L'énergie solaire en Algérie: potentiel et exploitation . . . . .	9
1.2.1 Ressources solaires et ensoleillement . . . . .	9
1.2.2 Projets et infrastructures solaires . . . . .	10
1.2.3 Défis et obstacles au développement du solaire . . . . .	11
1.3 L'énergie conventionnelle en Algérie : situation actuelle et perspectives . . . . .	14
1.3.1 Situation actuelle de la production électrique en Algérie . . . . .	14
1.3.1.1 Conséquences de cette dépendance fossile . . . . .	15
1.3.2 Impact économique et environnemental . . . . .	16
1.3.3 Perspectives d'évolution vers un mix énergétique durable . . . . .	17
1.4 Conclusion . . . . .	19

<b>2</b>	<b>Les Panneaux Photovoltaïques: Principe et Technologie</b>	<b>20</b>
2.1	Introduction . . . . .	21
2.2	Principes de fonctionnement des panneaux photovoltaïques . . . . .	21
2.2.1	Effet photovoltaïque . . . . .	21
2.2.2	Structure d'une cellule photovoltaïque . . . . .	22
2.3	Types de panneaux photovoltaïques . . . . .	23
2.3.1	Panneaux monocristallins . . . . .	23
2.3.1.1	Caractéristiques principales . . . . .	23
2.3.1.2	Avantages . . . . .	24
2.3.1.3	Inconvénients . . . . .	24
2.3.1.4	Applications . . . . .	25
2.3.2	Panneaux polycristallins . . . . .	25
2.3.2.1	Caractéristiques des panneaux polycristallins . . . . .	25
2.3.2.2	Avantages . . . . .	25
2.3.2.3	Inconvénients . . . . .	26
2.3.2.4	Applications . . . . .	26
2.3.3	Panneaux à couches minces . . . . .	26
2.3.3.1	Caractéristiques des panneaux à couches minces . . . . .	27
2.3.3.2	Avantages . . . . .	27
2.3.3.3	Inconvénients . . . . .	27
2.3.3.4	Applications . . . . .	28
2.3.3.5	Technologies utilisées . . . . .	28
2.4	Facteurs influant sur la performance des panneaux photovoltaïques . . . . .	28
2.4.1	Innovations pour améliorer l'efficacité . . . . .	35
2.5	Conclusion . . . . .	35
<b>3</b>	<b>Exploration des Fondements des Réseaux Neuronaux et du Deep Learning</b>	<b>37</b>
3.1	Introduction . . . . .	38
3.2	L'intelligence artificielle . . . . .	38
3.2.1	Machine Learning . . . . .	39
3.2.1.1	Apprentissage supervisé . . . . .	40
3.2.1.2	Apprentissage non-supervisé . . . . .	41
3.2.1.3	Apprentissage semi-supervisé . . . . .	41
3.2.1.4	Apprentissage par renforcement . . . . .	41
3.2.1.5	Apprentissage par transfert . . . . .	42

3.2.2	Deep Learning . . . . .	42
3.2.2.1	Le cerveau humain et les réseaux neuronaux artificiels . . . . .	44
3.2.2.2	L'architecture des réseaux neuronaux . . . . .	45
3.2.2.3	Les fonctions d'activation . . . . .	46
3.2.3	Convolutional Neural Networks (CNN) . . . . .	47
3.3	Apprentissage d'un réseau de neurones convolutifs . . . . .	50
3.3.1	Propagation avant (Forward Propagation) . . . . .	51
3.3.2	Calcul de la fonction de perte . . . . .	51
3.3.3	Rétropropagation (Backpropagation) . . . . .	53
3.3.4	Optimisation des poids . . . . .	53
3.4	Conclusion . . . . .	55
 <b>II Partie Pratique</b>		 <b>56</b>
<b>4</b>	<b>Le Deep Learning pour la Prédiction de la Consommation de l'Énergie</b>	<b>57</b>
4.1	Introduction . . . . .	58
4.2	Base de données . . . . .	58
4.2.1	Description de la base de données . . . . .	58
4.2.2	Analyse de la base de données . . . . .	60
4.2.3	Pré-traitement des données . . . . .	64
4.2.4	Préparation de la base de données . . . . .	64
4.2.4.1	Normalisation . . . . .	64
4.2.4.2	Transformation des séries temporelles pour un problème d'apprentissage supervisé . . . . .	65
4.2.4.3	Répartition des données . . . . .	66
4.3	Méthodologie . . . . .	67
4.3.1	Architecture du modèle . . . . .	67
4.3.1.1	Modèle proposé . . . . .	67
4.3.1.2	Modélisation . . . . .	68
4.3.2	Évaluation des performances . . . . .	71
4.4	Résultats expérimentaux et discussion . . . . .	73
4.5	Conclusion . . . . .	75
<b>5</b>	<b>Mise en Œuvre Embarquée sur la Plateforme Raspberry Pi</b>	<b>77</b>
5.1	Introduction . . . . .	78
5.2	Présentation du Raspberry . . . . .	78

5.3	Aspect matériel du Raspberry Pi . . . . .	79
5.3.1	Architecture d'un Raspberry Pi . . . . .	80
5.3.2	Principaux composants du Raspberry Pi 4 B+ . . . . .	80
5.3.3	Fonctionnement et avantages du Raspberry Pi . . . . .	81
5.4	Aspect logiciel du Raspberry Pi . . . . .	83
5.4.1	Système d'exploitation et installation . . . . .	83
5.4.2	Contrôle à distance avec VNC et SSH . . . . .	85
5.5	Conception du système embarqué . . . . .	87
5.5.1	Organigramme du système . . . . .	87
5.5.2	Bibliothèques et outils utilisés . . . . .	87
5.6	Interface utilisateur de simulation (SmartSolEM) . . . . .	89
5.6.1	Présentation de l'interface . . . . .	89
5.6.2	Paramétrage et affichage de la simulation . . . . .	90
5.7	Conclusion . . . . .	93

**A Code Listings** **101**

# Table des figures

1.1	Développement de la production d'énergie fossile par rapport aux énergies renouvelables. . . . .	8
1.2	Répartition mondiale du rayonnement solaire annuel en kWh/m <sup>2</sup> . . . . .	9
1.3	Aperçu de projets solaires emblématiques et initiatives en Algérie . . . . .	12
1.4	Comparaison de l'évolution de la production d'électricité en Algérie . . . . .	15
1.5	Évolution des émissions annuelles de CO <sub>2</sub> en Algérie (1965–2023) . . . . .	16
1.6	Évolution des émissions de CO <sub>2</sub> en Algérie par secteur . . . . .	17
1.7	Programme National pour les Énergies Renouvelables (PNER) . . . . .	18
2.1	L'effet photovoltaïque . . . . .	22
2.2	Panneaux monocristallins . . . . .	23
2.3	Panneaux polycristallins . . . . .	25
2.4	Panneau à couches minces . . . . .	27
2.5	L'effet de rayonnement solaire sur les panneaux photovoltaïques . . . . .	29
2.6	L'effet de température sur photovoltaïques . . . . .	29
2.7	ombrage . . . . .	30
2.8	Courbe P-U du PV sous différentes densités de poussière . . . . .	31
2.9	courbe $\rho - \eta$ . . . . .	31
2.10	$\rho - FF$ curve . . . . .	31
2.11	Courbe $\rho - FF$ . . . . .	32
2.12	La meilleure orientation . . . . .	33
2.13	La meilleure inclinaison . . . . .	33
2.14	Rackers solaire . . . . .	33
3.1	Les types de de ML . . . . .	40
3.2	Schéma explicatif de la différence entre IA, ML et DL . . . . .	44
3.3	Structure d'un neurone humain . . . . .	44

3.4	La différence entre les réseaux neuronaux simples et profonds . . . . .	45
3.5	Structure d'un perceptron . . . . .	46
3.6	Les courbes des fonctions d'activations . . . . .	47
3.7	Architecture d'un réseau CNN [1] . . . . .	48
3.8	Convolution 1D avec filtre de trois suivi d'un max-pooling . . . . .	49
3.9	Réseau neuronal avant et après le dropout . . . . .	50
3.10	Exemple de Flatten . . . . .	50
3.11	Fully connected layer . . . . .	51
3.12	Organigramme d'apprentissage avec optimiseur . . . . .	52
3.13	Impact des différents taux d'apprentissage sur la convergence vers le minimum de la fonction de perte . . . . .	54
4.1	Tendance annuelle de la consommation d'énergie . . . . .	59
4.2	Consommation moyenne mensuelle d'énergie (toutes années confondues) . . . .	61
4.3	Consommation moyenne quotidienne d'énergie (toutes années confondues) . .	61
4.4	Consommation moyenne horaire d'énergie (toutes années confondues) . . . . .	62
4.5	Matrice de corrélation entre les principales variables . . . . .	63
4.6	Architecture du modèle CNN 1D pour séries temporelles . . . . .	69
4.7	La variation de la fonction de perte . . . . .	73
4.8	Comparaison entre les valeurs réelles (en bleu) et les valeurs prédites (en rouge) de la consommation énergétique à l'aide du modèle CNN 1D. . . . .	75
5.1	Raspberry Pi 4 B+ . . . . .	78
5.2	La sortie graphique de [2] . . . . .	79
5.3	Schéma de l'architecture serveur proposée pour le système de supervision, présentant le système mis en œuvre avec les Raspberry Pi, les onduleurs et les batteries [3] . . . . .	80
5.4	Raspberry Pi Imager . . . . .	84
5.5	Étapes pour activer VNC sur Raspberry Pi . . . . .	85
5.6	Étapes pour activer SSH sur Raspberry Pi . . . . .	86
5.7	Interface graphique de Raspbian après démarrage . . . . .	87
5.8	Organigramme de la gestion énergétique . . . . .	88
5.9	Interface utilisateur de simulation (SmartSolEM) . . . . .	90
5.10	Interface de paramétrage des variables dans SmartSolEM . . . . .	91
5.11	Paramétrage du modèle de simulation et état du système en temps réel . . . .	91
5.12	Maquette de maison intelligente avec indicateurs lumineux des sources d'énergie	93

# Liste des tableaux

3.1	Tableau comparatif des différentes Stratégies d'apprentissage . . . . .	43
4.1	Description des données utilisées . . . . .	60
4.2	Liste des paramètres du modèle CNN . . . . .	71
4.3	Mesures de performance pour les prédictions du modèle . . . . .	74
5.1	Comparaison des différents modèles de Raspberry Pi . . . . .	82

# Code Listings

A.1	Code Python pour transformer une série temporelle en problème supervisé .	101
A.2	Importation des bibliothèques nécessaires . . . . .	101
A.3	Définition du modèle séquentiel . . . . .	101
A.4	Construction de couches convolutives . . . . .	101
A.5	Incorporation de la mise en commun et de l'aplatissement . . . . .	102
A.6	Ajouter des couches denses . . . . .	102
A.7	Compilation du modèle . . . . .	102

# Abréviations

ACP: **A**nalyse **C**omposante **I**ncipale  
Adagrad : **A**daptive **G**radient **D**escent  
ADAM : **A**daptive **M**oment **E**stimation  
AI: **A**rtificielle **I**ntelligence  
ARM : **A**dvanced **R**isc **M**achine  
ANN: **A**rtificial **N**eural **N**etworks  
BCM: **B**road**C**o**M** (nom de la série de puces Broadcom)  
CDER: **C**entre de **D**éveloppement des **É**nergie **R**enouvelable  
CdTe: **C**admium **T**elluride  
CIGS : **C**uivre **I**ndium **G**allium **S**élénium  
CNN: **C**onvolution **N**eural **N**etworks  
 $CO_2$ : **O**xide de **C**arbon  
CSP: **C**oncentrated **S**olar **P**ower  
CPU: **C**entral **P**rocessing **U**nit  
DL: **D**eep **L**earning  
DNN : **D**eep **N**eural **N**etwork  
DVI: **D**igital **V**isual **I**nterface  
EAM: **E**rreur **A**bsolue **M**oyenne  
EQM: **E**rreur **Q**uadratique **M**oyenne  
EAMP: **E**rreur **A**bsolue **M**oyenne en **P**ourcentage  
FAT32: **F**ile **A**llocation **T**able 32 bits  
gCO<sub>2</sub>éq: grammes de **CO**<sub>2</sub> équivalent  
GHz: **G**iga**H**ertz  
GPIO : **G**eneral **P**urpose **I**nput/**O**utput  
GPU : **G**raphics **P**rocessing **U**nit  
GRU: **G**ated **R**eurrent **U**nit

HDMI : **H**igh **D**efinition **M**ultimedia **I**nterface  
HJT : **H**été**r**Jon**ct**ion **T**echnologie  
IoT: **I**nternet of **T**hings  
kW: **k**ilo **W**att  
KWh : **K**ilo**W**att**h**eur**e**  
LPDDR4: **L**ow **P**ower **D**ouble **D**ata **R**ate **4**e génération  
LSTM: **L**ong **S**hort-**T**erm **M**emory  
LXDE: **L**ightweight **X**11 **D**esktop **E**nvironment  
microSD: **m**icro **S**ecure **D**igital  
ML: **M**achine **L**earning  
MTEP: **M**illion de **T**onnes **E**quivalent **P**étrole  
MW: **M**ega **W**att  
NaN : **N**ot a **N**umber  
NLP : **N**atural **L**anguage **P**rocessing  
OS : **O**perating **S**ystem  
PNER: **P**rogramme **N**ational pour les **É**nergies **R**enouvelables  
PV: **P**hoto**V**oltaïques  
RAM : **R**andom **A**ccess **M**emory  
ReLU: **R**ectified **L**inear **U**nits  
RL: **R**einforcement**L**earning  
RMSprop : **R**oot **M**ean **S**quared **P**ropagation  
SBC: **S**ingle **B**oard **C**omputer  
SCADA: **S**upervisory **C**ontrol **A**nd **D**ata **A**cquisition  
SD : **S**ecure **D**igital  
SGD : **S**tochastic **G**radient **D**escent  
SOC : **S**ystem **O**n **C**hip  
SSH : **S**ecure **S**Hell  
STATCOM: **S**TATIC synchronous **C**OMPensators  
STD : **S**Tandard **D**eviation  
TL: **T**ransfer **L**earning  
USB: **U**niversal **S**erial **B**us  
VAR: **V**olt **A**mpère **R**éactif  
VGA: **V**ideo **G**raphics **A**rray  
VNC: **V**irtual **N**etwork **C**omputing  
Wi-Fi: **W**ireless **F**idelity  
Wp: **W**att-**p**ea**k**



## Résumé

La gestion de la consommation d'électricité est d'une importance cruciale tant sur le plan environnemental qu'économique, notamment dans le contexte de la transition vers les énergies renouvelables. Dans ce cadre, ce travail présente une étude approfondie sur l'utilisation de l'intelligence artificielle, et plus particulièrement des algorithmes d'apprentissage profond, pour prédire la consommation et la production d'énergie solaire à partir de données historiques et météorologiques.

Une architecture de réseaux neuronaux a été proposée pour estimer, heure par heure, la consommation électrique ainsi que la production d'un panneau photovoltaïque. L'apprentissage du modèle a été réalisé à partir de séries temporelles, tandis que leur performance a été évaluée à l'aide de métriques telles que l'erreur absolue moyenne (EAM), la racine de l'erreur quadratique moyenne (REQM) et le coefficient de détermination ( $R^2$ ). Les résultats obtenus confirment la capacité du système à effectuer des prévisions fiables et précises.

Afin de démontrer la faisabilité et l'efficacité du système dans un contexte réel, une intégration matérielle a été réalisée sur la plateforme embarquée Raspberry Pi 4B+. Une application complète a été développée, permettant de visualiser les courbes de production et de consommation, d'enregistrer les résultats et de simuler différents scénarios énergétiques. Cette mise en œuvre ouvre la voie à la conception d'un système de gestion énergétique intelligent, capable de prendre des décisions optimales pour basculer entre l'énergie photovoltaïque et le réseau électrique en fonction des prévisions.

Ce travail a été réalisé dans le cadre du projet, intitulé 'Stabilizing weak grids through machine learning: empowering farmers in end-of-line-communities in North Africa through artificial neural networks' SWITCH. Il inscrit dans le cadre de l'appel à la recherche et à l'innovation Europe-Afrique sur les énergies renouvelables, LEAP-RE.

**Mots clés:** Prédiction, Deep Learning, réseaux neuronaux convolutifs, Panneau solaire, Raspberry Pi4B+.

## ملخص

يؤثر استهلاك الكهرباء تأثيرًا كبيرًا على كل من البيئة والتكاليف المرتبطة بتوزيع الطاقة، نظرًا لتأثيره تُعد إدارة استهلاك الكهرباء أمرًا بالغ الأهمية من الناحيتين البيئية والاقتصادية، لا سيما في سياق الانتقال نحو مصادر الطاقة المتجددة. وفي هذا الإطار، يعرض هذا العمل دراسة معمقة لاستخدام الذكاء الاصطناعي، وبشكل خاص خوارزميات التعلم العميق، من أجل التنبؤ باستهلاك وإنتاج الطاقة الشمسية اعتمادًا على البيانات التاريخية والبيانات المناخية.

تم اقتراح بنية من الشبكات العصبية لتقدير استهلاك الكهرباء وكذلك إنتاج الألواح الكهروضوئية على مدار الساعة. وقد تم تدريب النموذج اعتمادًا على سلاسل زمنية، وتم تقييم أدائه باستخدام مؤشرات مثل متوسط الخطأ المطلق ( $MAE$ )، والجذر التربيعي للخطأ المتوسط ( $RMSE$ )، ومعامل التحديد ( $R^2$ ). وتؤكد النتائج المحصل عليها قدرة النظام على تقديم توقعات دقيقة وموثوقة. ولإثبات جدوى النظام وفعاليته في السياق الواقعي، تم تنفيذ التكامل المادي على منصة *Raspberry Pi 4B+*. كما تم تطوير تطبيق كامل يمكن من عرض منحنيات الإنتاج والاستهلاك، وتسجيل النتائج، ومحاكاة سيناريوهات طاقة مختلفة. وتُهد هذه التجربة الطريق لتصميم نظام ذكي لإدارة الطاقة، قادر على اتخاذ قرارات مثالية للتبديل بين الطاقة الشمسية وشبكة الكهرباء استنادًا إلى التوقعات.

**الكلمات المفتاحية :** التنبؤ، التعلم العميق، الشبكات العصبية التلافيفية، *Raspberry Pi 4B+*

### Abstract

Electricity consumption management is of crucial importance both environmentally and economically, especially in the context of the transition to renewable energy sources. In this regard, this work presents a comprehensive study on the use of artificial intelligence, and more specifically deep learning algorithms, to predict solar energy consumption and production based on historical and meteorological data.

A neural network architecture has been proposed to estimate, on an hourly basis, both the electricity consumption and the production of a photovoltaic panel. The model was trained on time series data, and its performance was evaluated using metrics such as Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and the coefficient of determination ( $R^2$ ). The results obtained confirm the system's ability to deliver accurate and reliable forecasts.

To demonstrate the system's feasibility and effectiveness in a real-world context, hardware integration was carried out on the embedded platform Raspberry Pi 4B+. A complete application was developed, allowing visualization of consumption and production curves, recording of results, and simulation of various energy scenarios. This implementation paves the way for the design of an intelligent energy management system capable of making optimal decisions to switch between photovoltaic energy and the power grid based on the predictions.

This work was carried out as part of the SWITCH project entitled 'Stabilizing weak grids through machine learning: empowering farmers in end-of-line-communities in North Africa through artificial neural networks'. It is part of the Europe-Africa call for research and innovation on renewable energies, LEAP-RE.

**Keywords:** Prediction, Deep Learning, Convolutional Neural Networks, Raspberry Pi, Raspberry Pi 4B+.

# Introduction Générale

## Contexte

L'énergie électrique est un élément crucial du développement économique des nations, car toute consommation insuffisante de cette énergie peut entraver la croissance et le développement économique et constituer une menace pour la sécurité des nations. Toutefois, dans le contexte actuel de transition à grande échelle vers les énergies renouvelables, il devient impératif de mieux gérer la production et la consommation d'électricité.

L'Algérie, riche en ressources solaires, présente un potentiel exceptionnel pour le développement de l'énergie photovoltaïque. En raison de son fort ensoleillement annuel, l'intégration de systèmes intelligents de gestion et de prédiction de la production et consommation solaire devient une nécessité pour garantir un usage optimal de l'énergie.

Ce travail s'inscrit dans cette perspective et propose un système de prédiction de la consommation et de la production d'énergie solaire à l'aide de modèles d'apprentissage profond. L'approche repose sur l'analyse de données historiques de consommation ainsi que de données météorologiques pour estimer la production solaire.

## Motivation

L'Algérie bénéficie d'un des plus hauts taux d'irradiation solaire au monde. Ce potentiel solaire permettrait de produire localement une part significative de l'électricité nécessaire pour les besoins des foyers, réduire la dépendance au réseau national, et limiter les coupures en périodes critiques.

De plus, le secteur résidentiel représente près de 40% de la consommation électrique totale du pays. Il est donc essentiel d'optimiser la gestion énergétique à l'échelle domestique, notamment par l'utilisation de technologies d'intelligence artificielle embarquées (Raspberry Pi, Jetson Nano) capables de prédire les besoins et les apports énergétiques.

# Objectifs

Ce projet vise à concevoir un système intelligent de prédiction et de gestion de la consommation et de la production d'énergie solaire domestique. Les principaux objectifs sont :

1. Développer des modèles de prédiction basés sur des réseaux neuronaux convolutifs (CNN) permettant de prévoir, heure par heure, la consommation d'électricité et la production photovoltaïque à partir de données historiques et météorologiques.
2. Intégrer ces modèles sur des dispositifs embarqués tels que le Raspberry Pi et le Jetson Nano pour permettre une exécution en temps réel à la périphérie.
3. Simuler des scénarios de coupures et basculer automatiquement vers une gestion optimale de l'énergie solaire disponible.
4. Concevoir une interface utilisateur conviviale en Python pour visualiser les prédictions, l'historique de consommation/production, et fournir des recommandations d'optimisation.

# Structure

Ce document est structuré en deux grandes parties: **théorique** et **pratique**.

La partie **I** présente trois chapitres :

- Le chapitre **1** introduit les concepts fondamentaux de l'énergie électrique et les enjeux de la transition énergétique.
- Le chapitre **2** explique le fonctionnement des panneaux photovoltaïques, leurs types et les facteurs influençant leur performance. Il aborde aussi les méthodes d'optimisation et les innovations technologiques pour améliorer leur rendement.
- Le chapitre **3** donne un aperçu sur l'intelligence artificielle, le Deep Learning et les architectures de CNN utilisées.

La partie **II** est composée de deux chapitres :

- Le chapitre **4** expose la méthodologie adoptée pour la prédiction, les données utilisées et les métriques d'évaluation. Le chapitre **5** décrit l'environnement de développement (Raspberry Pi), présente les résultats de l'intégration du modèle, détaille l'application développée, l'interface utilisateur, ainsi que les tests de simulation réalisés à partir de scénarios réels.

Enfin, une conclusion générale synthétise les apports et propose des perspectives d'amélioration futures.

Première partie  
Partie Théorique

# Énergies Renouvelables et Hybridation des Sources d'Énergie en Algérie

## Sommaire

---

<b>1.1 Introduction aux énergies renouvelables en Algérie . . . . .</b>	<b>7</b>
1.1.1 Contexte énergétique en Algérie . . . . .	7
1.1.2 Besoin de transition énergétique . . . . .	7
1.1.3 Potentiel des énergies renouvelables . . . . .	8
<b>1.2 L'énergie solaire en Algérie: potentiel et exploitation . . . . .</b>	<b>9</b>
1.2.1 Ressources solaires et ensoleillement . . . . .	9
1.2.2 Projets et infrastructures solaires . . . . .	10
1.2.3 Défis et obstacles au développement du solaire . . . . .	11
<b>1.3 L'énergie conventionnelle en Algérie : situation actuelle et perspectives . . . . .</b>	<b>14</b>
1.3.1 Situation actuelle de la production électrique en Algérie . . . . .	14
1.3.2 Impact économique et environnemental . . . . .	16
1.3.3 Perspectives d'évolution vers un mix énergétique durable . . . . .	17
<b>1.4 Conclusion . . . . .</b>	<b>19</b>

---

## 1.1 Introduction aux énergies renouvelables en Algérie

### 1.1.1 Contexte énergétique en Algérie

En Algérie, la dépendance aux énergies fossiles occupe une place très importante dans le développement économique du pays, notamment le gaz naturel et le pétrole, pour sa production d'électricité. Cette dépendance pose des défis économiques et environnementaux significatifs.

D'un point de vue économique, les hydrocarbures constituent près de 60 % des revenus budgétaires de l'État et 95 % des exportations, ce qui rend l'économie algérienne sensible aux variations des tarifs sur le marché international. Cette circonstance freine la diversification économique et expose le pays à des déséquilibres budgétaires si les prix des hydrocarbures venaient à chuter [4].

D'un point de vue environnemental, l'Algérie se heurte à des enjeux environnementaux majeurs en s'appuyant sur les énergies fossiles, comme le gaz naturel et le pétrole, pour générer son électricité. En 2022, plus de 99 % de l'énergie électrifiée en Algérie était issue de sources fossiles, majoritairement du gaz, ce qui a engendré une intensité carbone de 487,27 gCO<sub>2</sub>eq/kWh. Cela contribue aux émissions de gaz à effet de serre, aggravant ainsi le réchauffement climatique [5].

### 1.1.2 Besoin de transition énergétique

L'Algérie connaît une croissance continue de sa demande énergétique, ayant enregistré une consommation nationale d'énergie de 55 millions de tonnes équivalent pétrole (MTEP) à la fin du mois de septembre 2024, ce qui représente une augmentation de 5 % comparée à l'année précédente. Cette évolution est due à l'augmentation de la population, à l'urbanisation et au progrès industriel [6].

Parallèlement, l'Algérie fait face à d'importants enjeux environnementaux, comme la pollution liée aux activités industrielles, l'érosion des sols et l'expansion du désert. L'ancienneté du parc industriel contribue à la pollution, alors que le climat aride et le manque de ressources en eau aggravent la fragilité écologique du pays [7].

