

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université 8 Mai 1945 – Guelma
Faculté des Mathématiques, d'Informatique et des Sciences de la Matière
Département d'Informatique



Mémoire de Fin d'études Master

Filière : Informatique

Option : Système d'informatique.

Thème :

Prédiction de la consommation d'énergie électrique dans les bâtiments intelligents

Présenté par : Aissaoui Rahma

Membres du jury :

Président : MADI Leila

Examineur : BOUGHAREB Djalila

Encadreur : KOUAHLA Zineddine

Juin 2025

Remerciements

Louange à Dieu Tout-Puissant (Allah), par Sa grâce et Sa miséricorde, j'ai pu mener à bien ce travail. C'est avec une profonde reconnaissance que je commence ces remerciements en Le remerciant pour la force, la patience et la persévérance qu'Il m'a accordées tout au long de ce parcours.

Je tiens à exprimer ma sincère gratitude à mon encadreur, **Monsieur Zineddine Kouahla**, pour m'avoir offert l'opportunité de travailler sous sa direction. Travailler avec lui a été une expérience enrichissante, tant sur le plan scientifique que personnel. Ses efforts, sa disponibilité, ses conseils avisés et sa bienveillance ont largement contribué à l'avancement et à l'aboutissement de ce mémoire. Je le remercie également d'avoir su créer un environnement de travail favorable, motivant et propice à la réflexion.

Je remercie également **Mademoiselle Rania Farah** pour son implication constante, son suivi rigoureux et ses conseils précieux. Son soutien à chaque étape du travail m'a été d'une grande aide.

Je tiens à adresser mes plus sincères remerciements aux **membres du jury, Madame MADI Leila et Madame BOUGHAREB Djalila**, pour l'intérêt qu'elles ont porté à mon travail, ainsi que pour leurs *critiques constructives et positives* qui ont contribué à améliorer la qualité de ce mémoire.

Je ne saurais oublier de remercier chaleureusement mes amis **Soria et Lina Djihane**, dont l'aide précieuse, le soutien moral et l'encouragement m'ont accompagné tout au long de cette aventure. Leur présence a été essentielle dans les moments de doute comme dans les moments de joie.

Le meilleur pour la fin ! Je tiens à exprimer toute ma gratitude à ma famille, qui a toujours été à mes côtés tout au long de mon parcours scolaire. Votre amour, votre soutien inconditionnel et votre présence bienveillante depuis mon enfance ont été une source de force et de motivation inestimable. Puisse Dieu vous accorder la santé, le bonheur, la sérénité, et faire en sorte que je sois toujours à la hauteur de votre confiance et de votre amour.

Dédicaces

À mon père, **Abdelazize Aissaoui**, symbole de force et de dévouement, pour son soutien indéfectible depuis mon enfance. À celui qui avait l'habitude de quitter son travail pour m'emmener étudier, croyant en moi bien avant que je ne croie en moi-même. Que Dieu te protège et te récompense pour chaque effort, chaque geste et chaque sacrifice.

À ma mère, **Nora Khaled**, mon pilier, ma lumière. Pour son amour infini, son courage silencieux et ses sacrifices innombrables. Merci d'avoir cru en mes capacités dans les moments où moi-même j'en doutais. Que Dieu t'accorde paix, santé et bonheur éternel.

À mon frère **Okba** et à ma sœur **Kawther**, pour votre tendresse, votre écoute et votre appui discret mais si précieux. Merci d'avoir toujours été là, dans l'ombre, avec amour.

À mon fiancé, le compagnon fidèle dans cette aventure universitaire, pour ta patience, ton soutien continu, et tes paroles encourageantes qui m'ont portée jusqu'à la fin. Ce parcours a été notre chemin commun.

Je remercie également toutes les personnes qui m'ont soutenue, même par un simple sourire. À vous tous, je dédie ce travail avec toute ma reconnaissance et mon affection.

Résumé

Anticiper la consommation énergétique ne constitue plus un simple avantage stratégique, mais une nécessité, notamment en Algérie, où plus de 98 % de l'électricité est produite à partir de gaz naturel. Dans un contexte où l'électricité ne peut être stockée, les pics de consommation — amplifiés par les conditions climatiques — engendrent souvent des coupures et fragilisent le réseau opéré par Sonelgaz.

Ce mémoire propose un modèle de prévision à court terme, adapté aux bâtiments algériens, basé sur l'intelligence artificielle. Il s'appuie sur des séries temporelles combinant des réseaux convolutifs (CNN) et des réseaux à mémoire longue (LSTM), capables de mieux capter les dynamiques horaires et saisonnières de la demande.

Les résultats obtenus sont prometteurs : le modèle CNN-LSTM a atteint un coefficient de détermination R^2 de 0,95, une MAE de 232 et une RMSE de 330, attestant de sa capacité à reproduire fidèlement la consommation réelle et à offrir une précision satisfaisante pour une intégration opérationnelle.

Mots-clés : prévision de la consommation électrique, réseaux CNN, réseaux LSTM, séries temporelles, consommation énergétique, Algérie.

Abstract

Anticipating future electricity consumption is no longer a mere strategic advantage, but a pressing necessity — especially in Algeria, where more than 98% of electricity production relies on fossil fuels, mainly natural gas. In a context where electricity cannot be stored, extreme demand peaks, often caused by climatic events, regularly exceed production capacity. This puts the national grid, managed by Sonelgaz, under severe stress, resulting in frequent outages and compromising overall system stability.

This study presents a short-term electricity load forecasting model specifically adapted to Algerian buildings. The proposed approach is based on time series modeling using artificial intelligence, combining Convolutional Neural Networks (CNN) and Long Short-Term Memory networks (LSTM) to capture both local patterns and temporal dependencies in the data.

The results obtained are promising : the hybrid CNN-LSTM model achieved a coefficient of determination (R^2) of 0.95, a Mean Absolute Error (MAE) of 232, and a Root Mean Squared Error (RMSE) of 330. These metrics confirm the model's ability to accurately replicate actual consumption and support its potential for operational energy management applications.

Keywords : electricity consumption forecasting, CNN networks, LSTM networks, time series, energy consumption, Algeria.

ملخص

تُعد التنبؤات المستقبلية لاستهلاك الطاقة الكهربائية ضرورة حتمية، وليست مجرد ميزة إستراتيجية. إذ تُسهم الدقة في التنبؤ بالطلب على الكهرباء في تحسين كفاءة الإنتاج، وتقليل الفاقد الطاقوي، وتعزيز استغلال الموارد المتاحة. وتكتسي هذه الإشكالية أهمية خاصة في الجزائر، حيث تعتمد منظومة إنتاج الكهرباء بشكل شبه كلي على المصادر الأحفورية، إذ يُستمد أكثر من 98٪ من الكهرباء من الغاز الطبيعي.

وفي ظل استحالة تخزين الكهرباء، غالباً ما تتجاوز ذروات الاستهلاك — خصوصاً خلال الظروف المناخية القاسية — قدرات الإنتاج، مما يضع الشبكة الوطنية، التي تديرها شركة "سونلغاز"، تحت ضغط شديد، يؤدي إلى انقطاعات متكررة، ويهدد استقرار النظام الكهربائي وكفاءته. وبالرغم من أن مفهوم المباني الذكية لا يزال في مراحله الأولى في الجزائر، إلا أن المباني السكنية والإدارية تستهلك حصة كبيرة من الطاقة الكهربائية. وفي هذا السياق، يقدّم هذا العمل نموذجاً للتنبؤ قصير الأمد باستهلاك الكهرباء، يعتمد على نمذجة السلاسل الزمنية باستخدام تقنيات الذكاء الاصطناعي، من خلال دمج الشبكات الالتفافية (CNN) وشبكات الذاكرة طويلة الأمد (LSTM)، مما يسمح بالنقاط أدق للتغيرات الزمنية والموسمية.

وقد أظهر النموذج الهجين المقترح (CNN-LSTM) أداءً ممتازاً، حيث بلغ معامل التحديد (R^2) نسبة 0.95، مع متوسط خطأ مطلق (MAE) قدره 232، وخطأ جذري متوسط التربيع (RMSE) بلغ 330، ما يثبت قدرة النموذج على محاكاة الاستهلاك الحقيقي بدقة عالية، ويفتح المجال أمام استخدامه في تحسين إدارة الطاقة مستقبلاً.

الكلمات المفتاحية: التنبؤ باستهلاك الكهرباء، الشبكات الالتفافية CNN، شبكات الذاكرة طويلة الأمد LSTM، السلاسل الزمنية، استهلاك الطاقة، الجزائر.

Table des matières

Liste des tableaux	iii
Table des figures	iv
Liste des Abréviations	v
1 Cadre Général et Concepts Utilisés	4
1.1 Terminologie et définitions de base	5
1.1.1 L'énergie	5
1.1.2 La consommation d'énergie électrique	6
1.1.3 L'Internet des Objets (IoT)	6
1.1.4 Smart Grid (Réseau électrique intelligent)	7
1.1.5 Bâtiments intelligents (Smart Buildings)	7
1.1.6 La prévision de la consommation comme levier de maîtrise de la surcon- somption énergétique	9
1.1.7 Évolution récente de la consommation mondiale d'énergie	10
1.2 Conclusion	11
2 État de l'art sur les modèles de prévision énergétique	12
2.1 Intelligence artificielle	13
2.1.1 Régression	13
2.1.2 Apprentissage automatique	15
2.1.3 Apprentissage profond	16
2.2 Travaux connexes	19
2.3 Conclusion	30
3 Conception et Mise en Œuvre du Système	31
3.1 Conception globale du système	31
3.1.1 Objectifs de la solution proposée	31
3.1.2 Architecture fonctionnelle du système	32
3.1.3 Schéma de fonctionnement du système	32
3.2 Prétraitement	33
3.2.1 Présentation du jeu de données	33

3.2.2	Analyse exploratoire des données	34
3.2.3	Nettoyage des données	36
3.2.4	Transformation vers un format temporel exploitable	36
3.2.5	Fractionnement des données	38
3.3	Modélisation	40
3.3.1	Conception des modèles de prévision et description architecturale	41
3.3.2	Métriques d'évaluation	46
3.4	Implémentation	47
3.4.1	Introduction technique	47
3.4.2	Préparation des données	49
3.5	Conclusion	52
4	Résultats expérimentaux et discussions	53
4.1	Introduction	53
4.2	Résultats	53
4.2.1	Modèle Réseau de Neurones Convolutif avec Mémoire à Long et Court Terme (CNN-LSTM)	53
4.2.2	Modèle Réseau de Neurones Convolutif avec LSTM Bidirectionnel (CNN- BiLSTM)	54
4.2.3	Modèle Réseau de Neurones Convolutif (CNN)	54
4.2.4	Modèle Mémoire à Long et Court Terme (LSTM)	55
4.3	Discussion	56
4.4	Conclusion	58
	Conclusion Générale	59
	Perspectives	60

Liste des tableaux

- 2.1 Synthèse des 21 articles de recherche analysés 19
- 3.1 Outils et bibliothèques utilisés dans le développement du système 48
- 4.1 Comparaison des performances des modèles d'apprentissage profond 56

Table des figures

1.1	Illustration des capteurs IoT appliqués à la surveillance des réseaux électriques intelligents [W1].	7
	8figure.caption.13	
1.3	Schéma illustrant l'écosystème de l'Internet des Objets dans un bâtiment intelligent [W3].	9
1.4	Évolution de la consommation mondiale d'électricité entre 1980 et 2023. [63] . .	10
2.1	Illustration du modèle de régression linéaire [W6]	15
2.2	Définition géométrique SVM [23]	16
2.3	Architecture typique d'un réseau de neurones convolutif ([17])	17
2.4	Schéma simplifié de l'architecture d'un réseau LSTM [18]	18
3.1	Diagramme de fonctionnement du système proposé	32
3.2	Importation des données depuis un fichier CSV	34
3.3	Évolution journalière de la consommation d'électricité (2008–2020)	35
3.4	Consommation maximale par saison et par année	36
3.5	Matrice de corrélation des variables explicatives avec la consommation	40
4.1	Courbes d'apprentissage pour les quatre modèles	57
4.2	Comparaison des valeurs réelles et prédites par les différents modèles	57

Liste des Abréviations

[AI]	Artificial Intelligence
[ANN]	Artificial Neural Network
[ARIMA]	AutoRegressive Integrated Moving Average
[BAS]	Building Automation System
[BiLSTM]	Bidirectional Long Short-Term Memory
[BMS]	Building Management System
[CNN]	Convolutional Neural Network
[CNN-GRU]	Convolutional Neural Network - Gated Recurrent Unit
[CNN-LSTM]	Convolutional Neural Network - Long Short-Term Memory
[CU]	Chulalongkorn University
[DL]	Deep Learning
[EIA]	U.S. Energy Information Administration
[ELM]	Extreme Learning Machine
[EWO]	Earth Worm Optimization (ou Enhanced Whale Optimization selon les contextes)
[GBDT]	Gradient Boosting Decision Tree
[GRU]	Gated Recurrent Unit
[IoT]	Internet of Things
[k-NN]	k-Nearest Neighbors
[kWh]	Kilowatt-hour
[LSTM]	Long Short-Term Memory
[MAE]	Mean Absolute Error
[MAPE]	Mean Absolute Percentage Error
[ML]	Machine Learning
[MLP]	Multi-Layer Perceptron
[MWh]	Megawatt-hour
[PHMR]	Penalized Hierarchical Multitask Regression
[R ²]	Coefficient de détermination
[RL]	Reinforcement Learning
[RMSE]	Root Mean Squared Error
[RNN]	Recurrent Neural Network
[SHAP]	SHapley Additive exPlanations
[STLF]	Short-Term Load Forecasting

[**SVR**] Support Vector Regression
[**SVM**] Support Vector Machine
[**TCN**] Temporal Convolutional Network
[**TWh**] Terawatt-hour
[**XGBoost**] Extreme Gradient Boosting

Introduction Générale

Ces dernières années, les bâtiments sont devenus des acteurs majeurs dans la consommation énergétique mondiale, en raison de l'essor des technologies numériques, de la généralisation des équipements connectés et de l'importance croissante accordée aux enjeux environnementaux. Cette transformation s'est vue renforcée par la montée du travail à distance, qui a contribué à une utilisation plus intensive des appareils électriques et des dispositifs intelligents dans les espaces résidentiels et professionnels.

Dans ce contexte, la prévision de la consommation d'énergie électrique à court terme (Short-Term Load Forecasting, ou STLF) s'impose comme un outil essentiel pour répondre aux nouveaux défis énergétiques. Elle permet d'anticiper la demande, d'optimiser la gestion des ressources, de limiter les pertes d'énergie et de favoriser l'intégration des sources d'énergie renouvelables. L'essor des bâtiments intelligents, dotés de systèmes de capteurs et d'automatisation, génère une quantité massive de données, dont l'analyse nécessite des méthodes avancées et performantes.

Toutefois, les approches statistiques traditionnelles, telles que les modèles ARIMA ou la régression linéaire, se révèlent souvent insuffisantes face à la complexité des profils de consommation modernes. Elles peinent notamment à prendre en compte la nature non linéaire des données, la multiplicité des effets saisonniers ainsi que l'influence de variables externes, telles que les conditions météorologiques ou les comportements des usagers.

Face à ces limites, les méthodes issues de l'intelligence artificielle, en particulier l'apprentissage automatique et l'apprentissage profond, offrent des alternatives prometteuses. Les modèles hybrides, comme ceux combinant des réseaux de neurones convolutifs (CNN) pour détecter les motifs locaux et des réseaux LSTM pour modéliser les dépendances temporelles, ont démontré une efficacité remarquable dans le domaine de la prévision énergétique.

Le présent mémoire s'inscrit dans cette démarche innovante. Il propose de concevoir un modèle prédictif hybride de type CNN-LSTM, entraîné sur des données réelles issues de bâtiments situés en Algérie, dans le but de prévoir la consommation horaire d'électricité avec une précision accrue.

Afin d'améliorer la représentativité des données et la qualité des prédictions, la base de données a été restructurée et enrichie à l'aide de variables temporelles cycliques (heures, mois), d'indicateurs saisonniers, ainsi que de statistiques glissantes (moyennes mobiles, extrêmes), permettant de mieux capturer les dynamiques de consommation à différentes échelles temporelles.

L'objectif est de mettre en place une solution technologique adaptée aux spécificités du

contexte algérien, marqué par des variations saisonnières importantes, une croissance constante de la demande énergétique et la nécessité d’une gestion plus efficiente des ressources. Ce travail de recherche est structuré comme suit :

- Le premier chapitre présente le cadre général de l’étude, en introduisant le contexte, la problématique, les objectifs visés ainsi que les contributions apportées.
- Le deuxième chapitre est consacré à une revue de la littérature, dans laquelle sont exposées les principales approches classiques et récentes en matière de prévision de la consommation électrique dans les bâtiments.
- Le troisième chapitre développe la méthodologie employée, décrit l’architecture du modèle proposé, les techniques de prétraitement et l’environnement de mise en œuvre.
- Le quatrième chapitre présente les résultats expérimentaux obtenus à partir de différents modèles, les évalue à l’aide d’indicateurs quantitatifs, et propose une discussion critique sur les performances du modèle hybride CNN-LSTM.

Enfin, une conclusion générale viendra récapituler les apports de cette étude et proposer des pistes d’amélioration pour de futurs travaux.

Problématique et Objectifs

Problématique

En Algérie, la consommation d’électricité dans les bâtiments présente d’importantes variations selon les saisons, surtout pendant l’été et l’hiver. Pendant les périodes de fortes chaleurs estivales, la demande en électricité augmente fortement en raison de l’utilisation massive des climatiseurs, dont l’efficacité diminue lorsque les températures atteignent des niveaux élevés.

En plus, des coupures de courant fréquentes, de jour comme de nuit, affectent la stabilité de la distribution d’électricité. Les tempêtes hivernales causent également des interruptions supplémentaires. Ces situations rendent la gestion de la demande énergétique difficile à prévoir.

