



UNIVERSITE D'ABOMEY-CALAVI



ECOLE POLYTECHNIQUE D'ABOMEY-CALAVI

CENTRE AUTONOME DE PERFECTIONNEMENT

DEPARTEMENT DE GENIE ELECTRIQUE

Option : Energie Electrique

MEMOIRE DE FIN DE FORMATION
POUR L'OBTENTION DU

**DIPLOME D'INGENIEUR DE CONCEPTION
GRADE MASTER**

**CONTRIBUTION AU DEVELOPPEMENT D'UN MODELE
PERFORMANT DE DEMANDE D'ACHAT D'ELECTRICITE
A LA SOCIETE BENINOISE D'ENERGIE ELECTRIQUE**

Présenté et soutenu par :

Jérôme SESSOU

Soutenu le vendredi 04 juillet 2025 devant le Jury composé de :

Président : Pr AGBOMAHENA Macaire, Enseignant à l'EPAC

Membres : 1. Pr FIFATIN François-Xavier, Maitre de Mémoire

2. Dr AZA-GNANDJI Maurel, Enseignant à l'EPAC

3. Dr DIDAVI Audace, Assistant à l'EPAC

Année académique : 2023 - 2024

DEDICACE

Je dédie ce travail

A

Dieu le créateur qui m'a donné la vie et la capacité de terminer ce travail qu'il a béni ;
Mon épouse, TOKEME SESSOU Véronique qui s'est sacrifiée afin que ses efforts aboutissent à la réalisation de ce projet.

REMERCIEMENTS

Derrière un travail bien accompli se trouvent de nombreuses personnes qui, chacune à leur manière, ont contribué à sa réalisation. Alors je ne saurais présenter les travaux de ce mémoire sans exprimer toute ma reconnaissance à l'endroit de toutes ces personnes qui ont œuvré afin que ces travaux aboutissent.

J'exprime toute ma reconnaissance au Professeur François-Xavier FIFATIN, Professeur Titulaire des Universités du CAMES, Enseignant-Chercheur à l'Ecole Polytechnique d'Abomey-Calavi, Superviseur du mémoire.

Mes remerciements vont aussi à l'endroit des Professeurs Guy Alain ALITONOU, Directeur de l'EPAC et Fidèle Paul TCHOBO, Directeur du CAP.

J'exprime mes vifs remerciements au Professeur Macaire AGBOMAHENAN, le Chef Département de Génie Electrique du CAP et de l'EPAC.

Je tiens à exprimer ma profonde gratitude à Dr Maurel AZA-GNANDJI, Maître Assistant des Universités du CAMES, Enseignant-Chercheur à l'Ecole de Génie Rural, Co-Superviseur du mémoire.

Mes sincères remerciements à M. Espéran PADONOU, Directeur de la Fondation Vallet, Président de l'ONG Bénin Excellence, M. Johannès HOUNSINOU, Responsable Pédagogique de l'ONG Bénin Excellence et Responsable du club de l'Intelligence Artificielle aussi qu'aux membres du club de l'Intelligence Artificielle.

J'exprime toute ma reconnaissance à M. William HOUNSA, Chef Département à la SBEE, Maître de stage.

Infiniment merci aux frères Marc GBEGNIDE, Magistrat, Léon DJOGBENOU, Responsable de la bibliothèque de l'Institut Français de Cotonou et Ghislain Cadnel BOSSAVI, Ingénieur en gestion et traitement des eaux et déchets.

LISTE DES SIGLES ET ACRONYMES

APR	: Appel à Projet de Recherche
AR	: AutoRegressive
ARCH	: Autoregressive Conditional Heterosdastic
ARE	: Autorité de Régulation de l'Electricité
ARIMA	: AutoRegressive Integrated Moving Average
ARIMAX	: Auto Regressive Moving Average with External
ARREC	: Autorité de Régulation Régionale du secteur de l'Électricité de la CEDEAO
BLSTM	: Bidirectional Long Short-Term Memory
BRMN	: Bureau de la Restructuration et de la Mise à Niveau
BT	: Basse Tension
CEB	: Communauté Électrique du Bénin
CEDEAO	: Communauté Economique des Etats de l'Afrique de l'Ouest
CFPP	: Centre de Formation Professionnelle et de Perfectionnement
CIE	: Compagnie Ivoirienne d'Electricité
CNN	: Convolutional Neural Network
CONTROLEC	: Agence de Contrôle des Installations Electriques Intérieures
CPN	: Comité de Pilotage National
DGPEERR	: Direction Générale de la Planification énergétique, de l'Électrification rurale, et de la Réglementation
DGRE	: Direction Générale des Ressources Energétiques
EEEOA	: Système d'Échanges d'Énergie Électrique Ouest Africain
EGARCH	: GARCH Exponentiel
ETS	: Error, Trend, Seasonality
GAM	: Generalized Additive Model
GARCH	: Generalized Autoregressive Conditional Heteroskedasticity
HTA	: Moyenne Tension catégorie A
HTB	: Haute Tension catégorie B
IGH	: Immeubles de Grande Hauteur, Immeubles de Grande Hauteur
IQR	: Ecart Interquartile
kV	: Kilo Volt
LSTM	: Long Short-Term Memory

MA	: Moving Average
MAE	: Mean Absolute Error
MAPE	: Mean Absolute Percentage Error
MCI	: Ministère du Commerce et de l'Industrie
MCVT	: Ministère du Cadre de vie et des Transports, en charge du Développement Durable
MEEM	: Ministère de l'Énergie, de l'Eau et des Mines
MEU	: Ministère de l'Environnement, de l'Habitat et de l'Urbanisme
MHI	: Manitoba Hydro International
MRI	: Maurice Réalisations Internationale
MSE	: Erreur Quadratique Moyenne
MW	: Méga Watt
PIE ou IPP	: Producteurs Indépendants d'Electricité
Q1	: Premier Interquartile
Q3	: Troisième Interquartile
R²	: Coefficient de détermination
RD-LSTM	: Residual Dilated Long Short-Term Memory
RLM	: Régression Linéaire Multiple
RMSE	: Root Mean Squared Error
RNN	: Recurrent Neural Network
S2S	: Sequence to Sequence
SBEE	: Société Béninoise d'Énergie Électrique
SBPE	: Société Béninoise de Production Electrique
SONEB	: Société Nationale des Eaux du Bénin
TAG	: Turbine à Gaz
TCN	: Transmission Company of Nigeria
TGARCH	: Threshold Generalized Autoregressive Conditional Heterosdasticity
UI	: Unités Industrielles
VRA	: Volta River Authority

LISTE DES TABLEAUX

Tableau 1.1: Production en énergie électrique de 2016 à 2018.....	8
Tableau 1.2: Nombre de perturbations recensées sur le réseau électrique 2022 & 2023	17
Tableau 2.1: Cartographie des modèles.....	32
Tableau 2.2 : Classification de différents types d'horizons temporels de prévisions	34
Tableau 3.1 : Cartographie des modèles de prévision d'énergie électrique retenus.....	42
Tableau 3.2 : Indicateurs de performance d'évaluation des modèles en régression	51
Tableau 4.1 : Comparaison des mesures de performance pour le modèle ARIMA implémenté	62
Tableau 4.2 : Comparaison des mesures de performance pour le modèle GAM implémenté	63
Tableau 4.3 : Comparaison des mesures de performance pour le modèle GARCH implémenté.....	63
Tableau 4.4 : Comparaison des mesures de performance pour le modèle lissage exponentiel implémenté	65
Tableau 4.5 : Comparaison des mesures de performance pour le modèle Prophet implémenté	66
Tableau 4.6 : Comparaison des mesures de performance pour le modèle LSTM implémenté	67
Tableau 4.7 : Comparaison des mesures de performance pour le modèle CNN implémenté	68
Tableau 4.8 : Comparaison des mesures de performance pour le modèle GRU implémenté	69
Tableau 4.9 : Comparaison des mesures de performance pour le modèle ARIMA-LSTM implémenté	69
Tableau 4.10 : Comparaison des mesures de performance pour le modèle CNN-LSTM implémenté	70
Tableau 4.11 : Comparaison des mesures de performance pour le modèle CNN-GRU implémenté	71
Tableau 4.12 : Résumé des modèles jugés performants	71
Tableau 4.14 : Récapitulatif des métriques de performance de LSTM pour les différents horizons de temps.....	72
Tableau 4.15 : Récapitulation des métriques de performance de CNN-LSTM pour différents horizons de temps	75
Tableau 4.16 : Récapitulation des métriques de performance de CNN pour les différents horizons de temps	77
Tableau 4.17 : Récapitulatif des métriques de performance de GRU pour différents horizons de temps.....	79
Tableau 4.18 : Récapitulation des métriques de performance du modèle avancé CNN-GRU pour les différents horizons de temps de prévisions	81

LISTE DES FIGURES

Figure 1.1: Carte présentant les 14 pays membres de la communauté économique régionale	11
Figure 1.2: Evolution du nombre de perturbations du réseau électrique 2022 & 2023	18
Figure 3.1: Liste des outils utilisés pour la construction du modèle de prédiction	39
Figure 3.2 : Constitution du modèle LSTM implémenté	44
Figure 3.3 : Constitution du modèle CNN implémenté.....	45
Figure 3.4 : Constitution du modèle CNN-LSTM hybride implémenté.....	45
Figure 3.5 : Constitution du modèle GRU implémenté.....	47
Figure 3.6 : Constitution du modèle CNN-GRU hybride implémenté	48
Figure 4.1: Evolution de la consommation en énergie électrique du 1 ^{er} janvier 2017 au 31 décembre	2023
.....	53
Figure 4.2 : Evolution de la consommation en énergie électrique du 1 ^{er} janvier au 31 mars 2024	53
Figure 4.3: Consommation d'énergie avec des anomalies.....	54
Figure 4.4 : Consommation d'énergie avec des anomalies du 1 ^{er} janvier au 31 mars 2024	54
Figure 4.5: Consommation d'énergie avec les données manquantes remplacées.....	55
Figure 4.6 : Consommation électrique avec les données manquantes interpolées du 1 ^{er} janvier au 31 mars 2024.....	55
Figure 4.7: Autocorrélogramme	56
Figure 4.8: Boîte à moustache représentant la série	56
Figure 4.9: Décomposition de la saisonnalité de la série sur la période 2017 - 2023	57
Figure 4.10: Décomposition de la saisonnalité sur une année (2017)	57
Figure 4.11 : Niveau d'inertie selon le nombre de groupes (clusters en anglais).....	58
Figure 4.12 : Visualisation sur 7 ans des groupes (clusters) de la variable Puissance par groupe (cluster) créé	59
Figure 4.13 : Visualisation sur l'année 2017 des groupes (clusters) de la variable puissance par groupe	(cluster) créé
.....	59
Figure 4.14 : Histogramme de la variable puissance catégorisée par groupe (cluster)	60
Figure 4.15 : Tendence de consommation par cluster de saison créé.....	61
Figure 4.16 : Modélisation de la demande en énergie électrique avec le modèle ARIMA implémenté	62
Figure 4.17 : Modélisation de la demande en énergie électrique avec le modèle GAM.....	63
Figure 4.18 : Résultats du modèle GARCH	64