Devant ces défis, il semble impératif de se tourner vers des énergies durables et renouvelables. Un ambitieux programme de développement des énergies renouvelables et d'efficacité énergétique a été initié par le gouvernement algérien, dans l'objectif de diversifier les sources d'énergie et de diminuer la dépendance vis-à-vis des combustibles fossiles.

Le plan révisé pour les énergies renouvelables, comme le montre la Figure 1.1, vise à mettre en place une capacité d'énergie renouvelable d'environ 22 000 MW d'ici 2030 pour

le marché domestique, tout en maintenant l'option d'exportation comme stratégique, si les conditions du marché sont favorables [8].



FIGURE 1.1 – Développement de la production d'énergie fossile par rapport aux énergies renouvelables.

L'augmentation constante de la demande en énergie et les enjeux environnementaux majeurs imposent à l'Algérie de se diriger vers des sources d'énergie plus viables. Les projets actuels illustrent la détermination du pays à surmonter ces défis et à s'orienter vers un développement énergétique davantage en phase avec les impératifs environnementaux.

### 1.1.3 Potentiel des énergies renouvelables

Avec une superficie de 2 381 745 km<sup>2</sup>, l'Algérie détient l'un des gisements solaires les plus importants au monde. Le Sahara algérien bénéficie en moyenne de 3 500 heures d'ensoleillement par an, et ce potentiel pourrait représenter un élément crucial pour le développement durable dans cette région, à condition qu'il soit utilisé de manière rentable. Les possibilités en matière d'éolien, de biomasse et de géothermie, par rapport à celles du solaire, sont considérablement moindres, tandis que le potentiel de l'hydroélectricité est particulièrement faible.

Confrontée à la double problématique de l'épuisement des énergies fossiles et du réchauffement climatique, l'Algérie peut trouver dans les énergies renouvelables une nouvelle option et un avenir rassurant pour sa sécurité énergétique.

Chaque année, l'Algérie reçoit, sur l'ensemble de son territoire (voir la Figure 1.2), l'une des plus fortes quantités d'énergie solaire au monde. Ce potentiel est estimé à environ 5,2 millions de milliards de kWh par an, soit l'équivalent de 430 fois les réserves prouvées en hydrocarbures de l'Algérie et 4,8 fois les réserves mondiales confirmées.

En effet, l'énergie solaire représente en Algérie le potentiel le plus significatif dans le domaine des énergies renouvelables. Elle est évaluée à environ 169,44 TWh/an, soit près de

5 000 fois la consommation nationale d'électricité [9].

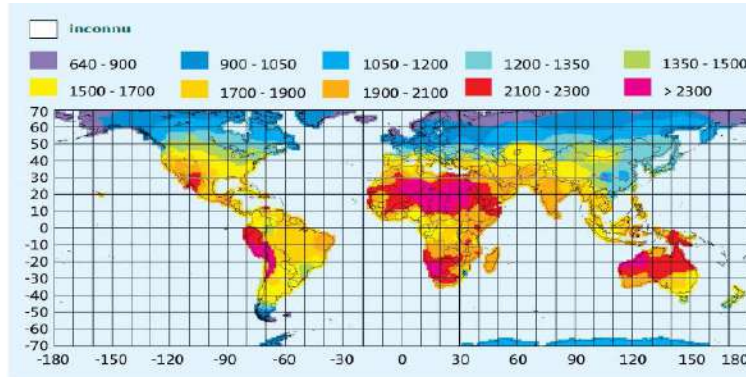


FIGURE 1.2 – Répartition mondiale du rayonnement solaire annuel en kWh/m<sup>2</sup>

## 1.2 L'énergie solaire en Algérie: potentiel et exploitation

### 1.2.1 Ressources solaires et ensoleillement

L'Algérie est considérée comme l'un des pays les plus riches en énergie solaire au monde et dans le bassin méditerranéen, en raison de son climat désertique. Elle bénéficie d'une moyenne annuelle de plus de 3 000 heures d'ensoleillement, pouvant atteindre 3 900 heures dans certaines régions sahariennes. Ce rayonnement représente l'un des indices d'irradiation solaire les plus élevés à l'échelle mondiale, avec une moyenne d'environ 6,57 kWh/m<sup>2</sup>/jour.

Ce potentiel est particulièrement lié à l'étendue du Sahara, qui couvre près de 86 % du territoire national. Ces conditions sont idéales pour le déploiement de Centrales Solaires à Concentration (CSP) et de systèmes photovoltaïques. Les zones les plus ensoleillées, telles qu'Adrar, Tamanrasset et Ghardaïa, sont particulièrement adaptées à des projets solaires de grande envergure.

Ce gisement solaire exceptionnel représente une opportunité majeure pour le développement économique et social du pays. Son exploitation permettrait de réduire la dépendance vis-à-vis des énergies fossiles, de générer des emplois et d'attirer des investissements dans le secteur de l'énergie renouvelable. En outre, la position géographique stratégique de l'Algérie offre la possibilité d'exporter de l'électricité verte vers l'Europe, ce qui renforcerait sa place économique et énergétique dans la région. Le pays participe notamment à l'Initiative industrielle Desertec, qui vise à exploiter les ressources solaires et éoliennes du Sahara pour couvrir jusqu'à 15% de la consommation électrique européenne d'ici 2050. Enfin, le premier Atlas

algérien du gisement solaire, élaboré par le Centre de Développement des Énergies Renouvelables (CDER), met en évidence l'ampleur de ce potentiel et constitue un outil essentiel pour la planification des projets solaires à l'échelle nationale [10].

### 1.2.2 Projets et infrastructures solaires

Plusieurs initiatives solaires à grande échelle ont été mises en place par l'Algérie afin d'exploiter son potentiel solaire remarquable. On peut mentionner parmi ces projets les centrales solaires de Hassi R'Mel et Boughezoul, sans oublier d'autres sites actuellement en phase de développement. L'objectif fixé par le gouvernement algérien est de générer 15 000 MW d'énergie solaire avant 2035. Afin de réaliser cet objectif, Sonelgaz, la société d'État responsable de la production et de la distribution d'électricité en Algérie, a lancé plusieurs appels d'offres.

En février 2023, un appel d'offres initial a été initié pour un projet de 2 000 MW, complété par une seconde sollicitation pour un projet de 1 000 MW, touchant plusieurs wilayas. Ces initiatives comprennent la mise en place de centrales solaires photovoltaïques localisées dans diverses régions du pays. En 2023, le consortium Sonelgaz a conclu 14 accords avec 8 soumissionnaires pour l'établissement de 15 centrales solaires photovoltaïques dotées d'une puissance globale de 2 000 MW. Ces centrales seront distribuées sur 12 wilayas, chacune ayant une capacité individuelle de 80 à 220 MW.

L'Algérie a lancé plusieurs projets solaires majeurs pour concrétiser sa stratégie de transition énergétique tels que:

#### 1. Cinq centrales solaires produisant 780 MW

Le projet majeur englobe cinq centrales solaires, mises en œuvre par un consortium chinois. Voici la répartition de ces installations:

- Batna : 220 MW
- Laghouat (Guelt El Sidi Saad) : 200 MW
- Oued (Douar El Maa) : 200 MW
- Béchar (Al Abadla) : 80 MW
- Ouled Djellal : 80 MW

#### 2. Centrale de Hassi Dallaa située à Laghouat, d'une capacité de 362 MW.

Le second projet, qui se trouve à Hassi Dallaa dans la wilaya de Laghouat, est mené à bien par la société turque Özgün. Avec une puissance de 362 MW, c'est l'une des plus importantes installations solaires actuellement en développement en Algérie. Les travaux, initiés en mars de cette année, avancent vite et l'entrée en opération est attendue pour fin 2025 ou début 2026.

### 3. Centrale d'El Oued

Une centrale de 300 MW, construite par la société chinoise, est aussi située dans la région d'El Oued. Ce projet vient compléter une autre centrale de 200 MW actuellement en développement dans la wilaya proche d'El Meghaïer, soulignant l'importance essentielle de cette région pour la stratégie solaire du pays.

### 4. Centrale de Ouargla

À Ouargla, la construction d'une centrale de 300 MW a été confiée au groupe public algérien Cosider, avec un délai de réalisation estimé entre 12 et 14 mois. Ce projet permettra de satisfaire la demande énergétique grandissante dans cette zone clé.

### 5. Centrale Biskra

En définitive, à Biskra, la société chinoise Power China met en œuvre une centrale de 220 MW. Une fois mise en service, cette installation devrait générer 400 millions de kilowattheures d'énergie propre, ce qui représente un apport considérable pour l'économie locale et nationale.

### 6. Projet Solar 1000

Ce projet vise à construire plusieurs centrales solaires photovoltaïques d'une capacité globale de 1 000 MW, réparties sur cinq wilayas : Béchar, Ouargla, El Oued, Touggourt et Laghouat. La construction des centrales se fera par tranches de 50 à 300 MW chacune comme le montre la Figure 1.3d.

### 7. Première communauté énergétique solaire

Le projet d'un village entièrement alimenté par l'énergie solaire est initié par le ministère de l'Environnement en Algérie. Ce projet, situé dans la wilaya d'Illizi, vise à promouvoir l'utilisation des énergies renouvelables dans les régions éloignées [11].

## 1.2.3 Défis et obstacles au développement du solaire

Bien que l'Algérie bénéficie d'un potentiel solaire remarquable, elle est confrontée à divers obstacles pour la mise en œuvre de l'énergie solaire. Ces enjeux englobent des dimensions économiques, technologiques, environnementales et politiques.

1. **Coût et financement des installations:** Le développement de l'énergie solaire en Algérie, bien que prometteur, se heurte à plusieurs obstacles économiques, notamment en ce qui concerne le coût initial des installations et l'accès au financement.

- **Coût de départ élevé:** Le coût initial des systèmes solaires est toujours considéré comme élevé, requérant des investissements conséquents pour mettre en route les projets. Malgré la diminution des prix des panneaux solaires ces dernières



FIGURE 1.3 – Aperçu de projets solaires emblématiques et initiatives en Algérie

années, le coût global de mise en place — incluant les systèmes de stockage et de transmission — demeure un frein pour les petits intervenants locaux.

- Investissements et financement L'obtention de fonds pour les projets solaires nécessite des investissements considérables, un défi majeur pour les acteurs locaux de petite taille. Des systèmes de financement ont été instaurés par le gouvernement algérien pour soutenir les initiatives solaires ; toutefois, l'accès aux crédits demeure difficile pour les entreprises locales.

2. **Technologie de stockage et intermittence** : l'intégration de l'énergie solaire à grande échelle soulève des défis techniques importants, en particulier concernant le stockage de l'énergie et la stabilité du réseau électrique. Ces aspects nécessitent des solutions technologiques avancées et des investissements ciblés.

- Technologies de stockage: Pour gérer efficacement l'énergie solaire, il est crucial de disposer de technologies de stockage performantes, capables de conserver l'énergie excédentaire. Cela représente toujours un défi, tant sur le plan technologique que financier. Les batteries lithium-ion sont fréquemment utilisées; toutefois, leur coût reste élevé et leur disponibilité peut parfois être limitée.
- Instabilité et stabilisation du réseau : la nature intermittente de l'énergie solaire

exige la mise en place de mesures pour garantir la stabilité du réseau électrique. Cela inclut l'installation de STATic synchronous COMPensators (STATCOM), dispositifs assurant la compensation de puissance réactive (mesurée en VAR), aux points stratégiques du réseau, ainsi que l'intégration de batteries à flux redox au vanadium.

3. **Manque d'infrastructures adaptées** : le développement des énergies renouvelables en Algérie est également freiné par l'absence d'infrastructures adaptées, tant sur le plan de la distribution que de la production locale des équipements.

- Écart entre les centres de demande et d'approvisionnement : l'écart entre les centres de demande situés au nord et les zones de production d'énergie renouvelable localisées au sud représente un défi significatif. L'intégration de l'énergie solaire dans le réseau national, via la construction d'infrastructures électriques adaptées, engendre des coûts élevés.
- Dépendance aux importations: La forte dépendance à l'importation d'équipements solaires en Algérie continue de freiner le développement du secteur. Toutefois, des efforts sont actuellement en cours pour renforcer les capacités locales de montage des modules solaires.

4. **Cadre de réglementation et politique**

Le développement des énergies renouvelables en Algérie est encadré par un dispositif juridique en constante évolution. Cependant, certains aspects réglementaires et politiques continuent de poser des obstacles à l'investissement et à la mise en œuvre efficace des projets.

- Normes légales: le cadre légal pour les énergies renouvelables en Algérie est actuellement en phase d'amélioration; cependant, des ambiguïtés juridiques subsistent et peuvent dissuader les investisseurs internationaux.
- Engagement politique: dans le passé, l'absence d'un engagement politique véritable en faveur de la transition énergétique a entravé la progression des énergies renouvelables. Toutefois, le gouvernement a récemment réaffirmé sa détermination à atteindre les objectifs établis.

5. **Défis environnementaux et sociaux**

Malgré les avantages de l'énergie solaire, certains défis environnementaux et sociaux subsistent. Ils doivent être pris en compte pour garantir une transition énergétique durable et équitable.

- Conséquences environnementales : Même si l'énergie solaire est considérée comme une énergie propre, la mise en place de vastes centrales solaires peut entraîner des répercussions sur l'environnement, notamment en ce qui concerne la biodiversité et l'exploitation des sols.
- Acceptation sociale : L'acceptation des projets solaires peut varier selon les régions, avec des inquiétudes locales relatives à leur effet sur l'agriculture et l'occupation des sols. Ces enjeux mettent en évidence le besoin d'une approche intégrée pour favoriser l'expansion du solaire en Algérie, incluant des collaborations internationales pour attirer des financements et des technologies de pointe

## 1.3 L'énergie conventionnelle en Algérie : situation actuelle et perspectives

Le réseau électrique algérien est très largement alimenté par des centrales fonctionnant au gaz naturel et au pétrole, ce qui rend le pays fortement dépendant de ses ressources fossiles.

### 1.3.1 Situation actuelle de la production électrique en Algérie


Le mix énergétique de l'Algérie repose quasi exclusivement sur les énergies fossiles. En 2023, 99,23 % de la production électrique provenait de sources fossiles, dont 95, % à partir du seul gaz naturel. Cette dépendance extrême est illustrée dans la Figure 1.4a, qui montre l'évolution de la production à partir du gaz naturel depuis les années 2000.

Selon le classement mondial, l'Algérie se situe à la 178<sup>e</sup> position en termes de part d'énergies bas-carbone dans la production d'électricité, avec à peine 0,8 % issue de sources renouvelables ou nucléaires.

En 2019, la situation était similaire, avec 99 % de la production électrique issue de centrales thermiques, principalement à gaz. L'hydraulique ne représentait alors que 0,2 %, tandis que l'énergie éolienne et solaire avaient une contribution négligeable. L'évolution de ces sources secondaires est représentée dans la Figure 1.4b.

En 2019, la production totale d'énergie électrique s'élevait à 81,5 TWh. Cette consommation se répartissait principalement entre le secteur résidentiel (33 %), l'industrie (27 %) et le secteur commercial (14 %).

Entre 2019 et 2023, l'économie algérienne est restée fortement dépendante des hydrocarbures, représentant 47 % des revenus budgétaires et 86 % des recettes d'exportation. Cette situation est illustrée par les courbes de la Figure 1.4a et la stagnation des autres sources visibles dans la Figure 1.4b.



(a) Dépendance à l'énergie produite à partir du gaz naturel

(b) Évolution des autres sources : hydraulique, éolien, solaire, pétrole

FIGURE 1.4 – Comparaison de l'évolution de la production d'électricité en Algérie

La quasi-absence d'énergie décarbonée aggrave l'empreinte écologique du pays, en raison des émissions massives de gaz à effet de serre. Il devient donc impératif d'accélérer la transition vers des sources plus durables, afin de réduire les impacts du changement climatique et de la pollution atmosphérique.

### 1.3.1.1 Conséquences de cette dépendance fossile

Les effets de la dépendance de l'Algérie aux énergies fossiles se manifestent sur plusieurs plans:

- **Vulnérabilité économique** : les variations du coût du pétrole et du gaz sur les marchés mondiaux influencent directement le budget public. Par exemple, les revenus énergétiques ont chuté de 58 milliards de dollars en 2014 à seulement 22 milliards en 2016 à cause de la baisse des prix [12].
- **Enjeux environnementaux** : la production d'électricité en Algérie émet 487,27 gCO<sub>2</sub>éq par kWh, classant ainsi le pays à la 134<sup>e</sup> place mondiale en matière d'intensité carbone [5].
- **Gaspillage énergétique** : les subventions appliquées aux prix de l'énergie en Algérie participent à une surconsommation structurelle. Le coût particulièrement bas de l'énergie par rapport aux pays voisins dissuade les consommateurs d'adopter des pratiques de sobriété énergétique.

### 1.3.2 Impact économique et environnemental

En Algérie, l'utilisation massive des énergies fossiles a des répercussions économiques et environnementales significatives.

- **Impact économique** : l'économie algérienne, en raison de sa dépendance aux hydrocarbures, est exposée aux fluctuations des prix sur les marchés internationaux. Par exemple, en 2020, les revenus liés aux hydrocarbures se sont élevés à 5 milliards de dollars, soit un milliard de moins que les prévisions initiales. Cette baisse s'explique par la diminution de la demande mondiale et l'effondrement des prix du pétrole.
- **Impact environnemental** : les émissions de dioxyde de carbone (CO<sub>2</sub>) en Algérie ont connu une hausse significative au fil des années, principalement à cause de l'utilisation intensive des énergies fossiles. En 2022, les émissions liées à la combustion des énergies fossiles étaient estimées à environ 184,6 millions de tonnes, avec une légère baisse de 3,5% en 2023, où elles ont atteint 178,1 millions de tonnes. L'évolution des émissions annuelles de CO<sub>2</sub> est présentée dans la Figure 1.5.




FIGURE 1.5 – Évolution des émissions annuelles de CO<sub>2</sub> en Algérie (1965–2023)

Cela représente environ 3,9 tonnes de CO<sub>2</sub> par habitant. Le secteur de l'énergie est le principal contributeur à ces émissions, représentant une part importante des gaz à effet de serre en Algérie. la Figure 1.6 illustre cette tendance.

En Algérie, l'utilisation massive des énergies fossiles a des répercussions économique et environnementale significatives.

- **Impact économique** : l'économie algérienne, en raison de sa dépendance à l'égard des hydrocarbures, est exposée aux variations des tarifs sur le marché international.

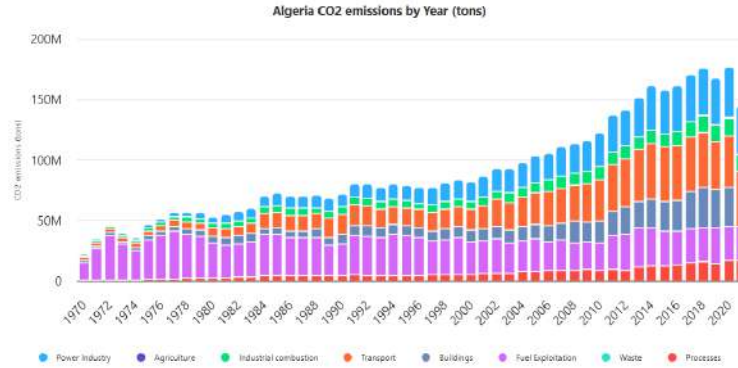


FIGURE 1.6 – Évolution des émissions de CO<sub>2</sub> en Algérie par secteur

Par exemple, en 2020, les revenus liés aux hydrocarbures se sont élevés à 5 milliards de Dollars, ce qui représente un milliard de moins que les attentes initiales, du fait de la diminution de la demande mondiale et de l'effondrement des prix du pétrole.

- **Impact environnemental:** en Algérie, les émissions de dioxyde de carbone (CO<sub>2</sub>) ont connu une hausse significative au fil des années, principalement à cause de l'utilisation intensive des sources d'énergie fossiles. On estimait qu'en 2022, les émissions de CO<sub>2</sub> provenant de la combustion des énergies fossiles s'élevaient à environ 177 millions de tonnes (voir la Figure 1.6), ce qui représente une modeste baisse de 0,96 % par rapport à l'année précédente. Ceci équivaut à approximativement 3,89 tonnes de CO<sub>2</sub> par individu.

### 1.3.3 Perspectives d'évolution vers un mix énergétique durable

Afin de diminuer son recours aux énergies fossiles, l'Algérie envisage des approches de transition énergétique qui favorisent une plus grande intégration des énergies renouvelables dans son ensemble énergétique. L'objectif du gouvernement algérien est de produire 15 000 MW d'énergie renouvelable avant 2035, visant à augmenter la proportion des énergies renouvelables à 30% dans le mélange énergétique national.

#### 1. Objectifs et approches stratégiques

- **Programme National pour les Énergies Renouvelables (PNER):** l'objectif de ce programme est d'implanter une capacité de 15 000 MW d'énergies renouvelables d'ici à 2035, en mettant l'accent sur le solaire et l'éolien. Plusieurs initiatives solaires de grande envergure ont déjà été initiées par l'Algérie, en particulier dans les zones d'Adrar, Tamanrasset et Ghardaïa.

Comme l'illustre la Figure 1.7, une progression régulière des capacités installées est prévue jusqu'au 2030, avec une montée en puissance marquée des projets solaires.




FIGURE 1.7 – Programme National pour les Énergies Renouvelables (PNER)

- **Actions visant à diminuer les émissions de CO<sub>2</sub>**: l'Algérie a pris l'engagement de diminuer ses émissions de CO<sub>2</sub> en favorisant l'efficacité énergétique et en développant les sources d'énergie renouvelables. Un programme d'efficacité énergétique cherche à diminuer la consommation d'énergie et à minimiser les émissions de CO<sub>2</sub>.
- **Élaboration de l'hydrogène vert** : l'Algérie envisage aussi le développement de l'hydrogène vert en tant que stratégie pour diversifier son mélange énergétique. Ce projet envisage de produire de l'hydrogène vert à partir d'énergies solaires et de le transporter vers l'Europe par le biais d'un gazoduc spécifique.

## 2. Interconnexions énergétiques

L'amélioration des liaisons électriques en Algérie et avec l'Europe sera essentielle pour accélérer la transition énergétique. L'intégration massive des énergies renouvelables sera possible grâce au projet d'interconnexion du réseau électrique du Sud algérien avec le réseau national. De plus, cela offrira des opportunités d'exportation vers l'Europe.

## 3. Défis et stratégies pour un mix énergétique durable

Pour un mix énergétique durable en Algérie, la transition énergétique requiert des modèles prospectifs qui englobent la diversification des sources d'énergie et l'optimisation de l'efficacité énergétique. Dans le cadre de ses efforts globaux pour un développement durable, l'Algérie a élaboré des stratégies visant à assurer une transition énergétique durable pour les générations à venir.

En définitive, l'augmentation de la demande énergétique et la préservation de l'environnement rendent indispensable la transformation du modèle énergétique actuel de l'Algérie. Il est essentiel de se diriger vers un mélange énergétique plus varié et durable pour garantir un développement économique et social durable sur le long terme.

## 1.4 Conclusion

L'Algérie est à un point crucial de son évolution énergétique. Bien qu'elle ait l'un des potentiels solaires les plus importants au monde, elle reste fortement dépendante des énergies fossiles et fait face à une demande énergétique en augmentation. Ce chapitre a mis en évidence les défis économiques et environnementaux associés à cette situation, tout en mettant en relief les possibilités qu'offrent les énergies renouvelables. Les efforts actuellement déployés, bien qu'encourageants, mettent en lumière le besoin d'un soutien structurel accru: investissements, avancées technologiques, infrastructures contemporaines et cadre législatif ajusté. Il est non seulement possible, mais essentiel de mettre en place une transition énergétique durable en Algérie.

# Les Panneaux Photovoltaïques: Principe et Technologie

## Sommaire

---

<b>2.1</b>	<b>Introduction</b>	<b>21</b>
<b>2.2</b>	<b>Principes de fonctionnement des panneaux photovoltaïques</b>	<b>21</b>
2.2.1	Effet photovoltaïque	21
2.2.2	Structure d'une cellule photovoltaïque	22
<b>2.3</b>	<b>Types de panneaux photovoltaïques</b>	<b>23</b>
2.3.1	Panneaux monocristallins	23
2.3.2	Panneaux polycristallins	25
2.3.3	Panneaux à couches minces	26
<b>2.4</b>	<b>Facteurs influant sur la performance des panneaux photovoltaïques</b>	<b>28</b>
2.4.1	Innovations pour améliorer l'efficacité	35
<b>2.5</b>	<b>Conclusion</b>	<b>35</b>

---

## 2.1 Introduction

L'adoption de sources d'énergie écologiques est désormais un élément crucial dans la lutte contre le changement climatique, la diminution de la dépendance aux énergies fossiles et la promotion du développement durable. Parmi ces sources d'énergie renouvelables, l'énergie solaire se distingue par sa flexibilité et son abondance. Cependant, à mesure que l'utilisation de l'énergie solaire se généralise, il devient crucial de garantir son bon fonctionnement. En matière d'énergie solaire, l'efficacité énergétique consiste à maximiser l'utilisation des systèmes tout en minimisant le gaspillage d'énergie. Prioriser l'économie d'énergie non seulement optimise le fonctionnement des installations solaires, mais permet également de réduire les coûts, d'augmenter leur fiabilité et de protéger l'environnement. Cette section détaille en profondeur les différents domaines de l'efficacité énergétique dans le solaire. La conception et la sélection des systèmes PhotoVoltaïques (PV) constituent les premières étapes vers une efficacité énergétique dans le domaine de l'énergie solaire. C'est parce que l'efficacité des panneaux solaires est un élément crucial pour juger de la performance globale du système. Le silicium cristallin, qui est plus performant que d'autres matériaux tels que les technologies à couches mince, est le matériau principal utilisé pour la fabrication des panneaux solaires modernes. L'efficacité de conversion d'énergie, qui décrit la quantité d'énergie solaire qu'un panneau peut transformer en énergie utilisable, est ce qu'on appelle son efficacité de conversion [13].

## 2.2 Principes de fonctionnement des panneaux photovoltaïques

Cette section explique le mécanisme physique sous-jacent au fonctionnement des panneaux solaires.