Actuellement, les bâtiments intelligents ne sont pas encore largement développés en Algérie. Bien que certaines données sur la consommation existent, les modèles prédictifs classiques rencontrent des difficultés à prévoir précisément la consommation électrique dans un contexte aussi instable. Les données deviennent de plus en plus complexes car elles dépendent de nombreux facteurs externes comme la température, l’heure de la journée, le type d’équipement utilisé et les comportements des utilisateurs.

Face à cette complexité, il est nécessaire d’utiliser des approches hybrides plus robustes. Dans cette optique, l’enrichissement des bases de données et l’expérimentation de plusieurs modèles d’intelligence artificielle offrent une piste prometteuse pour améliorer les performances de la prévision à court terme dans le contexte algérien.

Objectifs de la recherche

Ce travail de recherche vise à atteindre les objectifs suivants :

- Étudier le profil de consommation d'électricité dans les bâtiments algériens, en identifiant les principaux facteurs d'influence sur les variations de charge, tels que la saisonnalité, les horaires, la température ambiante, le type d'équipement utilisé et les comportements des occupants.
- Effectuer un prétraitement avancé des données et enrichir le jeu de données initial par l'ajout de nouvelles variables explicatives (features) pertinentes, dans le but d'améliorer la performance des modèles de prévision.
- Comparer et évaluer les performances de quatre modèles de prévision issus de l'intelligence artificielle, incluant des modèles hybrides, pour la prédiction de la consommation horaire d'électricité.
- Concevoir un modèle prédictif robuste, adapté aux spécificités du système électrique algérien, permettant d'anticiper les pointes de consommation et de favoriser une gestion énergétique plus efficace.
- Formuler des recommandations techniques afin de limiter les risques de surcharge du réseau électrique et d'optimiser l'usage des équipements énergivores, tels que les climatiseurs, durant les périodes critiques.

Chapitre 1

Cadre Général et Concepts Utilisés

Contexte général

En Algérie, la consommation d'énergie électrique dans les bâtiments connaît une croissance soutenue, alimentée par divers facteurs à la fois structurels et conjoncturels. D'une part, l'urbanisation rapide, l'accroissement démographique et l'amélioration du niveau de vie ont favorisé l'expansion du parc immobilier résidentiel et tertiaire. D'autre part, l'équipement progressif des ménages en appareils électroménagers, systèmes de climatisation et équipements électroniques contribue à accentuer la demande énergétique, en particulier lors des périodes de fortes chaleurs estivales.

La crise sanitaire liée à la pandémie de COVID-19 a également induit des transformations notables dans les modes de consommation d'énergie. Les périodes de confinement et la généralisation du télétravail ont entraîné une augmentation de la consommation domestique d'électricité, tout en modifiant les profils de charge traditionnels. Cette évolution des usages a mis en évidence les limites des systèmes actuels de gestion énergétique et a renforcé la nécessité de développer des outils de prévision plus performants, capables de s'adapter à des conditions de consommation variables et parfois imprévisibles.

Par ailleurs, le secteur énergétique algérien fait face à plusieurs défis majeurs, notamment une forte dépendance aux ressources fossiles, des pertes significatives sur le réseau de distribution, ainsi qu'un déséquilibre récurrent entre l'offre et la demande en période de pointe. Dans cette perspective, la transition vers un modèle de consommation plus durable constitue une priorité stratégique pour les pouvoirs publics. L'amélioration de l'efficacité énergétique dans les bâtiments, appuyée par l'intégration progressive des technologies intelligentes et des systèmes de contrôle automatisés, apparaît ainsi comme une voie incontournable pour alléger la pression exercée sur les infrastructures électriques existantes.

En outre, l'Algérie amorce progressivement l'intégration des outils de digitalisation dans le secteur énergétique, à travers le développement des réseaux intelligents (smart grids), l'installation de compteurs communicants et la collecte de données en temps réel. Ces évolutions ouvrent la voie à l'application des techniques d'intelligence artificielle en vue de mieux analyser, modéliser et anticiper les comportements de consommation énergétique dans les bâtiments.

Dans le cadre de ce travail, une base de données réelle relative à la consommation horaire d'un bâtiment a été exploitée. Initialement structurée sous forme tabulaire (jours en colonnes, heures en lignes), cette base a été soumise à un prétraitement afin de la rendre exploitable par des modèles d'apprentissage automatique. Elle a été enrichie par l'intégration de variables temporelles cycliques (heure, mois), d'indicateurs saisonniers (printemps, été, automne, hiver), ainsi que de statistiques glissantes (moyenne mobile sur 6 heures, maximum, minimum). Cette restructuration permet de mieux capturer les dynamiques complexes de consommation, en intégrant la dimension temporelle et saisonnière propre au contexte énergétique algérien.

C'est dans ce contexte national en pleine mutation, marqué par des enjeux d'efficacité énergétique, de durabilité et de modernisation des infrastructures, que s'inscrit le présent travail de recherche. Celui-ci vise à contribuer à une meilleure compréhension des dynamiques de consommation électrique dans les bâtiments algériens et à proposer une solution innovante pour la prévision de la demande à court terme.

1.1 Terminologie et définitions de base

1.1.1 L'énergie

L'énergie se définit comme la capacité d'un système à effectuer un travail ou à provoquer une transformation physique ou chimique. Dans le domaine des sciences économiques, elle est considérée comme une ressource fondamentale au sein du processus de production. La civilisation moderne repose largement sur l'aptitude à convertir l'énergie d'une forme à une autre afin de répondre à une diversité croissante de besoins : transports, production industrielle, éclairage, alimentation, ou encore exploration spatiale. Par conséquent, l'énergie constitue un pilier central du développement technologique et de la compétitivité industrielle [W4].

L'énergie électrique est une forme d'énergie résultant du déplacement de charges électriques à travers un conducteur. Elle est généralement produite par la conversion d'autres formes d'énergie, telles que l'énergie mécanique (dans les centrales hydroélectriques), thermique (dans les centrales à charbon ou à gaz), chimique (dans les piles et batteries), ou encore rayonnante (au moyen de panneaux solaires) [58].

L'énergie électrique occupe une place prépondérante dans les sociétés modernes, en raison de sa facilité de transport, de distribution et de conversion en différentes formes d'énergie utile, telles que la lumière, la chaleur ou le mouvement mécanique. Sa quantité est mesurée en joules (J) dans le système international d'unités ; cependant, dans le contexte de la consommation domestique et industrielle, elle est le plus souvent exprimée en kilowattheures (kWh), unité correspondant à l'énergie consommée par un appareil d'une puissance de 1 kilowatt fonctionnant pendant une durée d'une heure [59].

1.1.2 La consommation d'énergie électrique

La consommation d'énergie électrique désigne la quantité d'électricité utilisée par un dispositif, un bâtiment, un secteur d'activité ou une population au cours d'une période donnée. Elle est généralement exprimée en kilowattheures (kWh) ou en mégawattheures (MWh), et constitue un indicateur clé pour évaluer la demande énergétique d'un territoire donné [W5].

De nombreux facteurs influencent cette consommation, tels que les conditions climatiques, les comportements des usagers, le niveau d'activité économique, les caractéristiques techniques des équipements électriques, ainsi que les politiques énergétiques mises en œuvre [63].

Une compréhension fine de la consommation électrique est essentielle pour la planification énergétique, l'exploitation optimale des réseaux électriques, la réduction des émissions de gaz à effet de serre et l'intégration des sources d'énergie renouvelables. Par ailleurs, cette connaissance constitue un élément central pour les systèmes de prévision de la charge électrique, qui visent à maintenir en permanence l'équilibre entre la production et la consommation d'électricité [61].

1.1.3 L'Internet des Objets (IoT)

L'Internet des Objets (IoT) désigne l'ensemble des objets physiques — tels que les capteurs, compteurs intelligents, dispositifs de contrôle ou équipements domestiques — interconnectés et capables de collecter, transmettre et analyser des données en temps réel via Internet ou des réseaux dédiés. Cette interconnexion permet aux objets d'échanger des informations entre eux et avec des systèmes centraux, facilitant ainsi l'automatisation et la supervision avancée des processus [59].

Dans le secteur énergétique, l'IoT joue un rôle essentiel en permettant une surveillance fine de la consommation, une optimisation dynamique du fonctionnement des équipements, ainsi qu'une gestion intelligente des ressources. Ces technologies sont particulièrement stratégiques dans le contexte des bâtiments intelligents et des réseaux électriques évolués, où la diversité et le volume des données générées nécessitent des solutions de gestion et d'analyse performantes [59].

L'architecture typique d'un système IoT dédié à la surveillance énergétique repose sur un ensemble de capteurs déployés au sein des bâtiments ou du réseau électrique, des modules de communication assurant la transmission sécurisée des données, ainsi que des plateformes logicielles en charge du traitement, de l'analyse et de la visualisation des informations. L'intégration de ces dispositifs permet d'automatiser la collecte de données, de détecter en temps réel les anomalies de fonctionnement et d'optimiser les usages énergétiques en fonction des besoins réels.

L'organisation des capteurs IoT et leur intégration dans les systèmes de surveillance énergétique sont illustrées à la figure 1.1.




FIGURE 1.1 – Illustration des capteurs IoT appliqués à la surveillance des réseaux électriques intelligents [W1].

1.1.4 Smart Grid (Réseau électrique intelligent)

Le *Smart Grid*, ou réseau électrique intelligent, représente une évolution majeure des infrastructures électriques traditionnelles. Il repose sur l'intégration de technologies numériques avancées et de dispositifs de communication bidirectionnelle, permettant un échange en temps réel d'informations et d'énergie entre les producteurs, les consommateurs et les opérateurs du réseau [50].

Grâce à la coordination de capteurs sophistiqués, de compteurs intelligents, d'automates et de systèmes informatiques performants, le *Smart Grid* assure une surveillance continue du réseau, un pilotage dynamique de la distribution d'électricité, ainsi qu'une capacité d'auto-adaptation en cas d'incident, tout en garantissant une interopérabilité optimale entre les différents équipements [51].

Cette infrastructure intelligente facilite l'intégration des sources d'énergie renouvelables, permet un équilibrage instantané entre production et consommation, et encourage l'implication active des utilisateurs à travers des dispositifs de gestion de la demande et de tarification dynamique [53]. De plus, le *Smart Grid* améliore la fiabilité, la résilience et la sécurité du réseau électrique, tout en favorisant une exploitation plus durable, plus efficace et économiquement optimisée du système énergétique national [52].

L'architecture globale d'un *Smart Grid*, illustrant les principaux flux d'informations et d'énergie, ainsi que l'intégration des communications bidirectionnelles, des sources d'énergie distribuées et des systèmes de contrôle intelligents, est présentée à la figure 1.2.

1.1.5 Bâtiments intelligents (Smart Buildings)

Les bâtiments intelligents représentent une nouvelle génération de structures reposant sur l'intégration de technologies numériques avancées, telles que les capteurs, les systèmes d'automatisation et les dispositifs de gestion centralisée. Ces technologies permettent de superviser,




FIGURE 1.2 – Architecture globale d'un Smart Grid intégrant communication bidirectionnelle, sources d'énergie distribuées et systèmes de contrôle intelligents [W2].

de réguler et d'optimiser en continu divers paramètres du bâtiment, incluant la consommation énergétique, le confort thermique, la qualité de l'air intérieur, la sécurité ainsi que l'éclairage [54].

L'intégration de systèmes de gestion technique du bâtiment (BMS/BAS), associée à des algorithmes d'intelligence artificielle et à des outils d'analyse de données, confère aux bâtiments une capacité d'adaptation proactive aux besoins évolutifs des occupants et aux variations des conditions environnementales [55]. Ce mode de fonctionnement adaptatif favorise des économies d'énergie significatives, améliore le confort des usagers et encourage une gestion efficiente et rationnelle des ressources énergétiques [56].

Par ailleurs, l'intégration de sources d'énergie renouvelables et la mise en œuvre de stratégies de gestion prédictive de la demande permettent à ces bâtiments de contribuer activement à la réduction des émissions de gaz à effet de serre et de renforcer la résilience énergétique des infrastructures urbaines [57].

L'architecture générale d'un bâtiment intelligent, illustrant l'intégration des capteurs IoT, des modules de gestion centralisée et des services connectés, est présentée à la figure 1.3.




FIGURE 1.3 – Schéma illustrant l'écosystème de l'Internet des Objets dans un bâtiment intelligent [W3].

1.1.6 La prévision de la consommation comme levier de maîtrise de la surconsommation énergétique

La prévision de la consommation d'énergie électrique consiste à estimer, de manière anticipée, les besoins énergétiques futurs à partir de l'analyse de données historiques, climatiques, économiques et comportementales. Dans un contexte de croissance continue de la demande énergétique, cette approche représente un levier stratégique pour faire face aux problématiques de surconsommation. Elle permet une gestion préventive et optimisée des ressources disponibles, favorisant ainsi l'équilibre entre l'offre et la demande [61].

Les systèmes de prévision, notamment ceux fondés sur l'intelligence artificielle et l'apprentissage automatique, offrent aux gestionnaires de réseaux et aux décideurs la possibilité d'anticiper les pics de consommation, de moduler en temps réel la production, de prévenir les risques de surcharge et de définir des politiques adaptées en matière de tarification ou de sensibilisation aux comportements sobres en énergie [62].

Ainsi, la prévision de la demande énergétique ne se limite plus à une simple analyse statistique ; elle s'inscrit désormais dans une perspective de développement durable, visant à limiter le gaspillage énergétique, réduire les émissions issues d'une surproduction inutile, et faciliter l'intégration stable et efficace des énergies renouvelables au sein des réseaux électriques [W5].

1.1.7 Évolution récente de la consommation mondiale d'énergie

Au cours de la dernière décennie, la consommation d'électricité à l'échelle mondiale a enregistré une progression constante, traduisant une dynamique de croissance soutenue de la demande énergétique. Cette tendance s'explique notamment par l'expansion économique mondiale, l'intensification de l'urbanisation, ainsi que par la transformation numérique des sociétés contemporaines.

Comme le montre la figure 1.4, la consommation nette d'électricité est passée d'environ **20 987 TWh en 2013** à près de **25 530 TWh en 2023**. Cela représente une hausse de plus de **4 500 TWh** en dix ans, soulignant une évolution marquée vers une dépendance croissante à l'électricité dans l'ensemble des secteurs d'activité.

La période allant de 2013 à 2018 a été caractérisée par une croissance régulière, avec un accroissement annuel moyen avoisinant 600 TWh. En 2019, une relative stagnation a été observée, pouvant être attribuée à une conjoncture économique plus modérée ou à des gains en efficacité énergétique. L'année 2020 a vu une légère baisse, conséquence directe des perturbations liées à la pandémie de COVID-19. Toutefois, cette baisse a été rapidement corrigée par une reprise marquée dès 2021. Pour les années 2022 et 2023, les estimations indiquent une stabilisation autour de 25 530 TWh, avec une augmentation modérée d'environ 1,1 % attendue en 2023 selon l'EIA (U.S. Energy Information Administration).

L'analyse de cette trajectoire confirme le rôle de plus en plus central que joue l'électricité dans les politiques énergétiques internationales. L'accroissement de la consommation résulte à la fois de la transition vers des sources d'énergie plus durables, de la généralisation des véhicules électriques, de l'essor des technologies connectées, ainsi que de la croissance démographique mondiale, en particulier dans les pays émergents [63].




FIGURE 1.4 – Évolution de la consommation mondiale d'électricité entre 1980 et 2023. [63]

1.2 Conclusion

La compréhension des concepts fondamentaux liés à l'énergie électrique et à son utilisation dans les bâtiments met en lumière l'évolution rapide des besoins énergétiques à l'échelle mondiale. Cette évolution est principalement portée par l'urbanisation croissante, le développement technologique et l'intensification des usages domestiques et professionnels de l'électricité. Elle s'accompagne d'enjeux majeurs en matière de gestion des ressources, de stabilité des réseaux et de durabilité.

Les avancées technologiques, telles que l'intégration de l'Internet des objets, des réseaux intelligents ou encore des systèmes de gestion automatisée, offrent de nouvelles perspectives pour optimiser la consommation et anticiper les pics de demande. Toutefois, ces dispositifs ne peuvent pleinement atteindre leur potentiel sans une capacité de prévision précise et réactive.

Dans ce contexte, l'étude des dynamiques récentes de la consommation électrique révèle la nécessité de recourir à des approches innovantes, capables de prendre en compte la complexité croissante des données énergétiques. Les limites des modèles traditionnels appellent à l'adoption de méthodes basées sur l'intelligence artificielle, en particulier celles combinant des capacités d'analyse temporelle et structurelle.

Ces constats soulignent l'intérêt d'explorer des solutions prédictives avancées, adaptées aux spécificités du contexte énergétique local, en vue d'améliorer l'efficacité des systèmes existants et de contribuer à une transition énergétique plus intelligente et résiliente.

Chapitre 2

État de l’art sur les modèles de prévision énergétique

Introduction

La consommation d’électricité connaît aujourd’hui des transformations majeures, sous l’effet combiné de la numérisation des usages, de la généralisation des objets connectés (IoT), des fluctuations climatiques et de la diversité croissante des comportements de consommation. Cette évolution accentue considérablement la variabilité des charges énergétiques, rendant indispensable la prévision à court terme, aussi appelée *Short-Term Load Forecasting* (STLF), afin d’assurer la stabilité des réseaux, de limiter les pertes liées à la surproduction et d’optimiser l’utilisation des ressources disponibles [38].

Historiquement, les gestionnaires de réseaux ont largement eu recours à des modèles statistiques tels que la régression linéaire multiple ou les séries temporelles de type ARIMA. Bien que ces méthodes se soient révélées efficaces dans des environnements stables, elles montrent rapidement leurs limites face à des données fortement non linéaires, soumises à des effets saisonniers ou à des facteurs exogènes comme la météo ou les comportements humains [2].