Figure 4.19 : Modélisation de la demande en énergie électrique avec le modèle GARCH	65
Figure 4.20 : Modélisation de la demande en énergie électrique avec le modèle du lissage exponentiel	66
Figure 4.21 : Modélisation de la demande en énergie électrique avec le modèle prophet	67
Figure 4.22 : Modélisation de la demande en énergie électrique avec le modèle LSTM	67
Figure 4.23 : Modélisation de la demande en énergie électrique avec le modèle CNN	68
Figure 4.24 : Modélisation de la demande en énergie électrique avec le modèle GRU	69
Figure 4.25 : Modélisation de la demande en énergie électrique avec le modèle ARIMA-LSTM	70
Figure 4.26 : Modélisation de la demande en énergie électrique avec le modèle CNN-LSTM	70
Figure 4.27 : Modélisation de la demande en énergie électrique avec le modèle CNN-GRU	71
Figure 4.28 : Evolution des métriques de performance avec LSTM	73
Figure 4.29 : Evolution de prévisions de la consommation d'électricité avec le modèle LSTM sur l'horizon 24 heures	74
Figure 4.30 : Evolution de prévisions de la consommation d'électricité avec le modèle LSTM sur l'horizon 48 heures	74
Figure 4.31 : Evolution de prévisions de la consommation d'électricité avec le modèle LSTM sur l'horizon 72 heures	74
Figure 4.32 : Evolution des métriques de performance de CNN-LSTM pour différents horizons de temps	76
Figure 4.33 : Evolution de prévisions de la consommation d'électricité avec le modèle CNN-LSTM sur l'horizon 24 heures	76
Figure 4.34 : Evolution de prévisions de la consommation d'électricité avec le modèle CNN-LSTM sur l'horizon 48 heures	76
Figure 4.35 : Evolution de prévisions de la consommation d'électricité avec le modèle CNN-LSTM sur l'horizon 72 heures	77
Figure 4.36 : Evolution des métriques de performance de CNN pour différents horizons de temps	78
Figure 4.37 : Evolution de prévisions de la consommation d'électricité avec le modèle CNN sur l'horizon 24 heures	78
Figure 4.38 : Evolution de prévisions de la consommation d'électricité avec le modèle CNN sur l'horizon 48 heures	78
Figure 4.39 : Evolution de prévisions de la consommation d'électricité avec le modèle CNN sur l'horizon 72 heures	79
Figure 4.40 : Evolution des métriques de performance de GRU pour différents horizons de temps	80
Figure 4.41 : Evolution de prévisions de la consommation d'électricité avec le modèle GRU sur l'horizon 24 heures	80

Figure 4.42 : Evolution de prévisions de la consommation d'électricité avec le modèle GRU sur l'horizon 48 heures	80
Figure 4.43 : Evolution de prévisions de la consommation d'électricité avec le modèle GRU sur l'horizon 72 heures	81
Figure 4.44 : Evolution des métriques de performance de CNN-GRU pour différents horizons de temps.....	82
Figure 4.45 : Evolution de prévisions de la consommation d'électricité avec le modèle CNN-GRU sur l'horizon 24 heures	82
Figure 4.46 : Evolution de prévisions de la consommation d'électricité avec le modèle CNN-GRU sur l'horizon 48 heures	83
Figure 4.47 : Evolution de prévisions de la consommation d'électricité avec le modèle CNN-GRU sur l'horizon 72 heures	83
Figure 4.48 : Comparaison des MAPE pour différents modèles validés avec de nouvelles données	83
Figure 4.49 : Comparaison des MAE pour différents modèles validés avec de nouvelles données .	84
Figure 4.50 : Interface de l'application de déploiement du modèle	85
Figure 4.51 : Fonctionnalité chargement des fichiers application de déploiement	85
Figure 4.52 : Fonctionnalité de prévisualisation et analyse de données de l'application	86
Figure 4.53 : Fonctionnalité prédiction de l'application	86

RESUME

Le Bénin, en dépit des dispositions mis en œuvre pour accéder à la souveraineté énergétique, continue de s'appuyer sur les pays voisins pour répondre à ses besoins en énergie électrique. Dans ce cadre, pour atteindre l'efficacité de gestion en matière énergétique, il est crucial d'estimer avec précision la demande nationale future en électricité. Ce mémoire s'inscrit dans le cadre de l'amélioration des prévisions de la demande énergétique au Bénin, un enjeu stratégique pour répondre efficacement aux besoins croissants de la population tout en garantissant la stabilité du réseau électrique. L'objectif principal est de développer un modèle prédictif robuste et adapté au contexte du Bénin, capable de prédire avec précision la demande d'achat d'électricité à court terme. Les données utilisées, fournies par la SBEE, couvrent la période de janvier 2017 à décembre 2023 et de janvier à mars 2024. Une dizaine de modèles a été choisie et testée. Il s'agit de ARIMA, GAM, lissage exponentiel, Prophet, GARCH, LSTM, CNN, GRU, ARIMA-LSTM, CNN-LSTM et CNN-LSTM. Parmi ces modèles testés, cinq modèles ont été sélectionnés et utilisés des prévisions sur les horizons 24 h, 48 h et 72 h. A l'issue des prévisions, le modèle LSTM s'est avéré performant sur tous ces horizons de temps. Il a été intégré dans l'application développée avec l'outil Streamlit sous Python 3.11.4, pour faciliter son utilisation. Les métriques de performances du modèle – MAE, RMSE, MAPE et R^2 - selon chaque horizon de temps se présentent respectivement 4,8583 ; 5,8833 ; 2,05% et 0,9322 sur un horizon de 24 heures, 4,6765 ; 5,9106 ; 1,91% et 0,9292 sur un horizon de 48 heures et enfin 4,1490 ; 5,3930 ; 1,68% et 0,9313 sur un horizon de 72 heures.

Mots-clés : Prévion énergétique, LSTM, CNN, GRU, Benin.

ABSTRACT

Despite the steps taken to achieve energy sovereignty, Benin continues to rely on neighboring countries to meet its electricity needs. In this context, to achieve energy management efficiency, it is important to accurately estimate future national electricity demand. This dissertation is part of the effort to improve energy demand forecasting in Benin, a strategic challenge for effectively meeting the growing needs of the population while guaranteeing the stability of the power grid. The main objective is to develop a robust predictive model adapted to the Benin context, capable of accurately predicting short-term electricity purchase demand. The data used, provided by SBEE, cover the period from January 2017 to December 2023 and from January to March 2024. A dozen models were selected and tested. These were ARIMA, GAM, exponential smoothing, Prophet, GARCH, LSTM, CNN, GRU, ARIMA-LSTM, CNN-LSTM and CNN-LSTM. Among the models tested, five were selected and used for forecasts over 24h, 48h and 72h horizons. The LSTM model was found to perform well over all these time horizons. It has been integrated into the Streamlit Python application for ease of use. The model's performance metrics - MAE, RMSE, MAPE and R^2 - for each time horizon are respectively 4.8583; 5.8833; 2.05% and 0.9322 over a 24-hour horizon, 4.6765; 5.9106; 1.91% and 0.9292 over a 48-hour horizon and finally 4.1490; 5.3930; 1.68% and 0.9313 over a 72-hour horizon.

Keywords: Energy forecast, LSTM, CNN, GRU, Benin.

SOMMAIRE

DEDICACE	ii
REMERCIEMENTS	iii
LISTE DES SIGLES ET ACRONYMES	iv
LISTE DES TABLEAUX.....	vi
LISTE DES FIGURES.....	vii
RESUME	x
ABSTRACT	xi
SOMMAIRE	xii
INTRODUCTION GENERALE	1
Chapitre 1. Présentation du secteur de l'électricité au Bénin.....	3
1.1. INTRODUCTION PARTIELLE	3
1.2. CADRE INSTITUTIONNEL DU SECTEUR DE L'ELECTRICITE AU BENIN	3
1.3. CADRE JURIDIQUE DU SECTEUR DE L'ELECTRICITE AU BENIN.....	16
1.4. RESEAU ELECTRIQUE BENINOIS.....	16
1.5. MOYENS DE PRODUCTION DE L'ENERGIE AU BENIN.....	18
1.6. CONCLUSION PARTIELLE	20
Chapitre 2. Revue de littérature sur les modèles de prévision de la demande d'énergie...	21
2.1. INTRODUCTION PARTIELLE	21
2.2. ETAT DE L'ART SUR LES MODELES DE PREVISION DE DEMANDE D'ACHAT EN ELECTRICITE	21
2.3. DIFFERENTS TYPES D'HORIZONS TEMPORELS DE PREVISIONS	34
2.4. CONCLUSION PARTIELLE	34
Chapitre 3. Développement d'un modèle de prédiction de la demande d'achat en électricité	35
3.1. INTRODUCTION PARTIELLE	35
3.2. DONNEES	35
3.3. OUTILS ET MATERIELS.....	39
3.4. MODELISATION ET CHOIX D'UN MODELE DE PREVISION DE LA DEMANDE EN ENERGIE ELECTRIQUE.....	41
3.5. DESCRIPTION DE LA PLATEFORME DEVELOPPEE POUR LE DEPLOIEMENT	51
3.6. CONCLUSION PARTIELLE	52
Chapitre 4. Résultats et discussions.....	53

4.1.	INTRODUCTION GENERALE	53
4.2.	NETTOYAGE DES DONNEES.....	53
4.3.	ANALYSE EXPLORATOIRE DES DONNEES.....	55
4.4.	INGENIERIE DES DONNEES	58
4.5.	RESULTATS DES MODELES MIS EN ŒUVRE.....	61
4.6.	DEPLOIEMENT DU MODELE RETENU AU TRAVERS D'UNE APPLICATION.....	84
4.7.	CONCLUSION PARTIELLE	87
	CONCLUSION GENERALE ET PERSPECTIVES	88
	REFERENCES	I
	TABLE DES MATIERES.....	V
	ANNEXES	XI

INTRODUCTION GENERALE

La disponibilité en énergie électrique est un atout de taille pour tout territoire qui aspire à un développement économique. En effet, l'électricité stimule le développement de plusieurs secteurs critiques de l'économie du pays : industriel, tertiaire, agricole, éducatif et sanitaire. La qualité et le fonctionnement continu de ces secteurs critiques ainsi que la satisfaction des besoins des ménages sont subordonnés à la qualité, la fiabilité, l'accessibilité en termes de coût et de durabilité de l'énergie électrique. L'électricité produite alimente en continu les consommateurs. Egale à la somme de la consommation et des pertes dans le réseau électrique, cette production est un vecteur énergétique difficilement stockable dans un réseau électrique. Pour ce fait, les gestionnaires du réseau électrique et les producteurs cherchent un équilibre entre la production et la consommation pour éviter un effondrement du réseau lié à une inadéquation entre l'offre et la demande.