### 2.2.1 Effet photovoltaïque

La Figure 2.1 illustre le phénomène physique de l'effet photovoltaïque permet la transformation directe de la lumière en énergie électrique grâce à des matériaux semi-conducteurs. Lorsqu'un photon issu du rayonnement solaire pénètre dans la cellule, il est absorbé dans la zone de type n, ce qui entraîne l'excitation d'un électron depuis la bande de valence ( $E_v$ ) vers la bande de conduction ( $E_c$ ). Cette transition crée une paire électron-trou.

La cellule est composée de différentes couches dopées: une couche de type p (riche en trous), une couche de type n (riche en électrons), et parfois une fine couche  $n^+$  pour améliorer la collecte des électrons. Le champ électrique interne généré à la jonction p-n sépare les

porteurs de charge: les électrons sont dirigés vers la face arrière (H) tandis que les trous se déplacent vers la face avant (B).

Les électrons extraits à l'arrière peuvent alors circuler à travers un circuit externe, produisant un courant électrique. En parallèle, les trous rejoignent les électrons restitués à la face avant, assurant ainsi la continuité du courant.

Une partie de l'énergie des porteurs excités est perdue sous forme de chaleur, un phénomène appelé thermalisation. Finalement, le courant continu produit peut être converti en courant alternatif pour alimenter des appareils ou être injecté dans le réseau électrique. [14]. 2.1




FIGURE 2.1 – L'effet photovoltaïque

### 2.2.2 Structure d'une cellule photovoltaïque

1. **Semi-conducteur** : la partie centrale de la cellule est composée de matériaux semi-conducteurs, généralement du silicium. Ces semi-conducteurs sont dopés pour créer deux zones distinctes:

La conversion photovoltaïque, mise au jour par Antoine BECQUEREL (1839), constitue la seule méthode identifiée permettant de transformer directement la lumière en énergie électrique. L'exposition du matériau semi-conducteur (Silicium) à la lumière solaire provoque la génération de multiples paires d'électrons et de trous (transporteurs). Ces charges sont par la suite séparées par le champ électrique à la jonction PN, puis elles se déplacent vers les connexions électriques appropriées. On observe une différence de potentiel entre les deux connexions, approximativement de 0,5 V. Si l'on branche une charge sur les bornes de cette cellule, un courant électrique s'écoule.

2. **Contact électrique** :

- **Contact avant**

Une matrice métallique conductrice (habituellement en argent) est appliquée sur

la surface avant afin de recueillir les électrons. La conception de la grille étai à réduire l'ombre tout en maximisant la conductivité.

- **Contact arrière**

Une couche métallique continue (souvent en aluminium) est utilisée pour collecter les trous et former le contact arrière [15].

### 3. couches antireflet

Les panneaux solaires possèdent des couches antireflet afin d'optimiser l'absorption de la lumière du soleil par les cellules. Ces strates, habituellement constituées de matériaux multicouches de silice et d'oxyde de titane, diminuent la réverbération lumineuse et par conséquent optimisent l'efficacité générale du panneau [16].

## 2.3 Types de panneaux photovoltaïques

On distingue plusieurs types de panneaux photovoltaïques, chacun ayant ses propres caractéristiques. Les sections suivantes les présentent de manière détaillée.

### 2.3.1 Panneaux monocristallins

La Figure 2.2 un panneau monocristallin représentant l'une des technologies les plus abouties dans le domaine photovoltaïque. Issus d'un seul cristal de silicium, ils offrent une structure homogène assurant un rendement énergétique élevé. Grâce à leur efficacité, leur longévité et leur esthétique noire élégante, ils sont souvent considérés comme une solution haut de gamme pour les installations solaires.



FIGURE 2.2 – Panneaux monocristallins

#### 2.3.1.1 Caractéristiques principales

Voici les principales caractéristiques qui distinguent les panneaux monocristallins:

- Fabrication: Réalisés à partir de silicium monocristallin obtenu par la méthode de Czochralski, les lingots sont découpés en fines tranches (« wafers ») formant les cellules solaires.
- Efficacité: Leur rendement varie entre 16 % et 24 %, grâce à la pureté du matériau qui facilite la circulation des électrons.
- Esthétique: De couleur noire uniforme, ils sont prisés pour leur apparence moderne et discrète, adaptée aux bâtiments résidentiels et commerciaux.
- Puissance: Ces panneaux produisent généralement entre 300 et 500 Wp, et conservent une bonne performance même en conditions difficiles.

### 2.3.1.2 Avantages

Les panneaux monocristallins offrent plusieurs avantages qui expliquent leur large utilisation dans les systèmes solaires.

- Haut rendement: Leur efficacité permet de générer plus d'énergie sur une surface réduite.
- Longévité: Avec une durée de vie estimée entre 25 et 40 ans, ils résistent bien aux conditions climatiques extrêmes.
- Bonne performance par faible luminosité: Efficaces même en cas de faible ensoleillement ou par temps nuageux.
- Gain d'espace: Moins de panneaux sont nécessaires pour atteindre une production donnée.
- Design moderne: Leur apparence uniforme et élégante est souvent recherchée dans les projets haut de gamme.

### 2.3.1.3 Inconvénients

Malgré leurs nombreux avantages, les panneaux monocristallins présentent aussi certains inconvénients qu'il est important de connaître.

- Coût élevé: Leur fabrication implique un investissement initial plus important.
- Déchets de production: Le découpage des lingots génère des pertes de matière et des coûts supplémentaires.
- Sensibles à la chaleur: Leur rendement diminue légèrement à température élevée.
- Fragilité: Leur structure cristalline nécessite une manipulation précautionneuse.

#### 2.3.1.4 Applications

Les panneaux monocristallins sont idéals pour les installations nécessitant un rendement élevé ou un espace limité:

- Toits de maisons à surface restreinte
- Zones à faible ensoleillement ou conditions climatiques rudes
- Projets intégrant des exigences esthétiques (façades, bâtiments modernes) [17]

### 2.3.2 Panneaux polycristallins

La Figure 2.3 un panneau polycristallin, une autre catégorie de panneaux solaires, connus pour être moins chers et faciles à fabriquer.



FIGURE 2.3 – Panneaux polycristallins

#### 2.3.2.1 Caractéristiques des panneaux polycristallins

Les panneaux polycristallins possèdent plusieurs caractéristiques distinctives:

- Fabrication simple: silicium fondu qui forme plusieurs cristaux, rendant le procédé moins coûteux.
- Rendement entre 14 % et 18 %, légèrement inférieur aux monocristallins à cause des jonctions cristallines.
- Apparence bleutée avec texture marbrée due à la structure multicristalline.
- Durée de vie moyenne de 25 à 30 ans, adaptée à de nombreuses installations.

#### 2.3.2.2 Avantages

Les panneaux polycristallins présentent plusieurs avantages qui les rendent attractifs pour différentes applications solaires.

- Coût réduit: Leur fabrication plus simple entraîne un coût de production plus bas, rendant ces panneaux plus accessibles financièrement.
- Faible impact environnemental: Le processus de fabrication génère moins de déchets de silicium, ce qui limite leur empreinte écologique.
- Bonne stabilité thermique: Ils présentent une bonne tolérance aux températures élevées, ce qui leur permet de maintenir des performances stables dans les climats chauds.
- Installation variée: Ces panneaux conviennent à une large gamme d'applications, allant des systèmes résidentiels aux installations industrielles.

### 2.3.2.3 Inconvénients

Malgré leurs atouts, les panneaux polycristallins comportent aussi certains inconvénients à considérer.

- Rendement inférieur: Comparés aux monocristallins, leur efficacité est généralement plus faible, ce qui nécessite plus de surface pour produire la même quantité d'énergie.
- Durée de vie légèrement réduite: Leur espérance de vie est en général plus courte que celle des panneaux monocristallins.
- Esthétique moins homogène: Leur apparence bleutée avec des reflets irréguliers est souvent jugée moins élégante, surtout pour les installations architecturales.

### 2.3.2.4 Applications

Les panneaux polycristallins sont bien adaptés aux projets où le rapport coût-efficacité est prioritaire. Ils sont notamment utilisés dans:

- Les fermes solaires à grande échelle ;
- Les installations industrielles nécessitant une forte production d'énergie ;
- Les projets résidentiels avec un budget limité ;
- Les régions où la surface disponible n'est pas un facteur contraignant [15].

## 2.3.3 Panneaux à couches minces

Les panneaux à couches minces sont une technologie solaire légère et flexible, adaptée à divers types de surfaces et d'applications(voir la Figure 2.4).




FIGURE 2.4 – Panneau à couches minces

### 2.3.3.1 Caractéristiques des panneaux à couches minces

Les principales caractéristiques des panneaux à couches minces leur confèrent une grande adaptabilité et une conception unique.

- Structure fine : Constitués de couches semi-conductrices très minces déposées sur du verre, du plastique ou du métal.
- Flexibilité: Adaptés aux surfaces courbes ou non rigides grâce à leur souplesse.
- Légèreté: Leur poids réduit facilite l'installation et le transport.
- Installation polyvalente: Utilisables sur divers supports, y compris mobiles ou intégrés à l'architecture.

### 2.3.3.2 Avantages

Les panneaux à couches minces offrent plusieurs avantages qui les rendent utiles dans de nombreuses situations.

- Coût de fabrication réduit: Leur production nécessite moins de matière première et des procédés moins énergivores.
- Légèreté et souplesse: Leur structure fine permet une installation facile sur des surfaces courbes ou non conventionnelles.
- Performance par faible luminosité: Ils conservent une efficacité raisonnable même en cas de faible ensoleillement ou d'ombre partielle.
- Esthétique uniforme: Leur apparence homogène est souvent appréciée pour les intégrations architecturales.

### 2.3.3.3 Inconvénients

Bien qu'efficaces dans certains cas, les panneaux à couches minces présentent quelques inconvénients qu'il convient de connaître.

- Rendement plus faible: Leur efficacité est généralement inférieure à celle des panneaux cristallins (entre 10 % et 13 %).
- Durée de vie plus courte: Ces panneaux ont une longévité inférieure et peuvent se dégrader plus rapidement dans le temps.
- Surface requise plus grande: Pour une même puissance, ils nécessitent plus d'espace d'installation.

#### 2.3.3.4 Applications

Grâce à leur flexibilité et leur faible poids, les panneaux à couches minces sont utilisés dans:

- Les bâtiments aux surfaces irrégulières ou mobiles (toitures incurvées, façades vitrées, véhicules) ;
- Les petits dispositifs électroniques ou portables ;
- Les projets nécessitant une intégration esthétique discrète.

#### 2.3.3.5 Technologies utilisées

Plusieurs matériaux et technologies sont employés pour fabriquer les panneaux photovoltaïques à couches minces, chacun avec ses spécificités.

- CdTe (Cadmium Telluride): est une technologie à couche mince offrant un bon rendement (plus de 18 %) à faible coût, avec une bonne résistance aux conditions climatiques.
- CIGS (Cuivre-Indium-Gallium-Sélénium): Les panneaux CIGS sont flexibles, efficaces entre 10 % et 15 %, et performants même en faible luminosité.
- Silicium Amorphe: est utilisé pour des applications flexibles et portables, avec un rendement moindre mais un coût de production faible.

## 2.4 Facteurs influant sur la performance des panneaux photovoltaïques

### 1. Conditions météorologiques

- **Rayonnement solaire** : plus l'irradiance solaire est forte , plus la quantité d'électricité produite est grande . Une exposition idéale au soleil optimise la productivité toutefois, les fluctuation saisonnières et la présence de nuage, la pluie ou




FIGURE 2.5 – L’effet de rayonnement solaire sur les panneaux photovoltaïques

les tempêtes diminuent la quantité d’énergie captée par le panneau solaire (voir la Figure 2.5).

- **Température** : la performance et la longévité des panneaux solaires en silicium cristallin sont considérablement influencées par leur température de fonctionnement. L’efficacité énergétique diminue avec la montée de la température, perdant entre 0,3% et 0,5% pour chaque degré Celsius au-dessus de 25°C. Cela peut aussi accélérer la détérioration des matériaux, ce qui influence la durabilité des modules. Dans des situations concrètes, particulièrement dans les zones de chaleur [18] (voir la Figure 2.6).




FIGURE 2.6 – L’effet de température sur photovoltaïques

- **Ombre**: l’ombre influence de manière importante la performance des panneaux solaires. La présence d’obstacles tels que les arbres, les immeubles ou la poussière qui causent une ombre partielle peut significativement diminuer la génération d’énergie en engendrant des zones de chaleur (hot spots) et en perturbant le courant dans les cellules photovoltaïques reliées en série. Selon les auteurs, même une zone ombragée minime peut provoquer une chute disproportionnée de la puissance de sortie, étant donné que les cellules ombragées restreignent le flux de courant dans l’ensemble du circuit. Pour minimiser ces impacts, on fait appel à des diodes de dérivation, des micro-onduleurs ou des optimisateurs de performance,

qui aident à esquisser les cellules touchées et à optimiser la production énergétique. Il est également crucial d'optimiser les performances des systèmes photovoltaïques par une planification rigoureuse lors de l'installation, afin de réduire au maximum les ombres potentielles [19](voir la Figure 2.7).



FIGURE 2.7 – ombrage

- **Poussière:** On a établi la poussière avec des densités de couverture de  $10\text{g}/\text{m}^2$ ,  $20\text{g}/\text{m}^2$  et  $30\text{g}/\text{m}^2$  sur les trois surfaces photovoltaïques respectivement. En modifiant la résistance de la boîte de résistance variable, on obtient le courant correspondant sous différentes pressions partielles de PV. Comme illustré à la Figure 2.8, on remarque que la présence de poussière entraîne une baisse drastique du rendement des cellules photovoltaïques, et la poussière ayant une densité de  $10\text{ g}/\text{m}^2$  provoque une diminution d'environ 26% du courant de court-circuit et d'environ 12% de la tension en circuit ouvert. Cela indique que la poussière a un impact plus important sur le courant de court-circuit photovoltaïque et un impact moindre sur la tension en circuit ouvert. Il est à souligner que l'accroissement de la densité de poussière réduit l'amplitude du courant de court-circuit et de la tension en circuit ouvert, ce qui indique que la poussière a le plus grand impact sur les performances de production d'énergie photovoltaïque lors de la phase initiale d'accumulation de poussière. À ce stade, le nettoyage de la poussière sur la surface PV a l'effet le plus évident

Comme le montre la Figure 2.9, une densité de poussière de  $10\text{ g}/\text{m}^2$  diminue d'environ 34% la puissance maximale du PV, et plus la densité de la poussière est élevée, plus la puissance maximale du PV décroît. De plus, à mesure que la densité de poussière augmente, le pic de puissance se déplace progressivement vers la gauche, ce qui signifie que la valeur du voltage et du courant de la puissance maximale délivrée par le PV diminue progressivement

Comme illustré la Figure 2.10 lorsque la densité de poussière sur la surface photovoltaïque atteint  $10\text{g}/\text{m}^2$ , l'efficacité de conversion diminue considérablement, avec une






FIGURE 2.8 – Courbe P-U du PV sous différentes densités de poussière

FIGURE 2.9 – courbe  $\rho - \eta$ 

réduction de 30% . en procédant a un ajustement numérique de la densité de poussière et de l'efficacité de conversion , on a constate qu'il existe une meilleure corrélation non linéaire entre ces deux variable . l'efficacité de conversion des cellules photovoltaïque tend a diminuer progressivement avec l'accroissement de la densité de poussière, mais cette diminution s'estompe peu a peu. Lorsque la densité de poussière atteint un certain seuil ( $70\text{g/m}^2$ ) , l'efficacité de conversion tend a se stabiliser

FIGURE 2.10 –  $\rho - FF$  curve

La Figure 2.11 illustre l'impact sur le facteur de forme (FF) à différentes densités de poussière. Lorsque la densité de poussière des panneaux photovoltaïques atteint  $10\text{g/m}^2$ , FF diminue d'environ 3%. Plus la densité de poussière augmente, plus le facteur de forme (FF) diminue. Lorsque la densité de poussière passe de  $10\text{g/m}^2$  à  $40\text{g/m}^2$ ,

la diminution du facteur de forme (FF) est la plus importante. Lorsque la densité de poussière atteint 60g/m<sup>2</sup>, la valeur de FF tend à se stabiliser progressivement à un niveau constant, indiquant que l'impact de la poussière sur le FF est à son maximum.




FIGURE 2.11 – Courbe  $\rho - FF$

La présence de poussière diminue l'efficacité des panneaux solaires en obstruant une partie des rayons solaires, ce qui réduit la quantité d'énergie disponible pour le processus de conversion photovoltaïque. Ceci entraîne une réduction du courant de court-circuit ( $I_{sc}$ ) et de la puissance maximale ( $P_{max}$ ), ce qui affecte directement l'efficacité de conversion ( $\eta$ ). Cette efficacité est définie mathématiquement par L'Équation(2.1):

$$\eta = \frac{P_{max}}{A_{py} \times G_i} = \frac{FF \times V_{oc} \times I_{sc}}{A_{py} \times G_i} \quad (2.1)$$

- $\eta$ : Rendement de conversion du panneau photovoltaïque (sans unité, souvent exprimé en %).
- $P_{max}$ : Puissance maximale délivrée par le panneau (en watts, W).
- $A_{py}$ : Surface utile du panneau photovoltaïque (en mètres carrés, m<sup>2</sup>).
- $G_i$ : Irradiance solaire incidente sur le panneau (en watts par mètre carré, W/m<sup>2</sup>).
- $FF$ : Facteur de forme (*Fill Factor*).
- $V_{oc}$ : Tension en circuit ouvert (en volts, V).
- $I_{sc}$ : Courant de court-circuit (en ampères, A).

## 2. Orientation et inclinaison des panneaux

L'optimisation de l'efficacité énergétique des panneaux solaires dépend de leur orientation et inclinaison. Dans l'hémisphère nord, il est généralement conseillé de s'orienter plein sud comme le montre la Figure 2.12 pour bénéficier d'un maximum de lumière solaire durant toute la journée. En termes d'inclinaison, il est généralement recommandé de viser un angle situé entre 30° et 35° pour optimiser la production énergétique annuelle [20](voir la Figure 2.13).




FIGURE 2.12 – La meilleure orientation




FIGURE 2.13 – La meilleure inclinaison

- **Effet sur le rendement** : une orientation ou une inclinaison incorrectes peuvent conduire à des pertes considérables de rendement. Par exemple, une inclinaison trop élevée ou faible par rapport à l'angle idéal peut réduire la performance de la conversion de l'énergie solaire. Par ailleurs, une orientation éloignée du sud peut causer des pertes supplémentaires, il est donc crucial de définir avec exactitude ces paramètres afin d'optimiser la production d'énergie électrique.
- **Méthodes d'optimisation** :

### 1. Ajustement saisonnier de l'inclinaison

L'inclinaison d'un panneau solaire influence directement sur la quantité de lumière qu'il capte, qui varie chaque saison. Ajuster l'inclinaison des panneaux solaires en fonction des saisons afin de s'adapter à la trajectoire du soleil et maximiser l'exposition.

### 2. Utilisation de trackers solaires

Les systèmes de suivi solaire ajustent automatiquement l'orientation et l'inclinaison des panneaux solaires pour se synchroniser avec le mouvement du soleil, ce qui optimise la production d'énergie solaire (voir la Figure 2.14).




FIGURE 2.14 – Trackers solaires

3. **Dégradation et durée de vie** : l'espérance de vie des panneaux solaires est cruciale pour garantir la rentabilité et l'efficacité d'une installation photovoltaïque. gé-

néralement , ces panneaux ont une durée de vie de 20 a 30 ans , même si leur efficacité peut s'affaiblir graduellement au fil du temps . plusieurs facteurs influencent sur la durée de vie , et des mesures préventives peuvent être adoptées pour réduire leur de détérioration

- **Les facteurs influençant la longévité des panneaux solaire**

- (a) **La qualité des matériaux et la conception**

les panneaux solaires fabriqués avec des matériaux durables et de haute qualité dans leur conception. L'intégration des composants notamment le silicium monocristallin, le verre trempé et l'aluminium de haut qualité. ces matériaux offrent une excellente résistance au contraintes thermiques et mécaniques, réduisant les risques de défaillance et assure une stabilité de fonctionnement sur plusieurs décennies

- (b) **Conditions climatiques :**

les panneaux solaires installés dans les zones aux conditions climatiques extrêmes, tel que la chaleur intense, le gel, ou l'humidité excessive, les vents. Les panneaux peuvent subir une dégradation accélérée due à des variations climatiques. Les climats tempérés tendent généralement à être propices pour à une durée de vie longue

- (c) **Installation et entretien:**

L'installation des systèmes photovoltaïque requiert l'intervention par des expert qualifiés afin de garantir la stabilité mécanique, la sécurité électrique, l'efficacité à long terme. En outre, un entretien régulier, qui comprend le nettoyage de la surface des panneaux solaires et inspection régulière des composants (câblage, connecteurs), est crucial pour localiser la défaillance. Ces mesures assurent le maintien optimal du rendement et prolongent la durée de fonctionnement du système

- (d) **Technologie des cellules photovoltaïques**

Les cellules monocristallines offrent une meilleure performance et durabilité accrue comparé aux cellules polycristallins et amorphes

- **Méthodes de prévention de la dégradation**

- (a) **Nettoyage régulier**

Pour garantir une performance optimale, il est essentiel d'éliminer la poussière, les résidus et autres impuretés des panneaux.

(b) **La surveillance et la maintenance**

réaliser des inspections régulières pour d'identifier les signes de dégradation, notamment les microfissures ou la corrosion, et intervenir rapidement si nécessaire

(c) **Protection contre les surtensions**

prévoir des systèmes de sécurité pour éviter les dégâts liés aux surcharges électriques.

(d) **Choix de l'emplacement**

positionner les panneaux solaires dans des zone peu exposées aux conditions climatiques sévères pour réduire la dégradation de rendement.

### 2.4.1 Innovations pour améliorer l'efficacité

Les avancées technologiques permettent de renforcer la performance et la rentabilité des panneaux solaires. Parmi les plus notables, on trouve:

- **Suivi solaire:** Système automatisé orientant les panneaux selon la position du soleil. Il peut augmenter la production d'énergie de 25 % à 40 %. Trois variantes existent: suivi à axe unique, à double axe, et systèmes hybrides intégrant l'intelligence artificielle.
- **Cellules tandem:** Ces cellules combinent plusieurs couches (par exemple pérovskite et silicium) pour capter différentes longueurs d'onde, atteignant ainsi des rendements supérieurs à 40 % et réduisant la surface nécessaire à la production.
- **Matériaux innovants:** L'utilisation de matériaux comme les pérovskites, les cellules multijonctions, ou encore les panneaux bifaciaux (qui captent la lumière des deux côtés) permet d'augmenter la production et d'améliorer la durabilité. Certains alliages avancés améliorent aussi la résistance à l'humidité et à l'air.
- **Perspectives futures:** Ces technologies favoriseront une production plus efficace, économique et écologique de l'énergie solaire, s'inscrivant pleinement dans les objectifs de transition énergétique mondiale.

## 2.5 Conclusion

Les panneaux solaires représentent l'une des bases technologiques pour passer à une énergie propre et durable. Ce chapitre nous a permis d'examiner les bases scientifiques qui régissent le fonctionnement des cellules solaires, ainsi que les diverses sortes de panneaux proposés sur le marché. Chaque technologie offre des bénéfices distincts en termes d'efficacité,

de coût et de capacité d'adaptation. Néanmoins, le succès d'un projet photovoltaïque dépend d'une compréhension poussée de ces facteurs, ainsi que de décisions techniques ajustées aux conditions locales. Par conséquent, il est crucial de comprendre le fonctionnement des panneaux solaires pour exploiter au maximum le potentiel solaire exceptionnel de l'Algérie.

# Exploration des Fondements des Réseaux Neuronaux et du Deep Learning

## Sommaire

---

<b>3.1</b>	<b>Introduction</b>	<b>38</b>
<b>3.2</b>	<b>L'intelligence artificielle</b>	<b>38</b>
3.2.1	Machine Learning	39
3.2.2	Deep Learning	42
3.2.3	Convolutional Neural Networks (CNN)	47
<b>3.3</b>	<b>Apprentissage d'un réseau de neurones convolutifs</b>	<b>50</b>
3.3.1	Propagation avant (Forward Propagation)	51
3.3.2	Calcul de la fonction de perte	51
3.3.3	Rétropropagation (Backpropagation)	53
3.3.4	Optimisation des poids	53
<b>3.4</b>	<b>Conclusion</b>	<b>55</b>

---

## 3.1 Introduction

Le monde a connu une explosion des technologies numériques, plaçant l'intelligence artificielle (IA) au cœur des innovations contemporaines. Après avoir été cotonnée aux laboratoires de recherche, l'intelligence artificielle joue aujourd'hui un rôle stratégique dans de nombreux domaines. Car elle permet diverses tâches complexes tel que la prédiction, la classification et l'analyse des données, La détection d'anomalies dans les systèmes, La prise de décision intelligente en temps réel.

Ce chapitre est consacré à l'étude de l'intelligence artificielle (IA), qui tient une place clé dans notre Projet. Il vise à analyser les mécanismes de l'intelligence artificielle (IA), tout en examinant en explorant ses multiples domaines d'application et les mutations qu'elle provoque dans différents secteurs d'activité. Il s'agit également de comprendre pourquoi l'IA occupe aujourd'hui une place stratégique dans l'évolution des technologies modernes.

## 3.2 L'intelligence artificielle

D'après John McCarthy, l'un des pionniers de l'intelligence artificielle, la décrit comme « la science et l'ingénierie de la fabrication de machines intelligentes, en particulier de programmes informatiques intelligents » [21]. D'après cette définition l'IA a le caractère théorique et pratique, vise à la création d'outils concrets capable d'apprendre leur environnement et d'accomplir des tâches de manière autonome et intelligent.

En désignant l'IA comme une science, McCarthy fait référence à l'étude de mécanisme de l'intelligence cherche à comprendre et modalise les processus de l'intelligence tels que la perception, l'apprentissage, la planification ou la prise de décision. Des nombreuses disciplines sont sollicitées dans ces recherches, notamment les mathématiques, la logique et les sciences cognitives. En tant qu'ingénierie, elle traduit ces connaissances en système capables d'accomplir des tâches complexes de façon autonome ou une supervision limitée.