L’intelligence artificielle (IA) s’est ainsi imposée comme une alternative prometteuse. Les techniques d’apprentissage automatique (machine learning) et d’apprentissage profond (deep learning) permettent de modéliser des relations complexes entre les variables et de capturer des dynamiques temporelles fines dans les données énergétiques multivariées. Des approches simples telles que le *k-Nearest Neighbor* (k-NN) se sont montrées performantes dans des bâtiments intelligents équipés de capteurs [1], tandis que des architectures plus complexes, notamment les réseaux LSTM, ont obtenu de très bons résultats dans des environnements hospitaliers [2].

Dans une perspective d’amélioration continue des performances prédictives, les modèles hybrides suscitent un intérêt croissant. L’intégration d’un réseau CNN-GRU avec un algorithme d’optimisation bio-inspiré tel que l’Earth Worm Optimization (EWO) a ainsi permis d’atteindre une précision de 96,33 %, surpassant les résultats des méthodes classiques comme la régression logistique [5]. Par ailleurs, l’utilisation d’un modèle CNN-GRU sur un jeu de données résidentiel a permis d’obtenir un RMSE de seulement 0,31, nettement meilleur que ceux des modèles CNN-

LSTM ou SVM [9].

D'autres travaux ont mis en évidence l'intérêt de combiner les réseaux neuronaux à des techniques d'analyse fréquentielle. L'application de la *Stationary Wavelet Transform* (SWT) couplée à des architectures GRU ou Bi-LSTM permet de réduire le bruit des signaux énergétiques et d'en extraire des motifs temporels cachés, améliorant ainsi la précision des prévisions [6].

Les modèles dits « ensemblistes », tels que XGBoost, LightGBM ou CatBoost, se sont également révélés robustes dans de nombreux contextes d'application. Leur efficacité est encore renforcée lorsqu'ils sont associés à des méthodes d'explicabilité comme SHAP, qui permettent d'identifier les facteurs les plus influents dans la consommation énergétique, tels que les conditions météorologiques, les horaires ou les habitudes d'usage [6].

Des architectures encore plus avancées, comme les *Stacked LSTM* intégrant le principe du *Snapshot Ensemble*, ont permis d'atteindre des niveaux de précision extrêmement élevés, avec un coefficient de détermination proche de 0.999, au prix toutefois d'une complexité computationnelle importante [7]. D'autres configurations hybrides, comme la combinaison LSTM-XGBoost, cherchent à concilier performance, robustesse et interprétabilité [10].

Par ailleurs, des recherches récentes ont exploré des approches combinant la modélisation physique, via des outils de simulation thermique dynamique tels qu'IDA ICE, avec des algorithmes d'apprentissage automatique comme LightGBM. Cette stratégie permet de tirer parti des atouts respectifs de la physique et des données empiriques, et de produire des prédictions plus fiables et transférables [3].

Dans ce contexte, une étude récente, fondée sur le même jeu de données que celui exploité dans le présent travail, a mis en œuvre un modèle basé sur les réseaux neuronaux convolutionnels (CNN), montrant sa capacité à capter efficacement les tendances de la consommation résidentielle, notamment en intégrant les effets saisonniers et comportementaux [7].

En Algérie, malgré l'efficacité reconnue de ces approches à l'échelle internationale, leur mise en œuvre demeure encore marginale. Or, face aux contraintes structurelles, économiques et climatiques qui pèsent sur le système énergétique national, le développement de modèles prédictifs avancés constitue une nécessité stratégique. C'est dans cette optique que s'inscrit cette recherche, qui propose la conception d'un modèle hybride basé sur une architecture CNN-LSTM, spécifiquement adapté au contexte algérien. Ce modèle vise à améliorer la précision des prévisions de la consommation électrique à court terme, tout en contribuant à une gestion énergétique plus intelligente, proactive et durable.

2.1 Intelligence artificielle

2.1.1 Régression

Un modèle statistique constitue un outil mathématique essentiel permettant de conceptualiser et d'analyser les relations intrinsèques entre les variables d'un ensemble de données. Ces modèles sont employés pour réaliser des prédictions, formuler des conclusions et appuyer la prise de décision, notamment dans les domaines de la statistique, de la science des données et

de l'apprentissage automatique. Ils s'avèrent particulièrement adaptés à l'étude de problématiques complexes telles que la dynamique de la croissance économique, l'évolution des marchés ou encore l'analyse des résultats médicaux.

Il existe une grande variété de modèles statistiques, regroupant plusieurs catégories spécifiques telles que les modèles de régression, les modèles de séries temporelles, les modèles bayésiens, entre autres. Ces structures sont mobilisées afin de répondre à divers objectifs : la prévision de valeurs futures, l'identification des facteurs déterminants, l'estimation de relations causales, ainsi que d'autres applications selon les contextes d'analyse [64].

2.1.1.1 Modèle ARIMA

Le modèle *ARIMA* (AutoRegressive Integrated Moving Average) est un modèle statistique utilisé pour analyser et prévoir des séries temporelles, en particulier lorsque celles-ci présentent des tendances non stationnaires [28]. Il repose sur l'idée que les valeurs passées de la série (composante auto-régressive), les erreurs de prévision passées (composante moyenne mobile), ainsi qu'une ou plusieurs différenciations successives de la série (composante intégrée), peuvent être combinées pour modéliser son comportement futur [27].

Le modèle est noté $ARIMA(p, d, q)$ où :

- p indique le nombre de termes auto-régressifs (AR),
- d le nombre de différenciations appliquées pour rendre la série stationnaire (I),
- q le nombre de termes de moyenne mobile (MA).

Cette approche est particulièrement efficace pour la modélisation de séries temporelles dans des domaines tels que l'économie, la finance, la météorologie ou encore la prévision de la consommation d'énergie [28]. Elle permet de capturer des dépendances temporelles complexes en s'appuyant uniquement sur l'évolution passée des données.

2.1.1.2 Modèle de régression linéaire

La régression linéaire est un modèle statistique fondamental permettant de modéliser la relation entre une variable dépendante et une ou plusieurs variables indépendantes, en supposant que cette relation est linéaire. Le modèle s'exprime généralement sous la forme suivante :

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_n x_n + \varepsilon \quad (2.1)$$

où y représente la variable à prédire, $x_1, \dots, x_n$ les variables explicatives, β_0 l'ordonnée à l'origine, β_i les coefficients de régression, et ε l'erreur aléatoire supposée suivre une loi normale centrée réduite [25] [26].

L'objectif principal est d'estimer les coefficients β en minimisant la somme des carrés des résidus, selon la méthode des moindres carrés ordinaires (MMCO), afin d'obtenir une droite ou un plan de régression qui ajuste au mieux les données [24].

La régression linéaire est largement utilisée dans de nombreux domaines tels que la prévision énergétique, l'économie, le traitement des données biomédicales ou encore les sciences sociales

[26].




FIGURE 2.1 – Illustration du modèle de régression linéaire [W6]

2.1.2 Apprentissage automatique

Le concept d'apprentissage automatique (*machine learning*) a été défini de diverses manières dans les travaux scientifiques, traduisant la complexité et l'ampleur de ce domaine en constante évolution. Dans une approche générale, il peut être considéré comme un ensemble de méthodes permettant à un système informatique d'améliorer ses performances dans une tâche donnée à partir de données empiriques, sans avoir été explicitement programmé à cet effet [11]. Il s'agit d'un processus au cours duquel le système apprend à identifier des régularités ou des structures dans les données, afin de prendre des décisions ou effectuer des prédictions sur de nouvelles situations.

Selon Jordan et Mitchell, l'apprentissage automatique constitue une discipline qui repose essentiellement sur des techniques statistiques pour modéliser des phénomènes à partir de données, dans le but de construire des systèmes capables de généraliser au-delà des exemples observés [12]. De son côté, Bishop met l'accent sur l'utilisation de modèles probabilistes, ajustés par des algorithmes d'optimisation, pour minimiser les erreurs de prédiction sur des ensembles de données d'entraînement [11]. Enfin, Alpaydin définit ce champ comme le fait de « programmer des ordinateurs pour qu'ils optimisent un critère de performance en utilisant des données d'exemple ou une expérience passée » [14].

Ces différentes définitions révèlent les fondements communs du *machine learning* : l'usage de données comme expérience, l'amélioration progressive d'un système à travers l'apprentissage, et l'application de modèles mathématiques pour automatiser des tâches complexes. Cette approche est aujourd'hui essentielle dans de nombreux domaines, notamment la prévision énergétique, où les modèles doivent s'adapter à des comportements non linéaires, des variations saisonnières et des conditions d'exploitation dynamiques.

2.1.2.1 Machines à vecteurs de support (SVM)

Les machines à vecteurs de support, ou *Support Vector Machines* (SVM), constituent des modèles d'apprentissage supervisé largement employés en apprentissage automatique pour résoudre des problèmes de classification et de régression. Elles se distinguent particulièrement par

leur efficacité dans les tâches de classification binaire, où l'objectif est de trouver une frontière de décision optimale séparant les données de deux classes distinctes.

Le principe fondamental des SVM repose sur la maximisation de la marge, c'est-à-dire la distance entre l'hyperplan séparateur et les points de données les plus proches, appelés vecteurs de support. Cette stratégie assure une séparation nette et robuste entre les catégories. Lorsque les données ne sont pas linéairement séparables, les SVM utilisent une technique de projection dans un espace de dimension supérieure à l'aide de noyaux (ou *kernels*), permettant ainsi de modéliser des relations plus complexes.

Cette capacité à capturer des structures non linéaires rend les SVM particulièrement pertinents pour le traitement de données complexes, notamment dans les domaines de la bio-informatique, de la reconnaissance d'images, ou encore de la détection d'intrusions dans les réseaux [22].




FIGURE 2.2 – Définition géométrique SVM [23]

2.1.3 Apprentissage profond

L'*apprentissage profond* constitue une branche de l'apprentissage automatique, lui-même rattaché aux domaines plus larges de l'intelligence artificielle et de la statistique. Cette approche repose sur l'utilisation des *réseaux de neurones artificiels*, conçus pour imiter la structure du cerveau humain. Ces réseaux sont composés de *nœuds interconnectés*, appelés *neurones*, organisés en *couches successives*. Cette architecture leur permet d'extraire de manière autonome des

caractéristiques et des motifs complexes à partir des données.

Grâce à leur capacité à traiter de grandes quantités de données, qu'elles soient *étiquetées (supervisées)* ou *non étiquetées (non supervisées)*, les algorithmes d'apprentissage profond sont particulièrement efficaces pour accomplir des tâches avancées telles que *la reconnaissance d'images et de la parole, le traitement automatique du langage naturel*, ou encore *la conduite autonome* [15].

2.1.3.1 Réseaux de neurones convolutifs

Les *réseaux de neurones convolutifs* (CNN, pour *Convolutional Neural Networks*) représentent une catégorie de modèles d'apprentissage profond spécifiquement conçus pour le traitement de données structurées sous forme de grille, telles que les images. Inspirés de l'organisation du *cortex visuel des animaux*, ces réseaux sont capables d'apprendre automatiquement des *hiérarchies spatiales de caractéristiques*, allant des motifs simples aux représentations complexes de haut niveau.

Un réseau convolutif est généralement composé de *trois types de couches* : les couches de *convolution*, les couches de *sous-échantillonnage (ou pooling)*, et les *couches entièrement connectées*. Les couches de convolution et de pooling assurent l'extraction des *caractéristiques locales*, tandis que les couches entièrement connectées permettent d'effectuer la *classification finale*.

Les CNN traitent efficacement les images en appliquant un *noyau de convolution (ou filtre)*, c'est-à-dire une petite grille de paramètres, à chaque position de l'image. Cette technique permet de détecter des motifs pertinents n'importe où dans l'image. L'apprentissage du réseau s'effectue via un processus d'*optimisation des paramètres*, notamment les noyaux, en minimisant l'erreur entre les sorties prédites et les étiquettes réelles. Ce processus repose sur l'*algorithme de rétropropagation* combiné à la *descente de gradient* [16] .




FIGURE 2.3 – Architecture typique d'un réseau de neurones convolutif ([17])

2.1.3.2 Réseaux de mémoire à long et court terme (LSTM)

Les réseaux de mémoire à long et court terme, ou *Long Short-Term Memory* (LSTM), ont été spécifiquement conçus pour surmonter les limites des réseaux de neurones récurrents (RNN)

traditionnels, notamment leur difficulté à capturer les dépendances à long terme dans les séquences de données. Grâce à leur architecture particulière, les LSTM sont capables de conserver des informations pertinentes sur de longues périodes, ce qui les rend particulièrement efficaces pour les tâches impliquant des séries temporelles ou des données séquentielles complexes.

L'efficacité des LSTM repose sur la présence de *cellules mémoire* intégrant trois types de portes : la porte d'entrée, la porte d'oubli et la porte de sortie. Ces mécanismes régulent de manière dynamique le flux d'information, permettant au réseau de décider quelles informations doivent être retenues, oubliées ou utilisées pour la prédiction [19].

Cette capacité d'apprentissage à long terme rend les LSTM particulièrement utiles dans des domaines tels que la traduction automatique, le traitement du langage naturel ou encore la reconnaissance vocale. Par ailleurs, ils ont démontré leur efficacité dans la prédiction du trafic routier urbain, apportant des solutions pertinentes pour la gestion dynamique de la circulation et la réduction des congestions [20] [21].




FIGURE 2.4 – Schéma simplifié de l'architecture d'un réseau LSTM [18]

2.2 Travaux connexes

TABLE 2.1 – Synthèse des 21 articles de recherche analysés

Réf.	Auteurs	Type de modèle	Jeu de données	Résultats	Avantages / Inconvénients
[40]	Adel Bin-busayyis, Mohamed Sha (2025)	Modèle Deep Learning : Deep CNN + Bi-LSTM modifié avec mécanisme d'attention	Household Energy Consumption dataset (données de consommation énergétique domestique)	MSE = 0,123 ; MAE = 0,22 ; MAPE = 324,12 % ; temps d'entraînement = 692,12 s ; temps de prédiction = 1,87 s	Avantages : Spatiales ; Précision ; Attention Inconvénients : MAPE ; Complexité ; Ressources
[29]	Khaoula Elhabyb, Amine Baina, Mostafa Bellafkih, Ahmed Farouk Deifalla (2024)	LSTM (deep learning), Random Forest (machine learning), Gradient Boosting Regressor (hybride)	Données IoT de 3 bâtiments (2020–2023), 27 variables	LSTM : RMSE = 7,05, MAE = 5,60, MAPE = 5,49 % ; Random Forest : RMSE = 8,90, MAE = 6,97, MAPE = 6,88 % ; Gradient Boosting : RMSE = 7,82, MAE = 6,13, MAPE = 5,98 %	Avantages : Précision ; Adaptabilité ; Optimisation Inconvénients : Données ; Complexité ; Personnalisation

[4]	Jinrong Wu, Su Nguyen, Daminda Alahakoon, Daswin De Silva, Nishan Mills, Prabod Rathnayaka, Harsha Moraliyage, Andrew Jennings (2024)	XGBoost (Machine Learning) <i>Autres modèles testés</i> : ANN, SVM, Lasso	Données multi-types (résidentiel, commercial, industriel, académique)	Résidentiel : $R^2 = 0,85$, $CV(RMSE) = 18,47\%$, $MAPE = 13,80\%$ Commercial : $R^2 = 0,88$, $CV(RMSE) = 17,22\%$, $MAPE = 12,45\%$ Industriel : $R^2 = 0,81$, $CV(RMSE) = 21,33\%$, $MAPE = 16,42\%$ Académique : $R^2 = 0,87$, $CV(RMSE) = 17,81\%$, $MAPE = 13,02\%$	Avantages : Précision ; Robustesse ; Interprétabilité Inconvénients : Données ; BoîteNoire
[2]	Momina Qureshi, Masood Ahmad Arbab, Sadaqat ur Rehman (2024)	LSTM (Deep Learning) <i>Autres modèles testés</i> : optimisation des hyperparamètres	Données réelles : 8 760 mesures horaires collectées sur une année dans un hôpital à Phoenix (USA), exprimées en kWh	Précision de 95 % ; consommation mensuelle moyenne variant de 1 111 à 1 191 kWh	Avantages : Précision ; Anomalies ; Adaptabilité ; Efficacité Inconvénients : Généralisation ; Données ; Complexité

[32]	Roberto Morcillo-Jimenez, Jesús Mesa, Juan Gómez-Romero, M. Amparo Vila, Maria J. Martin-Bautista (2024)	Seq2Seq, CNN, RNN, MLP, XGBoost	ICPE (Bucarest), chauffage, météo, occupation, pas de 15 min (janv.–mars 2017)	D1 : NMAE = 0,21 (janv., Seq2Seq), 0,43 (fév.), 0,29 (mars). D5/2 : NMAE = 0,20 (janv., Seq2Seq), 0,30 (fév., CNN), 0,29 (mars). MAE moyen $\approx$ 5 kW	Avantages : Temporalité; Robustesse; Segmentation Inconvénients : Données; Surajustement; Complexité
[6]	Majdi Frikha, Khaled Taouil, Ahmed Fakhfakh, Faouzi Derbel (2024)	Modèles deep learning (LSTM, GRU, Bi-GRU, Bi-LSTM, Bi-GRU LSTM) combinés à la Stationary Wavelet Transform (SWT) avec ondelette bior2.4	Données réelles de consommation électrique à trois intervalles (1 min, 15 min, 1 h)	Pour l'intervalle 1 min : RMSE = 0,0257, MAPE = 2,25 %, MAE = 0,0152 (SWT/GRU bior2.4) vs. RMSE = 0,0674, MAPE = 5,91 %, MAE = 0,0362 (GRU seul); amélioration de plus de 60 %	Avantages : Précision; Tendances Inconvénients : Complexité; Ondelette