Au Bénin, la politique du gouvernement est d'avoir de l'électricité fiable, durable et à moindre coût, un accès à l'électricité pour tous et un service continu dans la fourniture d'énergie électrique. Malheureusement, le Bénin dépend encore en majorité des pays voisins pour l'approvisionnement de l'énergie électrique. En effet, cette dépendance en électricité estimée à plus de 50% en 2023 [1], a toujours des impacts sur le secteur électrique. En effet, des délestages perturbent les activités économiques du pays et durent depuis des années [2], [3]. Malgré ces déficits dans le secteur, de nombreux acteurs privés participent à la mise en œuvre de la politique énergétique du gouvernement. Ils financent la construction des sous-stations partout sur le territoire et le réseau électrique connaît de nouvelles extensions, ce qui permet d'alimenter les villages les plus reculés du pays [4]. Le réseau de distribution suscite l'adhésion de nouveaux clients à des offres promotionnelles de branchement des compteurs [5]. Ces améliorations laissent présager une augmentation du niveau de consommation du pays en énergie électrique. Cela entraîne une nécessité de faire des prévisions précises pour éviter des perturbations dans les centrales électriques de production et des lieux de consommation.

Par ailleurs, lorsque la quantité d'énergie demandée est en dessous des besoins réels de la population, l'offre des fournisseurs d'électricité est réduite, créant ainsi un déséquilibre entre cette dernière et la demande sur le réseau. Ce déséquilibre est souvent causé par des écarts de prévision de la consommation d'électricité. Alors des perturbations s'observent et impactent toutes les activités dépendant de l'énergie électrique. Parmi ces perturbations figurent des coupures volontaires aux heures de pointes afin d'éviter l'effondrement de tout

le réseau. De même, si la quantité d'énergie demandée est au-dessus des besoins sur le réseau, les producteurs fournissent l'énergie électrique nécessaire pour la satisfaction de la demande en utilisant les ressources de la production. Malheureusement cette énergie injectée sur le réseau n'est pas souvent entièrement consommée mais se dissipe car il est essentiellement difficile de la stocker.

Face à cette situation les gestionnaires du réseau électrique ont besoin d'un outil de prévision performant afin d'évaluer avec précision la demande et d'éviter les écarts de prévision entre les demandes exprimées et les consommations réelles sur le réseau. Aussi cet outil participe -t-il à la prise de décision pour des projets de développement futurs du réseau. C'est dans ce cadre que ce projet de fin d'étude aborde le thème : « **Contribution au développement d'un modèle performant de demande d'achat d'électricité à la Société Béninoise d'Énergie Électrique** ». Cette recherche se positionne sur la problématique de la prévision exacte de la demande précise d'achat d'électricité au niveau de la Société Béninoise d'Energie Electrique (SBEE).

L'objectif général est de développer un modèle d'apprentissage automatique capable de prédire à différents horizons de temps la demande d'achat d'électricité à la SBEE. Pour atteindre cet objectif, le travail est subdivisé en objectifs spécifiques que sont :

- Etablir une cartographie des différents modèles d'intelligence artificielle permettant la prédiction de la demande en énergie électrique sur le réseau électrique ;
- Implémenter les modèles cartographiés sur le réseau de la SBEE pour les horizons de précision ciblés ;
- Evaluer les performances des différents modèles choisis ;
- Construire une plateforme numérique pour le déploiement.

Le présent travail s'est articulé autour de quatre (04) chapitres. Le premier décrit les cadres théoriques, institutionnel et juridique du secteur de l'électricité au Bénin. Le deuxième consiste en la revue de littérature sur les travaux de prévisions de la demande en énergie électrique. Le troisième explique la méthodologie utilisée pour la construction des modèles. Quant au quatrième, il est consacré à la présentation des résultats obtenus avec les discussions faites autour.

Chapitre 1. Présentation du secteur de l'électricité au Bénin

1.1. INTRODUCTION PARTIELLE

Afin de renforcer son secteur énergétique et d'en assurer un fonctionnement optimal, le gouvernement du Bénin a adopté plusieurs politiques et stratégies. Ce chapitre a pour but de présenter les cadres institutionnel et réglementaire du secteur de l'énergie électrique en République du Bénin.

1.2. CADRE INSTITUTIONNEL DU SECTEUR DE L'ELECTRICITE AU BENIN

Le développement du secteur de l'énergie électrique et la disponibilité en continue de l'électricité requiert généralement l'implication de plusieurs acteurs, privés, nationaux, régionaux comme internationaux. Au Bénin, le Ministère de l'Énergie, de l'Eau et des Mines (MEEM) est le premier responsable du secteur, le Ministère du Commerce et de l'Industrie (MCI) et d'autres acteurs interviennent activement afin d'assurer la disponibilité de l'énergie électrique pour tous les béninois.

Chacune de ces structures intervient dans un domaine spécifique pour l'amélioration du secteur de l'électricité.

1.2.1. Ministère de l'Énergie de l'Eau et des Mines

Ce Ministère a en son sein trois portefeuilles, notamment celui de l'Energie, de l'Eau et des Mines et a pour mission d'en assurer la gestion efficace. Bien qu'il soit constitué de plusieurs cellules techniques, nous ne prendrons en compte, dans cette section, que celles qui interviennent dans le secteur de l'Energie.

Le Ministère a été réorganisé avec ses attributions et son fonctionnement suivant le décret n°2023 - 304 du 07 juin 2023.

Chacune de ces directions techniques et organismes disposent d'une organisation spécifique et participe activement au développement du secteur d'électricité.

1.2.1.1. Direction Générale de la Planification Énergétique, de l'Électrification Rurale et de la Réglementation (DGPEERR)

Créée en 2006 pour accélérer le développement du secteur et améliorer l'accès à l'électricité au Bénin, l'ex DGRE est désormais dénommée la Direction Générale de la Planification énergétique, de l'Électrification rurale, et de la Réglementation (DGPEERR).

Elle est dirigée par un Directeur Général, placé sous l'autorité du Secrétaire d'État à l'Énergie.

La DGPEERR oriente et coordonne les actions des structures opérationnelles du Ministère en charge de l'énergie. Elle élabore, en liaison avec les structures nationales compétentes, et veille à la mise en œuvre de la politique du Gouvernement relative au développement des ressources énergétiques nationales, à la maîtrise de l'énergie, à l'efficacité énergétique. Elle rend compte régulièrement au Ministre de l'Énergie de l'évolution du sous-secteur de l'électricité.

Plus spécifiquement, la DGPEERR :

- Assure le rôle de référent technique pour le Ministre de l'Énergie ;
- Formule la politique nationale, la stratégie et des plans d'actions du développement de l'énergie ;
- Promeut les énergies renouvelables et la maîtrise de l'énergie ;
- Gère le système d'information national de l'énergie ;
- Assure la planification énergétique ;
- Élabore et suit les statistiques énergétiques du secteur ;
- Propose le cadre réglementaire, législatif et tarifaire pour le développement du secteur de l'énergie ;
- Élabore et met à la disposition des acteurs une documentation sur l'énergie ;
- Met en place des textes juridiques applicables au secteur.

1.2.1.2. Agence de Contrôle des Installations Electriques Intérieures (CONTRELEC)

L'Agence de Contrôle des Installations Electriques Intérieures (CONTROLEC) est un établissement public à caractère scientifique et technique. Elle a été créée par décret n° 2008-629 du 22 octobre 2008. Les services de CONTRELEC sont installés dans tous les centres commerciaux de la SBEE pour assurer une veille en accord avec les normes électriques en vigueur.

Elle dispose d'un Conseil d'Administration et d'une Direction Générale qui assurent les activités de direction.

La CONTROLEC a pour mission d'œuvrer au respect des prescriptions techniques relatives à la réalisation des installations électriques intérieures pour assurer la sécurité des personnes et des biens. Les activités résultantes de sa mission sont entre autres :

- Effectuer le contrôle obligatoire des installations électriques intérieures avant leur première mise sous tension ;

- Exécuter sur demande, le contrôle des installations électriques intérieures déjà mises sous tension ;
- Réaliser l'expertise des installations électriques intérieures dans le bâtiment ;
- Elaborer et mettre en œuvre toutes études et actions en vue du respect des normes de sécurité dans la réalisation des installations électriques intérieures ;
- Effectuer le contrôle des installations électriques intérieures des immeubles de grande hauteur (IGH), des Unités Industrielles (UI), des Etablissements Recevant du Public et des Etablissements classés dangereux.

1.2.1.3. Société Béninoise de Production d'Électricité (SBPE)

Depuis des décennies, la gestion de la fourniture de l'électricité a été confiée à la Communauté Électrique du Bénin (CEB). Mais, pour réellement maîtriser le secteur de l'électricité au Bénin, il s'est avéré nécessaire de mettre en place des réformes visant à décentraliser le secteur en faisant apparaître de nouveaux acheteurs avec de nouveaux rôles. C'est dans ce cadre que le gouvernement a décidé d'instituer une séparation du transport et de la production de l'énergie électrique et par la création de la SBPE.

1.2.1.3.1. *Présentation de la SBPE*

La SBPE est créée en 2020, avec un statut de société publique, et comme dessein d'en faire le principal producteur et l'unique potentiel acheteur de l'énergie électrique en République du Bénin. Elle dispose des ressources nécessaires pour accomplir la politique gouvernementale que constitue la maîtrise du secteur de l'électricité [6].

1.2.1.3.2. *Mission de la SBPE*

Principalement, la SBPE a pour mission de garantir l'équilibre offre-demande dans le secteur de l'énergie électrique en fournissant l'énergie électrique et en assurant la disponibilité suffisante de l'offre d'électricité. Afin de garantir l'approvisionnement en qualité et à coût abordable de l'électricité, elle a en charge la mise en œuvre de la politique de l'État béninois en matière d'importation et de production d'énergie électrique.

Le décret n°2020-565 du 02 décembre 2020 lui confère ce monopole d'exercer cette activité sur toute l'étendue du territoire béninois.

1.2.1.3.3. Structure organisationnelle

Un Directeur Général, sous l'autorité d'un Conseil d'Administration, dirige la SBPE. D'autres Directions et Cellules assistent le Directeur Général dans ses fonctions [7].

1.2.1.3.4. Activités

La SBPE exploite ses actifs propres, importe de l'électricité et achète l'énergie électrique solaire que les producteurs indépendants fournissent dans le réseau électrique ou hors réseau. Cette énergie qu'elle aura achetée ou produite est ensuite revendue à la SBEE et aux clients industriels. Elle développe et facilite la pénétration des énergies renouvelables dans le mix énergétique béninois.