—par terme « machines intelligentes » englobe toute système que soit robot ou un logiciel capable d'exécuté des tâches similaire à celles du cerveau humain tels que la prédiction de la consommation d'énergie, la détection des fraudes, gérer la logistique dans les entrepôts automatisés.

Enfin, McCarthy souligne à l'importance sur les programmes informatiques intelligents car ils représentent la base de fonctionnel de l'intelligence artificielle. Ces programmes exploitent des données, des modèles statistiques avancés et des algorithmes complexes pour imiter des comportements intelligents. C'est à travers ces programmes les machines apprennent à traiter les informations, et reconnaître des motifs ou à communiquer avec leur environnement. Quel

que soit le domaine médicale, industrie, numérique.

L'intelligence artificielle fait appel à plusieurs technologies clé, dont le Machine Learning (ML), Deep Learning (DL), Naturel Language Processing (NLP).

L'IA déploie son potentiel dans une large gamme de domaines d'application et est aux cœurs de nombreux projets innovants.

1. **Google DeepMind : amélioration de l'efficacité énergétique des centres de données**

DeepMind, en collaboration avec Google, a utilisé l'intelligence artificielle pour optimiser la consommation énergétique des systèmes de refroidissement dans les centres de données. En exploitant des algorithmes de reinforcement learning, une réduction de 40 % de l'énergie utilisée pour le refroidissement a été obtenue, tout en maintenant la température optimale [22].

2. **AutoGrid: gestion intelligente des réseaux d'énergie**

AutoGrid développe des solutions basées sur l'IA pour optimiser la gestion des ressources énergétiques distribuées et la réponse à la demande. Leur plateforme permet une prise de décision en temps réel dans les smart grids, facilitant l'intégration des énergies renouvelables et la prévision des besoins énergétiques [23].

3. **IBM Maximo: maintenance prédictive dans les parcs éoliens**

IBM Maximo utilise l'IA et l'Internet des objets (IoT) pour prédire les défaillances des équipements dans les parcs éoliens. Grâce à la collecte de données en temps réel et à des modèles d'apprentissage automatique, il est possible de planifier les interventions de maintenance avant qu'une panne ne survienne, réduisant ainsi les coûts et augmentant la disponibilité des turbines [24].

### 3.2.1 Machine Learning

Le Machine Learning, ou apprentissage automatique, est un domaine essentiel de l'intelligence artificielle (IA). Il permet aux systèmes informatiques d'apprendre à partir des données et de s'adapter progressivement grâce à l'expérience, sans qu'il soit nécessaire de programmer explicitement chaque tâche. Plutôt que de suivre des instructions rigides, les algorithmes d'apprentissage automatique analysent de vastes ensembles de données pour y détecter des schémas récurrents et des relations pertinentes. Ces informations leur permettent ensuite de formuler des prédictions ou de prendre des décisions de manière autonome. Plus la quantité et la diversité des données utilisées sont importantes, plus les modèles développés gagnent en précision et en efficacité. On distingue plusieurs catégories d'apprentissage en machine

learning, chacune répondant à des objectifs et des contextes bien particuliers. Les principales formes sont présentées ci-dessous [25].

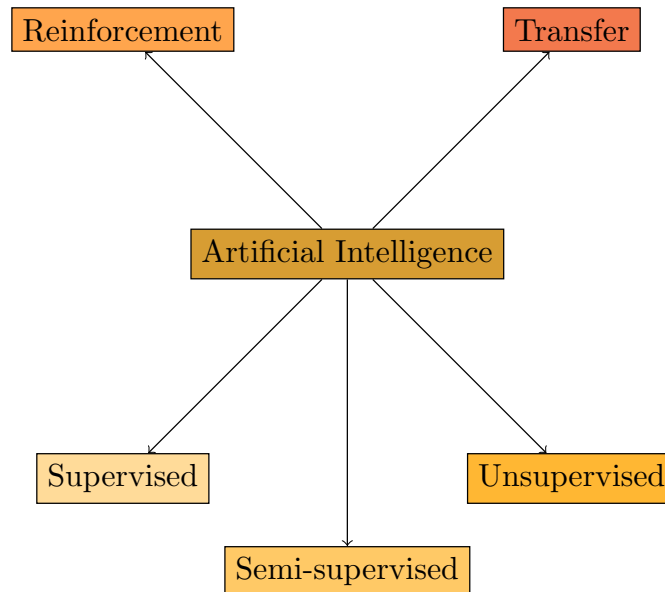


FIGURE 3.1 – Les types de de ML

### 3.2.1.1 Apprentissage supervisé

L'apprentissage supervisé est l'une des approches les plus utilisées en machine learning. Elle repose sur l'entraînement d'un modèle à partir d'un ensemble de données dites étiquetées, c'est-à-dire composées d'exemples pour lesquels les résultats attendus sont connus à l'avance. Le modèle apprend ainsi à associer les entrées aux sorties correspondantes en ajustant ses paramètres internes dans le but de réduire l'erreur de prédiction, mesurée par une fonction de perte. Pour garantir la fiabilité du modèle et limiter les risques de surapprentissage (overfitting), des méthodes comme la validation croisée sont généralement mises en œuvre. Les principales applications de cette méthode incluent :

1. **La classification:** consiste à affecter chaque donnée à une catégorie donnée; par exemple: distinguer les périodes de forte consommation électrique des périodes creuses, ou classer les types de pannes sur le réseau.
2. **La régression:** permet de prédire une valeur numérique continue, comme la consommation d'électricité d'un bâtiment à partir de ses caractéristiques (surface, nombre d'occupants, température extérieure, etc.).

### 3.2.1.2 Apprentissage non-supervisé

Contrairement à l'approche supervisée, l'apprentissage non supervisé repose sur l'analyse de données non étiquetées, c'est-à-dire sans indications explicites sur les résultats attendus. Le but est d'explorer ces données pour en extraire des structures cachées, identifier des regroupements naturels ou révéler des tendances non apparentes.

Parmi les techniques les plus courantes figurent :

1. **Le clustering:** regroupe les données présentant des similitudes, comme cela se fait dans la segmentation de la clientèle.
2. **La réduction de dimensionnalité:** qui permet de simplifier des ensembles de données complexes tout en conservant les informations essentielles — une méthode typique étant l'Analyse en Composantes Principales (ACP).

Ce type d'apprentissage est particulièrement adapté à l'analyse de grands ensembles de données brutes, et il permet souvent de mettre en lumière des informations nouvelles qui ne seraient pas détectables autrement.

### 3.2.1.3 Apprentissage semi-supervisé

L'apprentissage semi-supervisé constitue une approche intermédiaire entre les méthodes supervisées et non supervisées. Il exploite à la fois un petit ensemble de données étiquetées, pour guider l'apprentissage, et un volume plus important de données non étiquetées, généralement plus faciles à collecter.

Cette méthode se révèle particulièrement utile dans les contextes où l'annotation manuelle des données est coûteuse, chronophage ou difficile à réaliser, mais où l'on dispose malgré tout de grandes quantités de données brutes.

En tirant parti des informations implicites contenues dans les données non étiquetées, cette approche permet d'améliorer significativement la précision des modèles, tout en réduisant les besoins en ressources humaines. Elle est notamment utilisée dans des domaines comme la reconnaissance vocale, la vision par ordinateur ou encore le traitement du langage naturel.

### 3.2.1.4 Apprentissage par renforcement

L'apprentissage par renforcement, souvent abrégé RL (Reinforcement Learning), est une méthode où un agent — c'est-à-dire un système autonome — apprend à prendre les bonnes décisions en interagissant directement avec son environnement. Contrairement aux autres formes d'apprentissage, il ne s'appuie pas sur des exemples annotés. À la place, l'agent teste différentes actions et reçoit des retours sous forme de récompenses ou de sanctions. En fonction de ces retours, il ajuste peu à peu son comportement afin de maximiser les bénéfices à

long terme. Cette approche, inspirée du principe d'essai-erreur, repose sur une fonction de récompense qui guide l'agent vers les meilleures stratégies possibles. Elle est aujourd'hui largement utilisée dans des domaines comme la robotique, les jeux vidéo ou encore la conduite autonome, où les systèmes doivent apprendre à s'adapter à des environnements complexes et dynamiques.

### 3.2.1.5 Apprentissage par transfert

L'apprentissage par transfert (Transfer Learning TL) repose sur l'idée de tirer parti d'un modèle déjà entraîné sur une tâche donnée pour l'adapter à une autre tâche similaire. Cette approche permet de réutiliser les connaissances acquises lors d'un apprentissage initial afin d'enrichir ou d'accélérer l'apprentissage sur une nouvelle problématique, souvent avec un volume de données réduit. Elle est particulièrement avantageuse dans les situations où la collecte ou l'annotation de données pour la tâche cible est limitée, mais où un modèle performant existe déjà pour une tâche voisine. Par exemple, un modèle préalablement formé à la classification d'images issues de films peut être réutilisé et affiné pour classer des images liées à des pochettes d'albums musicaux, en exploitant les représentations visuelles communes [26].

Le Tableau 3.1 donne une comparaison des différents types d'apprentissage.

## 3.2.2 Deep Learning

L'apprentissage profond, ou Deep Learning (DL), est une branche avancée du ML, comme le montre la Figure 3.2, qui repose sur l'utilisation de réseaux de neurones artificiels comprenant un grand nombre de couches. Ces architectures multicouches permettent au système d'apprendre des représentations hiérarchisées et abstraites des données, ce qui les rend particulièrement efficaces pour le traitement de données complexes et massives.

Contrairement aux méthodes traditionnelles d'apprentissage automatique, le DL automatise l'extraction des caractéristiques à partir des données brutes, sans nécessiter de prétraitement manuel important. Il s'inspire du fonctionnement des réseaux de neurones biologiques: chaque *neurone* artificiel ajuste ses connexions (ou poids) en fonction des erreurs de prédiction ou classification, ce qui permet au réseau de s'améliorer progressivement.

Grâce à sa capacité à modéliser des relations non linéaires complexes, le DL s'est imposé comme une solution de pointe dans de nombreux domaines, notamment la reconnaissance d'images, la traduction automatique, la conduite autonome ou encore l'aide au diagnostic en médecine [27].

TABLE 3.1 – Tableau comparatif des différentes Stratégies d'apprentissage

Type d'apprentissage	Données utilisées	Objectif principal	Exemples d'applications
Apprentissage supervisé	Données étiquetées	Prédiction ou classification précise	Prédiction de la consommation, Optimisation de la production
Apprentissage non supervisé	Données non étiquetées	Découverte de structures ou regroupements cachés	Segmentation clients, Détection d'anomalies
Apprentissage semi-supervisé	Données étiquetées non étiquetées	Amélioration des performances avec peu de données étiquetées	Maintenance prédictive, Analyse de production renouvelable
Apprentissage par renforcement	Interaction avec l'environnement	Apprentissage de stratégies optimales par essais/erreurs	Régulation automatique, Contrôle intelligent
Apprentissage par transfert	Modèles préentraînés	Réutilisation des connaissances pour tâches connexes	Prédiction énergétique, Détection d'anomalies




FIGURE 3.2 – Schéma explicatif de la différence entre IA, ML et DL

### 3.2.2.1 Le cerveau humain et les réseaux neuronaux artificiels

L'apprentissage profond s'inspire étroitement du fonctionnement du cerveau humain, notamment de la manière dont les neurones biologiques traitent l'information. Le cerveau humain est composé d'environ 86 milliards de neurones interconnectés par des synapses, qui permettent la transmission de signaux électriques et chimiques. Ces neurones reçoivent, interprètent et transmettent des signaux, formant ainsi la base des processus cognitifs complexes

Les réseaux neuronaux artificiels, ou Artificial Neural Networks (ANN), cherchent à imiter ce fonctionnement à travers des modèles mathématiques. Chaque neurone artificiel, appelé aussi nœud, reçoit des signaux d'entrée pondérés, applique une fonction d'activation, puis transmet le résultat aux neurones suivants. Les connexions entre les nœuds sont caractérisées par des poids, ajustés au fil de l'apprentissage, ce qui rappelle la plasticité synaptique du cerveau biologique. la Figure 3.3 montre la structure d'un neurone humain.




FIGURE 3.3 – Structure d'un neurone humain

Grâce à cette structure en couches (réseaux multicouches) et à leur capacité à ajuster

dynamiquement les connexions, les réseaux neuronaux sont capables de capturer des relations complexes dans les données, rendant possible l'apprentissage de tâches sophistiquées [28].

### 3.2.2.2 L'architecture des réseaux neuronaux

L'architecture d'un réseau neuronal est basée sur trois principales couches:

— **Couche d'entrée (Input Layer):**

un réseau de neurones artificiel commence toujours par une couche d'entrée, qui joue un rôle de point de départ pour les données. Cette couche reçoit des données brutes de l'environnement externe. Chaque neurone au sein de cette couche représente une caractéristique distincte de l'entrée, que ce soit les pixels d'une image ou les mots d'une phrase. Elle transmet ces informations aux couches suivantes sans effectuer aucune modification. [29]

— **Couches cachées (Hidden Layers):** sont situées entre la couche d'entrée et la couche de sortie. Le rôle de ces couches consiste à effectuer des transformations sur les données reçues, chaque neurone de couche cachée agrège les informations de sorties des neurones précédents, applique une fonction d'activation puis transmet le résultat à la couche suivante. [30] [31]

— **Couche de sortie (Output Layer):** La dernière couche du réseau neuronale qui reçoit les informations des couches précédentes et produit le résultat final du traitement tels que la prédiction. [32]

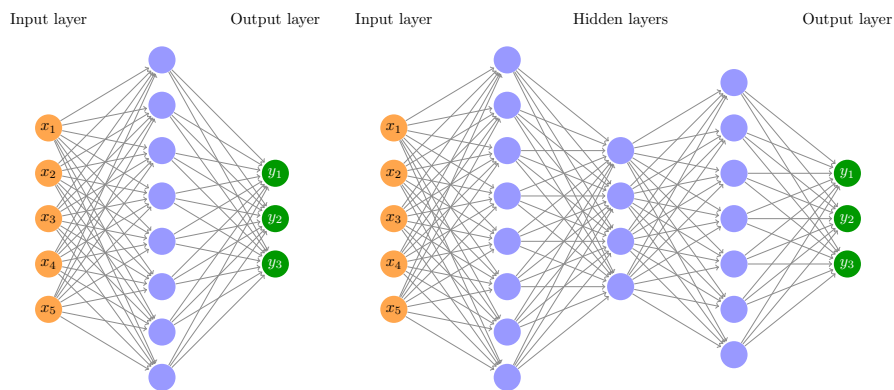


FIGURE 3.4 – La différence entre les réseaux neuronaux simples et profonds

la Figure 3.4 montre la différence entre les réseaux neuronaux simples et profonds.

Le même principe est utilisé pour entraîner des neurones. Ils sont modélisés comme des fonctions mathématiques contenant plusieurs variables, avec plusieurs entrées et une sortie.

Le perceptron a été inventé par Frank Rosenblatt en 1957, et est considéré comme le modèle simplifié du neurone artificiel. La structure d'un perceptron est composée de :

- entrées  $X$
- poids  $W$
- biais  $b$
- fonction d'activation  $f()$
- sortie  $y$

Le perceptron effectue l'opération suivante:

$$y = f\left(\sum_{i=1}^n w_i \times x_i + b\right) \quad (3.1)$$

. la Figure 3.5 représente une illustration d'un perceptron de base.




FIGURE 3.5 – Structure d'un perceptron

### 3.2.2.3 Les fonctions d'activation

Dans le contexte d'un réseau de neurones, le rôle de la fonction d'activation consiste à prendre la décision si un neurone doit être stimulé basé sur la somme pondérée dans ses entrées. La sigmoïde, la tangente hyperbolique ( $\tanh$ ) et la Rectified Linear unit (ReLU) figurent parmi les fonctions d'activations les plus fréquemment utilisées. La sélection de la fonction d'activation influence considérablement les performances du réseau.

Grâce à la non-linéarité qu'elle apportent, les fonctions d'activation rendent le réseau de neurones capable d'apprendre des relations complexes à travers les données.

Il existe diverses fonctions d'activation, chacune adaptée à des situations différentes telles que:

- **La fonction Sigmoid:** convertit toutes les valeurs réelles en une valeur située entre 0 et 1, ce qui la rend adaptée aux problèmes de classification binaire. La fonction sigmoïde représente une courbe en forme de “s”, tendant vers 0 pour des valeur négative et vers 1 pour les valeur positive. Son expression mathématique est donnée par l'équation 3.2:

$$F(x) = \frac{1}{1 + e^{-x}} \quad (3.2)$$

- **La fonction tangente hyperbolique(Tanh):** convertit les valeurs réelles en une valeur situe entre -1 à 1 de la même façon comme la fonction sigmoïde mais dans une plage différente. Ce qui peut faciliter la convergence lors de l'entraînement. Son expression mathématique est donnée par L'Équation 3.3:

$$F(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.3)$$

- **La fonction ReLU:** attribue une valeur de 0 a toute les valeurs négative. Elle introduit une transformation non-linéaire, qui permet au modèle d'apprendre des structure complexe dans les donner. Son expression mathématique est donnée par L'Équation 3.4: Représenter par:

$$F(x) = \max(0, x) \quad (3.4)$$

la Figure 3.6 illustre les fonctions d'activations citées précédemment.




FIGURE 3.6 – Les courbes des fonctions d'activations

### 3.2.3 Convolutional Neural Networks (CNN)

Les réseaux de neurones convolutifs, ou Convolutional Neural Networks (CNN), représentent une architecture avancée du DL spécifiquement conçue pour traiter des données

présentant une structure spatiale régulière. Inspirés du fonctionnement du cortex visuel chez les êtres vivants, ces réseaux sont capables d'apprendre automatiquement des représentations hiérarchiques à partir des données visuelles, sans nécessiter d'extraction manuelle de caractéristiques.

Grâce à leur efficacité dans la détection de motifs visuels complexes, les CNN sont largement utilisés dans le domaine de l'énergie, notamment pour l'inspection automatique des panneaux solaires, la détection de défauts dans les réseaux électriques, l'analyse d'images thermiques, ou encore la surveillance des infrastructures énergétiques.

Un réseau convolutif moderne se compose de plusieurs types de couches, chacune ayant un rôle spécifique dans le traitement et l'interprétation des données:

- Convolution
- Pooling
- Dropout
- Flatten
- Fully Connected (Entièrement connectée)

Cette architecture modulaire permet aux CNN d'être à la fois puissants et adaptables à une grande variété de tâches visuelles complexes. la Figure 3.7 illustre un CNN avec ces cinq types de couches.

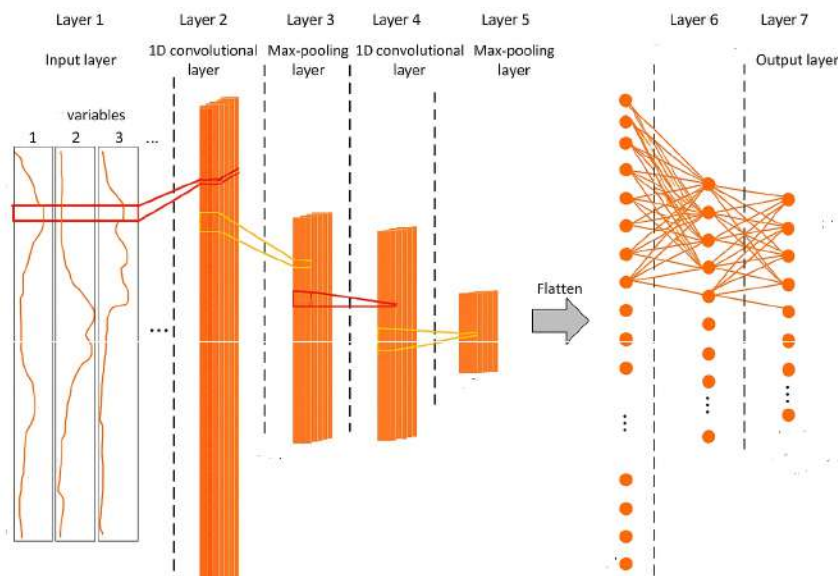


FIGURE 3.7 – Architecture d'un réseau CNN [1]

- **La couche de convolution:** constitue l'élément central d'un réseau de neurones convolutif. Elle utilise des filtres (ou noyaux) pour analyser localement l'entrée et détecter des motifs caractéristiques dans les séries temporelles d'entrée (comme des tendances, des pics, des cycles ou des anomalies). Concrètement, chaque filtre se déplace sur le signal et effectue un produit scalaire entre ses propres valeurs et celles de la zone locale correspondante du signal produisant ainsi une carte de caractéristiques (feature map).
- **La Couche de pooling:** également appelée sous-échantillonnage, joue un rôle clé dans les réseaux convolutifs en réduisant les dimensions spatiales des cartes de caractéristiques, tout en conservant les informations les plus pertinentes. Cette opération consiste à diviser chaque carte en régions distinctes, puis à résumer chacune d'elles par une valeur unique, ce qui permet d'alléger la complexité du modèle sans compromettre sa capacité de représentation. Il existe principalement deux types de pooling:
  - **Max pooling:** conserve la valeur maximale dans chaque sous-région, mettant en évidence les caractéristiques les plus marquantes.
  - **Average pooling:** calcule la moyenne des valeurs, produisant une version plus lissée de la carte.

la Figure 3.8 donne une illustration des couches convolution et pooling.

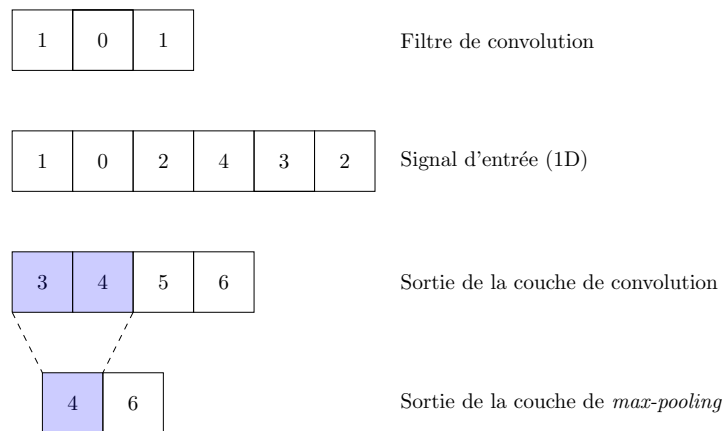


FIGURE 3.8 – Convolution 1D avec filtre de trois suivi d'un max-pooling

- **Dropout:** est une méthode de régularisation couramment utilisée pour améliorer la généralisation des réseaux de neurones profonds. Elle consiste à désactiver aléatoirement un certain pourcentage de neurones pendant la phase d'entraînement telle représenté dans la Figure 3.9. Cette désactivation temporaire empêche le réseau de devenir trop dépendant de certains neurones spécifiques et l'encourage à apprendre des représentations plus distribuées et robustes.




FIGURE 3.9 – Réseau neuronal avant et après le dropout

- **La couche flatten:** ou couche d'aplatissement, intervient à l'interface entre les couches convolutionnelles/pooling et les couches entièrement connectées) (voir la Figure 3.10). Elle a pour rôle de transformer les cartes de caractéristiques multidimensionnelles (généralement en 2D ou 3D) en un vecteur unidimensionnel.

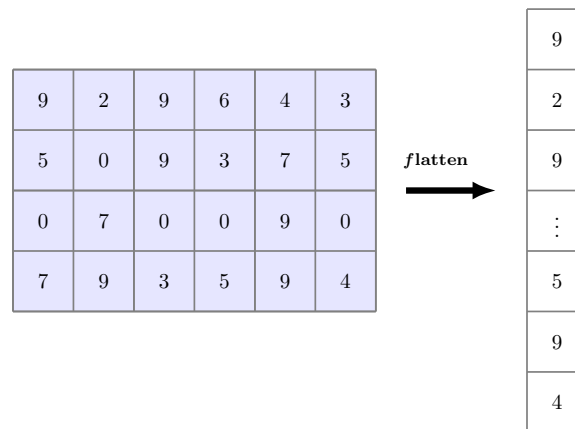


FIGURE 3.10 – Exemple de Flatten

- **Fully connected:** ou dense relie chaque neurone de sa couche précédente à tous les neurones de la couche suivante. Elle intègre et combine toutes les caractéristiques apprises par le réseau pour produire le résultat final, qu'il s'agisse d'une prédiction de classe ou d'une estimation numérique [33](voir la Figure 3.11).

### 3.3 Apprentissage d'un réseau de neurones convolutifs

L'apprentissage d'un CNN est un processus supervisé et itératif visant à permettre au modèle de détecter automatiquement les caractéristiques significatives des données d'entrée, afin d'accomplir des tâches comme la classification ou la prédiction. Ce mécanisme repose principalement sur l'ajustement progressif des poids du réseau à l'aide de la rétropropagation




FIGURE 3.11 – Fully connected layer

de l'erreur, dans le but de minimiser l'écart entre les prédictions du modèle et les résultats attendus (voir Figure 3.12).

### 3.3.1 Propagation avant (Forward Propagation)

Cette phase consiste à faire circuler les données d'entrée à travers les différentes couches du réseau. Chaque neurone applique une fonction d'activation non linéaire (comme ReLU ou sigmoid) à la somme pondérée de ses entrées pour générer sa sortie.

### 3.3.2 Calcul de la fonction de perte

La sortie du réseau est comparée à la réponse attendue à l'aide d'une fonction de perte. Cette fonction fournit une mesure quantitative de l'erreur commise par le modèle, qui servira de guide pour la mise à jour des poids.

La fonction de perte constitue un élément fondamental, car elle évalue l'écart entre les prédictions générées par un modèle et les valeurs attendues issues des données d'apprentissage. Elle attribue un score d'erreur à chaque prédiction : plus ce score est faible, plus la prédiction est considérée comme exacte. Contrairement à la fonction de coût, qui représente généralement la moyenne des erreurs sur l'ensemble du jeu de données, la fonction de perte s'applique à un seul exemple.

Il existe différents types de fonctions de perte, chacune étant choisie en fonction de la nature de la tâche à accomplir. Dans les problèmes de régression, les plus utilisées sont l'Erreur Quadratique Moyenne (EQM) et l'Erreur Absolue Moyenne (EAM). Ces fonctions évaluent l'écart entre les valeurs continues prédites et les valeurs réelles. L'EQM, en particulier, pénalise plus fortement les grandes erreurs, tandis que la EAM accorde un poids uniforme à toutes les erreurs.