[7]	Farah Rania, Brahim Farou, Zineddine Kouahla, Hamid Seridi (2023)	Convolutional Neural Network (CNN), Transformer, Random Forest <i>Autres modèles testés :</i> Linear Regression, Decision Trees	Base de données Sonalgaz (Algérie), données de consommation électrique 2008–2020, pas de 30 min	Random Forest : $R^2 = 0,99$, RMSE = 1,24, MAE = 1,55 Transformer-Encoder : $R^2 = 0,98$, RMSE = 0,71, MAE = 0,80 CNN : $R^2 = 0,98$, RMSE = 0,09, MAE = 0,099 Linear Regression : $R^2 = 0,99$, RMSE = 0,028, MAE = 0,08 Decision Trees : $R^2 = 0,97$, RMSE = 1,99, MAE = 3,50	Avantages : Robustesse ; Dépendances ; Précision ; Simplicité ; Interprétabilité Inconvénients : Précision ; RMSE ; Linéarité ; Performances ; Horizon
[37]	Tarana Singh, Arun Solanki, Sanjay Kumar Sharma, N. Z. Jhanjhi, Rania M. Ghoniem (2023)	Modèle hybride CNN-LSTM optimisé par Grey Wolf Optimization (GWO)	Smart Home Dataset (IoT et météo), collecte chaque minute pendant 350 jours, appareils domestiques et conditions météorologiques, données nettoyées et normalisées	RMSE = 0,6213, MSE = 0,3860, MAE = 0,2808	Avantages : Précision ; Optimisation ; Complexité ; Autoapprentissage Inconvénients : Coût ; Données ; Implémentation

[3]	Xia Chen, Tong Guo, Martin Kriegel, Philipp Geyer (2022)	Modèle hybride combinant simulation physique (IDA ICE v4.8) et machine learning (ANN, LightGBM) avec dé- compo- sition STL	Données réelles d'un bâtiment commercial à Shanghai (Chine), 3 ans de mesures horaires, don- nées statiques et dynamiques accessibles sur GitHub	Simulation seule : NRMSE = 20,1 %, R^2 = 0,82 ML seul (LightGBM) : NRMSE = 13,7 %, R^2 = 0,89 Hybride (LightGBM) : NRMSE = 7,5 %, R^2 = 0,95	Avantages : Écart ; Simplicité ; Exploita- tion ; Généralisation Inconvénients : Com- plexité ; Données ; Calibrage
-----	--	--	--	--	--

[34]	Yingjun Ruan, Gang Wang, Hua Meng, Fanyue Qian (2022)	Modèle hybride VMD + mRMR + LSTM (Deep Learning avec décomposition variationnelle et sélection de caractéristiques) <i>Autres modèles testés :</i> LSTM, VMD + mRMR + BPNN, EEMD + mRMR + BPNN, VMD + MIM + LSTM	Données réelles de consommation électrique d'un bâtiment de bureaux à Qingdao (Chine), séries temporelles complexes et instables	LSTM : MAE = 41,77 kWh, RMSE = 67,70 kWh, $R^2 = 0,87$ VMD + mRMR + BPNN : MAE = 36,42 kWh, RMSE = 47,54 kWh, $R^2 = 0,94$ EEMD + mRMR + BPNN : MAE = 50,39 kWh, RMSE = 62,21 kWh, $R^2 = 0,89$ VMD + MIM + LSTM : MAE = 33,15 kWh, RMSE = 46,42 kWh, $R^2 = 0,94$ VMD + mRMR + LSTM : MAE = 21,36 kWh, RMSE = 30,64 kWh, $R^2 = 0,97$	Avantages : Non-linéarité ; Séparation ; Sélection ; Dépendances ; Robustesse Inconvénients : Paramétrage ; Interprétation ; Calcul ; Données
------	---	---	--	--	--

[36]	Qingqing Ji, Shiyu Zhang, Qiao Duan, Yuhang Gong, Yaowei Li, Xintong Xie, Jikang Bai, Chunli Huang, Xu Zhao (2022)	Modèle hybride de fusion multi-modèles (XLG-LR : GBDT + XGBoost + LightGBM fusionnés par régression logistique) <i>Autres modèles testés :</i> GBDT, XGBoost, LightGBM, GRU, LSTM, TCN	Données publiques d'une ville chinoise sur 13 mois ; consommation électrique, météo (température, humidité, vent, pluie), pas de 15 minutes, nettoyage et découpage 70 % entraînement, 30 % test	GBDT : MAE = 1,553, RMSE = 2,119, MAPE = 2,31 %, $R^2 = 0,993$ XGBoost : MAE = 1,534, RMSE = 2,098, MAPE = 2,29 %, $R^2 = 0,993$ LightGBM : MAE = 1,527, RMSE = 2,091, MAPE = 2,28 %, $R^2 = 0,993$ XLG-LR : MAE = 1,513, RMSE = 2,072, MAPE = 2,25 %, $R^2 = 0,994$ GRU : MAE = 1,589, RMSE = 2,178, MAPE = 2,39 %, $R^2 = 0,992$ LSTM : MAE = 1,574, RMSE = 2,158, MAPE = 2,37 %, $R^2 = 0,992$ TCN : MAE = 1,561, RMSE = 2,139, MAPE = 2,35 %, $R^2 = 0,992$	Avantages : Précision ; Météo ; Légèreté ; Fusion Inconvénients : Données ; Complexité ; Sensibilité
------	--	--	--	---	---

[39]	Jaewon Chung, Beakcheol Jang (2022)	Modèle hybride CNN-LSTM (Deep Learning) <i>Autres modèles testés</i> : MLP, RNN, LSTM	Données multi-variées sud-coréennes (2004-2020) : consommation énergétique mensuelle (16 régions), import/export, météo (température, précipitations), issues des portails Open Data, Open MET, et Trade Statistics	Niveau national : CNN-LSTM : RMSE = 0,165 MLP : RMSE = 0,4521 RNN : RMSE = 0,1713 LSTM : RMSE = 0,174 Niveau régional : CNN-LSTM systématiquement meilleur que les autres modèles (RMSE et MAPE inférieurs)	Avantages : Multivarié ; Précision ; Régional ; Adaptabilité Inconvénients : Qualité ; Complexité ; Granularité
[30]	Majed A. Alotaibi (2022)	Deep Neural Network (DNN), ANN (MLP), Decision Tree (DT) <i>Autres modèles testés</i> : ANN (MLP), Decision Tree	Données historiques de demande électrique (Ontario, Canada) : IESO, météo (Environnement Canada), prix horaires de l'énergie (HOEP), échantillon de 200 lectures horaires	DNN (horaire) : MAE = 0,0221 kW, $R^2 = 0,988$ DNN (journalier) : MAE = 0,0342 kW, $R^2 = 0,973$ DNN (hebdomadaire) : MAE = 0,0408 kW, $R^2 = 0,965$	Avantages : Variables ; Catégorielles ; Précision ; Validité Inconvénients : Préparation ; Nettoyage ; Ressources

[9]	Muhammad Sajjad, Zulfiqar Ahmad Khan, Amin Ullah, Tanveer Hussain, Waseem Ullah, Mi Young Lee, Sung Wook Baik (2020)	Modèle hybride CNN-GRU (Deep Learning) <i>Autres modèles testés</i> : Linear Regression, SVR, Decision Tree, CNN, LSTM, CNN-LSTM	AEP (Appliances Energy Prediction) dataset et IHEPC dataset (pré-traitement par normalisation et suppression des valeurs aberrantes)	Linear Regression : MAE = 0,161, RMSE = 0,228, MAPE = 10,6 % SVR : MAE = 0,157, RMSE = 0,221, MAPE = 10,1 % Decision Tree : MAE = 0,149, RMSE = 0,211, MAPE = 9,8 % CNN : MAE = 0,143, RMSE = 0,203, MAPE = 9,2 % LSTM : MAE = 0,139, RMSE = 0,198, MAPE = 8,9 % CNN-LSTM : MAE = 0,137, RMSE = 0,195, MAPE = 8,7 % CNN-GRU (proposé) : MAE = 0,132, RMSE = 0,188, MAPE = 8,4 %	Avantages : Précision ; Généralisation ; Synergie ; Légèreté Inconvénients : Entraînement ; Déploiement ; Prétraitement
-----	--	--	--	---	--

[5]	Nasir Ayub, Muhammad Irfan, Muhammad Awaiz, Usman Ali, Tariq Ali, Mohammed Hamdi, Abdullah Al-ghamdi, Fazal Muhammad (2020)	Modèle ensembliste hybride combinant feature selection (RF, XGB), feature extraction (RFE), et prédiction par SVM-GWO et CNN-GRU-EWO	Données ISONE (ISO New England), charge électrique quotidienne de 2012 à 2019 (8 ans), 14 caractéristiques (DA_Demand, RT_Demand, Dew_Point, DA_LMP, RT_EC)	CNN-GRU-EWO : précision = 96,33 %, MAPE = 6 % SVM-GWO : précision = 93,99 %, MAPE = 1,33 % CNN : précision = 89 % SVM : précision = 87,99 % ELM : précision = 78,98 % Linear Regression : précision = 78,35 %	Avantages : Précision ; Overfitting ; Vitesse ; Innovation Inconvénients : Complexité ; Généralisation ; Calcul
-----	---	--	---	--	--

Dans le domaine de la prévision de la consommation électrique des bâtiments, une analyse approfondie de **21 travaux de recherche** a été réalisée et synthétisée dans le tableau présenté précédemment tableau 2.1. Ces études s'appuient sur diverses approches d'intelligence artificielle, mobilisant des jeux de données enregistrés selon des fréquences horaires ou journalières, et enrichis par l'intégration de variables temporelles, saisonnières, météorologiques ainsi que d'autres facteurs contextuels.

Les méthodes d'apprentissage les plus simples, telles que l'algorithme des k plus proches voisins (k -Nearest Neighbor, k -NN), ont démontré des performances relativement limitées, particulièrement dans les environnements où la variabilité des profils de consommation est importante. Leur structure algorithmique basique ne permet pas de capturer correctement les dépendances temporelles ni les relations non linéaires complexes inhérentes aux séries de consommation énergétique. Par conséquent, ces modèles génèrent fréquemment des erreurs de prédiction élevées (RMSE supérieur à 0,45), restreignant leur capacité à reproduire avec précision les dynamiques réelles de consommation.

En revanche, les réseaux de neurones récurrents, notamment les *Long Short-Term Memory* (LSTM) et leurs déclinaisons empilées (*Stacked LSTM*), présentent une aptitude renforcée à modéliser les dépendances temporelles longues ainsi que les relations non linéaires complexes. Ces modèles ont permis d'obtenir des résultats très satisfaisants, avec un MAE avoisinant 0,32 et des coefficients de détermination (R^2) pouvant atteindre 0,999. Toutefois, cette performance accrue s'accompagne souvent d'une complexité algorithmique importante, d'un temps d'entraî-

nement considérable et d'une vulnérabilité accrue au surapprentissage, notamment lorsque les volumes de données sont restreints ou affectés par du bruit.

Afin d'améliorer la qualité des prédictions tout en maîtrisant les risques de surajustement, de nombreuses études ont proposé des architectures hybrides combinant des réseaux convolutifs (*Convolutional Neural Networks*, *CNN*) et des réseaux récurrents (*GRU* ou *LSTM*). Ces approches permettent de tirer parti des capacités des *CNN* à extraire des motifs locaux fréquents et de celles des réseaux récurrents à capturer des dynamiques temporelles de plus longue durée. À titre d'exemple, un modèle *CNN-GRU* optimisé par un algorithme bio-inspiré (*Earth Worm Optimization - EWO*) a atteint une précision de 96,33 %, tandis qu'une autre architecture *CNN-GRU* a enregistré un RMSE de 0,31, surpassant ainsi les performances obtenues avec les *CNN-LSTM* ou les *SVM* sur certains jeux de données.

Les modèles hybrides *CNN-LSTM* exploitent quant à eux des cellules *LSTM* dotées de portes d'entrée, d'oubli et de sortie, leur permettant de gérer efficacement les dépendances temporelles longues et complexes en maintenant une mémoire adaptative sur des séquences étendues. En comparaison, les modèles *CNN-GRU* reposent sur des cellules *GRU* plus épurées, équipées uniquement de deux portes (mise à jour et réinitialisation), ce qui réduit la charge computationnelle tout en conservant une bonne capacité de traitement sur des séquences temporelles plus courtes.

Néanmoins, dans les contextes caractérisés par des séries temporelles présentant des dépendances longues, des cycles saisonniers marqués et une forte variabilité inter-annuelle — ce qui est fréquemment observé dans les données de consommation énergétique des bâtiments — les architectures *CNN-LSTM* tendent généralement à surpasser les performances des modèles *CNN-GRU*. Cette supériorité s'explique notamment par la capacité des cellules *LSTM* à mieux préserver l'information sur de longues périodes, alors que les *GRU* peuvent parfois perdre ces informations lorsque les séquences deviennent complexes et étendues.

Parallèlement, des modèles ensemblistes tels que *LightGBM*, *XGBoost* et *CatBoost*, parfois associés à des simulateurs physiques (comme *IDA ICE*) ou intégrés à des réseaux *LSTM* dans des approches hybrides (*LSTM-XGBoost*), ont également démontré des performances intéressantes. Ces méthodes ont permis d'atteindre un R^2 de 0,95 pour *LightGBM* lorsqu'il est couplé à une simulation physique, et un MAE de 0,28 pour le modèle hybride *LSTM-XGBoost*. Un atout majeur de ces approches réside dans leur capacité d'interprétation accrue, facilitée notamment par l'usage d'outils explicatifs tels que *SHAP*.

Enfin, d'autres travaux ont cherché à réduire le bruit présent dans les séries temporelles et à identifier des structures cachées, en associant des techniques d'analyse fréquentielle, telles que la *Stationary Wavelet Transform (SWT)*, avec des réseaux récurrents (*GRU* ou *Bi-LSTM*), permettant ainsi d'améliorer la précision des prévisions générées.

2.3 Conclusion

La prévision de la charge électrique représente un enjeu stratégique pour les entreprises de production et de distribution d'énergie, leur permettant d'optimiser à la fois leurs capacités opérationnelles et leur rentabilité économique. Une estimation précise de la consommation future contribue à assurer un approvisionnement stable et fiable, tout en minimisant les pertes et les surcoûts liés à une gestion inefficace des ressources.

L'émergence des approches d'intelligence artificielle, et en particulier des techniques d'apprentissage profond, a considérablement renforcé les capacités prédictives dans le domaine énergétique. Dans ce contexte, ce travail s'est attaché à étudier la problématique de la prévision de la consommation électrique, qui constitue l'objectif central de cette recherche.

Une revue approfondie de 21 contributions scientifiques récentes a été réalisée, puis synthétisée sous forme de tableau comparatif, permettant d'analyser et de comparer les différentes méthodes utilisées selon divers critères d'évaluation. Cette analyse a servi de base à la sélection des approches les plus pertinentes et performantes pour la suite de l'étude.

Il est important de souligner que la qualité, l'enrichissement et la maintenance continue des jeux de données constituent des facteurs déterminants dans la précision des modèles prédictifs. Des bases de données riches en variables temporelles, saisonnières et contextuelles permettent aux modèles hybrides de mieux saisir les variations complexes inhérentes à la consommation énergétique.

Sur la base de cette synthèse, l'architecture hybride CNN-LSTM a été retenue pour la poursuite de ce travail, en raison de sa capacité à modéliser simultanément les motifs locaux et les dépendances temporelles longues caractéristiques des séries de consommation électrique. La conception du modèle retenu ainsi que les expérimentations menées seront détaillées dans les prochains chapitres.

Chapitre 3

Conception et Mise en Œuvre du Système

Introduction

Dans le cadre de la gestion des réseaux électriques, la prévision de la consommation énergétique représente un levier stratégique permettant d'anticiper les fluctuations de la demande et d'assurer la stabilité du système. Face aux variations saisonnières marquées observées en Algérie, l'élaboration de modèles de prévision précis s'avère indispensable. Ce travail de recherche s'appuie sur des techniques d'apprentissage profond, notamment les réseaux de neurones convolutifs (CNN), les réseaux de mémoire à long et court terme (LSTM), ainsi que des architectures hybrides (CNN-LSTM et CNN-BiLSTM), afin de prédire la consommation horaire d'électricité. Après un prétraitement approfondi des données historiques couvrant la période 2008-2020, les modèles ont été évalués à l'aide d'indicateurs de performance standards, démontrant la capacité des approches hybrides à améliorer la précision des prévisions et à contribuer à une gestion plus efficace des ressources énergétiques.

3.1 Conception globale du système

3.1.1 Objectifs de la solution proposée

Cette section présente les objectifs généraux du système de prévision énergétique développé. L'enjeu principal consiste à concevoir un outil performant capable d'anticiper, à une échelle horaire, la consommation d'électricité, en tenant compte des variations saisonnières marquées qui caractérisent la demande énergétique en Algérie. La solution proposée repose sur l'exploitation de modèles d'apprentissage profond, associés à un prétraitement rigoureux des données historiques, afin d'obtenir des prédictions fiables et exploitables pour la gestion du réseau électrique.

3.1.2 Architecture fonctionnelle du système

Le système développé s'appuie sur l'apprentissage profond appliqué à des données de consommation couvrant la période 2008-2020. Après un nettoyage minutieux visant à éliminer les valeurs manquantes ou aberrantes, les données sont enrichies par l'introduction de variables temporelles (heure, mois, saison), codées de manière à respecter leur nature cyclique. Les données ainsi préparées alimentent ensuite les modèles de deep learning — CNN, LSTM et leurs variantes hybrides — en vue de produire des prévisions horaires de la demande. Ce dispositif contribue à la planification et à l'optimisation des ressources énergétiques, particulièrement dans les périodes de forte sollicitation du réseau national.

3.1.3 Schéma de fonctionnement du système

Le système de prévision développé dans le cadre de ce travail suit une série d'étapes structurées, illustrées dans la Figure 3.1. Ce schéma fonctionnel présente l'ensemble du processus de traitement, depuis la collecte des données jusqu'à la génération des prédictions finales.