1.2.1.4. Société Béninoise d'Énergie Électrique (SBEE)

La Société Béninoise d'Énergie Électrique a été créée en 1948 et nommée Compagnie Coloniale de la Distribution de l'Énergie Électrique. En 1973, elle a pris le nom de la Société Dahoméenne d'Électricité et d'Eau puis au moment de changement de nom de la nation, elle est devenue la Société Béninoise d'Électricité et d'Eau [8].

En janvier 2004, le Gouvernement, dans le souci de faire du secteur une priorité, a séparé les activités de l'électricité et celles de l'eau : la Société Béninoise d'Énergie Électrique (SBEE) et la Société Nationale des Eaux du Bénin (SONEB) ont vu le jour.

La gestion du réseau de distribution de l'énergie électrique du Bénin est principalement à la charge de la SBEE placée sous la tutelle du Ministère en charge de l'Énergie, de l'Eau et des Mines [9].

1.2.1.4.1. Présentation de la SBEE

Créée en janvier 2004 [10], [3], la SBEE est une structure, à caractère commercial et industriel, présente sur toute l'étendue du territoire national, à travers ses agences et a en charge la commercialisation de l'électricité.

En 2019, les réformes conduites par le Gouvernement au sein de toutes les institutions publiques l'ont conduit à soumettre la SBEE à une gestion déléguée. Elle a été dirigée par une équipe de Manitoba Hydro International (MHI), un groupe canadien, pendant quatre (04) ans [11]. Cette gestion déléguée est survenue dans la période où la SBEE traversait une crise économique et technique.

Sous cette gestion déléguée le réseau de distribution a s'est développé à travers de nouvelles constructions de postes et de lignes électriques grâce au projet financé par le

Gouvernement Américain. Ce réseau de distribution est actuellement conduit et exploité par deux centres de contrôle de distribution, aussi appelé Dispatching.

Par ailleurs, le renouvellement du contrat de la gestion déléguée a positionné une nouvelle équipe à la direction de la SBEE, celle de la société ERANOVE [12].

La SBEE alimente essentiellement les secteurs résidentiels, tertiaires et certains secteurs industriels à travers des infrastructures et des équipements électriques [3], [13].

1.2.1.4.2. Mission de la SBEE

La SBEE est chargée de l'exploitation du réseau de distribution de l'énergie électrique et a le devoir de surveiller les mouvements des flux de l'énergie électrique. Elle doit porter l'assistance à la CEB dans le maintien de la stabilité. Elle a aussi dans ses missions la veille au respect des tensions normales d'exploitation et de la qualité de la tension livrée aux abonnés [10].

De nos jours, les activités d'exploitation du réseau de distribution se réalisent progressivement sur l'ensemble du territoire de façon automatique grâce aux deux centres de contrôle du réseau.

1.2.1.4.3. Structure organisationnelle

La SBEE est une structure publique et industrielle avec un Conseil d'Administration qui contrôle sa gestion et fait régulièrement le compte rendu au Ministre de l'Énergie, de l'Eau et des Mines. Un Directeur Général dirige la SBEE sous l'autorité du Conseil d'Administration et est assisté dans ses fonctions par le Comité d'Audit Interne et d'Inspection ainsi que par la Direction Audit Interne [3].

Pour améliorer sa performance opérationnelle, la SBEE est structurée en trois (03) parties : le STAFF de la Direction Générale, les Directions opérationnelles et les Directions Supports. Ces trois divisions appuient la Direction Générale dans l'exécution des missions qui lui sont confiées [3].

1.2.1.4.4. Activités de la SBEE

Depuis des années, la SBEE enregistre d'importantes pertes de l'électricité commercialisée sur le réseau de distribution. Ces pertes d'énergie électrique sont essentiellement dues à la vétusté des infrastructures de distribution, au retard de recouvrement et à la fraude liée à la commercialisation de l'énergie électrique [3].

Les activités principales de la SBEE sont divisées en trois catégories :

- Les activités d'exploitation ;
- Les activités commerciales ;
- Les activités de développement.

➤ *Activités d'exploitation*

Il s'agit de la construction du réseau, de la maintenance et de l'exploitation des ouvrages électriques pour l'acheminement de l'électricité aux consommateurs finaux. Ces activités englobent également celles relative à la maintenance préventive et curative des ouvrages électriques. Elles sont exécutées par la Direction Technique.

La gestion prévisionnelle du réseau est également une tâche dévolue à la Direction Technique. Toutefois, il s'agit d'une activité qui relève particulièrement du Département Conduite Réseau HTA/HTB.

➤ *Activités commerciales*

Dans les activités commerciales sont classées les activités liées au branchement des compteurs, la gestion des clients, l'établissement des devis et le recouvrement de créances. Elles sont accomplies par les Directions Régionales.

Les Directions Support soutiennent les autres parties de la structure organisationnelle.

➤ *Activités de développement*

La SBEE ne fait pas que l'exploitation du réseau électrique de distribution et la vente d'énergie électrique. Elle intervient également dans la planification de la demande, des études, la recherche des financements des projets et le suivi des projets.

La Direction des Études, de la Planification et des Projets s'occupe particulièrement de ces activités.

➤ *Autres activités*

Autrefois la SBEE produisait de l'énergie électrique avec les centrales thermiques interconnectées au réseau électrique pour compléter les déficits sur le réseau de distribution. Elle louait des centrales constituées de groupes diesel lors de crises énergétiques.

Le tableau suivant présente la production par région de 2016 à 2018 [14].

Tableau 1.1: Production en énergie électrique de 2016 à 2018

Site de production	Production par année (MWH)		
	2016	2017	2018
Centrale Akpakpa	0	0	0
Aggreko Gbégamey + Akpakpa	88623	44181	6802
Aggreko Maria Gléta	0	19537	6022
MRI Vèdoko	57612	16645	2467
MRI Parakou	15550	2903	2918

Site de production	Production par année (MWH)		
	2016	2017	2018
APR Maria Gléta	0	2655	1107
TAG 80 MW Maria Gléta	0	0	0
Zou_Collines (Ouèssè)	0	0	0
Ouémé (centrale Wärtsilä Porto Novo)	14	295	240
Borgou (centrale Wärtsilä Parakou)	0	151	493
Atacora (centrale Wärtsilä Natitingou)	1140	1238	278
Total	162940	87605	20328

La SBEE disposait de plusieurs centrales installées dans les Départements de l'Atacora, de l'Ouémé et du Borgou. Ces centrales venaient en appui pour combler les manques d'énergie en cas d'urgence. Elles sont dorénavant classées dans le patrimoine de la SBPE. Actuellement, la SBEE n'a plus dans ses attributions la production d'énergie électrique depuis la création de la SBPE.

1.2.2. Communauté Électrique du Bénin (CEB)

Le 27 juillet 1968, les Chefs d'État du Bénin et du Togo d'alors ont eu la volonté de créer la Communauté Électrique du Bénin (CEB). Leur vision commune est de doter les deux pays d'une structure capable de produire et de transporter de l'énergie électrique de qualité à moindre coût.

1.2.2.1. Présentation de la CEB

La CEB est chargée du développement du secteur de l'électricité sur les territoires des deux États qui lui ont donné vie. Toutefois, depuis 2019, la CEB est devenue seulement gestionnaire du réseau de transport et exploitant des deux turbines de Nangbéto.

1.2.2.2. Mission de la CEB

La CEB étant le deuxième acteur principal du secteur d'électricité béninois, elle a pour mission le transport de l'énergie électrique pour le compte des deux pays le Bénin et le Togo.

1.2.2.3. Structure organisationnelle

La CEB est composée de six (06) directions notamment :

- La Direction Générale,
- La Direction Technique,
- La Direction des Marchés,
- La Direction du Contrôle de Gestion, de l'Informatique et de la Statistique,

- La Direction de l'Administration et des Ressources Humaines,
- La Direction Financière et de la Comptabilité,
- La Direction des Études, de la Planification et des Projets.

Les autres Directions assistent le Directeur Général pour l'accomplissement de ses fonctions.

1.2.2.4. Les activités de la CEB

Elles englobent la construction du réseau et l'exploitation des postes électriques de transport. La CEB effectue la maintenance préventive et curative des ouvrages électriques de son réseau, élabore la facturation de l'énergie électrique qui transite via le réseau de transport, planifie la demande, réalise des études, recherche des financements pour des projets et assure leur suivi.

Par ailleurs, la CEB dispose d'un centre de formation dénommé Centre de Formation Professionnelle et de Perfectionnement (CFPP), grâce auquel il propose des programmes de perfectionnement et des formations spécialisées aux métiers de l'électricité.

1.2.3. Système d'Échanges d'Énergie Électrique Ouest Africain

1.2.3.1. Présentation de l'EEEOA

Le Système d'Échanges d'Énergie Électrique Ouest Africain (EEEOA) a été créé en 1999 au cours du 22^{ème} sommet de la Conférence des Chefs d'État et de Gouvernement de la CEDEAO. Il regroupe en son sein les sociétés d'électricité des États membres signataires de la convention du système EEEOA et a pour responsabilité de développer des infrastructures électriques [15].

Au 29^{ème} sommet des Chefs d'État et de Gouvernement de la CEDEAO en janvier 2006, il y a eu l'adoption et la Conférence d'établissement de la CEDEAO par décision N° A/DEC.18/01/06.

Actuellement l'EEEOA compte quatorze (14) Etats membres de la sous-région. La figure suivante présente la carte des pays de la Communauté Economique Régionale [15].




Figure 1.1: Carte présentant les 14 pays membres de la communauté économique régionale

1.2.3.2. Mission de l'EEEOA

L'EEEOA assure la coordination des échanges d'électricité entre les pays membres de la CEDEAO, la promotion ainsi que le développement des infrastructures de production et de transport d'énergie électrique [16].

1.2.3.3. Structure organisationnelle

Pour accomplir sa mission, l'EEEOA peut compter sur ses organes, notamment l'Assemblée Générale qui est l'instance de décision suprême de l'EEEOA, qui regroupe l'ensemble des sociétés membres, le Conseil Exécutif, les Comités et le Secrétariat Général [16].

1.2.3.4. Activités

L'EEEOA s'occupe de la construction et de l'exploitation des systèmes d'échanges d'énergie électrique entre les pays membres de la CEDEAO. Il exécute des travaux de maintenance préventive et curative des éléments des systèmes d'échanges d'énergie électrique.

1.2.4. Autorité de Régulation Régionale du secteur de l'Électricité de la CEDEAO

1.2.4.1. Présentation

L'Autorité de Régulation Régionale du secteur de l'Électricité de la CEDEAO (ARREC) est le régulateur d'échanges transfrontaliers d'électricité en Afrique de l'Ouest. En effet, les États membres de la CEDEAO ont pris l'engagement d'effectuer des interconnexions électriques afin de mettre en commun et d'optimiser le partage des ressources énergétiques de la région. Cet engagement se traduit par l'adoption d'un certain

nombre de dispositions destinées à instaurer un environnement institutionnel et juridique approprié au développement du secteur de l'électricité de la région [17].