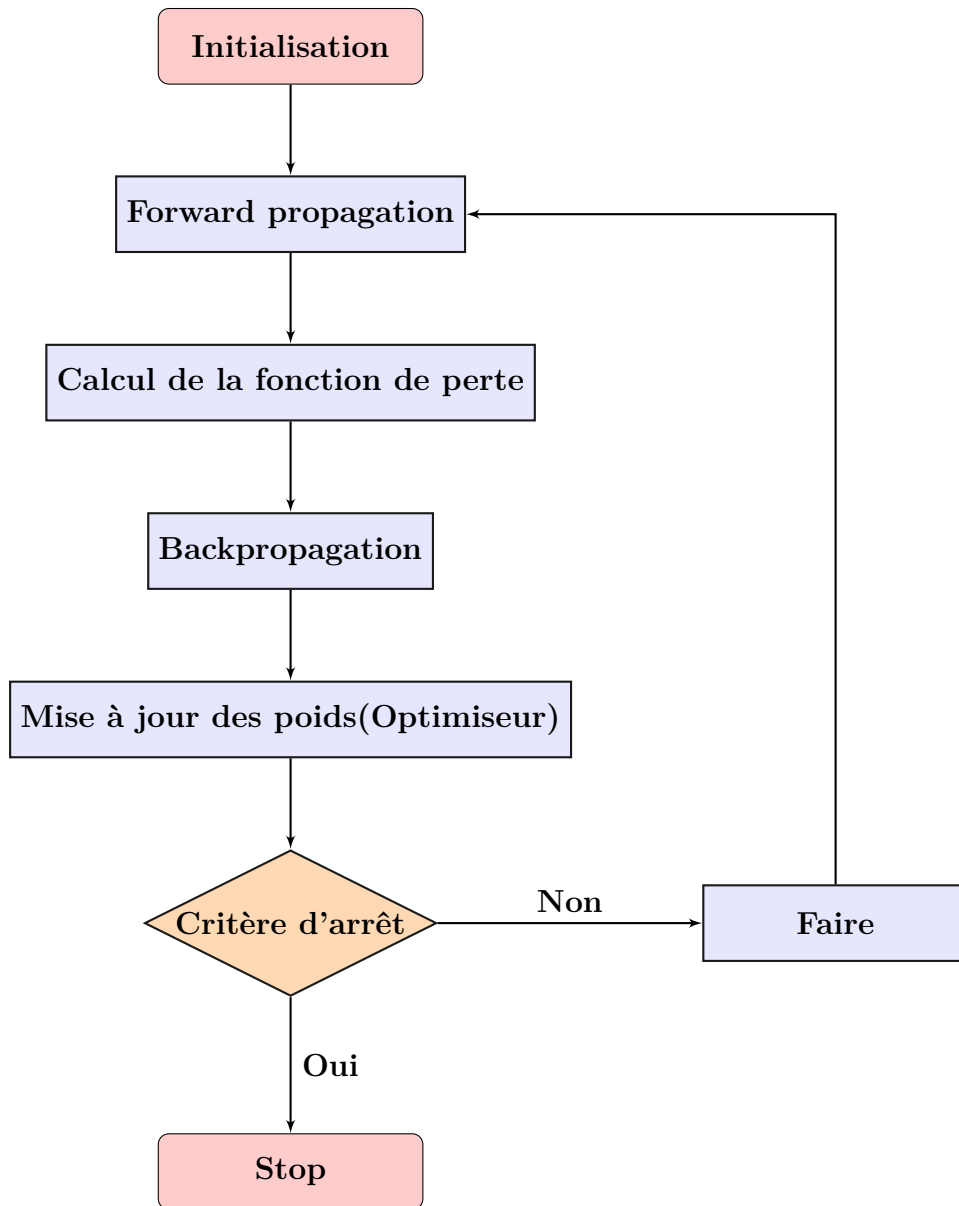


FIGURE 3.12 – Organigramme d'apprentissage avec optimiseur

L'EQM est définie par l'Équation (3.5) :

$$EQM = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (3.5)$$

- $n$ : le nombre d'exemples d'entraînement
- $\hat{y}$ : la valeur prédite
- $y$ : la valeur réelle

L'EAM est donnée par l'Équation (3.6):

$$EAM = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (3.6)$$

### 3.3.3 Rétropropagation (Backpropagation)

L'algorithme de rétropropagation calcule le gradient de la fonction de perte par rapport à chaque paramètre du réseau. En appliquant la règle de dérivation en chaîne, ce calcul est effectué en remontant du dernier neurone vers les couches d'entrée. Cela permet d'identifier la contribution de chaque poids à l'erreur globale.

### 3.3.4 Optimisation des poids

Les gradients obtenus sont utilisés pour ajuster les poids à l'aide d'un algorithme d'optimisation. C'est un élément fondamental dans l'apprentissage, chargé de modifier les paramètres internes d'un modèle (comme les poids et les biais) dans le but de réduire la fonction de perte. Il s'appuie sur les gradients obtenus par rétropropagation pour orienter les ajustements dans la direction qui diminue l'erreur de prédiction. Parmi les optimisateurs les plus utilisés, on trouve :

- Stochastic Gradient Descent (SGD): met à jour les paramètres en fonction du gradient calculé sur un sous-ensemble de données, ce qui permet une mise à jour plus fréquente et un apprentissage plus rapide qu'avec la descente de gradient standard [34].
- RMSprop: est un algorithme d'optimisation basé sur la descente de gradient. Il ajuste le taux d'apprentissage en utilisant une moyenne mobile des gradients au carré. Ceci permet de stabiliser et d'accélérer l'entraînement des réseaux de neurones profonds [27].
- Adagrad: est une approche adaptative qui ajuste dynamiquement le taux d'apprentissage en fonction de l'historique des gradients, ce qui améliore la stabilité du processus d'apprentissage [35].
- AdaDelta: est une extension de l'algorithme Adagrad, conçue pour corriger sa principale limite: la diminution trop rapide et irréversible du taux d'apprentissage. Elle adapte dynamiquement le taux d'apprentissage à chaque paramètre, sans nécessiter de taux initial global [36].
- ADAM: combine les principes de momentum et de RMSprop, en adaptant automatiquement le taux d'apprentissage pour chaque paramètre. Il est particulièrement performant dans les réseaux profonds grâce à sa capacité à accélérer la convergence.

Le choix de l'optimiseur est crucial, il influence non seulement la rapidité de convergence, mais aussi la stabilité du modèle et sa capacité à atteindre une solution optimale tout en évitant des

problèmes comme le surapprentissage ou la divergence. Le taux d'apprentissage constitue un hyperparamètre clé dans les algorithmes d'apprentissage automatique et d'apprentissage profond. Il contrôle l'amplitude des modifications apportées aux paramètres internes du modèle (comme les poids et les biais) à chaque itération durant la phase d'optimisation, généralement via la descente de gradient.

Le taux d'apprentissage constitue un hyperparamètre clé dans les algorithmes d'apprentissage automatique et d'apprentissage profond. Il contrôle l'amplitude des modifications apportées aux paramètres internes du modèle (comme les poids et les biais) à chaque itération durant la phase d'optimisation, généralement via la descente de gradient. Lors de l'apprentissage, le modèle tente de réduire une fonction de perte, qui évalue l'écart entre les prédictions produites et les valeurs attendues. Le taux d'apprentissage intervient comme un multiplicateur du gradient de cette fonction: il régule la taille du déplacement effectué dans l'espace des paramètres à chaque mise à jour.

- Un taux trop faible revient à faire de petits pas, ce qui ralentit considérablement la convergence (voir la Figure 3.13a).
- À l'inverse, un taux trop élevé engendre des sauts excessifs qui peuvent empêcher le modèle d'atteindre le minimum de la fonction de perte, voire provoquer une instabilité de l'apprentissage(voir la Figure 3.13c).

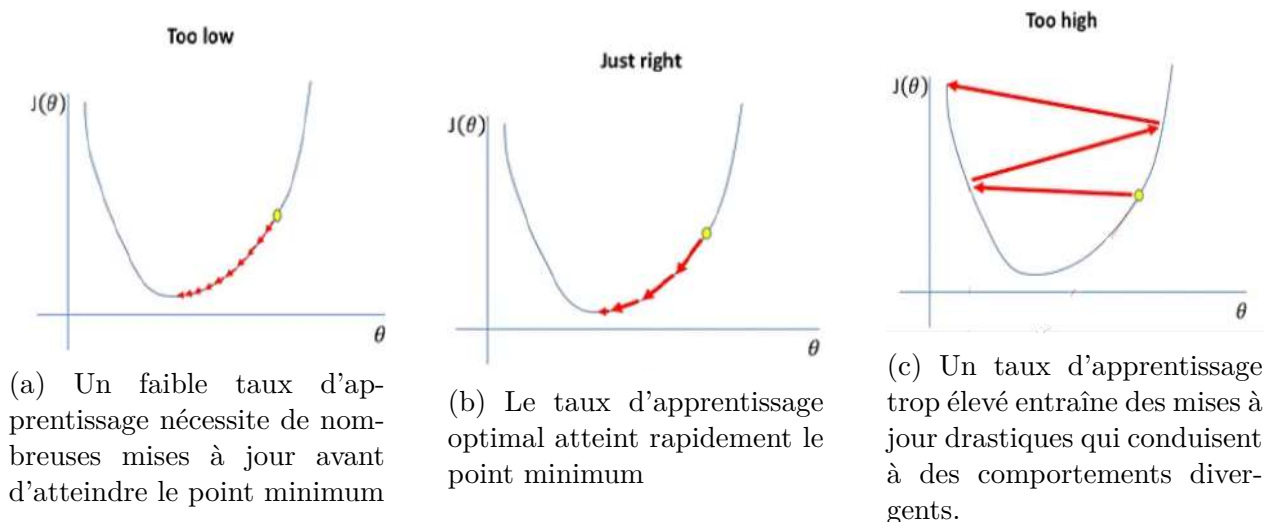


FIGURE 3.13 – Impact des différents taux d'apprentissage sur la convergence vers le minimum de la fonction de perte

Afin d'éviter que le réseau ne mémorise excessivement les données d'entraînement, diverses techniques de régularisation sont mises en œuvre : le Dropout, qui consiste en la désactivation aléatoire de neurones pendant l'entraînement; et l' Early stopping, qui correspond à une

interruption anticipée de l'entraînement dès que la performance sur un ensemble de validation commence à se dégrader.

Il est à noter que dans l'apprentissage profond, la structuration des données joue un rôle clé dans l'efficacité du processus d'entraînement. Le batch désigne un sous-ensemble d'exemples extrait du l'ensemble de données, utilisé pour mettre à jour les paramètres du modèle de manière progressive, tout en optimisant la mémoire et la stabilité de l'apprentissage. Quant à l'époque, elle correspond à un passage complet sur l'ensemble des données d'entraînement, permettant au modèle d'ajuster ses poids en revoyant chaque exemple une fois par cycle.

## 3.4 Conclusion

Ce chapitre a permis d'explorer les notions essentielles de l'IA, de l'apprentissage automatique et de l'apprentissage profond, en mettant en lumière leurs principes théoriques fondamentaux. Cette base théorique est essentielle pour appréhender les méthodes de prédiction énergétique présentées ultérieurement. Les chapitres suivants mettront en œuvre ces notions à travers la conception et l'évaluation d'un modèle d'apprentissage profond appliqué à la gestion énergétique intelligente, assurant ainsi une transition cohérente entre théorie et pratique.

Deuxième partie

Partie Pratique

# Le Deep Learning pour la Prédiction de la Consommation de l'Énergie

## Sommaire

---

<b>4.1</b>	<b>Introduction</b>	<b>58</b>
<b>4.2</b>	<b>Base de données</b>	<b>58</b>
4.2.1	Description de la base de données	58
4.2.2	Analyse de la base de données	60
4.2.3	Pré-traitement des données	64
4.2.4	Préparation de la base de données	64
<b>4.3</b>	<b>Méthodologie</b>	<b>67</b>
4.3.1	Architecture du modèle	67
4.3.2	Évaluation des performances	71
<b>4.4</b>	<b>Résultats expérimentaux et discussion</b>	<b>73</b>
<b>4.5</b>	<b>Conclusion</b>	<b>75</b>

---

## 4.1 Introduction

La prévision des séries temporelles joue un rôle fondamental dans de nombreux domaines, notamment dans le secteur de l'énergie. Dans le contexte actuel de transition énergétique, la capacité à anticiper la consommation de l'énergie électrique est devenue une nécessité stratégique. L'énergie solaire occupe une place centrale en raison de son potentiel abondant, particulièrement dans des pays fortement ensoleillés comme l'Algérie.

La prédiction de la consommation solaire est un défi technique, car elle dépend de plusieurs facteurs variables, notamment les conditions météorologiques et la température ambiante. Pour relever ce défi, les méthodes classiques de prévision, telles que les approches statistiques traditionnelles, se révèlent souvent insuffisantes, en particulier lorsqu'il s'agit de modéliser des relations complexes et non linéaires.

C'est dans ce contexte que le DL s'impose comme une approche prometteuse. Grâce à sa capacité à extraire automatiquement des caractéristiques pertinentes à partir de grandes quantités de données, il permet d'atteindre une précision supérieure dans la prédiction de séries temporelles complexes. Parmi les architectures les plus performantes dans ce domaine figurent les CNNs, initialement développés pour le traitement d'images, mais qui se sont révélés efficaces également pour l'analyse de données temporelles.

Ce chapitre présente une étude complète sur la prédiction de la consommation de l'énergie en utilisant des techniques basées sur le DL. Il s'articule autour de la description des données utilisées, de la méthodologie, et de l'analyse des résultats obtenus. L'objectif est de démontrer l'efficacité des approches basées sur les CNNs dans le domaine de la prévision énergétique, en mettant en évidence leur contribution à une gestion intelligente et durable des ressources solaires.

## 4.2 Base de données

### 4.2.1 Description de la base de données

Dans cette étude, nous utilisons une base de données issue d'un système énergétique local de type Energy Hub implanté en Iran. Elle couvre une période allant de décembre 2010 à novembre 2018, avec une résolution horaire. L'ensemble regroupe 70,080 enregistrements, représentant les profils de consommation horaire en électricité et en chaleur d'un site résidentiel [37].

Les principales composantes de la base de données sont décrites ci-dessous:

- **Consommation horaire d'énergie électrique(en kWh):** Cette section regroupe des informations sur la quantité d'énergie électrique consommée chaque heure, exprimée

en kilowatts par heure (kWh), sur une période donnée comme le montre la Figure 4.1. Ces données sont indispensables pour analyser les habitudes de consommation tout au long de la journée, de la semaine, du mois ou de l'année. Elles permettent notamment de repérer les heures de pointe, de détecter les variations saisonnières et de dégager les grandes tendances en matière de demande énergétique.




FIGURE 4.1 – Tendence annuelle de la consommation d'énergie

- **Température(en °C):** Les conditions climatiques, et plus particulièrement la température, jouent un rôle déterminant dans la variation de la demande en électricité. En effet, les systèmes de chauffage en hiver et de climatisation en été représentent une part significative de la consommation énergétique des foyers et des bâtiments commerciaux. L'analyse de la corrélation entre la température et la consommation permet de mieux comprendre l'impact des fluctuations météorologiques sur la demande énergétique. Cette compréhension est essentielle pour optimiser la gestion des ressources et orienter la planification des infrastructures énergétiques[38]. Afin de permettre cette analyse, les données de température sont collectées en parallèle avec les données de consommation, ce qui rend possible l'étude des liens entre les deux variables.
- **Irradiation solaire (en W/m<sup>2</sup>):** L'irradiation solaire correspond à la quantité de rayonnement solaire reçue par unité de surface. C'est un facteur déterminant de la production d'électricité à partir du soleil. Une irradiation élevée se traduit généralement par une production accrue. L'analyse de cette variable permet donc d'estimer avec précision la contribution de l'ensoleillement à la production énergétique. L'irradiation est couramment mesurée par des capteurs météorologiques au sol ou estimée à partir d'images satellites via des bases de données spécialisées.
- **Humidité (en %):** L'humidité relative constitue un paramètre climatique important susceptible d'influencer de manière significative la consommation de l'énergie électrique. En période estivale, un taux d'humidité élevé accentue la sensation de chaleur, ce qui peut provoquer une sollicitation accrue des systèmes de climatisation. À l'inverse, durant l'hiver, une faible humidité peut renforcer la sensation de froid, entraînant une

hausse de l'utilisation des dispositifs de chauffage. L'étude de l'humidité permet donc de mieux cerner les variations de la demande énergétique en fonction du ressenti thermique. Afin de rendre possible cette analyse, les données d'humidité sont recueillies simultanément avec les mesures de consommation, offrant ainsi une base pertinente pour évaluer les interactions entre conditions climatiques et usage de l'électricité dans le secteur résidentiel.

Pour mieux cerner les caractéristiques générales de la base de données, des statistiques descriptives ont été extraites pour quatre variables principales: la consommation d'énergie, la température, l'irradiation solaire et l'humidité. Ces résultats sont résumés dans le Tableau 4.1 ci-après.

TABLE 4.1 – Description des données utilisées

Statistiques	Consommation	Température	Irradiation	Humidité
Count	70 073	69 903	70 080	69 903
Mean	393,89	17,87	257,29	60,64
Std	239,19	10,68	258,73	22,00
Min	112,95	-14,40	0,00	4,00
25%	237,71	10,00	0,00	43,00
50%	323,09	18,90	299,50	61,00
75%	476,91	25,60	499,00	79,00
Max	1 592,89	43,30	699,00	100,00

Ce tableau regroupe plusieurs indicateurs statistiques essentiels permettant de résumer les caractéristiques des données. L'attribut count indique le nombre total d'observations valides enregistrées pour chaque variable, c'est-à-dire les lignes non manquantes. L'indicateur Mean correspond à la moyenne arithmétique, tandis que Min et Max désignent respectivement les valeurs minimale et maximale observées. L'écart-type (Std) permet d'évaluer la dispersion des données autour de la moyenne: plus cette valeur est élevée, plus les données sont étalées; à l'inverse, un faible écart-type traduit une concentration des valeurs autour de la moyenne. Enfin, les quartiles à 25%, 50% (Median) et 75% donnent une idée de la distribution des données en trois quartiles, permettant de visualiser comment les valeurs sont réparties dans chaque variable.

### 4.2.2 Analyse de la base de données

L'exploration des données constitue une phase essentielle pour mettre en évidence les tendances de consommation et mieux comprendre les variables qui influencent la demande

en énergie. En nous appuyant sur les données historiques de consommation électrique, nous avons réalisé une analyse temporelle approfondie, déclinée selon différentes échelles: mensuelle, quotidienne et horaire. Cette approche permet d'identifier les schémas récurrents dans le comportement des utilisateurs, et contribue à améliorer les décisions en matière de planification et d'optimisation énergétique.

la Figure 4.2 illustre l'évolution de la consommation moyenne mensuelle pour chaque année, établie à partir de l'ensemble des données disponibles.




FIGURE 4.2 – Consommation moyenne mensuelle d'énergie (toutes années confondues)

Cette figure illustre un schéma de consommation énergétique influencé par la saisonnalité. Une première augmentation est observée durant les mois de juin et juillet, en lien avec l'usage intensif de la climatisation. Une seconde hausse se manifeste en novembre et décembre, vraisemblablement due aux besoins de chauffage. En revanche, les mois du printemps et du début de l'automne présentent une consommation plus modérée. Ce comportement, stable d'une année à l'autre, traduit une régularité dans le profil saisonnier de la demande énergétique.

la Figure 4.3 illustre les variations des schémas de consommation moyenne d'énergie selon les jours de la semaine.

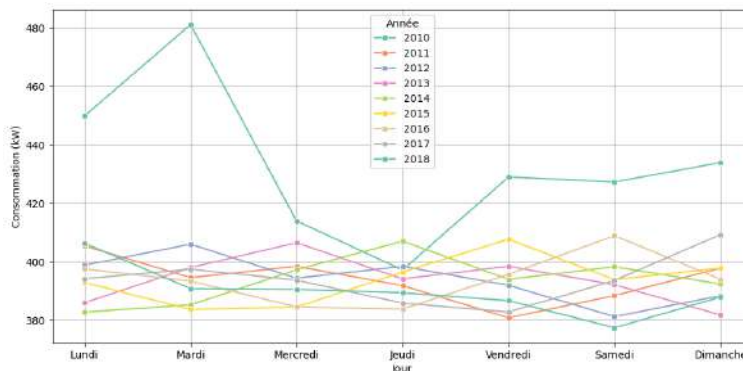


FIGURE 4.3 – Consommation moyenne quotidienne d'énergie (toutes années confondues)

On observe une relative stabilité des niveaux de consommation du lundi au dimanche, avec des variations modérées selon les années. Cette constance suggère que la consommation résidentielle ne dépend pas fortement du jour de la semaine. Toutefois, l'année 2010 se démarque par un pic inhabituel le mardi, ce qui pourrait refléter une anomalie de mesure ou un événement particulier ayant influencé la demande énergétique cette année-là.

la Figure 4.4 présente une visualisation détaillée du profil de consommation moyen de l'énergie au cours d'une journée type. Le graphique, structuré selon les 24 heures de la journée, met en évidence les variations horaires de la demande énergétique, permettant d'identifier les périodes de forte et de faible consommation.




FIGURE 4.4 – Consommation moyenne horaire d'énergie (toutes années confondues)

Deux phases principales se distinguent: une consommation faible durant la nuit et en matinée, suivie d'une montée progressive dans l'après-midi, culminant en soirée entre 19h et 22h. Cette tendance reflète les habitudes de vie typiques des ménages: réduction d'activité durant la nuit, reprise progressive après midi, et pic en soirée lié à la préparation des repas, l'éclairage et l'utilisation des appareils électroménagers. Les années 2015 à 2018 montrent une intensité plus élevée durant les premières heures (0h à 2h), probablement due à l'usage accru de la climatisation nocturne en été ou à des habitudes de veille prolongée.

Afin de renforcer cette analyse temporelle, nous avons enrichi la base de données par l'extraction de nouvelles variables temporelles: l'heure, le jour de la semaine et le mois correspondant à chaque enregistrement. Ces caractéristiques permettent de mieux capturer les effets saisonniers, hebdomadaires et journaliers qui influencent la demande énergétique, et jouent un rôle crucial dans l'amélioration de la performance prédictive des modèles d'apprentissage profond.

L'ajout des variables temporelles a permis d'explorer plus finement les relations entre la consommation énergétique et les effets temporels. La matrice de corrélation présentée à la Figure 4.5 met en évidence des corrélations:

L'étude de la matrice de corrélation (figure 4.5) permet de quantifier la relation linéaire entre la variable consommation et les autres variables du jeu de données. Les principales




FIGURE 4.5 – Matrice de corrélation entre les principales variables

observations sont les suivantes :

- **Heure** ( $r = 0,25$ ) : Une corrélation positive est observée entre la consommation d'énergie et l'heure de la journée. Cela reflète le fait que la demande énergétique augmente progressivement au fil de la journée pour atteindre un pic en soirée (entre 19h et 22h), comme observé précédemment dans la Figure 4.4. Cette tendance est typique d'un usage résidentiel.
- **Mois** ( $r = 0,11$ ) : Une faible corrélation positive suggère un effet saisonnier sur la consommation, en lien avec les besoins accrus en climatisation durant l'été et en chauffage durant l'hiver. Cette variation saisonnière est cohérente avec le profil mensuel présenté dans la Figure 4.2.
- **Jour de la semaine** ( $r = 0,04$ ) : La corrélation très faible avec le jour indique que la consommation reste relativement stable entre les jours ouvrés et les week-ends. Cela suggère un profil de consommation essentiellement résidentiel, moins sensible aux rythmes hebdomadaires.
- **Irradiation solaire** ( $r = -0,19$ ) : Une corrélation négative modérée est détectée entre

la consommation et l'irradiation solaire. Cette relation inverse s'explique probablement par une réduction de la demande énergétique pendant les heures de forte production solaire (en journée), en particulier si l'autoproduction solaire est intégrée au système étudié.

- **Température** ( $r = 0,01$ ) et **Humidité** ( $r = -0,03$ ) : Ces deux variables présentent des corrélations quasi-nulles avec la consommation. Cela peut indiquer une faible sensibilité de la consommation totale à ces facteurs dans ce contexte particulier, ou une compensation entre les effets opposés (chauffage vs climatisation).

### 4.2.3 Pré-traitement des données

Avant de passer à l'analyse des profils de consommation, un examen préliminaire. Pour éviter que ces manques n'altèrent les courbes ou ne créent de ruptures artificielles, une interpolation linéaire a été utilisée. Cette méthode permet de reconstituer les valeurs manquantes de façon continue, en s'appuyant sur les points précédents et suivants, tout en respectant le rythme naturel de la variation des données. Étant donnés deux points de données  $(t_1, y_1)$  et  $(t_2, y_2)$ , et un temps cible  $t$  tel que  $t_1 < t < t_2$ , la valeur interpolée  $y$  est calculée selon la formule d'interpolation linéaire suivante :

$$y = y_1 + \frac{(t - t_1)(y_2 - y_1)}{t_2 - t_1} \quad (4.1)$$

### 4.2.4 Préparation de la base de données

La phase de préparation des données consiste à transformer ou encoder l'information brute afin de la rendre exploitable par un algorithme. Cette transformation permet à la machine de traiter plus aisément les éléments essentiels contenus dans les données. Dans le cas des séries temporelles, une transformation préalable est nécessaire avant toute application d'un modèle d'apprentissage supervisé. Cette étape garantit une meilleure capacité d'apprentissage du modèle et une précision accrue lors des prédictions [39]. Nous présentons ci-après une analyse de trois étapes clés de ce processus .

#### 4.2.4.1 Normalisation

La normalisation est une méthode de prétraitement qui vise à ajuster l'échelle des données afin d'en faciliter l'analyse et l'interprétation. Ce procédé permet d'assurer une meilleure interopérabilité entre différentes sources[40].