FIGURE 3.1 – Diagramme de fonctionnement du système proposé

Dans cette étude, nous avons conçu un modèle de prévision de la consommation électrique à une échelle horaire, fondé sur l'exploitation de données historiques importées au format CSV. Le processus commence par une phase de nettoyage des données, durant laquelle les doublons sont supprimés et les valeurs manquantes sont traitées. Ensuite, les données sont restructurées d'un format large vers un format long, mieux adapté à l'analyse temporelle.

Des variables explicatives supplémentaires sont ensuite introduites pour enrichir les données : les saisons (printemps, été, automne, hiver) sont encodées par la méthode one-hot encoding, tandis que les heures et les mois sont représentés sous forme cyclique à l'aide de fonctions trigonométriques (sinus et cosinus), ce qui permet de capturer la périodicité inhérente à ces variables. Par ailleurs, des indicateurs statistiques saisonniers tels que les minimums, maximums et moyennes mobiles sont également calculés afin de renforcer la représentation des dynamiques de consommation.

Les données sont ensuite normalisées à l'aide de la méthode Min-Max Scaling, puis scindées en deux ensembles chronologiquement ordonnés : un ensemble d'entraînement et un ensemble de test.

Le modèle proposé combine deux types d'architectures neuronales complémentaires : les réseaux de neurones convolutifs (CNN), capables d'extraire des motifs locaux dans les séries temporelles, et les réseaux à mémoire longue à court terme (LSTM), conçus pour capturer les dépendances temporelles à long terme. Cette combinaison permet au système de tirer parti à la fois des structures spatiales et des dynamiques temporelles présentes dans les données.

L'entraînement du modèle est réalisé à l'aide de l'optimiseur Adam, en utilisant la fonction de perte Huber, avec un taux d'apprentissage fixé à 0,001. Un mécanisme d'arrêt anticipé (early stopping) est mis en place pour interrompre l'entraînement si aucune amélioration n'est observée après 20 itérations consécutives.

Enfin, la performance du modèle est évaluée à l'aide d'indicateurs classiques de régression : l'erreur absolue moyenne (MAE), la racine de l'erreur quadratique moyenne (RMSE), le coefficient de détermination (R^2), ainsi que le pourcentage moyen d'erreur absolue (MAPE). Les prédictions sont effectuées sur des données de test non vues durant l'entraînement, afin de garantir une évaluation impartiale de la capacité généralisatrice du modèle.

3.2 Prétraitement

3.2.1 Présentation du jeu de données

Le présent travail s'appuie sur un jeu de données horaires relatif à la consommation d'électricité en Algérie, issu de l'étude intitulée « Data Driven Models on Load Forecasting : Case Study Algeria » [44] [10]. Ce jeu de données, fourni par l'entreprise nationale de distribution de l'électricité, couvre une période de treize années, allant de 2008 à 2020. Il se distingue par sa qualité, sa fiabilité et sa structuration, ce qui en fait une base solide pour l'analyse des tendances de consommation électrique à court terme.

Les données sont organisées sous forme tabulaire, avec une ligne par jour. Chaque ligne comporte 24 colonnes correspondant aux différentes heures de la journée (de 1h à 24h), ainsi qu’une colonne **Date** indiquant le jour concerné. Ce format facilite l’analyse fine de la consommation heure par heure, élément essentiel pour la compréhension des comportements énergétiques au fil du temps.

Le fichier CSV contient un total de 4 907 lignes (jours) et 25 colonnes. Il comprend une colonne **Date**, qu’il convient de convertir au format `datetime` afin d’être exploitée dans les traitements ultérieurs, ainsi que 24 colonnes horaires de type `int64`, représentant la consommation électrique à chaque heure de la journée. Ce jeu de données constitue ainsi la base d’apprentissage et de validation du modèle de prévision proposé.

La Figure 3.2 illustre l’étape d’importation du fichier CSV dans l’environnement de travail, première étape du processus de traitement des données.

Il est également important de souligner que cette base de données, utilisée dans le présent travail pour des prévisions à court terme, est exploitée par l’entreprise **Sonelgaz** principalement dans une perspective de *prévision à long terme*. Lors de mon stage au sein de cette entreprise, j’ai pu observer l’utilisation de ces données dans le cadre de projets de grande envergure, comme la planification énergétique pour de nouvelles zones urbaines. Un exemple concret concerne la commune de **Hajar El M’goub** (wilaya de Guelma), où des estimations ont été menées pour anticiper la consommation électrique sur une période de dix ans, dans le but de dimensionner les générateurs à installer.

En revanche, le présent projet adopte une *approche complémentaire*, axée sur la prévision à court terme, afin d’optimiser la gestion quotidienne du réseau électrique. Ces prévisions à plus courte échéance permettent de détecter les pics de consommation, de réduire les pertes énergétiques et d’améliorer l’efficacité du système. Ainsi, les deux approches – à long et à court terme – se complètent et contribuent ensemble à une meilleure maîtrise des besoins énergétiques.




FIGURE 3.2 – Importation des données depuis un fichier CSV

3.2.2 Analyse exploratoire des données

3.2.2.1 Évolution de la consommation d’électricité dans le temps

Cette section propose une analyse descriptive de l’évolution de la consommation d’électricité en Algérie sur la période allant de 2008 à 2020. Pour ce faire, un graphique en ligne a été réalisé

afin de visualiser les variations journalières de la demande en électricité.




FIGURE 3.3 – Évolution journalière de la consommation d’électricité (2008–2020)

Comme l’illustre la Figure 3.3, la courbe de consommation électrique présente des variations saisonnières notables. Des pics récurrents sont observés durant les périodes estivales et hivernales, correspondant aux phases de forte sollicitation des systèmes de climatisation et de chauffage. Ce comportement cyclique témoigne d’une dépendance marquée de la demande énergétique aux conditions météorologiques.

Ces observations soulignent l’importance d’intégrer des variables exogènes telles que les saisons, la température ou encore les événements climatiques extrêmes dans les modèles de prévision. En tenant compte de ces facteurs, il devient possible d’améliorer la précision des prédictions, en particulier lors des périodes critiques de forte demande, contribuant ainsi à une gestion plus efficace et résiliente du réseau électrique national.

3.2.2.2 Consommation maximale selon les saisons et les années

Dans cette sous-section, nous analysons l’évolution des pics de consommation d’électricité en fonction des saisons et des années. Pour ce faire, un graphique en barres a été élaboré, mettant en évidence les valeurs maximales de consommation enregistrées à chaque saison, pour chaque année de la période d’étude.

Comme l’illustre la Figure 3.4, les pics de consommation estivale présentent une tendance haussière, particulièrement marquée à partir de l’année 2015. Cette évolution peut s’expliquer par plusieurs facteurs : la croissance démographique et urbaine, la généralisation de l’usage des climatiseurs, ainsi que la fréquence accrue des épisodes de canicule.

L’analyse de ces pics saisonniers est essentielle pour affiner les modèles de prévision de la demande énergétique. En anticipant les pointes de consommation, les gestionnaires du réseau électrique peuvent mettre en place des stratégies de réponse plus efficaces, ce qui contribue à renforcer la résilience du système face aux défis liés au changement climatique et aux évolutions socio-économiques.




FIGURE 3.4 – Consommation maximale par saison et par année

3.2.3 Nettoyage des données

Le nettoyage des données constitue une étape fondamentale avant toute opération de modélisation. Il s'agit de vérifier la qualité et l'intégrité du jeu de données afin de garantir la fiabilité des résultats produits par le modèle de prévision.

Dans cette phase, une inspection minutieuse a été réalisée pour détecter d'éventuelles valeurs manquantes, incohérentes ou dupliquées. Après analyse, il a été constaté que le jeu de données ne présente ni valeurs manquantes ni doublons. Ces résultats confirment la bonne qualité des données disponibles et permettent d'entamer les étapes suivantes sur une base saine et cohérente.

Résultats du contrôle de qualité des données :

Absence de valeurs manquantes

Aucune donnée dupliquée détectée

Liste 1 : Vérification de l'intégrité des données brutes

3.2.4 Transformation vers un format temporel exploitable

Cette étape consiste à restructurer le jeu de données afin de le rendre exploitable pour une analyse temporelle fine. Initialement, les données étaient organisées sous un format dit « large », où chaque ligne correspond à une journée complète, répartie sur 24 colonnes représentant chacune une heure, de h1 à h24.

Pour faciliter une étude horaire détaillée, ce format a été converti en format « long », où chaque observation horaire devient une ligne distincte comportant la date et l'heure précises. Cette transformation permet d'appréhender plus efficacement la dynamique temporelle de la consommation électrique.

Mathématiquement, cette conversion peut s'exprimer comme suit :

$$X_{d,h} \rightarrow (t_i, x_i)$$

où $X_{d,h}$ désigne la consommation enregistrée à la date d et à l'heure h , transformée en une paire (t_i, x_i) représentant respectivement le timestamp exact t_i (date et heure) et la consommation correspondante x_i .

Ce remaniement structurel constitue une étape essentielle pour l'application optimale de modèles prédictifs basés sur les séries temporelles [5].

3.2.4.1 Création et encodage de la variable saisonnière

Dans cette partie, nous avons enrichi le jeu de données avec une nouvelle variable : la saison de l'année correspondant à chaque enregistrement. Cette information permet de mieux capturer les variations saisonnières de la consommation électrique, liées notamment à l'utilisation accrue du chauffage en hiver et de la climatisation en été.

Chaque ligne du tableau est associée à une date. À partir de cette date, nous extrayons le mois, puis déterminons la saison selon la règle suivante :

$$s = \begin{cases} \text{Printemps,} & m \in \{3, 4, 5\} \\ \text{Été,} & m \in \{6, 7, 8\} \\ \text{Automne,} & m \in \{9, 10, 11\} \\ \text{Hiver,} & m \in \{12, 1, 2\} \end{cases} \quad (3.1)$$

Codage des saisons en fonction du mois [44]

Notation : m représente le mois, et s la saison correspondante.

Pour exploiter cette variable dans les modèles de machine learning, nous avons procédé à un encodage *one-hot* de la saison. Autrement dit, chaque saison est représentée par une colonne binaire. Par exemple, si une observation correspond à l'hiver, la colonne « hiver » prend la valeur 1, tandis que les colonnes des autres saisons valent 0.

3.2.4.2 Codage cyclique des variables temporelles

Dans les séries temporelles, certaines variables présentent une périodicité intrinsèque. Par exemple, les heures d'une journée évoluent de 0 à 23 avant de revenir à 0, tout comme les mois de l'année qui s'enchaînent de décembre (12) à janvier (1). Si ces variables sont considérées sous leur forme numérique brute, un modèle risque de mal interpréter la proximité entre 23h et 0h, ou entre décembre et janvier, en les percevant comme distantes.

Afin de pallier cette limitation, un **codage cyclique** fondé sur les fonctions trigonométriques sinus et cosinus est appliqué. Chaque valeur horaire h et mensuelle m est ainsi convertie en deux variables selon les relations suivantes :

$$\text{Heuresin} = \sin\left(2\pi \cdot \frac{h}{24}\right), \quad \text{Heurecos} = \cos\left(2\pi \cdot \frac{h}{24}\right) \quad (3.2)$$

$$\text{Moisin} = \sin\left(2\pi \cdot \frac{m}{12}\right), \quad \text{Moiscos} = \cos\left(2\pi \cdot \frac{m}{12}\right) \quad (3.3)$$

Codage cyclique des heures et des mois [7]

Notation : h représente l'heure, variant de 0 à 23, et m le mois, variant de 1 à 12.

Ce codage cyclique permet aux modèles d'apprentissage automatique de saisir la nature circulaire des variables temporelles, améliorant ainsi la qualité et la cohérence des prédictions.

3.2.4.3 Agrégations statistiques par saison

Afin d'approfondir l'analyse de la consommation électrique en fonction des saisons, nous avons calculé des indicateurs statistiques essentiels, à savoir les valeurs minimales et maximales de consommation enregistrées pour chacune des quatre saisons.

Ces agrégats fournissent une compréhension fine des comportements saisonniers de la consommation, tout en constituant des repères pertinents pour les modèles prédictifs. Ils permettent notamment de détecter des anomalies ou des variations inhabituelles par rapport aux tendances saisonnières habituelles.

Formellement, pour chaque saison $s \in \{\text{Printemps}, \text{Été}, \text{Automne}, \text{Hiver}\}$, les extrêmes de consommation sont définis par :

$$\text{Conso}_{\min}^s = \min_{i \mid \text{Saison}_i = s} x_i, \quad \text{Conso}_{\max}^s = \max_{i \mid \text{Saison}_i = s} x_i \quad (3.4)$$

Agrégation des extrêmes saisonniers [8]

où x_i représente la consommation à l'instant i , et Saison_i correspond à la saison associée.

Ces valeurs sont ensuite intégrées au jeu de données sous forme de deux nouvelles variables : `Conso_min` et `Conso_max`, qui indiquent respectivement les bornes inférieure et supérieure historiques de la consommation pour la saison considérée. Cette étape contribue à améliorer la capacité des modèles à modéliser les variations saisonnières et à accroître la précision des prévisions.

3.2.5 Fractionnement des données

3.2.5.1 Séparation chronologique apprentissage/test

L'analyse des séries temporelles exige impérativement le respect de la séquentialité chronologique lors du fractionnement des données. Contrairement aux jeux de données classiques où un échantillonnage aléatoire peut être envisagé, il est essentiel ici d'éviter que le modèle accède à des informations provenant du futur, ce qui pourrait biaiser l'évaluation des performances et compromettre la validité des prédictions.

Pour cette raison, une méthode simple mais rigoureuse a été appliquée : les 80 % premiers points chronologiques ont été affectés à l'ensemble d'apprentissage, tandis que les 20 % restants constituent l'ensemble de test. Cette répartition garantit que le modèle s'entraîne uniquement sur des observations passées afin de prédire des valeurs futures de manière réaliste.

$$\text{Train} = \{x_i \mid i < 0,8 \times N\}, \quad \text{Test} = \{x_i \mid i \geq 0,8 \times N\} \quad (3.5)$$

Fractionnement séquentiel des séries temporelles [6]

Notation : N représente le nombre total d'exemples dans le jeu de données.

Objectif : préserver l'ordre chronologique et éviter toute fuite d'information entre les ensembles.

Après l'ensemble des étapes de préparation des données — comprenant le nettoyage, les transformations temporelles, l'enrichissement par variables explicatives et la normalisation — les données ont été découpées en séquences temporelles de 24 heures.

Les dimensions finales des jeux de données ainsi préparés sont les suivantes :

- **Ensemble d'apprentissage** : (94190, 24, 12) pour les entrées, et (94190,) pour les sorties ;
- **Ensemble de test** : (23530, 24, 12) pour les entrées, et (23530,) pour les sorties.

3.2.5.2 Normalisation Min-Max des variables

Les réseaux de neurones bénéficient d'une homogénéisation des échelles des variables en entrée. En effet, des différences importantes entre les amplitudes des variables peuvent ralentir la convergence et compliquer l'optimisation, en perturbant notamment le calcul des gradients lors de la rétropropagation.

Afin de remédier à ces difficultés, une normalisation Min-Max a été appliquée, ramenant chaque valeur dans l'intervalle $[0, 1]$, selon la transformation suivante :

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (3.6)$$

où x désigne la valeur initiale, $x_{\min}$ et $x_{\max}$ représentent respectivement les valeurs minimale et maximale observées sur l'ensemble d'apprentissage, et x' correspond à la valeur normalisée.

Cette opération facilite la convergence des modèles et stabilise l'apprentissage en évitant la présence de gradients excessivement grands ou faibles.

3.2.6.3 Corrélation entre les variables explicatives et la consommation

Avant de procéder à l'analyse de corrélation, rappelons que chaque séquence temporelle contient les 12 variables explicatives suivantes :

```

    hour_sin, hour_cos, month_sin, month_cos,
    season_fall, season_spring, season_summer, season_winter,
    rolling_mean_6h, Conso_max, Conso_min, Datetime.
    
```

Pour comprendre quelles variables influencent le plus la consommation d'électricité, nous avons calculé une matrice de corrélation linéaire entre les différentes caractéristiques et la consommation.

Les résultats montrent que certaines variables, comme la moyenne glissante sur six heures (`rolling_mean_6h`) ou les données saisonnières, ont une corrélation positive importante avec la consommation. Par contre, les variables codées avec un encodage cyclique (`hour_sin`, `month_cos`, etc.) et les variables saisonnières en binaire ont une corrélation plus faible.

Il faut aussi noter que même si certaines variables ont une faible corrélation linéaire, elles peuvent être très utiles dans des modèles non linéaires, comme les réseaux de neurones. Ces modèles peuvent trouver des relations complexes entre les variables que les méthodes classiques ne peuvent pas voir.

La figure suivante montre la matrice de corrélation faite avec les données normalisées :




FIGURE 3.5 – Matrice de corrélation des variables explicatives avec la consommation

3.3 Modélisation

Dans le cadre de cette étude, plusieurs architectures de réseaux de neurones ont été développées et analysées dans le but d'identifier l'approche la plus performante pour la prévision

horaire de la consommation électrique. La sélection de chaque modèle repose sur sa capacité à capturer des caractéristiques spécifiques des séries temporelles, qu'il s'agisse des motifs locaux, des tendances globales ou encore des variations saisonnières.

Cette section présente en détail les différentes architectures mises en œuvre ainsi que les critères retenus pour évaluer leurs performances. Parmi les indicateurs de performance figurent : l'erreur absolue moyenne (*Mean Absolute Error*, MAE), l'erreur quadratique moyenne (*Root Mean Squared Error*, RMSE), le coefficient de détermination (R^2) et l'erreur absolue en pourcentage moyenne (*Mean Absolute Percentage Error*, MAPE). Ces métriques seront utilisées ultérieurement dans la section **Résultats et discussions** afin de comparer objectivement les performances des différents modèles après entraînement.

3.3.1 Conception des modèles de prévision et description architecturale


3.3.1.1 Modèle Réseau de Neurones Convolutif (CNN)

Le modèle de réseau de neurones convolutif (*Convolutional Neural Network*, CNN) est particulièrement adapté à la détection de motifs locaux au sein des séries temporelles, tels que les schémas récurrents observés dans la consommation électrique horaire. Il repose sur des couches de convolution unidimensionnelles (**Conv1D**) capables d'extraire des caractéristiques temporelles pertinentes, notamment les pics de consommation à certaines heures de la journée.