La Conférence des Chefs d'États de la CEDEAO met alors en place en janvier 2008, par acte additionnel N° A/SA.2/01/08, l'Autorité de Régulation Régionale du secteur de l'Électricité de la CEDEAO dans le cadre du Système d'Échanges d'Énergie Électrique Ouest Africain (EEEOA) [17].

1.2.4.2. Mission de l'ARREC

L'ARREC a pour mission principale de garantir le niveau de revenus nécessaire aux sociétés d'électricité et de déterminer les combinaisons tarifaires et subventions compensatoires requises [18].

1.2.4.3. Structure organisationnelle

Le Système d'Échanges d'Énergie Électrique Ouest Africain (EEEOA) dispose d'un Conseil de Régulation qui est l'organe de direction et de gestion de l'ARREC. Cet organe est constitué de trois membres nommés pour un mandat fixe de cinq ans, non renouvelable.

Un groupe d'experts en charge des questions liées à la régulation et une unité en charge des Ressources humaines, de l'Administration et des Finances assistent le Conseil de Régulation dans ses attributions [19].

1.2.5. Autorité de Régulation de l'Électricité (ARE)

1.2.5.1. Présentation de l'ARE

L'Autorité de Régulation de l'Électricité (ARE) est un établissement public, un organe indépendant doté d'une personnalité morale et de l'autonomie financière. Elle a été créée pour assurer le respect des réglementations et des lois dans le secteur d'électricité, la qualité du service, ainsi que la stabilité financière du secteur.

1.2.5.2. Mission

L'Autorité de Régulation de l'Électricité a été créée par décrets N° 2009-182 du 13 mai 2009 et N°2015 – 074 du 27 février 2015 portant modification des articles 3, 8, 18 et 19 du décret n°2009-182 du 13 mai 2009. Elle veille, entre autres, au respect des textes législatifs et réglementaires régissant le secteur de l'électricité au Bénin afin de protéger l'intérêt général, de garantir la continuité et la qualité de service, l'équilibre financier du secteur et son développement harmonieux.

1.2.5.3. Structure organisationnelle

Placée sous l'autorité du Président de la République, l'Autorité de Régulation de l'Électricité est dirigée par un Président qui exerce ses fonctions avec six membres qui sont tous nommés.

1.2.5.4. Activités de l'ARE

L'ARE s'occupe du respect des normes en matière de production, de transport de distribution de l'énergie électrique, à la continuité et la qualité du service public de l'électricité, à l'approbation des grilles tarifaires avant leur publication par l'État. Elle vérifie également leur application, à l'approbation du modèle de contrat d'achat et vente d'énergie électrique.

1.2.6. Production Indépendant d'Électricité (PIE ou IPP)

Les Producteurs Indépendants d'Electricité (PIE ou IPP) sont des producteurs titulaires d'un titre d'exploitation les autorisant à établir, gérer et maintenir une installation de production. Généralement, cette installation de production utilise des sources d'énergies renouvelables pour produire de l'électricité destinée exclusivement à la vente aux gestionnaires de réseau interconnectés (transport ou distribution) ou à l'exportation.

Toutefois, il existe des producteurs d'électricité hors-réseau qui se servent d'énergies renouvelables. Ils sont titulaires d'un titre d'exploitation d'un système hors réseau, pour l'activité intégrée de production, de distribution et de fourniture d'électricité de service public.

1.2.6.1. Mission

L'objectif principal des Producteurs Indépendants d'Électricité est de produire de l'énergie électrique renouvelable pour transport, distribution ou exportation.

1.2.6.2. Activités

Ces producteurs construisent des centrales de production électrique et procèdent à son exploitation. Ils font la maintenance préventive régulière pour la fiabilité des centrales.

1.2.7. Ministère de l'Industrie et du Commerce

1.2.7.1. Présentation

Le Ministère de l'Industrie et du Commerce est le département ministériel d'échanges du gouvernement. Il a sous sa tutelle d'une part des sociétés d'importation, d'exportation et

de distribution des produits pétroliers et d'autre part des sociétés de transformation des différents produits [20].

Le Ministère de l'Industrie et du Commerce s'occupe de l'importation et de l'exportation des sources d'énergie d'origine fossile, des énergies renouvelables.

1.2.7.2. Mission

Le Ministère de l'Industrie et du Commerce a en charge la mise en œuvre, le suivi et l'évaluation de la politique générale de l'État en matière de promotion de l'industrie, du commerce intérieur et extérieur conformément aux lois et règlements en vigueur en République du Bénin [21].

1.2.7.3. Structure organisationnelle

Le Ministère de l'Industrie et du Commerce est dirigé par un Ministre, membre du gouvernement. Pour bien accomplir sa mission, il collabore avec plusieurs directions techniques. Il s'agit notamment de la :

- **Direction du Développement Industriel** qui élabore et veille à la mise en œuvre de la politique nationale en matière de la promotion, d'autorisation, de la réglementation et du contrôle des activités industrielles mises en œuvre sur le territoire béninois ;
- **Direction du Commerce Intérieur** qui propose et veille à la mise en œuvre de la politique nationale en matière du commerce intérieur ;
- **Direction de la Concurrence** dont les attributions sont la proposition et la veille pour la mise en œuvre de la politique nationale de la lutte contre la fraude commerciale, la concurrence déloyale et les pratiques anti-concurrentielles ;
- **Direction du Commerce Extérieur** dont les attributions regroupent l'élaboration et la veille pour la mise en œuvre de la politique nationale en matière de commerce extérieur.

Le Ministre fixe par décret l'organisation et le fonctionnement des directions techniques et départementales.

En plus des directions techniques énumérées précédemment, il existe des organismes qui sont placés sous tutelle du Ministère. Entre autres, il s'agit de :

- L'Agence nationale de Normalisation, de Métrologie et du Contrôle Qualité qui a pour mission la mise en œuvre et le suivi-évaluation de la politique nationale

de normalisation, de métrologie, de certification, de vérification des produits et de la promotion de la qualité ;

- Le Bureau de la Restructuration et de la Mise à Niveau (BRMN), créé par arrêté N° 08-063/MCPEA/SG/DGDI, du 08 mars 2008. Il met en œuvre les décisions et est en contact direct avec les entreprises. Il est placé sous l'autorité directe du Comité de Pilotage National (CPN) ;
- Le Cadre intégré renforcé ;
- La Chambre de Commerce et d'Industrie du Bénin ;
- La Société sucrière de Savè ;
- La Société des Industries textiles du Bénin ;
- La Compagnie Béninoise des Textiles.

1.2.8. Ministère de Cadre de Vie, des Transports en charge du Développement Durable

1.2.8.1. Présentation

Anciennement connu sous l'appellation de Ministère de l'Environnement, de l'Habitat et de l'Urbanisme (MEU) jusqu'en avril 2016, le Ministère du Cadre de vie et des Transports, en charge du Développement Durable (MCVTDD) est un acteur important dans la construction d'un cadre de vie agréable et dans la promotion du développement durable.

Le développement du secteur de l'électricité présente plusieurs externalités, positives comme négatives, sur le cadre de vie. Pour cela, le Ministère de Cadre de Vie et du Développement Durable devient un acteur à prendre en compte dans l'analyse du fonctionnement de ce secteur.

1.2.8.2. Missions

En vertu des articles 20, 46, 50, 55, 86, 88 de la loi cadre sur l'environnement en République du Bénin, le Ministère de Cadre de Vie et du Développement a pour mission de concevoir et de mettre en place des politiques et stratégies pour l'État en relation avec l'environnement. La pertinence et l'efficacité de l'environnement l'obligent à surveiller et à évaluer ces politiques et stratégies [22].

Par ailleurs, la promotion des énergies nouvelles et renouvelables, dans le secteur électrique, pour la production de l'énergie biomasse demande essentiellement l'accompagnement du MCVTDD afin de garantir toutes les ressources forestières appropriées au Ministre en charge de l'énergie [23].

1.2.8.3. Structure organisationnelle

Le MCVTDD est composé de structures rattachées au Cabinet, de directions centrales, de directions techniques, des cellules [24]. Chaque partie de l'organigramme travaille en respectant les lois-cadres sur l'environnement en République du Bénin.

1.3. CADRE JURIDIQUE DU SECTEUR DE L'ELECTRICITE AU BENIN

Dans cette section, nous discuterons des lois qui régissent le secteur de l'énergie électrique au Bénin.

Les États béninois et togolais ont élaboré depuis le 27 juillet 1968 le code Bénino-Togolais afin de réglementer les activités de ce sous-secteur [20]. Cependant, ce code n'a pas favorisé la contribution des acteurs privés au développement du secteur. Ce n'est qu'avec la révision du code, le 23 décembre 2003, que les choses se sont améliorées et que des conditions plus favorables à l'intervention de producteurs indépendants se sont installées. La CEB adopte désormais le statut d'acheteur unique.

Par ailleurs, la loi 2006-16 du 27 mars 2007 portant code de l'électricité en République du Bénin vient renforcer l'arsenal juridique du Bénin, dans le cadre de la régulation du secteur de l'énergie électrique. Cette nouvelle loi, complète celle commune au Bénin et au Togo, en définissant la politique générale d'organisation du secteur de l'électricité, le cadre juridique au sein duquel sont exercées les activités inhérentes au secteur ainsi que les modalités de participation des entreprises privées, notamment le régime de propriété et d'usage des installations électriques situées sur le territoire national [25], [20], [3].

La loi 2020-05 du 1^{er} avril 2020 constitue le dernier instrument du cadre juridique régissant le secteur de l'énergie électrique au Bénin. Cette loi a complété les lois citées précédemment et précisé les missions de l'ARE, les règles et les lois concernant l'environnement dans le secteur de l'électricité.

1.4. RESEAU ELECTRIQUE BENINOIS

Le fonctionnement optimal du réseau électrique béninois fait appel à trois expertises interconnectées : la production, le transport et la distribution. Bien que dépendantes les unes des autres, elles sont toutefois assurées par trois différents acteurs principaux : la SBEE, la SBPE et la CEB. L'objectif derrière cette subdivision est d'assurer un fonctionnement optimal du réseau électrique.

1.4.1. Réseau de transport

Les centres de production constituent la première étape dans le transport de l'énergie électrique. L'électricité ainsi produite est relayée par des postes sources ou sous-stations, au travers de lignes électriques de différents niveaux de tension : 63 kV, 161 kV et 330 kV [3].

Par ailleurs, soulignons que le réseau de transport béninois est interconnecté avec ceux du Nigéria et du Togo.