En réduisant l'influence excessive des variables ayant de grandes amplitudes, la normalisation garantit que l'ensemble des caractéristiques contribue équitablement à l'analyse. Elle recentre ainsi les données autour d'une échelle commune, ce qui favorise des comparaisons plus fiables. En l'absence de normalisation, certaines variables pourraient dominer les autres ou introduire des biais dans les résultats.

Dans le cadre de ce travail, la méthode MinMaxScaler a été retenue. Il s'agit d'une technique largement utilisée qui ramène les valeurs d'une variable dans un intervalle défini, généralement entre 0 et 1. Ce procédé consiste à transformer la plus petite valeur en 0, la plus grande en 1, et à ajuster toutes les autres en proportion dans cette plage. La transformation est effectuée selon l'Équation (4.2) [41].

$$X_{\text{scaled}} = \frac{(X - X_{\min})}{(X_{\max} - X_{\min})} \quad (4.2)$$

#### 4.2.4.2 Transformation des séries temporelles pour un problème d'apprentissage supervisé

Avant de pouvoir exploiter efficacement les données de séries temporelles dans le cadre de l'apprentissage supervisé, celles-ci doivent être préalablement restructurées. En partant d'une séquence chronologique de valeurs, il est possible de transformer ces données afin de les adapter à une tâche prédictive supervisée [42]. Cette transformation consiste à utiliser les valeurs passées de la série notées  $CE_t, CE_{t-1}, CE_{t-2}, \dots, CE_{t-w+1}$ , où  $w$  désigne le décalage temporel exprimé en heures comme variables d'entrée, et à prédire la valeur suivante  $CE_{t+1}$ , qui devient la sortie du modèle.

Ce processus peut être formalisé comme suit:

$$CE_{t+1} = f(CE_t, CE_{t-1}, CE_{t-2}, CE_{t-3}, \dots, CE_{t-w+1}) \quad (4.3)$$

où  $CE$  représente la consommation d'énergie à l'instant  $t$ ,  $t - 1$  correspond à l'heure précédente,  $t - 2$  à deux heures auparavant, et  $t + 1$  désigne l'heure à prédire.

Pour prédire la consommation d'énergie à un instant donné, une stratégie couramment utilisée consiste à exploiter les valeurs observées lors des instants précédents. Cette approche est désignée sous le nom de *fenêtre coulissante* (*sliding window*). Le nombre de pas de temps antérieurs pris en compte noté  $w$  est appelé *taille de la fenêtre*. Cette méthode constitue une base essentielle pour convertir une base de données de séries temporelles en un problème d'apprentissage supervisé [43].

Par ailleurs, la structure d'une base de données temporelles dépend aussi du nombre de

variables mesurées à chaque instant. On distingue généralement deux cas:

- **Séries temporelles univariées:** elles consistent à suivre l'évolution d'une seule variable dans le temps.
- **Séries temporelles multivariées:** elles impliquent l'enregistrement simultané de plusieurs variables à chaque pas de temps, permettant ainsi d'étudier des relations temporelles croisées.

Dans notre cas, la base de données contient plusieurs variables mesurées simultanément, ce qui correspond à une série temporelle multivariée. Cette configuration est représentée formellement par l'Équation (4.4).

$$CE_{t+1} = f\left([CE_t, T_t, I_t, H_t], [CE_{t-1}, T_{t-1}, I_{t-1}, H_{t-1}], \dots, [CE_{t-w+1}, T_{t-w+1}, I_{t-w+1}, H_{t-w+1}]\right) \quad (4.4)$$

où  $CE$  représente la consommation d'énergie,  $T$  la température,  $I$  l'Irradiation solaire et  $H$  l'humidité.

Dans ce travail, la valeur de  $w$  est fixée à 96 ( $24 \times 4$ ) où 24 désigne le nombre d'heures par jour et 4 désigne le nombre de jours.

#### 4.2.4.3 Répartition des données

Il est essentiel d'évaluer la précision des prédictions à l'aide de données réelles. En effet, la taille des résidus ne constitue pas un indicateur fiable de l'ampleur réelle des erreurs de prédiction. La fiabilité d'un modèle ne peut être jugée qu'en analysant ses performances sur un ensemble de données inédites, non exploitées durant la phase d'apprentissage.

Lors de la sélection et de l'évaluation des modèles, il est courant de diviser les données disponibles en trois ensembles distincts: d'apprentissage, de validation, et de test. L'ensemble d'apprentissage sert à ajuster les paramètres du modèle en lui permettant d'identifier les motifs et les corrélations sous-jacents dans les données. L'ensemble de validation est ensuite utilisé pour évaluer les performances intermédiaires du modèle. Ce processus est généralement itératif, permettant d'optimiser progressivement les performances. Enfin, l'ensemble de test intervient à la dernière étape pour évaluer la capacité généralisatrice du modèle sur des données totalement inédites, simulant des situations réelles. Il fournit une mesure objective et finale de l'efficacité du modèle sur des données qu'il n'a jamais vues auparavant [43].

Dans ce travail, la répartition de la base de données que nous avons adoptée est la suivante:

1. Train: du 01-12-2010 à 00h au 05-07-2016 à 23h, soit 70%.

2. Validation: du 06-07-2016 à 00h au 23-04-2017 à 23h, soit 10%.
3. Test: du 24-04-2017 à 00h au 28-11-2018 à 23h, soit 20%.

De manière générale, il est courant d'allouer environ 70% des données à l'apprentissage, 10% à la validation et 20% aux tests. Cette répartition est souvent considérée comme une stratégie équilibrée et efficace pour évaluer les performances d'un modèle [44].

## 4.3 Méthodologie

Après la phase de préparation, les données sont structurées de manière à pouvoir être utilisées pour entraîner un modèle d'apprentissage. Plusieurs approches basées sur l'apprentissage profond peuvent être appliquées. Dans ce travail, nous avons retenu l'architecture des CNNs.

### 4.3.1 Architecture du modèle

Les CNNs se révèlent particulièrement efficaces dans le traitement des séries temporelles. Grâce à leur aptitude à extraire automatiquement des caractéristiques pertinentes à partir de données brutes, ils peuvent être utilisés pour résoudre des tâches de prédiction dans ce domaine [45, 46, 47].

#### 4.3.1.1 Modèle proposé

Dans le cadre de l'analyse de séries temporelles multi-variées, les CNNs sont capables de traiter efficacement des séquences d'observations passées en apprenant à identifier les caractéristiques les plus pertinentes pour prédire les valeurs futures.

Le modèle que nous avons conçu repose sur une architecture séquentielle composée des couches suivantes:

- **Couche de convolution 1D (Conv1D)**: cette première couche applique 16 filtres de taille 3 à l'entrée, avec une fonction d'activation ReLU. Elle permet de détecter les motifs locaux dans la série temporelle tout en limitant le nombre de paramètres, ce qui contribue à une meilleure efficacité computationnelle.
- **Couche de max pooling (MaxPooling1D)**: une opération de regroupement est effectuée avec une fenêtre de taille 2 afin de réduire la dimensionnalité des données, en conservant uniquement les caractéristiques les plus significatives extraites par la convolution.

- **Couche de convolution 1D (Conv1D)**: cette seconde couche applique 32 filtres de taille 5 à l'entrée, avec une fonction d'activation ReLU.
- **Couche de max pooling (MaxPooling1D)**
- **Couche Flatten**: les données issues des couches précédentes sont aplaties en un vecteur unidimensionnel, ce qui permet leur traitement par les couches entièrement connectées.
- **Couche dense (Fully Connected)**: cette couche contient 64 neurones activés par la fonction ReLU. Elle est chargée d'apprendre des représentations de plus haut niveau à partir des caractéristiques extraites.
- **Couche de sortie**: constituée d'un seul neurone activé par ReLU, elle permet de produire une prédiction en sortie.

Le diagramme 4.6 présente une vue d'ensemble de l'architecture du modèle utilisé.

#### 4.3.1.2 Modélisation

Pour la mise en œuvre du modèle CNN proposé, nous avons utilisé le langage de programmation Python, accompagné de bibliothèques spécialisées dans l'apprentissage automatique et profond. La construction du modèle suit une démarche séquentielle bien structurée, que nous détaillons dans cette section.

La première étape consiste en l'importation des bibliothèques nécessaires à la conception, à l'entraînement et à l'évaluation du réseau de neurones convolutif. Cette phase d'initialisation inclut l'importation de TensorFlow et Keras — deux bibliothèques de référence présentées dans l'Annexe A.2 — ainsi que de l'optimiseur Adam, dont les principes ont été introduits dans le Chapitre 3.

Après avoir importé les bibliothèques nécessaires, la construction du modèle s'effectue à travers une architecture linéaire de couches, où la sortie de chaque couche est directement transmise en entrée à la suivante. Cette structure est mise en place à l'aide de Keras, une bibliothèque réputée pour sa simplicité d'utilisation. Son interface intuitive facilite la création rapide de modèles, tout en offrant une grande flexibilité pour ajouter, supprimer ou modifier des couches. Cette souplesse permet d'expérimenter facilement différentes configurations afin d'évaluer leur impact sur les performances du modèle.

Suite à l'initialisation du modèle, la première couche convolutive est ajoutée. Il est important de souligner que, pour cette couche initiale, la définition explicite de la forme des données en entrée est nécessaire, incluant notamment la taille de la séquence temporelle ainsi que le nombre de caractéristiques par pas de temps.

À la suite des couches convolutives, une opération de mise en commun maximale (Max-Pooling) est intégrée. Cette étape est suivie par l'ajout d'une couche d'aplatissement (Flat-

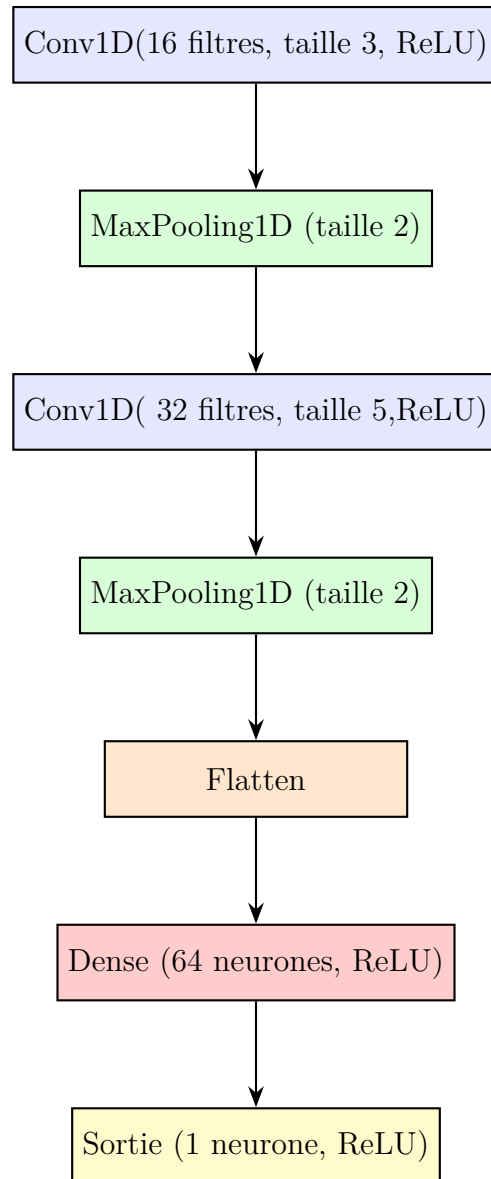


FIGURE 4.6 – Architecture du modèle CNN 1D pour séries temporelles

ten), permettant de transformer la sortie multidimensionnelle en un vecteur unidimensionnel adapté aux couches entièrement connectées.

Après avoir aplati la sortie issue des couches précédentes, on insère des couches entièrement connectées afin de combiner linéairement les caractéristiques extraites, dans le but d'aboutir à une prédiction. Une première couche dense de 64 neurones est ajoutée, avec la fonction d'activation ReLU pour introduire de la non-linéarité. Enfin, une couche de sortie contenant un seul neurone est utilisée pour fournir la prédiction finale, correspondant à une valeur unique.

La compilation du modèle consiste à spécifier la fonction de perte ainsi que l'algorithme

d'optimisation. Dans ce cas, la fonction de perte utilisée est l'erreur quadratique moyenne (EQM), qui évalue l'écart entre les prédictions et les valeurs réelles. L'optimiseur choisi est Adam, configuré avec un taux d'apprentissage de 0,0001, permettant d'ajuster progressivement les poids du modèle afin de réduire l'erreur. Un taux d'apprentissage trop élevé peut entraîner une instabilité de l'apprentissage, tandis qu'un taux trop faible peut ralentir considérablement la convergence du modèle.

Une présentation détaillée de l'architecture du modèle ainsi que de l'ensemble de ses paramètres est fournie dans le Tableau [4.2](#).

TABLE 4.2 – Liste des paramètres du modèle CNN

Catégorie	Paramètre	Valeur
<b>Couche Convolutive</b>	Type de convolution	Conv1D
	Nombre de couches convolutives	1
	Nombre de filtres	16
	Taille du filtre	3
	Fonction d'activation	ReLU
	Nombre de paramètres	352
<b>Couche de Pooling</b>	Type de pooling	MaxPooling1D
	Taille de la fenêtre de pooling	2
<b>Couche Convolutive</b>	Type de convolution	Conv1D
	Nombre de couches convolutives	16
	Nombre de filtres	32
	Taille du filtre	5
	Fonction d'activation	ReLU
	Nombre de paramètres	2592
<b>Couche de Pooling</b>	Type de pooling	MaxPooling1D
	Taille de la fenêtre de pooling	2
<b>Couche Flatten</b>	Nombre de couches Flatten	1
<b>Couche Fully Connected</b>	Nombre de neurones	64
	Fonction d'activation	ReLU
	Nombre de paramètres	43072
<b>Couche Fully Connected</b>	Nombre de neurones	1
	Fonction d'activation	ReLU
	Nombre de paramètres	65
<b>Nombre total de paramètres</b>		<b>64080</b>

### 4.3.2 Évaluation des performances

L'évaluation des modèles constitue une étape essentielle dans le processus de modélisation. Elle permet non seulement d'optimiser les hyperparamètres d'apprentissage, mais aussi de comparer les performances relatives de plusieurs modèles, en vue de sélectionner celui offrant les meilleurs résultats pour la prédiction de la consommation énergétique [48], [49].

Divers indicateurs sont utilisés pour mesurer la qualité des prédictions dans les modèles appliqués aux séries temporelles. Parmi les plus courants figurent: l'Erreur Absolue Moyenne (EAM), l'Erreur Quadratique Moyenne (EQM), et la Racine de l'Erreur Quadratique Moyenne (REQM). Ces métriques classiques permettent d'évaluer l'écart moyen entre les valeurs prédites et les observations réelles.

En complément, l'Erreur Absolue Moyenne en Pourcentage (EAMP) est souvent utilisée pour exprimer l'erreur en termes relatifs, ce qui la rend plus facilement interprétable. Par ailleurs, le coefficient de détermination  $R^2$  fournit une mesure de la qualité de l'ajustement du modèle, en indiquant dans quelle proportion les variations des données observées sont expliquées par les prédictions du modèle [50], [51].

Une description succincte de ces métriques d'évaluation est proposée ci-dessous:

- **EAM, EQM, REQM:** Ces trois indicateurs sont les plus fréquemment utilisés dans les tâches de régression. Ils sont particulièrement utiles pour comparer les performances de plusieurs approches appliquées à un même ensemble de données [52], [53]. Leurs formulations mathématiques sont données dans les Équations 4.5, 4.6 et 4.7.

$$\text{EAM} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.5)$$

$$\text{EQM} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4.6)$$

$$\text{REQM} = \sqrt{\text{MSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4.7)$$

- **EAMP:** Cette métrique peut être considérée comme une extension du MAE, dans la mesure où elle élimine la dépendance à l'échelle des données. En exprimant l'erreur sous forme de pourcentage, elle fournit une évaluation intuitive de l'erreur relative. L'EAMP est donc particulièrement utile pour comparer les performances de modèles sur différents ensembles de données [54]. Sa formule mathématique est présentée dans l'Équation 4.8.

$$\text{EAMP} = \frac{1}{n} \sum_{i=1}^n \frac{(y_i - \hat{y}_i)}{y_i} \times 100 \quad (4.8)$$

- **$R^2$ :** Cette métrique, également appelée coefficient de détermination, permet d'évaluer dans quelle mesure la variance de la variable dépendante est expliquée par le modèle à partir de la variance de la variable indépendante. Une valeur élevée de  $R^2$  indique une forte corrélation entre les valeurs prédites et les observations réelles [55]. L'expression

mathématique de cette mesure est donnée dans l'Équation 4.9.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4.9)$$

Dans les équations précédentes,  $y_i$  représente la valeur réelle,  $\hat{y}_i$  la valeur prédite associée à l'indice  $i$ ,  $\bar{y}$  la moyenne des valeurs observées, et  $n$  le nombre total de données.

## 4.4 Résultats expérimentaux et discussion

Contrairement à d'autres travaux qui explorent diverses structures de réseaux neuronaux telles que les LSTM, GRU ou des architectures convolutives complexes nous avons opté dans cette étude pour l'utilisation exclusive d'un modèle basé sur deux couches convolutives. Ce choix repose sur la volonté de maintenir une architecture à la fois efficace sur le plan du temps d'apprentissage, et suffisamment performante pour capter les dynamiques des séries temporelles liées à la consommation d'énergie et aux variables météorologiques.

L'apprentissage du modèle a été réalisé sur 100 époques avec une taille de lot de 96, en utilisant l'environnement Google Colab, qui offre une infrastructure cloud adaptée à l'entraînement de réseaux de neurones profonds.

la Figure 4.7 illustre la variation de la fonction de perte, mesurée par l'EQM, tout au long des 100 itérations d'apprentissage. Cette courbe, tracée à la fois pour les données d'entraînement et de validation, offre un aperçu clair de l'évolution du processus d'apprentissage et de la capacité du modèle à généraliser sur des données inédites.




FIGURE 4.7 – La variation de la fonction de perte

Dès les premières époques, on observe une diminution marquée de la fonction de perte sur les données d'apprentissage, montrant la capacité du modèle à s'ajuster rapidement aux caractéristiques de la base de données. Par la suite, cette baisse s'atténue progressivement

jusqu'à atteindre une phase de stabilisation, indiquant que le modèle approche un minimum local de l'erreur.

La courbe correspondant aux données de validation présente une évolution parallèle à celle de l'apprentissage, traduisant une bonne capacité de généralisation du modèle. L'absence de divergence marquée ou de hausse soudaine de cette courbe suggère que le phénomène de surapprentissage (overfitting) est limité.

le Tableau 4.3 présente les résultats de l'évaluation du modèle CNN sur les ensembles d'apprentissage, de validation et de test. Les métriques retenues incluent l'EQM, l'EAM, l'EQM, l'EAMP, ainsi que le coefficient de détermination ( $R^2$ ).

Ces indicateurs permettent de juger la précision du modèle sur l'ensemble du processus, depuis l'apprentissage jusqu'à la prédiction finale. le Tableau inclut également le temps total d'apprentissage, mesuré à environ secondes, ce qui témoigne de la rapidité du processus d'apprentissage.

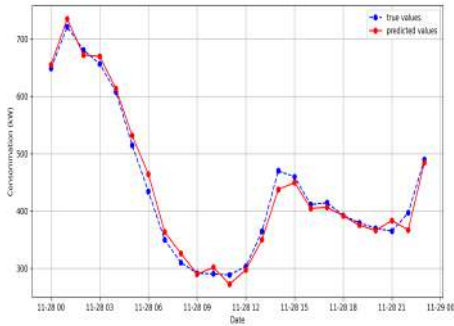
TABLE 4.3 – Mesures de performance pour les prédictions du modèle

<b>Dataset</b>	<b>Métriques</b>	<b>Conv1D</b>
<b>Train</b>	MAE (kW)	13,524
	EQM (kW <sup>2</sup> )	192,890
	REQM (kW)	10,260
	EAMP (%)	3,151
	$R^2$	0,997
<b>Validation</b>	MAE (kW)	15,911
	EQM (kW <sup>2</sup> )	253,145
	REQM (kW)	12,089
	EAMP (%)	3,783
	$R^2$	0,994
<b>Test</b>	MAE (kW)	18,111
	EQM (kW <sup>2</sup> )	327,991
	REQM (kW)	13,776
	EAMP (%)	4,145
	$R^2$	0,995
Temps d'apprentissage (s)		205.24


Les résultats montrent que le modèle offre de bonnes performances sur les trois ensembles de données, avec des écarts limités entre les erreurs d'entraînement et de test, ce qui souligne sa capacité à généraliser correctement sans surapprentissage.

la Figure 4.8 met en évidence la performance du modèle en comparant les valeurs réelles de consommation d'énergie (en bleu) aux valeurs prédites (en jaune), sur une période de un, deux, trois et quatre jours respectivement de l'ensemble de test. Cette visualisation permet


d'évaluer la précision temporelle du modèle, notamment sa capacité à suivre les fluctuations rapides ainsi que les tendances globales de la demande énergétique.




(a) Vue globale des prédictions sur plusieurs jours.



(b) Visualisation sur un jour



(c) Visualisation sur deux jours consécutifs



(d) Visualisation sur quatre jours consécutifs

FIGURE 4.8 – Comparaison entre les valeurs réelles (en bleu) et les valeurs prédites (en rouge) de la consommation énergétique à l'aide du modèle CNN 1D.

## 4.5 Conclusion

Ce chapitre a présenté une analyse approfondie de la prédiction des séries temporelles à travers l'utilisation de l'apprentissage profond, notamment via les CNNs. Une exploration rigoureuse de l'ensemble de données, incluant sa description, son analyse ainsi que les étapes de prétraitement, a permis de dégager des informations essentielles sur les caractéristiques et les structures sous-jacentes des données temporelles.

La section méthodologique a détaillé l'architecture du modèle CNN développé pour cette tâche de prédiction, mettant en avant sa capacité à modéliser efficacement les dépendances temporelles complexes.

Enfin, l'évaluation des performances du modèle a démontré son aptitude à anticiper avec précision les tendances futures, comme le montre les résultats obtenus.

# Mise en Œuvre Embarquée sur la Plateforme Raspberry Pi

## Sommaire

---

<b>5.1</b>	<b>Introduction</b>	<b>78</b>
<b>5.2</b>	<b>Présentation du Raspberry</b>	<b>78</b>
<b>5.3</b>	<b>Aspect matériel du Raspberry Pi</b>	<b>79</b>
5.3.1	Architecture d'un Raspberry Pi	80
5.3.2	Principaux composants du Raspberry Pi 4 B+	80
5.3.3	Fonctionnement et avantages du Raspberry Pi	81
<b>5.4</b>	<b>Aspect logiciel du Raspberry Pi</b>	<b>83</b>
5.4.1	Système d'exploitation et installation	83
5.4.2	Contrôle à distance avec VNC et SSH	85
<b>5.5</b>	<b>Conception du système embarqué</b>	<b>87</b>
5.5.1	Organigramme du système	87
5.5.2	Bibliothèques et outils utilisés	87
<b>5.6</b>	<b>Interface utilisateur de simulation (SmartSOLEM)</b>	<b>89</b>
5.6.1	Présentation de l'interface	89
5.6.2	Paramétrage et affichage de la simulation	90
<b>5.7</b>	<b>Conclusion</b>	<b>93</b>

---

## 5.1 Introduction

Dans un contexte de transition énergétique, la gestion intelligente de la consommation devient essentielle. Ce chapitre présente la mise en œuvre d'un système de prédiction basé sur un réseau de neurones convolutif (CNN), déployé sur un Raspberry Pi. Grâce à sa compacité et ses performances, cette plateforme permet d'optimiser l'usage de l'énergie solaire et de réduire le recours au réseau électrique.

## 5.2 Présentation du Raspberry

Le Raspberry Pi, souvent abrégé RPi, est un ordinateur monocarte (Single Board Computer (SBC) compact, développé par la Raspberry Pi Foundation au Royaume-Uni, et lancé le 29 février 2012. Conçu initialement dans un but éducatif, il visait à initier les enfants à la programmation et aux compétences informatiques de base. Cependant, son accessibilité et sa polyvalence en ont rapidement fait un outil apprécié dans les domaines de l'électronique embarquée, de l'Internet of Things (IoT) et de la domotique.

Illustré dans la Figure 5.1, il fonctionne sous une distribution Linux, principalement Debian via l'environnement Raspberry Pi OS (anciennement Raspbian), avec une interface graphique légère appelée LXDE. Il dispose de ports USB permettant de connecter un clavier et une souris, ainsi qu'une sortie HDMI pour l'affichage sur un écran ou téléviseur. Les écrans dotés uniquement d'une entrée VGA ne sont pas compatibles, sauf via un convertisseur HDMI-VGA ou HDMI-DVI pour les écrans DVI.



FIGURE 5.1 – Raspberry Pi 4 B+

Malgré sa taille réduite, équivalente à celle d'une carte bancaire, le Raspberry Pi se comporte comme un véritable ordinateur. Il peut exécuter une suite bureautique, lire des fichiers multimédias, héberger des applications, voire des jeux. Son coût abordable s'explique par une conception minimaliste : il est vendu sans boîtier ni alimentation. L'utilisateur doit

se procurer une alimentation externe de 5V via un port micro-USB, semblable à celle utilisée pour les smartphones, mais souvent avec une intensité de sortie plus élevée pour garantir la stabilité du système.

Le Raspberry Pi est aujourd'hui largement utilisé dans des contextes professionnels, énergétiques, industriels, scientifiques et domestiques, tels que:

- **Surveillance énergétique industrielle (IoT en temps réel)**: une étude scientifique présente un système de surveillance énergétique en temps réel, illustré dans la Figure 5.2, déployé dans un environnement industriel et reposant sur un Raspberry Pi. Ce dispositif permet de mesurer et d'analyser la consommation d'énergie avec précision. Ce travail met en avant le Raspberry Pi comme une solution idéale pour ce type d'application, en raison de son faible coût, de sa flexibilité et de sa fiabilité [2].



FIGURE 5.2 – La sortie graphique de [2]

- **Supervision de micro grids photovoltaïques + stockage**/ la Figure 5.3 montre un projet de recherche qui a démontré la faisabilité d'un système SCADA open source basé sur Raspberry Pi pour le pilotage d'une micro grille intégrant des panneaux photovoltaïques, des batteries, des onduleurs et des charges. La communication entre les composants est assurée via le protocole Modbus, permettant l'acquisition de données, le contrôle des équipements et la visualisation en temps réel des paramètres du système [3].