L'architecture débute par une couche **Conv1D** comportant 64 filtres de taille 3, associée à la fonction d'activation **ReLU**. Une seconde couche **Conv1D** suit, avec 128 filtres de même taille, puis une couche de **MaxPooling1D** est appliquée afin de réduire la dimensionnalité des données. Pour limiter le risque de surapprentissage, un mécanisme de régularisation par **Dropout** est utilisé avec un taux de 0,3.

Les sorties convolutives sont ensuite aplaties via une couche **Flatten** avant d'être transmises à deux couches entièrement connectées (**Dense**), comportant respectivement 64 et 32 neurones, également activées par la fonction **ReLU**. La couche finale de sortie est constituée d'un neurone unique avec une activation linéaire, fournissant ainsi la prédiction de la consommation.

Ce modèle est efficace pour modéliser des séries temporelles caractérisées par des variations locales fréquentes. En capturant automatiquement des motifs significatifs, tels que les fluctuations horaires ou journalières, il permet d'obtenir des prévisions précises à court terme. Par ailleurs, son apprentissage rapide, couplé à une bonne capacité de généralisation, en fait un outil robuste et performant pour l'analyse des phénomènes énergétiques présentant des variations rapides et fréquentes.




Architecture du modèle CNN

3.3.1.2 Modèle Mémoire à Long et Court Terme (LSTM)

Le modèle *Long Short-Term Memory* (LSTM) est un type de réseau de neurones récurrent particulièrement adapté à l'analyse des séries temporelles. Il est capable d'apprendre et de modéliser des dépendances à long terme, telles que les tendances globales et les variations saisonnières présentes dans la consommation d'électricité.

Dans cette étude, l'architecture retenue comprend une seule couche LSTM composée de 128 unités, spécifiquement conçue pour traiter les données horaires. Afin de limiter le risque de surapprentissage, une couche de régularisation Dropout avec un taux de 0,2 a été intégrée après la couche LSTM.

La sortie de cette couche est ensuite transmise à une couche Dense constituée d'un unique neurone, chargé de fournir la prédiction finale de la consommation électrique.

**Architecture du modèle LSTM**

Grâce à sa structure interne, fondée sur un mécanisme de mémoire contrôlé par des portes (entrée, oubli et sortie), le modèle **LSTM** est en mesure de conserver et d'exploiter efficacement les informations temporelles pertinentes sur de longues séquences. Cette capacité est particulièrement avantageuse dans le contexte de la prévision de la consommation d'électricité, caractérisée par des cycles étendus et des évolutions progressives. Ainsi, le modèle **LSTM** permet d'améliorer la précision des prédictions sur des horizons prolongés, même en présence de fluctuations irrégulières dans les données.

3.3.1.3 Modèle Réseau de Neurones Convolutif avec Mémoire à Long et Court Terme (CNN-LSTM)

Le modèle *CNN-LSTM* repose sur une architecture hybride combinant la puissance d'extraction de caractéristiques locales des réseaux de neurones convolutifs (*CNN*) avec la capacité des réseaux à mémoire longue et courte terme (*LSTM*) à modéliser les dépendances temporelles à long terme. Cette approche exploite ainsi la complémentarité de deux paradigmes d'analyse des séries temporelles.

Les couches *CNN*, placées en amont, permettent de capturer les motifs locaux présents dans les données, tels que les variations horaires récurrentes, en exploitant des filtres convolutifs capables d'identifier automatiquement des schémas pertinents à court terme. Les représentations ainsi extraites sont ensuite transmises aux couches *LSTM*, qui modélisent les dépendances temporelles globales en intégrant les dynamiques saisonnières, hebdomadaires et les variations progressives.


Dans l'implémentation adoptée, la séquence d'entrée est d'abord traitée par deux couches **Conv1D** successives, comportant respectivement 64 et 128 filtres avec un noyau de taille 5, une activation **ReLU**, et un **padding** de type « same » assurant la préservation de la dimension temporelle. Un sous-échantillonnage est ensuite réalisé via une couche **MaxPooling1D** de taille 2, permettant de réduire la complexité tout en conservant l'essentiel de l'information.

La séquence transformée est transmise à deux couches **LSTM** en cascade : la première, avec 128 unités, restitue l'intégralité de la séquence pour apprendre des représentations temporelles complètes, tandis que la seconde, avec 64 unités, ne conserve que la dernière sortie. À chaque

niveau, un **Dropout** de 0,05 est appliqué pour améliorer la généralisation, et une normalisation par couche stabilise l'apprentissage.

La sortie est ensuite transmise à une couche **Dense** intermédiaire de 64 neurones activés par **ReLU**, avant d'être projetée dans l'espace de sortie via une couche linéaire à un seul neurone chargé de produire la prédiction finale.

Le modèle *CNN-LSTM* permet ainsi une double analyse des séries temporelles : l'extraction automatique des motifs locaux via les couches convolutives, et la modélisation des relations temporelles globales par les couches *LSTM*. Cette synergie permet de capturer simultanément les phénomènes à court et à long terme dans les séries de consommation énergétique. L'architecture *CNN-LSTM* s'avère ainsi particulièrement adaptée aux contextes multi-échelles, où la demande énergétique est influencée à la fois par des variations journalières et des dynamiques saisonnières plus lentes.



Architecture du modèle CNN-LSTM


3.3.1.4 Modèle Réseau de Neurones Convolutif avec LSTM Bidirectionnel (CNN-BiLSTM)

Le modèle *CNN-BiLSTM* constitue une extension du modèle *CNN-LSTM*, enrichie par l'intégration d'une couche *LSTM bidirectionnelle*. Cette dernière permet de traiter simultanément les données temporelles dans les deux directions, en exploitant à la fois les dépendances issues du passé et celles issues du futur. Cette capacité améliore significativement la modélisation des relations temporelles complexes, notamment lorsque la consommation d'énergie est influencée par des facteurs présents avant et après l'instant étudié.

L'architecture débute par deux couches **Conv1D** comportant respectivement 64 et 128 filtres, avec un noyau de taille 3 et une fonction d'activation **ReLU**. Ces couches permettent de détecter automatiquement les motifs locaux caractéristiques tels que les variations horaires ou les pics de consommation. Les représentations extraites sont ensuite transmises à une couche **Bidirectional LSTM** de 128 unités, qui explore les séquences temporelles dans les deux directions pour capturer une représentation contextuelle globale. Cette sortie est ensuite affinée par une couche **LSTM** unidirectionnelle de 64 unités.

Afin de limiter le surapprentissage, un **Dropout** de 0,3 est appliqué après les couches séquentielles, tandis qu'une **LayerNormalization** est introduite pour stabiliser et accélérer la convergence de l'apprentissage. Enfin, la sortie est transmise à une couche **Dense** composée d'un unique neurone chargé de fournir la prédiction de la consommation.

L'atout majeur du modèle *CNN-BiLSTM* réside dans sa capacité à combiner trois mécanismes complémentaires : l'extraction locale de motifs par les couches convolutives, la mémorisation séquentielle par les couches **LSTM**, et l'intégration du contexte temporel global via le traitement bidirectionnel. Cette combinaison permet de modéliser efficacement des séries temporelles complexes, incluant aussi bien des variations rapides que des effets de contexte à plus long terme (jours fériés, week-ends, périodes exceptionnelles, etc.). Par sa robustesse et sa polyvalence, l'architecture *CNN-BiLSTM* constitue ainsi une solution performante pour la prévision énergétique dans des environnements fortement variables.



Architecture du modèle CNN-BiLSTM

3.3.2 Métriques d'évaluation

Dans ce travail, quatre métriques ont été retenues afin d'évaluer la performance des modèles appliqués aux séries temporelles de consommation d'électricité. Ces mesures permettront, dans la section **Résultats et discussions**, de comparer objectivement les performances obtenues par les différentes architectures.

- **MAE (Erreur Absolue Moyenne)** : cette métrique calcule la moyenne des écarts absolus entre les valeurs observées y_i et les valeurs prédites $\hat{y}_i$ [W7]. Son principal avantage réside dans sa facilité d'interprétation, car elle s'exprime dans la même unité que la variable cible. Le MAE est peu sensible aux valeurs aberrantes, offrant ainsi une évaluation globale de l'erreur moyenne du modèle. Sa formule est donnée par :

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.7)$$

- **RMSE (Racine Carrée de l'Erreur Quadratique Moyenne)** : à la différence du MAE, le RMSE amplifie l'impact des grandes erreurs en élevant au carré les écarts avant de calculer la moyenne [W7]. Cette caractéristique le rend particulièrement pertinent lorsque l'objectif est de minimiser les erreurs importantes, notamment lors de la prévision des pics

de consommation. Il est défini par :

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.8)$$

- **R² (Coefficient de Détermination)** : cette métrique évalue la capacité du modèle à expliquer la variance des observations [W8]. Une valeur de R^2 proche de 1 indique que le modèle reproduit fidèlement les variations des données, tandis qu’une valeur proche de 0 témoigne d’une faible qualité de prédiction. Sa formulation est la suivante :

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.9)$$

où $\bar{y}$ désigne la moyenne des valeurs observées.

- **MAPE (Erreur Pourcentuelle Absolue Moyenne)** : le MAPE exprime l’erreur moyenne en pourcentage par rapport aux valeurs réelles [W9], ce qui le rend utile pour comparer des séries de différentes échelles ou unités. Cependant, cette métrique peut devenir instable lorsque certaines valeurs observées y_i sont proches de zéro. La formule est donnée par :

$$\text{MAPE} = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (3.10)$$

3.4 Implémentation

3.4.1 Introduction technique

Dans cette section, nous présentons l’environnement de développement ainsi que les outils technologiques mobilisés pour la conception du système de prévision de la consommation énergétique. Le choix du langage **Python** s’est imposé de manière naturelle en raison de sa large adoption dans les domaines de la science des données, de l’intelligence artificielle et de l’apprentissage automatique, ainsi que de la richesse de son écosystème de bibliothèques spécialisées.

Le développement du système s’est articulé autour de plusieurs étapes clés de traitement des données : le **nettoyage**, la **transformation des séries temporelles**, la **normalisation**, la **division des données en ensembles d’apprentissage et de test**, ainsi que la **visualisation** dans le cadre de l’analyse exploratoire. Chaque étape est illustrée à l’aide de blocs de **code Python commentés**, facilitant ainsi la reproductibilité et la compréhension de la méthodologie adoptée.

Le tableau suivant synthétise les principaux outils et bibliothèques utilisés au cours du développement, accompagnés de leur rôle spécifique dans le projet :

Outil / Bibliothèque	Type	Rôle dans le projet
Python	Langage de programmation	Utilisé pour l'ensemble du traitement : nettoyage, modélisation, visualisation et évaluation.
NumPy	Calcul numérique	Gestion efficace des structures de données matricielles et réalisation de calculs mathématiques optimisés.
Pandas	Manipulation de données	Importation, structuration, nettoyage et transformation des jeux de données sous forme de DataFrames.
Matplotlib	Visualisation de données	Génération de graphiques personnalisés pour illustrer les tendances et les patterns temporels.
Seaborn	Visualisation statistique	Complément à Matplotlib pour produire des représentations graphiques esthétiques et informatives.
TensorFlow / Keras	Framework de deep learning	Conception, compilation et entraînement des modèles de réseaux de neurones (LSTM, CNN et modèles hybrides).
Scikit-learn	Machine learning	Prétraitement des données (normalisation, partitionnement) et calcul des indicateurs de performance.

TABLE 3.1 – Outils et bibliothèques utilisés dans le développement du système

Deux environnements de développement complémentaires ont également été mobilisés pour faciliter la programmation et l'exécution du code :

- **Google Colab** : plateforme cloud collaborative permettant l'exécution de notebooks Python avec accès gratuit à des ressources GPU, facilitant ainsi l'entraînement des modèles de deep learning.
- **Visual Studio Code (VS Code)** : éditeur de code multiplateforme utilisé pour organiser le projet de manière modulaire et développer des scripts complémentaires (API avec **Flask**, interface utilisateur avec **Node.js**).

En résumé, cette infrastructure technique a permis de couvrir l'ensemble des étapes du projet, depuis la préparation initiale des données jusqu'à la modélisation avancée et la visualisation des résultats. Ce choix d'outils s'est révélé essentiel pour garantir la robustesse, la lisibilité et l'efficacité du système développé.

3.4.2 Préparation des données

La préparation des données constitue une étape déterminante dans le processus de développement des modèles prédictifs, en particulier lorsqu'il s'agit d'analyser des séries temporelles. Elle vise à garantir la qualité, la cohérence et la fiabilité des données avant leur exploitation par les algorithmes d'apprentissage automatique.

3.4.2.1 Nettoyage des données

Avant toute modélisation, une vérification systématique de l'intégrité des données est impérative. Cette phase consiste à détecter et traiter les valeurs manquantes ainsi que les doublons, sources potentielles de bruit et de biais pouvant altérer la qualité des résultats.

<code>df.isnull().sum()</code>	# Détection des valeurs manquantes
<code>df.duplicated().sum()</code>	# Identification des doublons

Liste 1 : Détection des anomalies dans le jeu de données

Une fois les anomalies identifiées, les traitements appropriés (suppression ou imputation) sont appliqués afin de garantir la cohérence statistique et structurelle du jeu de données. Les données nettoyées sont ainsi prêtes à être transformées et enrichies pour les étapes ultérieures.

3.4.2.2 Transformation du format temporel

Afin de faciliter l'analyse chronologique et la modélisation séquentielle, les données initialement structurées au format *large* (chaque colonne représentant une heure de la journée) sont converties au format *long*, où chaque ligne correspond à une observation horaire unique, associée à un horodatage précis.

<pre>df_long = df.melt(id_vars=['Date'], var_name='Hour', value_name='Consumption') df_long['Datetime'] = df_long['Date'] + pd.to_timedelta(df_long['Hour'] - 1, unit='h') df_long = df_long.sort_values(by="Datetime").reset_index(drop=True)</pre>
--

Liste 2 : Conversion des données au format temporel long

Cette transformation permet d'associer chaque mesure de consommation à un instant précis, facilitant ainsi les visualisations graphiques, les analyses temporelles et l'entraînement des modèles séquentiels tels que les réseaux de neurones récurrents (RNN) et les architectures hybrides CNN-LSTM.

3.4.2.3 Création de nouvelles variables explicatives

Pour enrichir les données d'apprentissage, plusieurs variables dérivées ont été générées afin de capturer les effets temporels susceptibles d'influencer la consommation d'énergie.

a. Identification des saisons :

Une variable catégorielle saisonnière a été introduite en fonction du mois de l'année. Celle-ci a ensuite été transformée en variables indicatrices (*one-hot encoding*) pour faciliter son intégration dans les modèles d'apprentissage.

```
def get_season(month):
    if month in [12, 1, 2]: return "winter"
    elif month in [3, 4, 5]: return "spring"
    elif month in [6, 7, 8]: return "summer"
    else: return "fall"

df['season'] = df.index.month.map(get_season)
df = pd.get_dummies(df, columns=["season"], prefix="season")
```

Liste 3 a : Encodage saisonnier des observations

b. Codage cyclique des variables temporelles :

Les variables temporelles (heure et mois) présentent une structure cyclique (ex. : 23h est proche de 0h, décembre proche de janvier). Afin de préserver cette périodicité dans les représentations numériques, un encodage trigonométrique a été appliqué.

```
df["hour_sin"] = np.sin(2 * np.pi * df.index.hour / 24)
df["hour_cos"] = np.cos(2 * np.pi * df.index.hour / 24)
df["month_sin"] = np.sin(2 * np.pi * df.index.month / 12)
df["month_cos"] = np.cos(2 * np.pi * df.index.month / 12)
```

Liste 3 b : Transformation cyclique des variables temporelles

Ce codage cyclique permet de préserver la nature périodique des variables et d'améliorer la capacité des modèles à capturer les variations saisonnières et journalières de la consommation énergétique.

3.4.2.4 Agrégations statistiques par saison

Afin d'analyser les variations de la consommation énergétique en fonction des saisons, des agrégations statistiques ont été réalisées. Plus précisément, les valeurs maximales et minimales de consommation ont été calculées pour chaque saison et chaque année. Ces indicateurs permettent d'identifier les périodes de forte ou faible demande énergétique et de mieux caractériser les extrêmes de consommation au fil du temps.

```
season_stats = df_processed.groupby(['Year', 'Season'])['Consumption']
    .agg(['max', 'min']).reset_index()
```

Liste 4 : Calcul des maximums et minimums de consommation par saison et par année

Cette étape fournit une vision synthétique des variations saisonnières et contribue à la compréhension des périodes critiques de consommation.

3.4.2.5 Fractionnement et normalisation des données

Avant l'entraînement des modèles prédictifs, il est indispensable de structurer les données correctement. Deux opérations fondamentales sont réalisées : la création de séquences temporelles et la normalisation des variables.

a. Création des séquences temporelles :

Pour tenir compte de la dépendance temporelle inhérente à la consommation énergétique, les données sont segmentées en séquences de 24 heures consécutives. Chaque séquence sert à prédire la valeur de consommation à l'instant suivant. Cette structuration est essentielle dans les approches séquentielles, notamment pour les réseaux de neurones de type LSTM.

```
def create_sequences(data, target_col, seq_length=24):
    X, y = [], []
    for i in range(len(data) - seq_length):
        X.append(data.iloc[i : i + seq_length].values)
        y.append(data.iloc[i + seq_length][target_col])
    return np.array(X), np.array(y)

X_train, y_train = create_sequences(train_scaled, 'Consumption')
X_test, y_test = create_sequences(test_scaled, 'Consumption')
```

Liste 5a : Génération des séquences temporelles d'entrée pour l'entraînement

Cette découpe temporelle permet aux modèles de mieux intégrer les dynamiques locales de consommation et d'optimiser la précision des prédictions.

b. Normalisation des variables :

Étant donné les différences d'échelle entre les différentes variables, une standardisation est appliquée. Cette opération permet de centrer les variables et de réduire leur variance à une échelle comparable, favorisant ainsi la stabilité et la convergence rapide des algorithmes d'apprentissage automatique.

```
from sklearn.preprocessing import StandardScaler
scaler = StandardScaler()
train_scaled = scaler.fit_transform(train_data)
test_scaled = scaler.transform(test_data)
```

Liste 5b : Application de la normalisation aux ensembles d'apprentissage et de test

Cette étape prévient l'effet de domination éventuelle d'une variable sur les autres et garantit un apprentissage équilibré de l'ensemble des caractéristiques.