1.4.2. Réseau de distribution

Pour assurer la commercialisation de l'énergie électrique sur toute l'étendue du territoire national, la SBEE utilise différents niveaux de tension : 63 kV, 33 kV, 20 kV et 15 kV. Elle exerce son autorité sur la totalité du réseau basse tension (BT et utilise les niveaux de tension 33 kV, 20 kV et 15 kV pour la desserte des postes de répartition et de distribution HTA [26].

La vétusté du réseau de distribution et la surcharge des postes de distribution causent des dommages aux clients et à la SBEE. On note également des baisses de tension qui empêchent le fonctionnement normal des compteurs à prépaiement. Des perturbations s'observent également sur le réseau, notamment des coupures électriques intempestives. Le tableau 1.2 présente l'évolution et les différentes catégories de perturbations sur le système électrique observées en 2022 et 2023 [27].

Tableau 1.2: Nombre de perturbations recensées sur le réseau électrique 2022 & 2023

Année	Jan	Fev	Mar	Avr	Mai	Juin	Juil	Août	Sep	Oct	Nov	Dec
2022	319	328	586	654	713	854	589	516	592	577	471	354
2023	545	549	899	718	953	918	793	760	1094	976	669	669




Figure 1.2: Evolution du nombre de perturbations du réseau électrique 2022 & 2023

La figure 1.2 illustre l'évolution mensuelle du nombre de perturbations du réseau électrique en 2022 et 2023.

En 2022, le nombre de perturbations augmente progressivement entre janvier et juin, atteignant un pic en juin, avant de diminuer régulièrement jusqu'à la fin de l'année. En revanche, en 2023, les perturbations sont plus nombreuses sur l'ensemble de l'année, avec un pic notable en septembre. Cependant, on observe une baisse progressive à partir d'octobre, qui se stabilise en décembre.

Comparativement, la courbe de 2023 se situe globalement au-dessus de celle de 2022, indiquant une tendance générale à une augmentation des perturbations en 2023. Les mois de juin et décembre sont des exceptions où la tendance de 2023 est similaire ou légèrement décroissante, comparée à celle de 2022.

La figure 1.2 met en évidence une saisonnalité potentielle, avec des périodes de hausse et de baisse régulières au cours des deux années, bien que les volumes totaux soient significativement plus élevés en 2023.

1.5. MOYENS DE PRODUCTION DE L'ENERGIE AU BENIN

L'énergie électrique est produite au moyen de centrales électriques. Elles utilisent des énergies primaires (gaz naturel, HFO, gasoil, rayonnement solaire, énergie potentielle de l'eau) qu'elles transforment en énergie secondaire (électricité) [28].

Pour aborder cette section de notre mémoire, nous présenterons le parc national de production avant d'aboutir sur une discussion du système d'approvisionnement externe en énergie électrique.

1.5.1. Parc national de production

Le parc national de production est composé de centrales électriques thermiques, solaires photovoltaïques et hydroélectriques et dispose en 2019, d'une puissance totale installée de 177,5 MW [13]. Actuellement la disponibilité du parc est de 134 MW.

Le Bénin possède quatre (04) centrales électriques thermiques. Il s'agit des centrales thermiques de Maria-Gléta 2, Porto-Novo, Natitingou et Parakou. Ces centrales ont des puissances installées et des puissances disponibles réparties comme suit :

- Maria Gléta 2, avec une capacité installée de 127 MW pour une disponibilité de 105 MW. Cette centrale est alimentée par le gaz naturel et le fioul lourd (HFO).
- Porto-Novo, d'une puissance installée de 14 MW avec une disponibilité de 8 MW est alimentée par le gasoil.
- Natitingou, avec une puissance installée de 12 MW, dispose aujourd'hui 3 MW et utilise de gasoil pour son fonctionnement.
- Parakou d'une puissance installée de 12 MW et disponible de 3 MW, cette centrale fonctionne avec le gasoil.

La seule centrale solaire photovoltaïque, DEFISSOL, possède une capacité installée de 25 MW crête et délivre actuellement une puissance de 15 MW. Elle attend une extension de 25 MW crête pour avoir une puissance totale installée de 50 MW crête. Le dernier type de centrale, la centrale hydroélectrique est installée à Yéripao, à Natitingou, avec une capacité de 480 kW.

La centrale thermique de Maria Gléta 2 dispose de moteurs dual fuel (gaz-HFO). Elle a été mise en exploitation avec une puissance de 127 MW en août 2019 [29]. La centrale solaire photovoltaïque et celle de Maria Gléta 2 ont contribué à augmenter le niveau d'autosuffisance énergétique du pays de 39,88% en 2019 à 64,95% en 2020 [1].

Les centrales thermiques de Porto-Novo, de Parakou et de Natitingou ont atteint le nombre d'heures de révision. Quant à la centrale hydroélectrique de Yéripao, la seule turbine dont elle dispose nécessite une réhabilitation et il faudrait l'installation de la deuxième turbine afin de bénéficier de la totalité de l'eau du barrage pendant la saison pluvieuse. De

plus, quatre (04) centrales solaires photovoltaïques sont en construction à Bohicon, Parakou, Djougou et Natitingou avec une capacité totale de 50 MW crête.

1.5.2. Approvisionnements externes en énergie électrique

Les approvisionnements externes en énergie électrique proviennent essentiellement des centrales (hydroélectrique et TAG) de la CEB et des pays voisins notamment le Nigéria, le Ghana et la Côte d'Ivoire via respectivement la TCN, la VRA et la CIE.

La CEB avait auparavant le statut d'acheteur unique que lui conférait le code Bénino-Togolais du 27 juillet 1968. Cependant le décret n°2020-565 du 02 décembre 2020 lui confie dorénavant le transport de l'énergie sur son réseau électrique reliant le réseau du Nigéria et celui du Ghana.

Les postes sources primaires de la CEB assurent le transit de l'énergie importée. Ces postes desservent les postes sources secondaires et postes de répartition de la SBEE.

1.6. CONCLUSION PARTIELLE

Ce chapitre a fait l'état des lieux du secteur de l'énergie électrique en prenant en compte les acteurs principaux intervenant dans le secteur de l'électricité. Le présent travail s'attèle à présent à étudier et à répertorier les différents travaux de recherche qui se sont intéressés à la modélisation de la demande électrique dont les résultats pourraient fournir de précieuses informations.

Chapitre 2. Revue de littérature sur les modèles de prévision de la demande d'énergie

2.1. INTRODUCTION PARTIELLE

Ce chapitre dont l'objectif principal est de faire une cartographie des travaux de recherche effectués dans le sillage du domaine du présent mémoire est subdivisé en deux grandes parties. La première partie est consacrée aux différents modèles dans la littérature tandis que la seconde met en exergue les diverses métriques habituellement utilisées pour évaluer la performance des modèles construits.

2.2. ETAT DE L'ART SUR LES MODELES DE PREVISION DE DEMANDE D'ACHAT EN ELECTRICITE

L'énergie électrique est un bien également soumis au principe de rareté. Pour une allocation optimale des ressources disponibles, il faut une planification vraiment rigoureuse et efficace. Dans ce contexte, la prévision de la demande en énergie électrique revêt d'une importance capitale d'autant plus qu'elle permet d'atteindre un certain équilibre entre l'offre et la demande.

Dans les pays en développement, l'exercice de prévision de la demande est crucial en raison des défis socio-économiques qui les caractérisent.

2.2.1. Méthodes de régression linéaire multiple

La régression linéaire multiple (RLM) est l'une des méthodes les plus simples et les plus utilisées pour la prévision de la demande en électricité. Cette méthode repose sur l'hypothèse qu'une relation linéaire existe entre la demande d'électricité et un ensemble de variables explicatives notamment :

- La température,
- La croissance économique,
- La population,
- La croissance démographique.

Une des métriques souvent utilisées pour évaluer la précision des modèles de régression est l'erreur absolue moyenne ou Mean Absolute Error (MAE) [30]. Les modèles de régression sont particulièrement adaptés pour des prévisions à court terme. Plusieurs recherches considèrent le court terme comme un horizon temporel allant de quelques heures à plusieurs jours [31], [32], [33]. La régression linéaire a, par exemple, été utilisée pour

développer des modèles de prévision de la demande à court terme, sur un horizon de 24 heures, au Togo avec une Mean Absolute Percentage Error (MAPE) de moins de 5% [34]. En Afrique du Sud, elle a été utilisée en tenant compte de variables comme la température et l'activité économique [35] pour prédire la demande d'électricité par année.

Les résultats montrent une bonne précision dans des conditions stables, mais les fluctuations saisonnières et les chocs peuvent réduire l'efficacité de ces modèles. En effet, la rigidité de la régression linéaire ne permet pas de bien capter les effets non-linéaires de certains facteurs, ce qui représente une limite importante, surtout dans les contextes où les données sont limitées ou de faible qualité [36]. De plus, ces environnements sont marqués par des taux de croissance économiques imprévisibles et des événements politiques ou climatiques inattendus qui affectent grandement la demande en électricité. C'est pourquoi la régression linéaire multiple est souvent complétée par d'autres approches plus robustes et flexibles.

2.2.2. Analyse des séries chronologiques

L'analyse des séries chronologiques est une autre méthode largement utilisée dans la prévision de la demande en électricité. Elle s'appuie sur l'étude des données historiques pour identifier des schémas, des tendances et des cycles, afin de prédire les fluctuations futures de la demande. Ce type d'approche est fréquemment utilisé au Sénégal, où des chercheurs comme Diagne [37], ont, par exemple, mis en place des modèles de ce type.

Le modèle ARIMA est largement utilisé dans les prévisions énergétiques en raison de sa simplicité et de son efficacité pour modéliser des données temporelles stationnaires. Une autre variante de ARIMA est le modèle ARIMAX qui, contrairement à ARIMA, prend des variables exogènes en plus de la variable prédite. C'est un modèle utilisé par DANGBEDJI [20] dans le cadre de ses travaux de modélisation numérique de la prévision de la demande en électricité au Bénin. Il explore également l'utilisation de techniques telles que le bootstrap, qui permettent de simuler des distributions statistiques et de mesurer l'incertitude des prévisions, en particulier pour les consommations fluctuantes tout au long de l'année.

Cependant, les limites du modèle ARIMA sont apparues dans des contextes où les séries temporelles présentent des tendances non linéaires et des effets saisonniers marqués. Les auteurs soulignent que la complexité des facteurs socio-économiques et climatiques en Afrique de l'Ouest rend parfois difficile l'application de ce modèle sans ajustement supplémentaire.