## 5.3 Aspect matériel du Raspberry Pi

Sur le plan matériel, le Raspberry Pi se distingue par une architecture compacte intégrant processeur, mémoire, stockage et interfaces d'entrée/sortie. Ses broches General Purpose Input/Output (GPIO) permettent de connecter divers composants électroniques pour piloter ou surveiller un système en temps réel.

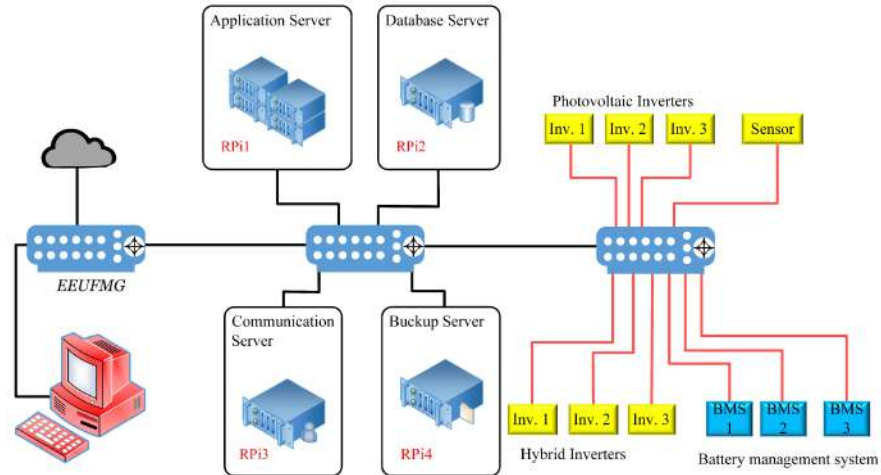


FIGURE 5.3 – Schéma de l'architecture serveur proposée pour le système de supervision, présentant le système mis en œuvre avec les Raspberry Pi, les onduleurs et les batteries [3]

### 5.3.1 Architecture d'un Raspberry Pi

Le Raspberry Pi est un nano-ordinateur monocarte compact, comparable à une carte mère miniature, intégrant l'ensemble des composants nécessaires à son fonctionnement. Il permet de connecter des périphériques d'entrée/sortie, de stockage, ainsi que des interfaces réseau, ce qui en fait un véritable ordinateur à part entière. Plusieurs modèles sont disponibles, notamment les versions A (plus simples) et B (plus complètes). Le modèle B se distingue par la présence d'un port Ethernet et de ports Universal Serial Bus (USB) supplémentaires. Dans le cadre de ce projet, nous avons utilisé un Raspberry Pi 4 Model B+, l'un des modèles les plus puissants de la gamme.

### 5.3.2 Principaux composants du Raspberry Pi 4 B+

Pour mieux comprendre le fonctionnement du Raspberry Pi 4 B+, nous présentons d'abord ses principaux composants.

- **Processeur (CPU)/Processeur graphique (GPU)**: le Pi 4 B+ est équipé d'un SoC Broadcom BCM2711, intégrant un processeur ARM Cortex-A72 quad-core 64 bits cadencé à 1.5 GHz, ainsi qu'un GPU VideoCore VI pour les traitements graphiques.
- **Mémoire RAM**: disponible en plusieurs configurations: 1 Go, 2 Go ou 4 Go de RAM LPDDR4.
- **Stockage**: le système d'exploitation est installé sur une carte microSD, insérée dans un lecteur dédié. Elle fait office de disque dur principal.

- **Affichage**: deux ports micro-HDMI permettent de connecter jusqu'à deux écrans en haute définition.
- **Alimentation**: le Raspberry Pi 4 est alimenté via un port USB Type-C, nécessitant une alimentation stable de 5V/3A.
- **Broches GPIO** : le Raspberry Pi comprend 40 broches GPIO, utilisées pour interfacer des composants électroniques (capteurs, LED, relais, etc.). Ces broches sont essentielles pour les applications en domotique, robotique et automatisation.
- **Connectivité réseau et sans fil**; le Raspberry Pi 4 B+ est équipé du Wi-Fi 802.11ac bi-bande (2,4 GHz et 5 GHz), du Bluetooth 5.0 BLE, ainsi que d'un port Ethernet Gigabit pour des connexions filaires rapides.
- **Connectivité USB**: le Raspberry Pi 4 B+ dispose de 2 ports USB 3.0 et 2 ports USB 2.0 pour la connexion de périphériques externes.
- **Audio**: une sortie audio jack 3,5 mm est disponible pour la connexion de haut-parleurs ou écouteurs.

Les modèles Raspberry Pi 2B, 3B, 3B+, 4B, Pi zéro 2, Pi Pico et Pi 5 diffèrent principalement par leur processeur, la quantité de RAM, la présence de Wi-Fi/Bluetooth, la connectique USB et la capacité réseau comme le montre le Tableau 5.1.

### 5.3.3 Fonctionnement et avantages du Raspberry Pi

Le Raspberry Pi fonctionne à partir d'un système sur puce (SoC), qui regroupe sur un seul composant le processeur (CPU), le processeur graphique (GPU), la mémoire vive (RAM), ainsi que les interfaces USB, Ethernet et autres. Contrairement à un ordinateur traditionnel, il ne dispose ni de disque dur intégré ni de lecteur optique. Cependant, grâce à une carte microSD servant de support de stockage principal, il réunit tous les éléments essentiels pour exécuter un système d'exploitation et fonctionner comme un ordinateur complet.

- Faible coût, idéal pour les étudiants et projets à petit budget
- Taille compacte, facile à intégrer dans des systèmes embarqués
- Consommation d'énergie très faible, adapté aux solutions autonomes
- Polyvalence dans les applications : domotique, robotique, IoT, serveur, etc.
- Compatible avec plusieurs systèmes Linux (Raspbian, Ubuntu, etc.)
- Supporte plusieurs langages de programmation (Python, C/C++, Scratch...)
- Facile à utiliser pour les débutants en programmation et électronique

TABLE 5.1 – Comparaison des différents modèles de Raspberry Pi

Modèle	RPI 2 B	RPI 3 B	RPI 3 B+	RPI 4 B	RPI 400	RPI Zero 2 W	RPI Pico	RPI 5
SoC	BCM2836	BCM2837	BCM2837B0	BCM2711	BCM2711 (1.8 GHz)	BCM2710A1	RP2040	BCM2712
Processeur (CPU)	4 × Cortex-A7, 900 MHz	4 × Cortex-A53, 1.2 GHz	4 × Cortex-A53, 1.4 GHz	4 × Cortex-A72, 1.5 GHz	4 × Cortex-A72, 1.8 GHz	4 × Cortex-A53, 1 GHz	2 × Cortex-M0+, 133 MHz	4 × Cortex-A76, 2.4 GHz
Mémoire vive (RAM)	1 Go	1 Go	1 Go	1-8 Go	4 Go	512 Mo	264 Ko SRAM	4/8 Go LPDDR4X
GPU	VideoCore IV	VideoCore IV	VideoCore IV	VideoCore VI	VideoCore VI	VideoCore IV	—	VideoCore VII
Ports USB	4 × USB 2.0	4 × USB 2.0	4 × USB 2.0	2 × USB 3.0 + 2 × USB 2.0	3 ports (dont 2 × USB 3.0)	1 × micro-USB OTG	1 × micro-USB (data/debug)	2 × USB 3.0 + 2 × USB 2.0
Réseau Ethernet	100 Mb/s	100 Mb/s	Gigabit (300 Mb/s)	Gigabit (1 Gb/s)	Gigabit Ethernet	Non	Non	Gigabit Ethernet
PoE (via HAT)	Non	Non	Oui	Oui	Oui	Non	Non	Oui
Wi-Fi	Non	802.11n	802.11ac (Dual Band)	802.11ac (Dual Band)	802.11ac	802.11n	Non	802.11ac
Bluetooth	Non	4.1	4.2 BLE	5.0 BLE	5.0 BLE	4.2 BLE	Non	5.0 BLE
Sortie vidéo	HDMI/3.5 mm/DSI	HDMI/3.5 mm/DSI	HDMI/3.5 mm/DSI	2 × micro-HDMI/DSI	mini-HDMI/DSI	mini-HDMI	GPIO (UART)	2 × micro-HDMI
Sortie audio	HDMI/3.5 mm/I <sup>2</sup> S	HDMI/3.5 mm/I <sup>2</sup> S	HDMI/3.5 mm/I <sup>2</sup> S	HDMI/3.5 mm/I <sup>2</sup> S	HDMI/3.5 mm/I <sup>2</sup> S	HDMI (adaptateur)	PWM/FS (GPIO)	HDMI / FS
Entrée caméra	15 broches CSI	15 broches CSI	15 broches CSI	15 broches CSI	15 broches CSI	Oui (CSI)	Non	22 broches CSI
Broches GPIO	40	40	40	40	78 (40 compatibles)	40	26	40
Stockage	microSD	microSD	microSD	microSD	microSD	microSD	Mémoire flash	microSD / PCIe (NVMe)

## 5.4 Aspect logiciel du Raspberry Pi

Le software du Raspberry Pi comprend principalement le système d'exploitation Raspberry Pi OS, basé sur Debian, qui assure la gestion des ressources et l'exécution des applications. Il permet d'utiliser la carte en mode graphique ou en ligne de commande, avec des outils comme VNC ou SSH pour un contrôle à distance.

### 5.4.1 Système d'exploitation et installation

Pour faire fonctionner une carte Raspberry Pi, l'installation d'un système d'exploitation est indispensable. Plusieurs options sont disponibles, allant des systèmes polyvalents (bureautique, développement, multimédia) aux distributions spécialisées pour les applications embarquées. Le système le plus couramment utilisé et officiellement recommandé est Raspbian (aujourd'hui appelé Raspberry Pi OS), basé sur la distribution Debian, reconnu pour sa légèreté, sa stabilité et sa compatibilité avec les composants de la carte.

Raspbian, désormais appelé Raspberry Pi OS, est une distribution Linux dérivée de Debian Wheezy, spécialement optimisée pour le Raspberry Pi. Officiellement soutenu par la Fondation Raspberry Pi, il constitue le système d'exploitation recommandé pour la majorité des utilisateurs. Il peut être utilisé en mode console, nécessitant une maîtrise des commandes Linux, ou en mode graphique, offrant une interface utilisateur conviviale et intuitive, similaire à celle de Windows ou macOS.

Pour installer Raspbian (Raspberry Pi OS), rendez-vous sur le site officiel de la Fondation Raspberry Pi : <https://www.raspberrypi.com/software/operating-systems/> et télécharger l'image ISO correspondant à vos besoins parmi les versions proposées:

- Raspberry Pi OS avec bureau et logiciels recommandés
- Raspberry Pi OS avec bureau
- Raspberry Pi OS Lite (sans interface graphique)

Si vous envisagez d'utiliser votre Raspberry Pi comme un ordinateur personnel, optez pour une version avec interface graphique. En revanche, pour un usage embarqué ou nécessitant peu de ressources, la version Lite est plus adaptée.

Une fois l'image ISO téléchargée, il est nécessaire d'utiliser un outil pour la transférer sur une carte microSD. Le moyen le plus simple et recommandé est d'utiliser Raspberry Pi Imager, un logiciel gratuit compatible avec Windows, macOS et Ubuntu. Téléchargez-le depuis le site officiel: <https://www.raspberrypi.com/software/> Installez-le en suivant les instructions correspondant à votre système d'exploitation, puis utilisez-le pour sélectionner l'image de Raspbian et la graver sur la carte SD.

Avant d'installer le système, la carte microSD doit impérativement être formatée en FAT32, format requis par le Raspberry Pi au démarrage. Pour cela, utilisez Raspberry Pi Imager :

1. Lancez l'application.
2. Dans le menu « Système d'exploitation », sélectionnez l'option « Formatage » pour effectuer un formatage.
3. Dans le menu « Stockage », choisissez votre carte microSD.
4. Cliquez sur « Écrire » pour lancer le formatage.

**Attention** : cette opération efface toutes les données présentes sur la carte. Veillez à sauvegarder les fichiers importants avant de commencer.

Après avoir formaté la carte microSD, suivez les étapes ci-dessous pour y installer Raspbian (voir la Figure 5.4).



FIGURE 5.4 – Raspberry Pi Imager

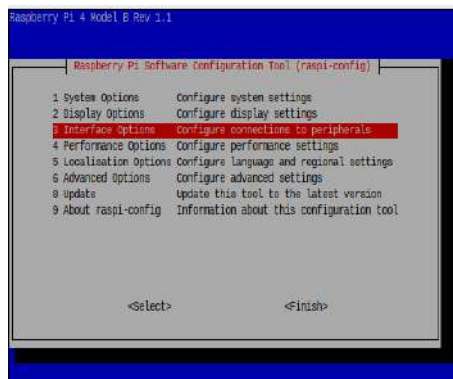
1. Lancez Raspberry Pi Imager
2. Cliquez sur « Choisir le système d'exploitation », puis sélectionnez « Utiliser une image personnalisée » pour importer l'image ISO précédemment téléchargée.
3. Sélectionnez votre carte microSD comme support de stockage.
4. Cliquez sur « Écrire » pour lancer l'installation.

Après quelques minutes, la carte SD est prête à l'emploi. Insérez-la dans le Raspberry Pi, connectez un écran, un clavier, et branchez l'alimentation. Le système démarre automatiquement. Une interface de configuration initiale s'affiche afin de finaliser l'installation (langue, mot de passe, réseau, mise à jour, etc.).

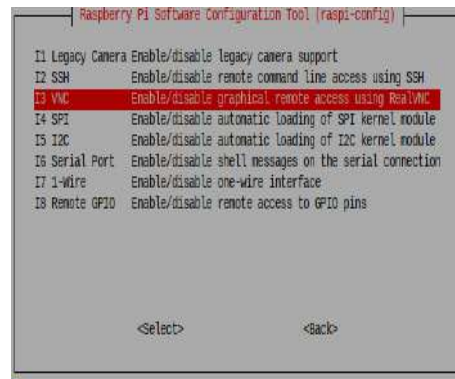
### 5.4.2 Contrôle à distance avec VNC et SSH

Le VNC est une solution de contrôle à distance qui permet d'accéder à l'interface graphique du Raspberry Pi depuis un autre ordinateur, sans avoir besoin d'un écran, d'un clavier ou d'une souris connectée à la carte. Grâce à VNC Viewer, vous pouvez piloter votre Raspberry Pi en utilisant les tapes suivantes:

- Ouvrez un terminal sur le Raspberry Pi.
- Tapez la commande suivante pour accéder à la configuration: `sudo raspi-config`
- Dans le menu, allez à Interface Options comme le montre la Figure 5.5a, puis sélectionnez VNC cela est représenté dans la Figure 5.5b et activez-le (Voir figure 5.5c).
- Quittez le menu avec <Finish> comme le montre la Figure 5.5d.
- Téléchargez et installez VNC Viewer depuis <https://www.realvnc.com>.
- Lancez l'application, saisissez l'adresse IP du Raspberry Pi, puis connectez-vous avec les identifiants .



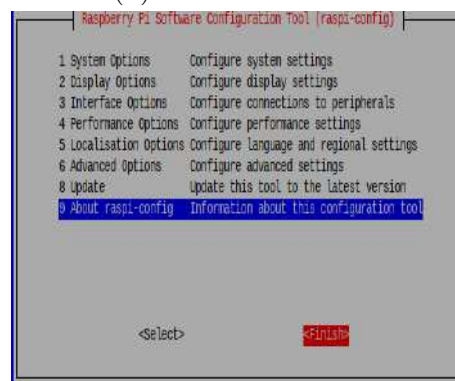
(a) Interface Options



(b) Choix de VNC



(c) Activer VNC




(d) Quitter avec Finish

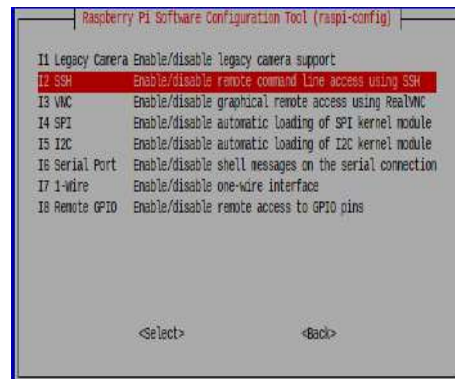
FIGURE 5.5 – Étapes pour activer VNC sur Raspberry Pi

Le SSH est un protocole qui permet de contrôler le Raspberry Pi à distance, via une connexion sécurisée en ligne de commande, depuis un autre ordinateur. Cela évite d'avoir besoin d'un écran, clavier et souris connectés directement à la Raspberry Pi. Grâce au SSH, vous pouvez accéder votre Raspberry Pi en utilisant les étapes suivantes:

- Ouvrez un terminal sur le Raspberry Pi.
- Tapez la commande suivante pour accéder à la configuration: `sudo raspi-config`
- Allez dans Interface Options comme le montre la Figure 5.6a, puis sélectionnez SSH comme illustré dans la Figure 5.6b et choisissez Yes pour l'activer (Voir Figure 5.6c).
- Quittez avec `<Finish>` comme représenté dans la Figure 5.6d.
- Après avoir configuré le service SSH, il est possible de télécharger PuTTY par le site web <https://www.putty.org/> afin de contrôler le système à distance.



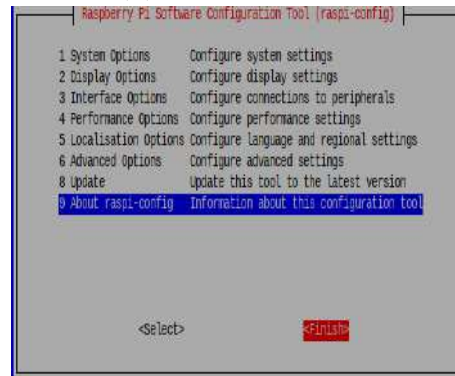
(a) Interface Options



(b) Choix de SSH



(c) Activer SSH



(d) Quitter avec Finish

FIGURE 5.6 – Étapes pour activer SSH sur Raspberry Pi

Après avoir installé le système et terminé la configuration initiale, le Raspberry Pi redémarre et affiche l'interface graphique du système Raspbian. Cette interface à celle présentée dans la Figure 5.7.



FIGURE 5.7 – Interface graphique de Raspbian après démarrage

## 5.5 Conception du système embarqué

### 5.5.1 Organigramme du système

L'organigramme ci-dessous (Figure 5.8) montre comment le système décide quelle source d'énergie utiliser à chaque instant : panneau solaire, batterie ou réseau. Le principe est simple :

- Si le soleil produit assez d'énergie, on l'utilise directement. S'il en reste, on recharge la batterie.
- Si la production solaire ne suffit pas, la batterie prend le relais si elle est suffisamment chargée. Sinon, on complète avec le réseau.
- En absence de soleil, le système vérifie si la batterie peut fournir l'énergie. Si ce n'est pas le cas, le réseau est utilisé.

Cette logique permet d'optimiser l'usage de l'énergie solaire et de limiter le recours au réseau électrique.

### 5.5.2 Bibliothèques et outils utilisés

Nous avons utilisé les bibliothèques suivantes :

- **TensorFlow/Keras** : Ces bibliothèques ont été utilisées pour la prédiction de la consommation énergétique. TensorFlow, développé par Google, est une plateforme puissante de machine learning, tandis que Keras offre une interface intuitive pour la conception et l'exécution de réseaux de neurones. Ensemble, elles permettent de charger un modèle préalablement entraîné et de générer des prédictions précises à partir de données climatiques et énergétiques.

---

**Algorithm:** Gestion énergétique d'un panneau solaire avec batterie et réseau

---

**Entrée:** Production solaire  $P$ ,  
 Consommation électrique  $C$ ,  
 État de la batterie  $B$ ,  
 Capacité max batterie  $B_{\max}$ ,  
 Seuil batterie minimal  $B_{\text{seuil}}$

**Sortie :** Source d'énergie utilisée, batterie chargée ou non

```

(1) if  $P > 0$  then
(2)   | if  $P \geq C$  then
(3)   |   | Utiliser production solaire directement
(4)   |   |  $S \leftarrow P - C$ 
(5)   |   | if  $B < B_{\max}$  then
(6)   |   |   | Charger la batterie avec  $S$ 
(7)   |   |   | end
(8)   |   |   | else
(9)   |   |   |   | Ne rien faire (batterie pleine)
(10)  |   |   |   | end
(11)  |   |   | end
(12)  |   | else
(13)  |   |   |  $D \leftarrow C - P$ 
(14)  |   |   | if  $B \geq D$  then
(15)  |   |   |   | Utiliser la batterie pour combler le déficit
(16)  |   |   |   | end
(17)  |   |   |   | else
(18)  |   |   |   |   | Utiliser batterie + réseau pour combler le déficit
(19)  |   |   |   |   | end
(20)  |   |   |   | end
(21)  |   |   | end
(22)  |   | else
(23)  |   |   | if  $B > B_{\text{seuil}}$  then
(24)  |   |   |   | Utiliser la batterie et compenser avec le réseau si nécessaire
(25)  |   |   |   | end
(26)  |   |   |   | else
(27)  |   |   |   |   | Utiliser uniquement le réseau
(28)  |   |   |   |   | end
(29)  |   |   |   | end

```

---

FIGURE 5.8 – Organigramme de la gestion énergétique

- **NumPy, Pandas** : NumPy et Pandas ont été des outils essentiels pour la préparation et le traitement des données du projet. NumPy, bibliothèque de calcul scientifique, a permis de manipuler efficacement des tableaux numériques et de réaliser des opérations mathématiques complexes (moyennes, normalisations, conversions de formats) de

manière rapide et précise. De son côté, Pandas a été utilisée pour la gestion, la structuration et l'analyse des jeux de données, notamment pour la lecture des fichiers CSV, le filtrage des colonnes utiles ainsi que le traitement des valeurs manquantes. Grâce à leur combinaison, le jeu de données a été préparé de manière optimale pour l'entraînement du modèle de prédiction.

- **Matplotlib, Seaborn** : Matplotlib et Seaborn ont été utilisées conjointement pour la visualisation des données du projet. Matplotlib a permis de créer des courbes et des graphiques détaillés illustrant l'évolution de la consommation énergétique, de la production solaire, du niveau de charge de la batterie ainsi que de l'utilisation du réseau, offrant ainsi une vision précise du comportement du système à chaque instant. Seaborn, quant à elle, a été employée pendant la phase d'analyse exploratoire des données pour produire des représentations plus esthétiques et lisibles, facilitant la compréhension des corrélations et des tendances entre les différentes variables climatiques et énergétiques.
- **PyQt5** : PyQt5 est une bibliothèque permettant de développer des interfaces graphiques (GUI) en Python. Elle a été utilisée pour concevoir une interface utilisateur interactive facilitant la sélection des paramètres de simulation, le lancement du modèle de prédiction, ainsi que l'affichage des résultats sous forme de graphiques directement intégrés à l'application.
- **Raspberry.GPIO** (optionnel) : RPI.GPIO est une bibliothèque permettant de contrôler les broches GPIO du Raspberry Pi. Dans ce projet, elle a été utilisée de manière expérimentale pour piloter des LEDs, afin d'indiquer visuellement la disponibilité de l'énergie solaire, l'activation de la batterie ainsi que le basculement vers le réseau électrique.

## 5.6 Interface utilisateur de simulation (SmartSolEM)

### 5.6.1 Présentation de l'interface

L'interface graphique du système SmartSol Energy management (SmartSolEM), conçue avec PyQt5, permet de simuler en temps réel la gestion énergétique d'une habitation dotée de panneaux solaires, de batteries et raccordée au réseau électrique. Elle s'appuie sur le modèle de prédiction basé sur le modèle CNN, capable d'estimer la consommation énergétique à partir de données historiques et climatiques passées. Sa page d'accueil est illustrée dans la Figure 5.9

L'utilisateur est accueilli par une interface simple contenant le nom de l'université, de la faculté et du département, le nom du projet, et deux boutons fonctionnels:

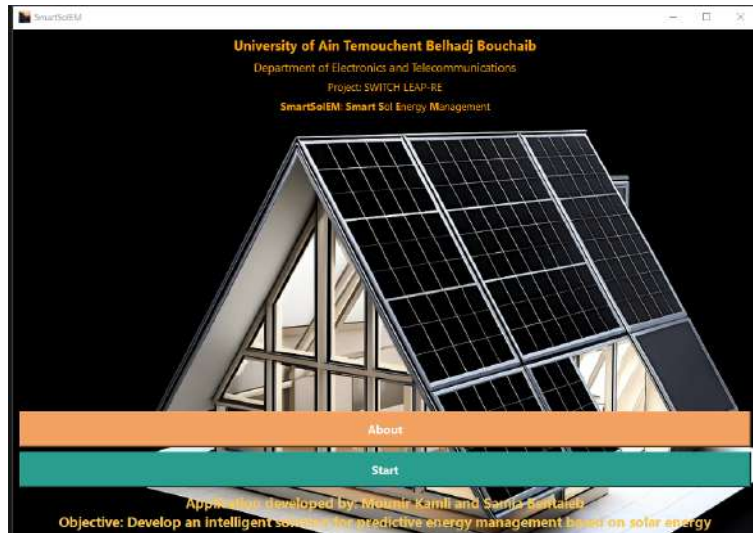


FIGURE 5.9 – Interface utilisateur de simulation (SmartSoLEM)

- About: pour afficher les informations générales sur le projet.
- Start: pour accéder à la simulation.

Pour permettre une exécution autonome et réactive, le modèle CNN a été déployé sur un Raspberry Pi. Grâce à sa taille réduite (576 ko) et à un temps d'inférence moyen de 0,26 seconde, il reste performant même lorsqu'il reçoit des données toutes les minutes. Cette rapidité assure une simulation fluide et réaliste du comportement énergétique.

### 5.6.2 Paramétrage et affichage de la simulation

Une fois la simulation lancée, l'utilisateur accède à une interface graphique, affichée dans la Figure 5.10, lui permettant de définir et de paramétrer les différentes variables du système énergétique:

- Nombre et surface des panneaux solaires
- Nombre de batteries et leur capacité
- Niveau de sécurité (faible, moyen, élevé)

Après la configuration des paramètres, l'utilisateur peut observer différents scénarios de fonctionnement du système comme le montre la Figure 5.11. Les quatre simulations illustrent la flexibilité et l'intelligence du modèle de gestion énergétique mis en œuvre par SmartSoLEM.