3.4.2.6 Analyse de corrélation

Dans le but de mieux comprendre les relations entre les différentes variables, une analyse de corrélation a été réalisée. Cette étape permet d'identifier les variables les plus étroitement associées à la consommation d'énergie, et facilite ainsi la sélection des attributs les plus informatifs.

Pour cela, une carte de chaleur (*heatmap*) a été générée afin de visualiser les coefficients de corrélation de Pearson entre les variables.

```
import seaborn as sns
sns.heatmap(df_processed.corr(), annot=True, cmap='coolwarm')
```

Liste 6 : Visualisation des corrélations via carte de chaleur

L'analyse met en évidence les relations significatives, qu'elles soient positives ou négatives, entre les variables explicatives (telles que l'heure, le mois, les variables cycliques) et la variable cible **Consumption**. Ces résultats orientent la phase de sélection des variables, permettant d'écarter les caractéristiques redondantes ou peu contributives.

3.5 Conclusion

L'ensemble des travaux réalisés dans ce chapitre a permis de mettre en place l'infrastructure méthodologique nécessaire au développement des modèles de prévision de la consommation énergétique. Après avoir préparé et structuré les données temporelles, différentes architectures de réseaux de neurones ont été conçues, en tenant compte des spécificités des séries temporelles et des dynamiques propres à la consommation électrique.

L'implémentation des modèles, appuyée par un environnement de développement adapté, a conduit à la production de prédicteurs exploitables et comparables. Les performances de ces modèles seront évaluées et discutées dans le chapitre suivant, à travers une analyse quantitative fondée sur des indicateurs de précision définis préalablement.

Chapitre 4

Résultats expérimentaux et discussions

4.1 Introduction

À la suite de la mise en œuvre des différentes architectures de réseaux de neurones, ce chapitre présente les résultats expérimentaux obtenus et en propose une analyse comparative. Les modèles ont été évalués selon des métriques de performance rigoureuses, afin d'identifier l'approche la plus efficace pour la prévision de la consommation électrique

4.2 Résultats

4.2.1 Modèle Réseau de Neurones Convolutif avec Mémoire à Long et Court Terme (CNN-LSTM)

Dans le cadre de cette étude, plusieurs configurations de l'architecture *CNN-LSTM* ont été explorées dans le but d'identifier celle offrant les meilleures performances pour la prévision à court terme de la consommation électrique. Il a été constaté que les couches convolutionnelles jouent un rôle central dans la capacité du modèle à extraire des motifs locaux pertinents à partir des séquences d'entrée. Leur suppression a conduit à une dégradation significative des performances prédictives, confirmant leur contribution essentielle au processus d'apprentissage.

La composante *LSTM* a été optimisée à l'aide de deux couches successives, renforcées par des mécanismes de normalisation (*Layer Normalization*) et de régularisation, notamment un taux de *dropout* fixé à 0,05, dans le but d'améliorer la stabilité de l'entraînement et la capacité de généralisation du modèle. La fonction de perte utilisée est la fonction de Huber, paramétrée avec un seuil $\delta = 1,5$, offrant un bon compromis entre sensibilité aux petites erreurs et robustesse face aux valeurs aberrantes. L'optimisation du modèle a été assurée à l'aide de l'algorithme *Adam*, avec un taux d'apprentissage initial fixé à 0,001 et une norme de gradient (*clipnorm*) plafonnée à 10,0 pour prévenir les explosions de gradient.

L'apprentissage a été réalisé sur un maximum de vingt époques, avec une taille de lot de 32. Un mécanisme d'arrêt anticipé (*early stopping*), basé sur la surveillance de la perte sur l'ensemble de validation, a été mis en œuvre avec une patience de trois époques. Ce mécanisme

a permis de prévenir le surapprentissage, l'entraînement ayant été interrompu à la neuvième époque suite à une stagnation des performances. Les poids correspondant à la meilleure performance de validation ont été automatiquement restaurés. Enfin, les principaux hyperparamètres tels que le nombre de filtres convolutionnels, les unités *LSTM* et les coefficients de régularisation ont été ajustés de manière itérative afin d'affiner la précision prédictive du modèle.

4.2.2 Modèle Réseau de Neurones Convolutif avec LSTM Bidirectionnel (CNN-BiLSTM)

Après avoir testé le modèle *CNN-LSTM*, nous avons essayé une autre version en ajoutant une couche *LSTM bidirectionnelle*. Cette couche lit les données dans deux sens : du passé vers le futur, et du futur vers le passé. Cela aide le modèle à mieux comprendre les changements rapides ou les inversions dans les données. L'idée est d'utiliser les couches *CNN* pour détecter les petits motifs dans les données, et les couches *BiLSTM* pour apprendre les relations dans le temps, dans les deux directions.

Pour avoir de bons résultats, plusieurs tests ont été faits en changeant les paramètres du modèle. Par exemple : le nombre de filtres dans les couches *CNN*, la taille des filtres, le nombre d'unités *LSTM*, le taux de *dropout* et le taux d'apprentissage. Le modèle final qui a donné les meilleurs résultats avait deux couches *CNN* (avec 64 et 128 filtres, taille 3, fonction *ReLU*), suivies d'une couche *BiLSTM* avec 128 unités, puis d'une couche *LSTM* normale avec 64 unités. Le modèle a aussi utilisé un *dropout* de 0,3 et une normalisation pour améliorer l'apprentissage.

L'entraînement a utilisé la fonction de perte de Huber (avec $\delta = 1,5$), qui est utile pour éviter que les erreurs extrêmes aient trop d'influence. Le modèle a été entraîné avec l'optimiseur *Adam* et un taux d'apprentissage de 0,001. Même si on avait prévu 50 époques, l'entraînement s'est arrêté à la 18e époque, car les performances sur les données de validation ne s'amélioraient plus. L'apprentissage a duré environ 36 minutes.

Une autre série de tests a été faite pour voir comment certains paramètres influencent les résultats. On a remarqué que si le *dropout* est trop grand (plus de 0,4), le modèle donne de moins bons résultats. Si le *dropout* est trop petit (moins de 0,2), le modèle apprend trop les détails du jeu d'entraînement. De plus, un taux d'apprentissage trop grand (plus que 0,001) rend l'apprentissage instable, et un taux trop petit (moins que 0,0005) ralentit l'apprentissage sans donner de meilleurs résultats. Les résultats ont été mesurés avec les métriques *MAE*, *RMSE*, R^2 et *MAPE*. Enfin, des tests ont montré que sans les couches *CNN*, les résultats deviennent moins bons, ce qui prouve qu'elles sont importantes pour comprendre les motifs dans les données.

4.2.3 Modèle Réseau de Neurones Convolutif (CNN)

Dans cette partie, nous avons étudié un modèle *CNN* unidimensionnel (1D) pour voir s'il peut bien apprendre les motifs locaux présents dans les séries temporelles de consommation d'électricité. L'architecture choisie contient deux couches *Conv1D*, avec 64 et 128 filtres, une taille de noyau de 3, et la fonction d'activation *ReLU*. Ces couches permettent de détecter des

formes répétées ou importantes dans les données.

Ensuite, une couche de type `MaxPooling1D` avec une fenêtre de taille 2 a été ajoutée pour réduire la taille des données tout en gardant les informations utiles. Pour éviter que le modèle apprenne trop bien les données d'entraînement (surapprentissage), un *dropout* de 0,3 a été utilisé. Après cela, les données ont été aplaties, puis envoyées dans deux couches complètement connectées (`Dense`) avec 64 et 32 neurones, avant d'aller dans une dernière couche qui donne la prédiction.

Le modèle a été entraîné avec la fonction de perte de Huber ($\delta = 1,5$), qui est utile pour limiter l'impact des erreurs extrêmes. L'optimisation a été faite avec l'algorithme *Adam*, en utilisant un taux d'apprentissage de 0,001. Même si le nombre d'époques était fixé à 50, l'entraînement s'est arrêté automatiquement à la 24^e époque grâce à l'option *early stopping*, car la performance ne s'améliorait plus. Chaque entraînement a duré environ 30 minutes sur un GPU.

Enfin, plusieurs tests ont été faits pour voir comment certains paramètres influencent les résultats. Par exemple, un *dropout* trop petit (moins de 0,2) faisait que le modèle apprenait trop vite et risquait de mal fonctionner sur de nouvelles données. Un *dropout* trop grand (plus de 0,4) empêchait le modèle d'apprendre correctement. De plus, si le taux d'apprentissage était trop élevé (plus de 0,001), le modèle devenait instable. S'il était trop faible (moins de 0,0005), l'apprentissage devenait trop lent sans amélioration importante des résultats.

4.2.4 Modèle Mémoire à Long et Court Terme (LSTM)

Dans cette partie, nous avons testé un modèle composé uniquement de couches LSTM, pour voir s'il pouvait bien prédire la consommation d'électricité à court terme. Plusieurs configurations ont été essayées pour trouver celle qui donnait les meilleurs résultats, tout en gardant un temps d'exécution raisonnable. Le modèle a été entraîné avec l'optimiseur *Adam*, en utilisant un taux d'apprentissage de 0,001. La fonction de perte choisie était la moyenne des carrés des erreurs (*MSE*), car elle est adaptée aux problèmes de régression et permet de bien mesurer les erreurs importantes.

L'apprentissage a été prévu pour 20 époques, avec des lots de 64 exemples. Cependant, grâce à la méthode d'*early stopping*, l'entraînement s'est arrêté automatiquement à la 16^e époque, car la performance ne s'améliorait plus. Cela a permis d'éviter que le modèle apprenne trop les détails des données d'entraînement. En tout, l'entraînement a duré environ 2 heures et 36 minutes.

Nous avons aussi fait des tests pour voir quels paramètres donnaient les meilleurs résultats. Trois valeurs de *dropout* (0,1, 0,2 et 0,3) ont été comparées. La valeur 0,2 a donné un bon équilibre entre apprentissage et généralisation. Ensuite, on a testé différentes tailles de la couche LSTM : 64, 128 et 256 unités. Le meilleur résultat a été obtenu avec 128 unités. Enfin, on a essayé trois taux d'apprentissage (0,0005, 0,001 et 0,005) ; le taux de 0,001 a permis un apprentissage plus rapide et plus stable.

Pour évaluer les performances du modèle, on a utilisé les mesures suivantes : l'erreur absolue moyenne (*MAE*), la racine de l'erreur quadratique moyenne (*RMSE*), le coefficient R^2 et le

pourcentage moyen d'erreur absolue (*MAPE*).

4.3 Discussion

Les résultats présentés dans le tableau 4.1 montrent clairement que les modèles hybrides, comme le **CNN-LSTM** et le **CNN-BiLSTM**, sont plus performants que les modèles simples utilisés seuls. Parmi tous les modèles testés, le **CNN-LSTM** obtient les meilleurs résultats. Il présente les plus faibles erreurs (MAE de 232,74, RMSE de 330,60 et MAPE de 3,12 %) et le meilleur score de détermination ($R^2 = 0,9549$). Cela signifie qu'il réussit à bien apprendre à la fois les motifs locaux et les relations dans le temps dans les données de consommation énergétique. En effet, les couches CNN détectent les formes locales, tandis que les couches LSTM gèrent les séquences dans le temps.

Le modèle **CNN-BiLSTM** arrive en deuxième position. Ses performances sont un peu moins bonnes que celles du CNN-LSTM, mais il reste meilleur que les modèles non hybrides. Grâce aux LSTM bidirectionnels, il peut comprendre les informations du passé et du futur. Cependant, cette complexité rend l'apprentissage un peu plus difficile, ce qui peut expliquer pourquoi il est un peu moins performant que le CNN-LSTM.

Le modèle **LSTM** seul est moins bon que les deux précédents, mais meilleur que le CNN utilisé seul. Il est capable d'apprendre les dépendances dans le temps, mais il ne peut pas détecter les motifs locaux comme le fait un CNN. Cela le rend plus sensible au bruit dans les données.

Quant au modèle **CNN** utilisé seul, c'est celui qui donne les moins bons résultats. Il a une MAE de 393,69, une RMSE de 531,05, un MAPE élevé et un score $R^2 = 0,8836$. Même s'il sait détecter des motifs locaux, il n'est pas adapté pour apprendre les relations longues dans le temps, qui sont importantes dans ce type de données.

En résumé, les modèles hybrides comme le **CNN-LSTM** et le **CNN-BiLSTM** sont les plus efficaces, car ils combinent les avantages des CNN et des LSTM. Ces résultats vont dans le même sens que d'autres études récentes qui recommandent l'utilisation de modèles hybrides pour prédire des séries temporelles complexes.

Modèle	MAE	RMSE	Score R^2	MAPE
CNN-LSTM	232,7406	330,6046	0,9549	3,12 %
CNN-BiLSTM	280,5946	381,7233	0,9399	3,78 %
LSTM	320,6516	445,8256	0,9180	4,30 %
CNN	393,6871	531,0480	0,8836	5,21 %

TABLE 4.1 – Comparaison des performances des modèles d'apprentissage profond




FIGURE 4.1 – Courbes d'apprentissage pour les quatre modèles




FIGURE 4.2 – Comparaison des valeurs réelles et prédites par les différents modèles

L'analyse des courbes et des résultats numériques montre encore une fois que le modèle **CNN-LSTM** est le meilleur. Sur la figure figure 4.2, on voit que les prédictions du CNN-LSTM suivent de très près les vraies valeurs. Il réussit à bien suivre les hausses et les baisses de la consommation, même quand elles sont complexes.

Le modèle **CNN-BiLSTM** donne aussi de bonnes prédictions, mais elles sont parfois un peu moins stables. Les modèles **LSTM** et **CNN** seuls ont plus d'erreurs, ce qui montre qu'ils sont moins bons pour généraliser à de nouvelles données.

Les résultats chiffrés confirment cela. Le CNN-LSTM atteint une **MAE de 242,90**, un **RMSE de 345,25**, un $R^2 = 0,9508$ et un **MAPE de 3,30 %**. Cela montre qu'il fait très peu d'erreurs, même sur des données complexes.

La figure figure 4.1 montre que pendant l'entraînement, la perte diminue de façon stable sans signe de surapprentissage. Cela signifie que le modèle peut bien fonctionner sur d'autres données que celles utilisées pour l'apprentissage.

En conclusion, tous les résultats — les chiffres, les courbes d'apprentissage et les graphiques de prédiction — montrent que le **CNN-LSTM** est le modèle le plus performant. Grâce à sa structure hybride, il combine les avantages des CNN pour trouver les motifs locaux, et des LSTM pour gérer les séquences dans le temps. C'est une solution très adaptée pour prédire la consommation d'énergie.

4.4 Conclusion

L'analyse approfondie des résultats expérimentaux a permis de dégager des conclusions claires quant à l'efficacité des différentes architectures de réseaux de neurones testées. Il ressort de cette étude que les modèles hybrides, notamment l'architecture *CNN-LSTM*, offrent les meilleures performances pour la prévision à court terme de la consommation électrique. Cette supériorité s'explique par la complémentarité des deux composantes du modèle : les couches convolutionnelles permettent d'extraire efficacement les motifs locaux présents dans les données, tandis que les couches *LSTM* assurent une modélisation robuste des dépendances temporelles.

Les résultats obtenus selon des indicateurs rigoureux tels que la *MAE*, la *RMSE*, le coefficient de détermination R^2 et le *MAPE* confirment la capacité du modèle *CNN-LSTM* à fournir des prédictions précises et stables, y compris face à des variations complexes de la demande énergétique. Les autres architectures, bien qu'efficaces sur certains aspects, se sont révélées moins performantes, en particulier lorsqu'elles ne combinaient pas les deux types de traitement.

En somme, cette étude valide l'intérêt des approches hybrides pour le traitement de séries temporelles dans un contexte de prévision énergétique. Elle souligne également l'importance d'un ajustement rigoureux des hyperparamètres et d'un encadrement méthodologique strict pour garantir la fiabilité des résultats. Ces conclusions constituent un apport significatif pour le développement futur de solutions intelligentes de gestion de la demande en électricité.

Conclusion Générale

Dans un contexte de transition énergétique mondiale et de pressions croissantes sur les systèmes de production et de distribution électrique, la prévision de la consommation énergétique à court terme constitue un levier stratégique pour améliorer l'efficacité, la résilience et la durabilité des infrastructures. Ce mémoire a exploré cette problématique à travers la conception et l'implémentation d'un modèle prédictif hybride basé sur l'architecture CNN-LSTM, spécifiquement adapté aux bâtiments algériens.

L'étude a permis, dans un premier temps, de mettre en évidence les enjeux liés à la consommation électrique dans le secteur du bâtiment en Algérie, notamment la forte dépendance aux énergies fossiles, les variations saisonnières marquées, ainsi que les limitations des approches traditionnelles de prévision. Un important travail de prétraitement et d'enrichissement des données a ensuite été réalisé afin de capter avec plus de précision les dynamiques temporelles et les effets exogènes influençant la demande.

À travers une comparaison rigoureuse entre plusieurs modèles d'apprentissage automatique et d'apprentissage profond, les résultats obtenus ont confirmé l'intérêt des approches hybrides. L'intégration de réseaux convolutifs (CNN) pour l'extraction de caractéristiques locales, couplée à des réseaux à mémoire longue (LSTM) pour la modélisation des dépendances temporelles, a permis d'atteindre des performances prédictives élevées, surpassant celles des modèles classiques.