Pour contourner les limites d'ARIMA, une dimension saisonnière est intégrée avec le modèle SARIMA lorsque la série présente des schémas de saisonnalité. L'avantage du modèle SARIMA est sa capacité à mieux gérer les pics saisonniers, souvent observés dans les pays où la consommation énergétique varie avec les conditions météorologiques (notamment l'usage de climatisation). Cette méthode a été également utilisée au Sénégal par Ndiaye et al. Les résultats produits par le modèle SARIMA, une MAE de 0.166997, bien qu'intéressants étaient inférieurs à ceux produits par le second modèle [38]. Toutefois, l'étude a souligné que l'efficacité de ce modèle dépend de la qualité des données disponibles et de la capacité à ajuster les paramètres saisonniers avec précision.

Comme l'a mentionné l'étude de Ndiaye et al, les réseaux de neurones artificiels sont de plus en plus utilisés dans la prévision de la demande d'énergie, car ils peuvent capturer des schémas non linéaires complexes dans les séries temporelles. Ils sont connus pour permettre de prévoir la demande en énergie électrique du jour prochain avec une erreur de 4.86 % par rapport à la consommation réelle [39].

Lorsqu'il a été utilisé, le modèle LSTM a produit de meilleurs résultats, face au modèle SARIMA, avec une MAE de 0.148597 [38]. De même, l'utilisation de ces modèles dans l'Etat de Lagos, au Nigeria, pour la prévision de la demande en énergie électrique a démontré une performance de 97%, avec un faible niveau de root mean squared error (RMSE). L'étude a conclu que les réseaux de neurones sont vraiment pertinents pour la prévision [36].

Par ailleurs, malgré ces belles performances, les réseaux de neurones nécessitent de grandes quantités de données pour un entraînement optimal, ce qui représente parfois un défi en Afrique de l'Ouest, où la collecte de données fiables est très souvent limitée.

2.2.3. Modèles Long Terme et Approche Multisectorielle

Les modèles de prévision à long terme, tels que ceux utilisés au Ghana et au Nigeria, se concentrent sur les dynamiques économiques et industrielles à grande échelle.

Le Nigeria adopte une approche plus sophistiquée en combinant des modèles bottom-up basés sur la demande sectorielle et des modèles top-down macroéconomiques pour estimer la demande future. Au Nigeria, Energy Outlook intègre un modèle à deux volets, où les demandes des secteurs résidentiel et industriel sont modélisées séparément, en fonction de variables telles que le PIB, la démographie, et la disponibilité des infrastructures énergétiques [40].

Les méthodes de prévision de la demande au Ghana combinent des approches économétriques et des analyses par simulation. Un modèle d'équilibre partiel qui relie l'évolution des prix de l'énergie, la croissance économique, et la consommation par secteur. Les prévisions sont ajustées avec des données en temps réel provenant du réseau électrique, notamment pour les pertes de transmission et l'exportation d'électricité vers des pays voisins comme le Bénin, le Togo et le Burkina Faso. Le modèle prend également en compte les investissements dans les énergies renouvelables, qui ajoutent une variabilité dans les projections à cause de l'intermittence des sources solaires et hydroélectriques.

L'approche multisectorielle au Nigeria est également une méthode efficace pour intégrer les dynamiques propres à différents secteurs économiques. Cette méthode permet une vision plus globale de la demande énergétique, en tenant compte des interactions entre les secteurs industriel, résidentiel et commercial, et en anticipant ainsi les besoins en infrastructure électrique.

Les modèles à long terme sont toutefois fortement dépendants de la précision des hypothèses sur la croissance économique et la stabilité politique, deux éléments souvent incertains dans les pays d'Afrique de l'Ouest, ce qui peut rendre leurs prévisions obsolètes en cas de perturbations majeures.

2.2.4. Modèles GARCH

Les modèles GARCH (Generalized Autoregressive Conditional Heteroskedasticity) ont été introduits par Bollerslev en 1986 pour étendre les modèles ARCH d'Engle (1982). Cette avancée a permis de capturer les fluctuations conditionnelles de la variance dans des séries temporelles, une caractéristique cruciale pour les séries marquées par une hétéroscédasticité conditionnelle, comme celles observées dans les domaines financiers et énergétiques. Depuis leur introduction, ces modèles ont été largement adoptés pour modéliser la volatilité et améliorer les prévisions dans divers contextes, y compris la demande énergétique.

Les travaux de YOTTO [41], qui expliquent que l'horizon horaire pour du court terme peut aller de quelques heures à plusieurs semaines, représentent une application notable des modèles GARCH en Afrique de l'Ouest. En combinant des modèles ARIMA et GARCH, l'auteur a pu modéliser les séries temporelles de consommation électrique au Bénin. Son approche méthodologique comprenait la vérification de la stationnarité des séries à l'aide du test ADF et l'utilisation de la méthode Box-Jenkins pour déterminer les paramètres optimaux

des modèles ARIMA. Une fois les modèles ARIMA ajustés, les modèles GARCH ont été intégrés pour modéliser la volatilité conditionnelle. Les résultats de YOTTO ont montré que le modèle ARIMA (0,1,1) – GARCH (1,1) offrait un MAPE inférieur à 1 % (0,985 %). Cette précision a permis d'estimer des pics de demande énergétique à 595 MW et une consommation totale entre 4 100 et 4 200 GWhs pour l'horizon 2030 [41]. YOTTO a également souligné les défis liés à la qualité des données et recommandé l'intégration de variables exogènes comme les conditions météorologiques et les indicateurs économiques pour améliorer les performances du modèle. En outre, il a préconisé l'exploration de modèles hybrides combinant GARCH avec des techniques d'intelligence artificielle, telles que les réseaux de neurones, pour pallier les limitations des modèles GARCH seuls. Une autre étude notable est celle de Kibala Kuma [42], menée sur l'utilisation des modèles ARCH, GARCH et leurs variantes avancées pour modéliser des séries temporelles marquées par une forte volatilité, en particulier dans le domaine énergétique. L'objectif principal de ces travaux était d'examiner la performance comparative des modèles standards (ARCH) et GARCH) par rapport à leurs extensions plus complexes (EGARCH et TGARCH), afin d'identifier les meilleures approches pour la prévision dans des contextes dynamiques et asymétriques. Dans son étude, Kuma s'est concentré sur des séries temporelles énergétiques provenant de marchés où les fluctuations sont influencées par des facteurs saisonniers, économiques et technologiques. Il a analysé des données couvrant une période de dix ans, incluant des informations sur la consommation énergétique, les prix de l'électricité et des variables explicatives exogènes telles que les températures, les jours fériés et les tendances macroéconomiques. Les modèles ont été estimés en utilisant des méthodes robustes de maximum de vraisemblance, et leur performance a été évaluée à l'aide de métriques standards telles que le MAPE, le RMSE et les tests de Ljung-Box pour vérifier la qualité de l'ajustement [42].

Les résultats ont montré que les modèles EGARCH surpassaient les autres variantes, en particulier pour capturer les asymétries dans les données, où les chocs positifs (augmentation de la demande) et négatifs (réduction soudaine de la consommation) n'ont pas les mêmes impacts sur la variance conditionnelle [42]. Le modèle EGARCH a également démontré une meilleure capacité à modéliser les périodes de forte volatilité, une caractéristique fréquente des marchés énergétiques soumis à des variations saisonnières ou à des changements structurels rapides.

Cependant, Kuma a également identifié des limites importantes dans l'utilisation de ces modèles. Les variantes simples comme le GARCH standard se sont révélées inadéquates

pour capturer les tendances non linéaires complexes ou les ruptures structurelles importantes dans les données [42]. Par ailleurs, l'efficacité des modèles dépendait fortement de la qualité des données utilisées. Kuma a souligné la nécessité d'un prétraitement rigoureux des séries temporelles, notamment pour gérer les valeurs aberrantes, les données manquantes et les discontinuités.

Dans l'ensemble, ces travaux convergent vers une reconnaissance des modèles GARCH comme outils puissants pour modéliser la volatilité et améliorer les prévisions énergétiques. Cependant, les défis persistent, notamment la sensibilité des modèles aux anomalies dans les données et leur incapacité à saisir les transformations structurelles. Les chercheurs s'accordent sur l'importance d'intégrer des variables exogènes, d'améliorer la qualité des données et d'explorer des modèles hybrides. Ces recommandations offrent des pistes prometteuses pour surmonter les limitations actuelles et optimiser l'utilisation des modèles GARCH dans des contextes particuliers comme celui du Bénin.

2.2.5. Réseaux de Neurones Recurrents

Les réseaux de neurones récurrents (RNN) se distinguent par leur capacité à capturer les relations temporelles dans des séries chronologiques complexes. Contrairement aux modèles traditionnels comme ARIMA, les RNN exploitent les dynamiques non linéaires des données, prenant en compte l'ordre et la dépendance temporelle inhérente. Ces propriétés en font des outils particulièrement adaptés à la prévision de la consommation énergétique, où les variations saisonnières et les comportements humains introduisent une forte non-linéarité dans les données.

Les RNN intègrent une boucle récurrente qui transmet des informations d'un état temporel à un autre. Cela leur permet de "mémoriser" les informations passées pour influencer les prévisions futures. Cependant, cette architecture présente des défis majeurs, notamment le problème de gradient évanescent ou explosif. Ces limitations réduisent considérablement leur capacité à modéliser les dépendances sur de longues séquences temporelles, un aspect pourtant critique dans les prévisions énergétiques à long terme.

Nachawati [43] a appliqué les RNN pour la prévision de la consommation énergétique multivariée en Finlande. Cette étude a montré que les RNN surpassent les modèles statistiques traditionnels pour des prévisions à court terme (moins de 72 heures). Néanmoins, leur performance diminue pour des prédictions à long terme, en raison de leur faible capacité de mémorisation des dépendances lointaines. Ces résultats mettent en lumière le niveau de

sophistication des architectures utilisées comme prérequis pour répondre aux exigences de précision dans ce domaine.

Pour surmonter les limitations des RNN traditionnels, les modèles Long Short-Term Memory (LSTM) ont été développés. Introduits par Hochreiter et Schmidhuber en 1997 [44], les LSTM intègrent une architecture sophistiquée composée de cellules mémoire et de mécanismes de régulation appelés "portes" (input, forget et output). Ces éléments permettent de conserver et de gérer efficacement les informations importantes sur de longues périodes, tout en supprimant celles jugées non pertinentes.

Nugaliyadde et al. [45] ont démontré l'efficacité des RNN et LSTM dans un contexte londonien, où ces modèles en atteignant une erreur quadratique moyenne (RMSE) de 0,1 mettent en lumière leur performance pour les prévisions à court, moyen et long terme.

Une autre avancée significative a été réalisée par Guimarães da Silva et Meneses, qui ont comparé les performances des LSTM unidirectionnels et bidirectionnels (BLSTM). Leur étude a révélé que les BLSTM surpassaient les LSTM classiques, grâce à leur capacité à intégrer des relations temporelles dans les deux directions, améliorant ainsi la précision des prévisions [46].