Le graphique supérieur, dans chaque cas, fournit une vue instantanée à une heure spécifique. Il met en évidence la répartition de l'énergie disponible: la production solaire du moment, le niveau de charge de la batterie, la part potentielle fournie par le réseau, ainsi que

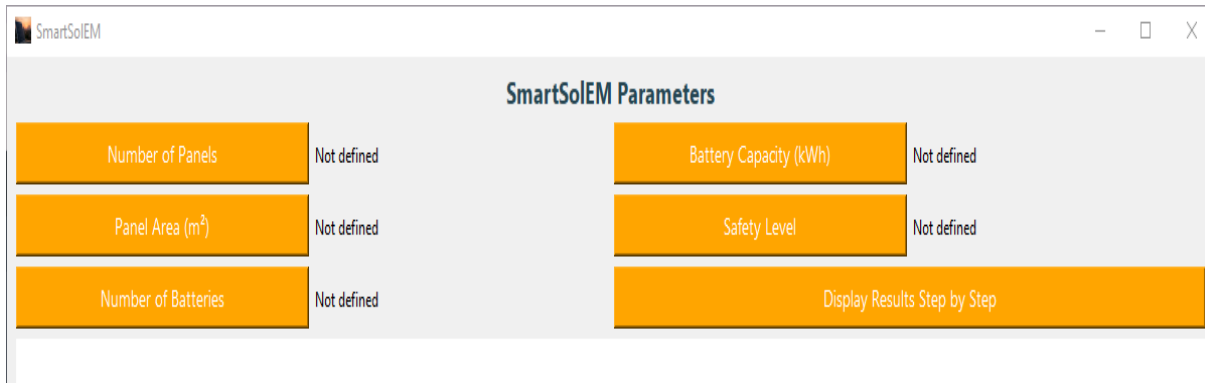


FIGURE 5.10 – Interface de paramétrage des variables dans SmartSolEM



FIGURE 5.11 – Paramétrage du modèle de simulation et état du système en temps réel

la consommation réelle comparée à celle prédite par le modèle CNN. Cette représentation permet de vérifier la précision des prédictions et d'observer le comportement décisionnel du système en temps réel. Le graphique inférieur trace l'évolution des variables clés tout au long de la journée. Il présente la courbe de la consommation réelle, celle prédite par le modèle, la production solaire, le niveau de la batterie et l'éventuelle sollicitation du réseau. Cette visualisation temporelle permet d'identifier les périodes critiques (haute consommation, faible production), et de mieux comprendre comment le système répartit les sources d'énergie pour

satisfaire la demande.

À travers ces scénarios, on constate que SmartSolEM applique systématiquement une logique de priorité énergétique: l'énergie solaire est utilisée en premier, suivie de la batterie lorsque nécessaire, puis le réseau en dernier recours. Le bon dimensionnement du système (panneaux, batteries) ainsi que le choix du niveau de sécurité influencent directement l'autonomie énergétique et la dépendance au réseau.

La production d'énergie solaire a été calculée à l'aide de la formule suivante, en prenant en compte l'ensemble des panneaux solaires installés :

$$E_{\text{solaire}} = N \times A \times G \times \eta \times 0.001 \quad (5.1)$$

avec:

- $E_{\text{solaire}}$ : énergie solaire produite (en kWh)
- $N$ : nombre de panneaux
- $A$ : surface d'un panneau (en m<sup>2</sup>)
- $G$ : irradiation solaire (en W/m<sup>2</sup>)
- $\eta$ : rendement du panneau (%)

La capacité totale des batteries est calculée en utilisant:

$$C_{\text{totale(kWh)}} = N_{\text{batt}} \times C_{\text{batt}} \quad (5.2)$$

où:

- $C_{\text{totale(kWh)}}$ : capacité totale des batteries en kilowattheures (kWh)
- $N_{\text{batt}}$ : nombre de batteries
- $C_{\text{batt}}$ : capacité d'une batterie en wattheures (kWh)

Le circuit électronique mis en œuvre permet de représenter visuellement l'état du système énergétique simulé. Il est constitué de trois LEDs connectées au Raspberry Pi, chacune symbolisant respectivement la source solaire, la batterie et le réseau électrique. La Figure 5.12 présente l'affectation de chaque LED, indiquant clairement le rôle attribué à chacune dans le système.

- La LED jaune représentant le panneau solaire est connectée à la broche GPIO 17.
- La LED vert représentant la batterie est connectée à la broche GPIO 27.
- La LED bleu représentant le réseau est connectée à la broche GPIO 22.



FIGURE 5.12 – Maquette de maison intelligente avec indicateurs lumineux des sources d'énergie

Dans chaque cas, la cathode de la LED est reliée à la masse (GND) à travers une résistance limitant le courant (valeur typique:  $220 \Omega$  ou  $330 \Omega$ ), afin de protéger la LED et le GPIO contre une surcharge.

Lorsque la simulation est lancée, chaque GPIO est pilotée dynamiquement pour indiquer la source d'énergie active à un instant donné. Une LED allumée signale que la source correspondante (solaire, batterie ou réseau) est utilisée. L'état des LEDs reflète ainsi, en temps réel, les décisions prises par le système de gestion de l'énergie simulé

## 5.7 Conclusion

Ce chapitre a détaillé la mise en place du système de gestion intelligente de l'énergie solaire SmartSolEM, en décrivant à la fois le fonctionnement du modèle de prédiction de la consommation à base de CNN et la manière dont l'interface graphique permet de simuler la répartition de l'énergie entre la production solaire, la batterie et le réseau électrique. Les différentes bibliothèques utilisées (NumPy, Pandas, Matplotlib, Seaborn, RPI.GPIO) illustrent l'intégration d'outils essentiels à la préparation des données, à la visualisation des résultats ainsi qu'au contrôle du matériel. L'interface ainsi développée offre une vision précise du comportement du système en temps réel, répondant ainsi à l'objectif global du projet: proposer une solution intelligente pour la gestion optimisée de l'énergie dans un environnement résidentiel.

# Conclusion Générale

Dans le cadre de ce travail, nous avons conçu et réalisé un système intelligent dédié à la gestion énergétique, reposant sur l'intégration de l'énergie solaire et les techniques avancées d'intelligence artificielle, notamment le Deep Learning et les réseaux de neurones convolutifs (CNN). Les résultats obtenus confirment la capacité de ces approches à fournir des prévisions fiables, contribuant ainsi à une optimisation pertinente de la consommation énergétique.

Les principaux objectifs fixés ont été atteints:

1. Élaboration de modèles prédictifs performants : l'architecture CNN proposée a démontré une aptitude significative à anticiper la demande énergétique, en exploitant des données historiques et météorologiques . Cela permet une régulation proactive de la consommation.
2. Implémentation sur des plateformes embarquées: le modèle a été déployé avec succès sur un dispositif compact Raspberry Pi 4B+ , assurant des prédictions locales en temps réel et rendant possible une gestion autonome et décentralisée des ressources.
3. Optimisation de la consommation d'énergie: les résultats issus de l'application du modèle prédictif a permis une gestion plus efficace de l'énergie, en particulier dans des contextes critiques comme les interruptions de service. L'intégration des énergies renouvelables, notamment le solaire, a renforcé la résilience du système proposé.
4. Développement d'un outil d'interface interactif : une application fonctionnelle a été mise en place, facilitant la visualisation des données de consommation, l'analyse des tendances et la prise de décision en temps réel. Cette interface apporte une valeur ajoutée en termes d'usage pratique et d'accessibilité.

En définitive, cette étude contribue activement à la transition énergétique en Algérie, en démontrant que les technologies prédictives basées sur l'IA peuvent jouer un rôle essentiel dans la construction de systèmes énergétiques intelligents, autonomes et durables.

Ce travail, réalisé dans le cadre du projet SWITCH, s'inscrit pleinement dans une logique

---

d'innovation au service de la durabilité, et ouvre la voie à des perspectives de recherche nombreuses, telles que l'intégration de nouvelles sources d'énergie dans le mix énergétique, ainsi que l'extension du système à l'échelle de réseaux urbains intelligents. En somme, cette étude constitue une base solide pour le développement futur de solutions énergétiques durables, résilientes et intelligentes.

# Bibliographie

- [1] Yuerong Zhou, Wenyan Wu, Rory Nathan, and QJ Wang. Deep learning-based rapid flood inundation modeling for flat floodplains with complex flow paths. *Water Resources Research*, 58(12):e2022WR033214, 2022.
- [2] Mani Dheeraj Mudaliar and N Sivakumar. Iot based real time energy monitoring system using raspberry pi. *Internet of Things*, 12:100292, 2020.
- [3] Fernanda Moura Quintão Silva, Menaouar Berrehil El Kattel, Igor Amariz Pires, and Thales Alexandre Carvalho Maia. Development of a supervisory system using open-source for a power micro-grid composed of a photovoltaic (pv) plant connected to a battery energy storage system and loads. *Energies*, 15(22):8324, 2022.
- [4] Deutsche Gesellschaft für Internationale Zusammenarbeit (GIZ). Technologie et développement socioéconomique des énergies renouvelables et de l'hydrogène vert en algérie. <https://www.giz.de/en/downloads/giz2023-fr-technologie-developpement-socioeconomique-energies-algerie.pdf>, 2023. Consulté en mai 2025.
- [5] Low-Carbon Power. Électricité en algérie en 2023. <https://lowcarbonpower.org/fr/region/Alg%C3%A9rie>, 2023. Consulté en mai 2025.
- [6] AHK Algérie. Consommation d'énergie en algérie pour 2024. <https://algerien.ahk.de/fr/news/consommation-d-energie-en-algerie-pour-2024>, 2024. Consulté en mai 2025.
- [7] Hassiba Bouabdesselam, Abdelkrim Liazid, and Youcef Bouzidi. La politique environnementale en algérie : réalités et perspectives. *Environnement, Ingénierie & Développement*, 38:29–33, 2005.
- [8] Ministère de l'Énergie et des Mines de la République Algérienne Démocratique et Populaire. Énergies nouvelles, renouvelables et maîtrise de l'Énergie. <https://www.energy.gov.dz/?rubrique=>

- [energies-nouvelles-renouvelables-et-maitrise-de-lrenergie](#), 2025. Consulté en mai 2025.
- [9] Adel Larbaoui. La contribution potentielle des énergies renouvelables au développement durable : le cas de l’algérie. *Revue des Sciences Sociales et Humaines*, 6(1):1–15, 2022.
- [10] B. Benyoucef. *Les ressources énergétiques renouvelables en Algérie: potentiel et perspectives de développement*. CDER – Centre de Développement des Énergies Renouvelables, Alger, Algérie, 2005.
- [11] CDER Ministère de l’Énergie et des Mines. Programme national de développement des énergies renouvelables et de l’efficacité énergétique à l’horizon 2030. Document officiel, 2015. Consulté via [www.cder.dz](http://www.cder.dz).
- [12] Wikipédia. Énergie en algérie. [https://fr.wikipedia.org/wiki/%C3%89nergie\\_en\\_Alg%C3%A9rie](https://fr.wikipedia.org/wiki/%C3%89nergie_en_Alg%C3%A9rie), 2025. Consulté en mai 2025.
- [13] M. Parker. *Off-Grid Solar Power: : A Complete Guide to Energy Independence, Harnessing the Sun for Sustainable Living*. Matthew Parker, 2025.
- [14] Catherine Jeandel, Rémy Mosseri, and Alain Fuchs. *L’énergie à découvert*. Editions du CNRS, 2017.
- [15] Antonio Luque and Steven Hegedus. *Handbook of photovoltaic science and engineering*. John Wiley & Sons, 2011.
- [16] É.S. énergies. *Le guide indispensable pour tout savoir sur les panneaux photovoltaïques*. Éditions Le guide indispensable, 2024.
- [17] Martin A. Green. *Solar Cells: Operating Principles, Technology, and System Applications*. Prentice-Hall, Englewood Cliffs, NJ, 1982.
- [18] Giuseppina Ciulla, Valerio Lo Brano, Vincenzo Franzitta, and Marco Trapanese. Assessment of the operating temperature of crystalline pv modules based on real use conditions. *International Journal of Photoenergy*, 2014(1):718315, 2014.
- [19] R.A. Messenger and H.A. Abtahi. *Photovoltaic Systems Engineering*. CRC Press, 2010.
- [20] J. Grossmann. *La Chaleur renouvelable et la rivière*. Société des écrivains, 2015.
- [21] W. Holmes, Z. Hui, F. Miao, and H. Ronghuai. *IA et éducation: Guide pour les décideurs*. Organisation des Nations unies pour l’éducation, la science et la culture (UNESCO), 2021.
- [22] DeepMind. Deepmind ai reduces google data centre cooling bill by 40%. <https://www.deepmind.com/blog/deepmind-ai-reduces-google-data-centre-cooling-bill-by-40>, 2016. Consulté en juin 2025.

- [23] AutoGrid. Autogrid flex: Ai-powered energy management platform. <https://www.auto-grid.com/products/autogrid-flex/>, 2023. Consulté en juin 2025.
- [24] IBM. Ibm maximo application suite: Predictive maintenance for wind energy. <https://www.ibm.com/products/maximo>, 2023. Consulté en juin 2025.
- [25] Tom M Mitchell and Tom M Mitchell. *Machine learning*, volume 1. McGraw-hill New York, 1997.
- [26] Kevin P Murphy. *Machine learning: a probabilistic perspective*. MIT press, 2012.
- [27] Ian Goodfellow, Yoshua Bengio, and Aaron Courville. *Deep learning*. MIT press, 2016.
- [28] Peter Dayan and L. F. Abbott. *Theoretical Neuroscience: Computational and Mathematical Modeling of Neural Systems*. MIT Press, Cambridge, MA, 2001.
- [29] M.Z. Kurdi. *Traitement automatique des langues et linguistique informatique 1*. Number vol. 1 in Collection sciences cognitives. ISTE Editions, 2017.
- [30] Adrian Dan, Jasha Oosterbaan, and Philippe Jamet. Contribution des réseaux de neurones artificiels (rna) à la caractérisation des pollutions de sol. exemples des pollutions en hydrocarbures aromatiques polycycliques (hap). *Comptes rendus. Géoscience*, 334(13):957–965, 2002.
- [31] IBM. Que sont les réseaux neuronaux ?, 2025. Consulté le 18 mai 2025.
- [32] Aurélien Libert et al. Analysis of spatial scales in satellite data reconstructed using a neural network. 2022.
- [33] Yann LeCun, Léon Bottou, Yoshua Bengio, and Patrick Haffner. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11):2278–2324, 1998.
- [34] Léon Bottou. Stochastic gradient descent tricks. In *Neural Networks: Tricks of the Trade: Second Edition*, pages 421–436. Springer, 2012.
- [35] John Duchi, Elad Hazan, and Yoram Singer. Adaptive subgradient methods for online learning and stochastic optimization. *Journal of machine learning research*, 12(7), 2011.
- [36] Matthew D Zeiler. Adadelata: an adaptive learning rate method. *arXiv preprint arXiv:1212.5701*, 2012.
- [37] Saman Taheri, Mohammad Jooshaki, and Moein Moeini-Aghtaie. 8 years of hourly heat and electricity demand for a residential building, 2021.
- [38] M. Hekkenberg, R. M. J. Benders, H. C. Moll, and A. J. M. Schoot Uiterkamp. Indications for a changing electricity demand pattern: The temperature dependence of electricity demand in the netherlands. *Energy Policy*, 37(4):1542–1551, 2009.

- [39] Edward Baumann, Charles Hsu, Hayley Buba, and Taylor Cox. An introductory approach to time-series data preparation and analysis. In *Annual Conference of the PHM Society*, volume 15, October 2023.
- [40] Luai Shalabi, Shaaban Zyad, and Basil Kasasbeh. Data mining: A preprocessing engine. *Journal of Computer Science*, 2, September 2006.
- [41] S. Gopal Krishna Patro and Kishore Kumar Sahu. Normalization: A preprocessing stage. *CoRR*, abs/1503.06462, 2015.
- [42] J. Brownlee. *Deep Learning for Time Series Forecasting: Predict the Future with MLPs, CNNs and LSTMs in Python*. Machine Learning Mastery, 2018.
- [43] Rob J Hyndman and George Athanasopoulos. *Forecasting: principles and practice*. OTexts, 2018.
- [44] Jaedong Kim, Seunghwan Oh, Heesoo Kim, and Woosung Choi. Tutorial on time series prediction using 1d-cnn and bilstm: A case example of peak electricity demand and system marginal price prediction. *Engineering Applications of Artificial Intelligence*, 126:106817, 2023.
- [45] Konstantinos Benidis, Syama Sundar Rangapuram, Valentin Flunkert, Bernie Wang, Danielle C. Maddix, Ali Caner Türkmen, Jan Gasthaus, Michael Bohlke-Schneider, David Salinas, Lorenzo Stella, Laurent Callot, and Tim Januschowski. Neural forecasting: Introduction and literature overview. *CoRR*, abs/2004.10240, 2020.
- [46] Kheir Eddine Yassine HAMZI, Mohamed Nabil BENMAROUF, and Samia BENTAIEB. *Optimisation des Ressources Énergétiques grâce à la Prédiction de la Consommation Électrique: Approche Analytique et Prédicative basée sur l'Intelligence Artificielle*. PhD thesis, 2024.
- [47] Samia Bentaieb, Kheir Eddine Yassine Hamzi, Mohamed Nabil Benmarouf, and Driss Nehari. Real-time deep learning model deployment on raspberry pi using streamlit for electricity consumption forecasting. In *2024 IEEE International Multi-Conference on Smart Systems & Green Process (IMC-SSGP)*, pages 1–6. IEEE, 2024.
- [48] J. Scott Armstrong. Evaluating forecasting methods. In J. Scott Armstrong, editor, *Principles of Forecasting: A Handbook for Researchers and Practitioners*, pages 443–472. Springer, 2001.
- [49] Alexei Botchkarev. A new typology design of performance metrics to measure errors in machine learning regression algorithms. *Interdisciplinary Journal of Information, Knowledge, and Management*, 14:045–076, 2019.

- 
- [50] Davide Chicco, Matthijs J. Warrens, and Giuseppe Jurman. The coefficient of determination r-squared is more informative than smape, mae, mape, mse and rmse in regression analysis evaluation. *PeerJ Computer Science*, 7:e623, 2021.
- [51] Rob J. Hyndman and Anne B. Koehler. Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4):679–688, 2006.
- [52] Tianfeng Chai and Roland R. Draxler. Root mean square error (rmse) or mean absolute error (mae)?—arguments against avoiding rmse in the literature. *Geoscientific Model Development*, 7:1247–1250, 2014.
- [53] Timothy Hodson, Thomas Over, and Sydney Foks. Mean squared error, deconstructed. *Journal of Advances in Modeling Earth Systems*, 13(12):e2021MS002750, 2021.
- [54] Arnaud de Myttenaere, Boris Golden, Bénédicte Le Grand, and Fabrice Rossi. Mean absolute percentage error for regression models. *Neurocomputing*, 192:38–48, 2016. Advances in artificial neural networks, machine learning and computational intelligence.
- [55] Gloria B. Barrett. The coefficient of determination: Understanding  $r^2$  and  $r^2$ . *The Mathematics Teacher*, 93(3):230–234, 2000.

# Annexe A

## Code Listings

```
def to_sequence(data, time_steps=1):
    x_seq = []
    y_seq = []
    for i in range(len(data) - time_steps):
        window = data.iloc[i:i + time_steps, :]
        x_seq.append(window)
        y_seq.append(data.iloc[i + time_steps, 0])

    return np.array(x_seq), np.array(y_seq)
```

Code Listing A.1 – Code Python pour transformer une série temporelle en problème supervisé

```
import tensorflow as tf
from tf.keras.optimizers import Adam
from tf.keras.metrics import RootMeanSquaredError
```

Code Listing A.2 – Importation des bibliothèques nécessaires

```
cnn_model = tf.keras.Sequential()
```

Code Listing A.3 – Définition du modèle séquentiel

```
cnn_model.add(tf.keras.layers.Conv1D(
    filters=32,
    kernel_size=3,
    activation='relu',
    input_shape=(X_train_seq.shape[1], X_train_seq.shape[2])
))
```

---

---

Code Listing A.4 – Construction de couches convolutives

```
cnn_model.add(tf.keras.layers.MaxPooling1D(pool_size=2))  
cnn_model.add(tf.keras.layers.Flatten())
```

Code Listing A.5 – Incorporation de la mise en commun et de l'aplatissement

```
cnn_model.add(tf.keras.layers.Dense(64, activation='relu'))  
cnn_model.add(tf.keras.layers.Dense(1, activation='relu'))
```

Code Listing A.6 – Ajouter des couches denses

```
cnn_model.compile(loss='mse', optimizer=Adam(learning_rate=0.0001),  
                 metrics=['mae'])
```

Code Listing A.7 – Compilation du modèle

## Résumé

La gestion de la consommation d'électricité est d'une importance cruciale tant sur le plan environnemental qu'économique, notamment dans le contexte de la transition vers les énergies renouvelables. Dans ce cadre, ce travail présente une étude approfondie sur l'utilisation de l'intelligence artificielle, et plus particulièrement des algorithmes d'apprentissage profond, pour prédire la consommation et la production d'énergie solaire à partir de données historiques et météorologiques.

Une architecture de réseaux neuronaux a été proposée pour estimer, heure par heure, la consommation électrique ainsi que la production d'un panneau photovoltaïque. L'apprentissage du modèle a été réalisé à partir de séries temporelles, tandis que leur performance a été évaluée à l'aide de métriques telles que l'erreur absolue moyenne (MAE), la racine de l'erreur quadratique moyenne (RMSE) et le coefficient de détermination ( $R^2$ ). Les résultats obtenus confirment la capacité du système à effectuer des prévisions fiables et précises.

Afin de démontrer la faisabilité et l'efficacité du système dans un contexte réel, une intégration matérielle a été réalisée sur la plateforme embarquée Raspberry Pi 4 B+. Une application complète a été développée, permettant de visualiser les courbes de production et de consommation, d'enregistrer les résultats et de simuler différents scénarios énergétiques. Cette mise en œuvre ouvre la voie à la conception d'un système de gestion énergétique intelligent, capable de prendre des décisions optimales pour basculer entre l'énergie photovoltaïque et le réseau électrique en fonction des prévisions.

Ce travail a été réalisé dans le cadre du projet, intitulé 'Stabilizing weak grids through machine learning: empowering farmers in end-of-line-communities in North Africa through artificial neural networks' SWITCH. Il inscrit dans le cadre de l'appel à la recherche et à l'innovation Europe-Afrique sur les énergies renouvelables, LEAP-RE.

**Mots clés:** Prédiction, Deep Learning, réseaux neuronaux convolutifs, Panneau solaire, Raspberry Pi 4 B+.

## ملخص

يؤثر استهلاك الكهرباء تأثيرًا كبيرًا على كل من البيئة والتكاليف المرتبطة بتوزيع الطاقة، نظرًا لتأثيره تُعد إدارة استهلاك الكهرباء أمرًا بالغ الأهمية من الناحيتين البيئية والاقتصادية، لا سيما في سياق الانتقال نحو مصادر الطاقة المتجددة. وفي هذا الإطار، يعرض هذا العمل دراسة معمقة لاستخدام الذكاء الاصطناعي، وبشكل خاص خوارزميات التعلم العميق، من أجل التنبؤ باستهلاك وإنتاج الطاقة الشمسية اعتمادًا على البيانات التاريخية والبيانات المناخية. تم اقتراح بنية من الشبكات العصبية لتقدير استهلاك الكهرباء وكذلك إنتاج الألواح الكهروضوئية على مدار الساعة. وقد تم تدريب النموذج اعتمادًا على سلاسل زمنية، وتم تقييم أدائه باستخدام مؤشرات مثل متوسط الخطأ المطلق (MAE)، والجذر التربيعي للخطأ المتوسط (RMSE)، ومعامل التحديد ( $R^2$ ). وتؤكد النتائج المحصل عليها قدرة النظام على تقديم توقعات دقيقة وموثوقة. ولإثبات جدوى النظام وفعالته في السياق الواقعي، تم تنفيذ التكامل المادي على منصة Raspberry Pi 4B+. كما تم تطوير تطبيق كامل يمكن من عرض منحنيات الإنتاج والاستهلاك، وتسجيل النتائج، ومحاكاة سيناريوهات طاغوية مختلفة. وتُهد هذه التجربة الطريق لتصميم نظام ذكي لإدارة الطاقة، قادر على اتخاذ قرارات مثالية للتبديل بين الطاقة الشمسية وشبكة الكهرباء استنادًا إلى التوقعات.

**الكلمات المفتاحية:** التنبؤ، التعلم العميق، الشبكات العصبية التلافيفية، Raspberry Pi 4+

## Abstract

Electricity consumption management is of crucial importance both environmentally and economically, especially in the context of the transition to renewable energy sources. In this regard, this work presents a comprehensive study on the use of artificial intelligence, and more specifically deep learning algorithms, to predict solar energy consumption and production based on historical and meteorological data.

A neural network architecture has been proposed to estimate, on an hourly basis, both the electricity consumption and the production of a photovoltaic panel. The model was trained on time series data, and its performance was evaluated using metrics such as Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and the coefficient of determination ( $R^2$ ). The results obtained confirm the system's ability to deliver accurate and reliable forecasts.

To demonstrate the system's feasibility and effectiveness in a real-world context, hardware integration was carried out on the embedded platform **Raspberry Pi 4 B+**. A complete application was developed, allowing visualization of consumption and production curves, recording of results, and simulation of various energy scenarios. This implementation paves the way for the design of an intelligent energy management system capable of making optimal decisions to switch between photovoltaic energy and the power grid based on the predictions.

This work was carried out as part of the SWITCH project entitled 'Stabilizing weak grids through machine learning: empowering farmers in end-of-line-communities in North Africa through artificial neural networks'. It is part of the Europe-Africa call for research and innovation on renewable energies, LEAP-RE.

**Keywords:** Prediction, Deep Learning, Convolutional Neural Networks, Raspberry Pi, Raspberry Pi 4 B+.