En définitive, cette recherche constitue une contribution concrète à la modernisation des outils de gestion énergétique en Algérie. Elle souligne l'importance de l'intelligence artificielle comme moteur d'innovation pour anticiper les besoins, optimiser les ressources et accompagner la transition vers un modèle énergétique plus intelligent, résilient et durable.

Perspectives

Ce travail ouvre plusieurs perspectives de recherche en vue d'améliorer la précision et la fiabilité des modèles de prévision énergétique à court terme. Une première évolution possible consisterait à intégrer des variables exogènes, notamment des données météorologiques telles que la température, l'humidité ou le rayonnement solaire, afin de mieux modéliser les facteurs environnementaux influençant la consommation. Toutefois, cette démarche n'a pas été retenue dans le cadre de cette étude, dans la mesure où les données utilisées représentent la consommation nationale agrégée, sans information géographique associée. Or, en Algérie, le climat varie considérablement d'une région à une autre, ce qui rend impossible l'association rigoureuse des données énergétiques à des conditions climatiques locales. L'absence de localisation spécifique empêche ainsi toute corrélation fiable entre les variables climatiques et les séries temporelles de consommation.

Une seconde perspective prometteuse concerne l'enrichissement des données par des informations sur les équipements électroménagers présents dans les bâtiments, comme les climatiseurs, les réfrigérateurs ou les machines à laver. Ces appareils ont un impact significatif sur la consommation énergétique globale. Cependant, l'accès à ce type d'informations reste limité. Les tentatives de recensement menées précédemment par des institutions nationales telles que Sonelgaz, via des enquêtes de terrain, ont été suspendues en raison du manque de fiabilité des réponses collectées. Cette contrainte souligne la nécessité d'explorer de nouvelles méthodes de collecte, fondées notamment sur l'Internet des objets (IoT) ou des plateformes de gestion énergétique intelligentes.

Enfin, l'intégration future de données météorologiques et comportementales, dès lors qu'elles seront disponibles à une échelle compatible avec les données énergétiques, permettrait de construire des modèles prédictifs plus complets. Ces avancées contribueraient à une gestion énergétique plus fine et proactive, en appui aux politiques de transition vers un système énergétique plus durable et plus intelligent en Algérie.

Bibliographie

- [1] SARI, Mustika, BERAWI, Mohammed Ali, ZAGLOEL, Teuku Yuri, MADYANINGARUM, Nunik, MIRAJ, Perdana, PRANOTO, Ardiansyah Ramadhan, SUSANTONO, Bambang, et WOODHEAD, Roy. « *Machine learning-based energy use prediction for the smart building energy management system* », Journal of Information Technology in Construction, vol. 28, 2023.
- [2] QURESHI, Momina, ARBAB, Masood Ahmad, et REHMAN, Sadaqat ur. « *Deep learning-based forecasting of electricity consumption* », Scientific Reports, vol. 14, no. 1, p. 6489, 2024.
- [3] CHEN, Xia, GUO, Tong, KRIEGEL, Martin, et GEYER, Philipp. « *A hybrid-model approach for reducing the performance gap in building energy forecasting* », arXiv preprint arXiv :2206.00460, 2022.
- [4] WU, Jinrong, NGUYEN, Su, ALAHAKOON, Damminda, DE SILVA, Daswin, MILLS, Nishan, RATHNAYAKA, Prabod, MORALIYAGE, Harsha, et JENNINGS, Andrew. « *A comparative analysis of machine learning-based energy baseline models across multiple building types* », Energies, vol. 17, no. 6, p. 1285, 2024.
- [5] AYUB, Nasir, IRFAN, Muhammad, AWAIS, Muhammad, ALI, Usman, ALI, Tariq, HAMD, Mohammed, ALGHAMDI, Abdullah, et MUHAMMAD, Fazal. « *Big data analytics for short and medium-term electricity load forecasting using an AI techniques ensembler* », Energies, vol. 13, no. 19, p. 5193, 2020.
- [6] FRIKHA, Majdi, TAOUIL, Khaled, FAKHFAKH, Ahmed, et DERBEL, Faouzi. « *Predicting Power Consumption Using Deep Learning with Stationary Wavelet* », Forecasting, vol. 6, no. 3, 2024.
- [7] RANIA, Farah, BRAHIM, Farou, KOUAHLA, Zineddine, et SERIDI, Hamid. « *A Comparison of the Finest Electrical Energy Forecast Models* », in 2023 International Conference on Decision Aid Sciences and Applications (DASA), IEEE, pp. 570–575, 2023.
- [8] ALGHAMDI, Mona Ahamd, ABDULLAH, S., et RAGAB, Mahmoud. « *Predicting energy consumption using stacked LSTM snapshot ensemble* », Big Data Mining and Analytics, vol. 7, no. 2, pp. 247–270, 2024.
- [9] SAJJAD, Muhammad, KHAN, Zulfiqar Ahmad, ULLAH, Amin, HUSSAIN, Tanveer, ULLAH, Waseem, LEE, Mi Young, et BAIK, Sung Wook. « *A novel CNN-GRU-based hybrid approach for short-term residential load forecasting* », IEEE Access, vol. 8, pp. 143759–143768, 2020.
- [10] MOON, Jihoon, MAQSOOD, Muazzam, SO, Dayeong, BAIK, Sung Wook, RHO, Seungmin, et NAM, Yunyoung. « *Advancing ensemble learning techniques for residential building electricity consumption forecasting : Insight from explainable artificial intelligence* », PLoS ONE, vol. 19, no. 11, p. e0307654, 2024.
- [11] JUMONVILLE, Anne. « *Encyclopedia of the Sciences of Learning* », Reference Reviews, vol. 26, no. 8, pp. 23–24, 2012.
- [12] JORDAN, Michael I., et MITCHELL, Tom M. « *Machine learning : Trends, perspectives,*

- and prospects* », Science, vol. 349, no. 6245, pp. 255–260, 2015.
- [13] BISHOP, Christopher M., et NASRABADI, Nasser M. « *Pattern Recognition and Machine Learning* », Springer, New York, vol. 4, no. 4, 2006.
 - [14] ALPAYDIN, Ethem. « *Introduction to Machine Learning* », MIT Press, 2020.
 - [15] PALUSZEK, Michael, et THOMAS, Stephanie. « *What Is Deep Learning?* », in Practical MATLAB Deep Learning : A Project-Based Approach, Springer, pp. 1–24, 2020.
 - [16] YAMASHITA, Rikiya, NISHIO, Mizuho, DO, Richard Kinh Gian, et al. « *Convolutional Neural Networks : An Overview and Application in Radiology* », Insights into Imaging*, vol. 9, pp. 611–629, 2018.
 - [17] PHUNG, V. H., et RHEE, E. J. « *A High-Accuracy Model Average Ensemble of Convolutional Neural Networks for Classification of Cloud Image Patches on Small Datasets* », Applied Sciences, vol. 9, no. 21, p. 4500, 2019.
 - [18] LE, X.-H., HO, H. V., LEE, G., et JUNG, S. « *Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting* », Water, vol. 11, no. 7, p. 1387, 2019.
 - [19] ZHAO, Jingyu, HUANG, Feiqing, LV, Jia, DUAN, Yanjie, QIN, Zhen, LI, Guodong, et TIAN, Guangjian. « *Do RNN and LSTM Have Long Memory?* », in Proceedings of the International Conference on Machine Learning, PMLR, pp. 11365–11375, 2020.
 - [20] SHIN, Dong-Hoon, CHUNG, Kyungyong, et PARK, Roy C. « *Prediction of Traffic Congestion Based on LSTM Through Correction of Missing Temporal and Spatial Data* », IEEE Access, vol. 8, pp. 150784–150796, 2020.
 - [21] SUN, Jie, et KIM, Jiwon. « *Joint Prediction of Next Location and Travel Time from Urban Vehicle Trajectories Using Long Short-Term Memory Neural Networks* », Transportation Research Part C : Emerging Technologies, vol. 128, p. 103114, 2021.
 - [22] CHANDRA, Mayank Arya, et BEDI, S. S. « *Survey on SVM and their application in image classification* », 2021.
 - [23] TOLEDO-PÉREZ, Diana C., RODRÍGUEZ-RESÉNDEZ, Juan, CUEVAS-TÉLLEZ, Josué, et al. « *Support vector machine-based EMG signal classification techniques : A review* », Applied Sciences, vol. 9, no. 20, p. 4402, 2019.
 - [24] MONTGOMERY, Douglas C., PECK, Elizabeth A., et VINING, G. Geoffrey. « *Introduction to Linear Regression Analysis* », John Wiley & Sons, 2021.
 - [25] SEBER, George A. F., et SCHOFIELD, Matthew R. « *Model Building* », in Estimating Presence and Abundance of Closed Populations, Springer International Publishing, Cham, pp. 1–15, 2023.
 - [26] JAMES, Gareth, WITTEN, Daniela, HASTIE, Trevor, et TIBSHIRANI, Robert. « *An Introduction to Statistical Learning* », Springer, New York, 2013.
 - [27] HYNDMAN, Rob J., et ATHANASOPOULOS, George. « *Forecasting : Principles and Practice* », OTexts, 2018.
 - [28] BOX, George E. P., JENKINS, Gwilym M., REINSEL, Gregory C., et LJUNG, Greta M. « *Time Series Analysis : Forecasting and Control* », John Wiley & Sons, 2015.
 - [29] ELHABYB, Khaoula, et al. « *Machine Learning Algorithms for Predicting Energy Consump-*

- tion in Educational Buildings », International Journal of Energy Research, vol. 2024, no. 1, p. 6812425, 2024.
- [30] ALOTAIBI, Majed A. « *Machine learning approach for short-term load forecasting using deep neural network* », Energies, vol. 15, no. 17, p. 6261, 2022.
- [31] MATOS, Miguel, et al. « *A machine learning-based electricity consumption forecast and management system for renewable energy communities* », Energies, vol. 17, no. 3, p. 630, 2024.
- [32] MORCILLO-JIMENEZ, Roberto, et al. « *Deep learning for prediction of energy consumption : an applied use case in an office building* », Applied Intelligence, vol. 54, no. 7, pp. 5813–5825, 2024.
- [33] SILVA, Jose, et al. « *Energy consumption forecasting using ensemble learning algorithms* », in Distributed Computing and Artificial Intelligence, 16th International Conference, Special Sessions, Springer International Publishing, 2020.
- [34] RUAN, Yingjun, et al. « *A hybrid model for power consumption forecasting using VMD-based the long short-term memory neural network* », Frontiers in Energy Research, vol. 9, p. 772508, 2022.
- [35] NING, Shuluo, et YOON, Hyunsoo. « *A New Model for Building Energy Modeling and Regression (PHMR)* », Indoor Air, vol. 2024, no. 1, p. 5595459, 2024.
- [36] JI, Qingqing, et al. « *Short-and medium-term power demand forecasting with multiple factors based on multi-model fusion* », Mathematics, vol. 10, no. 12, p. 2148, 2022.
- [37] SINGH, Tarana, SOLANKI, Arun, SHARMA, Sanjay Kumar, et al. « *Grey Wolf Optimization-Based CNN-LSTM Network for the Prediction of Energy Consumption in Smart Home Environment* », IEEE Access, vol. 11, pp. 114917–114935, 2023.
- [38] WU, Meng-Ping, et WU, Fan. « *Predicting residential electricity consumption using CNN-BiLSTM-SA neural networks* », IEEE Access, 2024.
- [39] CHUNG, Jaewon, et JANG, Beakcheol. « *Accurate prediction of electricity consumption using a hybrid CNN-LSTM model based on multivariable data* », PloS One, vol. 17, no 11, p. e0278071, 2022. .
- [40] BINBUSAYYIS, Adel, et SHA, Mohemmed. « *Energy consumption prediction using modified deep CNN-Bi LSTM with attention mechanism* », Heliyon, vol. 11, no. 1, 2025.
- [41] MAE. « *Mean absolute error* », Consulté le 19 septembre 2016.
- [42] CHITRA, R., RAJENDRAN, S., PRASANNA, D., et KIRUBAKARAN, A. « *Prediction of body weight using appropriate regression model in adult female Malabari goat* », Veterinary World, vol. 5, no. 7, 2012.
- [43] DE MYTTENAERE, A., GOLDEN, B., LE GRAND, B., et ROSSI, F. « *Mean absolute percentage error for regression models* », Neurocomputing, vol. 192, pp. 38–48, 2016.
- [44] FARAH, Rania, FAROU, Brahim, KOUAHLA, Zineddine, et al. « *Data driven models on load forecasting : Case study Algeria* », Data in Brief, vol. 52, p. 109854, 2024.
- [45] GÉRON, Aurélien. « *Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow : Concepts* », Google Books, 2019.

- [46] SUGANTHI, L., et SAMUEL, Anand A. « *Energy models for demand forecasting—A review* », Renewable and Sustainable Energy Reviews, vol. 16, no. 2, pp. 1223–1240, 2012.
- [47] SCHUSTER, Mike, et PALIWAL, Kuldip K. « *Bidirectional recurrent neural networks* », IEEE Transactions on Signal Processing, vol. 45, no. 11, pp. 2673–2681, 1997.
- [48] USHA, T. M., et BALAMURUGAN, S. Appavu Alias. « *Seasonal based electricity demand forecasting using time series analysis* », Circuits and Systems, vol. 7, no. 10, pp. 3320–3328, 2016.
- [49] GUBBI, J., BUYYA, R., MARUSIC, S., et al. « *Internet of Things (IoT) : A vision, architectural elements, and future directions* », Future Generation Computer Systems, vol. 29, no. 7, pp. 1645–1660, 2013.
- [50] HABER, A., et BLIEM, M. G. « *Smart grids and their impact on network charges ; Smart Grids. Auswirkungen auf die Netzentgelte* », ET, Energiewirtschaftliche Tagesfragen, vol. 60, 2010.
- [51] DORJI, S., STONIER, A. A., PETER, G., et al. « *An extensive critique on smart grid technologies : Recent advancements, key challenges, and future directions* », Technologies, vol. 11, no. 3, p. 81, 2023.
- [52] STEPHENSON, J., FORD, R., NAIR, N.-K., et al. « *Smart grid research in New Zealand – A review from the GREEN Grid research programme* », Renewable and Sustainable Energy Reviews, vol. 82, pp. 1636–1645, 2018.
- [53] SALMAN, S. K., et al. « *Introduction to the smart grid : Concepts, technologies and evolution* », IET, 2017.
- [54] SHAH, S. F. A., IQBAL, M., AZIZ, Z., et al. « *The role of machine learning and the internet of things in smart buildings for energy efficiency* », Applied Sciences, vol. 12, no. 15, p. 7882, 2022.
- [55] KIM, D., YOON, Y., LEE, J., et al. « *Design and implementation of smart buildings : A review of current research trend* », Energies, vol. 15, no. 12, p. 4278, 2022.
- [56] BUCKMAN, A. H., MAYFIELD, M., et BECK, S. B. M. « *Smart and Sustainable Built Environment* », Environment, vol. 3, no. 2, pp. 92–109, 2014.
- [57] DOGAN, M. E., GORU DOGAN, T., et BOZKURT, A. « *The use of artificial intelligence (AI) in online learning and distance education processes : A systematic review of empirical studies* », Applied Sciences, vol. 13, no. 5, p. 3056, 2023.
- [58] HUANG, T., BOMPARD, E., MASERA, M., et al. « *The Structural Dimensions in the Security of Power Transmission Systems* », In : Infranomics : Sustainability, Engineering Design and Governance, Springer International Publishing, Cham, pp. 311–337, 2013.
- [59] GÜREL, D. K., et ERYILMAZ, A. « *A content analysis of physics textbooks as a probable source of misconceptions in geometric optics* », Hacettepe Üniversitesi Eğitim Fakültesi Dergisi, vol. 28, no. 28-2, pp. 234–245, 2013.
- [60] ABUELLA, M., et CHOWDHURY, B. « *Solar power forecasting using support vector regression* », arXiv preprint, arXiv :1703.09851, 2017.
- [61] HONG, T., et FAN, S. « *Probabilistic electric load forecasting : A tutorial review* », Inter-

national Journal of Forecasting, vol. 32, no. 3, pp. 914–938, 2016.

- [62] AMASYALI, K., et EL-GOHARY, N. M. « *A review of data-driven building energy consumption prediction studies* », Renewable and Sustainable Energy Reviews, vol. 81, pp. 1192–1205, 2018.
- [63] KIESSLING, S., GOHARI DARABKHANI, H., et SOLIMAN, A.-H. « *Greater energy independence with sustainable steel production* », Sustainability, vol. 16, no. 3, p. 1174, 2024.
- [64] FOUCART, Thierry. « *Colinéarité et régression linéaire* », Mathématiques et sciences humaines. Mathematics and Social Sciences, no. 173, 2006.

Webographie

- [W1] <https://fredcavazza.net/internet-des-objets/>, consulté le : 10/06/2025.
- [W2] <https://www.encyclopedie-energie.org/des-reseaux-electriques-aux-smartgrids/>, consulté le : 10/06/2025.
- [W3] https://tektelic.com/expertise/smart-buildings_iot/, consulté le : 10/06/2025.
- [W4] <https://www.eia.gov/energyexplained/what-is-energy/>, consulté le : 12/06/2025.
- [W5] <https://www.iea.org/reports/world-energy-outlook-2021>, consulté le : 12/06/2025.
- [W6] <https://datatab.fr/tutorial/linear-regression> consulté le : 15/06/2025.
- [W7] <https://gmd.copernicus.org/articles/15/5481/2022/> consulté le : 16/06/2025.
- [W8] <https://www.scribbr.com/statistics/coefficient-of-determination/> consulté le : 16/06/2025.
- [W9] <https://www.statology.org/how-to-interpret-mape/> consulté le : 16/06/2025.
- [W10] <https://data.mendeley.com/datasets/z5x2d3mhw7/1> consulté le : 29/06/2025.