Par ailleurs, Al Khafaf et ses collaborateurs ont mis en évidence l'efficacité des LSTM pour des prévisions énergétiques, obtenant une erreur absolue moyenne en pourcentage (MAPE) de 3,15 % [47]. Leur approche innovante inclut la quantification du temps comme variable, améliorant les performances prédictives du modèle.

Enfin, Marino et al., ont exploré l'application des LSTM pour la charge énergétique résidentielle, montrant que l'architecture Sequence to Sequence (S2S) basée sur LSTM performe efficacement sur des données horaires et à la minute [48], renforçant ainsi la pertinence des LSTM pour des contextes variés de prévision énergétique.

Ces études, bien qu'ancrées dans des contextes différents, permettent d'avoir des idées intéressantes pour l'application des LSTM au contexte énergétique du Bénin, où la qualité des données souvent caractérisées par des variations saisonnières complexes et la complexité des séries temporelles nécessitent des approches avancées et inédites.

Cho et al. [49] ont amélioré le fonctionnement des modèles LSTM pour réduire sa complexité en proposant en 2014 les modèles GRU. Ces modèles GRU ont été utilisés en 2023 par Abumohsen et al. [50] pour la prévision d'électricité à court terme en Palestine. Dans leur recherche ils ont mis en évidence les modèles de mémoire à long terme (LSTM), l'unité récurrente gated (GRU) et le réseau neuronal récurrent (RNN). Parmi ces trois modèles évalués, le GRU se trouve performant avec le coefficient de détermination (R^2) de

0,90228, l'erreur quadratique moyenne (MSE) de 0,00215 et l'erreur absolue moyenne (EAM) de 0,03266.

En 2020, Sajjad et al. [51] ont réalisé dans leur recherche la combinaison des modèles convolutionnels (CNN) et l'unité récurrente gated (GRU) pour la prédiction de la consommation résidentielle à court terme en République de la Corée. La combinaison de ces deux modèles leur a permis d'avoir l'erreur quadratique moyenne (MSE) de 0,09, racine carrée de l'erreur quadratique moyenne (RMSE) de 0,31 et l'erreur absolue moyenne (MAE) de 0,24.

2.2.6. Lissage exponentiel

Le lissage exponentiel, méthode éprouvée pour analyser et prévoir les séries chronologiques, est au cœur des travaux de nombreux chercheurs. Cette section met en lumière les résultats et les contributions des auteurs Paweł Pełka et al, Abdi-Basid Ibrahim et Adan. Leurs études, bien que variées dans leur approche, illustrent l'efficacité et les limites de cette méthode dans des contextes divers.

Dans leur étude, Paweł Pełka et al. [43] introduisent une approche hybride combinant l'efficacité des modèles statistiques classiques avec la flexibilité des réseaux de neurones récents.

Dans cette étude, le lissage exponentiel (ETS) sert d'outil de décomposition initiale des séries temporelles. Il extrait les composantes de niveau et de saisonnalité, qui sont ensuite utilisées pour normaliser les données avant leur traitement par un réseau de neurones résiduel dilaté (RD-LSTM). Cette combinaison permet de tirer parti des forces respectives de ces méthodes : l'ETS pour sa simplicité et sa robustesse dans la capture des composantes saisonnières, et le RD-LSTM pour sa capacité à modéliser les dépendances non linéaires et à long terme.

L'étude a été réalisée sur des données couvrant 35 pays européens. Parmi les métriques employées pour évaluer les performances du modèle figurent le RMSE et le MAPE. Les résultats montrent une réduction significative des erreurs, avec des RMSE généralement inférieurs à ceux des modèles classiques (tels que ARIMA ou ETS seul), 347,24 [52].

Des MAPE faibles : pour des pays comme l'Espagne (1,61 %), l'Italie (2,12 %) et l'Allemagne (2,29 %), les prévisions étaient particulièrement précises. Cependant, le Royaume-Uni, avec un MAPE de 8,52 %, a présenté des résultats moins convaincants en raison de variations inattendues de la demande [52].

Les auteurs insistent sur l'une des limites notables du modèle : sa dépendance à des données de qualité, rendant son application complexe dans des environnements à ressources limitées.

Adan [53] applique aussi le lissage exponentiel, pour analyser les séries économiques, en mettant un accent particulier sur la prévision de l'investissement. Il compare les performances de différentes méthodes, dont le lissage exponentiel simple et le modèle de Holt-Winters non saisonnier.

Il s'appuie sur des métriques telles que le RMSE, le MAE, et le MAPE, pour évaluer l'efficacité des modèles. Les résultats montrent une supériorité du modèle de Holt-Winters par rapport au lissage exponentiel simple, avec les performances suivantes :

- Lissage exponentiel simple : RMSE de 708,97, MAPE de 46,14 % [53].
- Holt-Winters : RMSE de 694,00, MAPE de 44,26 % [53].

Ces différences, bien que modestes, mettent en évidence l'intérêt d'intégrer des composantes de tendance et de saisonnalité pour améliorer les prévisions, en particulier dans des séries relativement régulières.

Les prévisions à court terme réalisées avec Holt-Winters ont montré une meilleure précision, particulièrement en raison de sa capacité à intégrer des variations modérées de tendance. Toutefois, les deux modèles se sont avérés sensibles aux ruptures structurelles ou aux chocs économiques imprévus, limitant leur utilisation dans des contextes marqués par une volatilité importante.

2.2.7. Modèles Additifs Généralisés (GAM)

L'adaptabilité des modèles GAM en fait un outil prisé pour la prévision de la demande en électricité. Cette revue se concentre sur deux travaux récents : ceux de Caston Sigauke [54], qui applique les GAM dans le contexte sud-africain, et de Linxiao Yang [55], dont l'innovation porte sur un GAM interactif.

Sigauke, dans son étude, explore une application innovante des GAM pour la prévision de la demande horaire d'électricité en Afrique du Sud, couvrant les années 2009 à 2013. L'auteur se distingue par une approche méthodique où la sélection des variables et les interactions entre celles-ci jouent un rôle central.

En structurant son modèle autour du GAM-Lasso et de son extension GAM-Tensor-Lasso, Sigauke combine l'élégance des bases statistiques avec la capacité des tenseurs à capter des relations croisées entre variables. La sélection des covariables est réalisée via

Lasso, une méthode de régression pénalisée qui réduit le risque de surajustement tout en gardant les facteurs pertinents, tels que la température, les variations saisonnières hebdomadaires et annuelles.

Comparé à un modèle de gradient boosting utilisé comme benchmark, le GAM-Tensor-Lasso a démontré une supériorité notable [54]. Cependant, au-delà de la simple comparaison de résultats, le véritable atout réside dans la capacité de ce modèle à capturer des non-linéarités complexes grâce aux interactions de tenseur. Les prévisions, mesurées par la fonction de perte en pinball, ont montré une meilleure précision pour les scénarios de demande moyenne et extrême.

Un des points forts majeurs de cette étude est la prise en compte de deux régions climatiques sud-africaines, une variable clé dans la modélisation énergétique. Cela dit, la complexité de ce modèle accru due aux interactions de tenseur peut représenter un obstacle, en particulier au Bénin, où les ressources nécessaires pour tourner ces modèles sont limitées.

À travers son article [55], Linxiao Yang propose une approche audacieuse et novatrice pour modéliser la demande électrique, en particulier dans des conditions extrêmes. Contrairement à Sigauke, Yang s'écarte des structures standard pour introduire un GAM interactif, conçu pour gérer à la fois des scénarios extrêmes et des ensembles de données restreints.

Le modèle interactif de Yang se distingue par l'intégration de contraintes spécifiques définies par des experts du domaine, telles que la monotonie ou la convexité. Cette personnalisation, combinée à des techniques d'apprentissage boosté, permet de capturer des relations complexes que les GAM classiques auraient négligées [55]. De manière particulièrement élégante, ces contraintes assurent la stabilité des prévisions, même en présence de variations soudaines de la demande.

Yang a évalué son modèle sur des ensembles de données publiques et industrielles, et les résultats ont été impressionnants. Comparé à des GAM standards comme PyGAM ou EBM, le GAM interactif a maintenu une précision remarquable, même sous des températures extrêmes ($>40^{\circ}\text{C}$), un exploit rare dans la prévision énergétique.

Bien que prometteur, ce modèle présente des limites. Sa mise en œuvre exige des données bien structurées, une connaissance approfondie des contraintes et des ressources de calcul importantes.

2.2.8. Modèle Facebook Prophet

Le modèle Prophet, développé par Facebook en 2017, s'est imposé comme un outil polyvalent et efficace pour la prévision de séries temporelles complexes. Reposant sur un modèle additif combinant des tendances non linéaires, des effets saisonniers, et des événements exceptionnels, Prophet est très souvent utilisé dans le domaine énergétique. Cette revue examine les applications et performances du modèle à travers les travaux de John Cockerill [56], Fatima Fahs [57], et Almazrouee et al. [38], en mettant en lumière ses forces, ses limites, et ses résultats.

Dans le cadre de la gestion énergétique du site MiRIS, John Cockerill a comparé le modèle Prophet à d'autres modèles tels que SARIMAX et STL+ARIMA pour prédire la consommation électrique d'un site industriel. Prophet s'est distingué par une précision et une rapidité accrue [56]. L'étude rapporte que le modèle a atteint un RMSE de 33412 W, correspondant à seulement 6 % de la variation maximale, et un coefficient R^2 de 0,948, surpassant largement STL+ARIMA ($R^2 = 0,507$) et SARIMAX ($R^2 = 0,571$). Prophet a également démontré une capacité unique à intégrer des paramètres spécifiques tels que les jours fériés et les variations saisonnières, offrant ainsi une flexibilité et une personnalisation inégalées.

En outre, Fatima Fahs explore l'utilisation de Prophet pour prédire la consommation électrique résidentielle et tertiaire en France, notamment pendant les périodes de confinement dues à la pandémie de COVID-19. Prophet a intégré des « changepoints » pour modéliser les changements de tendance associés aux confinements. L'étude montre une réduction de l'erreur MAPE à 6,78 %, bien qu'elle souligne que l'amélioration reste modeste comparée aux méthodes manuelles utilisées par les fournisseurs [37].

Fahs met en avant la capacité de Prophet à gérer des données bruitées et des changements soudains de comportement grâce à son approche bayésienne et son algorithme robuste de détection des points de changement. Cependant, elle souligne que la qualité des prévisions dépend fortement de la configuration des paramètres, ce qui nécessite une expertise avancée pour optimiser le modèle.

D'un autre côté, Almazrouee et al ont comparé Prophet au modèle Holt-Winters pour des prévisions à long terme de la consommation électrique au Koweït. Sur un horizon de 10 ans, Prophet a surpassé Holt-Winters en termes de RMSE, MAPE, R^2 , et CVRMSE, démontrant une meilleure robustesse face à des bruits gaussiens artificiellement ajoutés [58]. Cette étude met en évidence la résilience du modèle Prophet à des conditions de données

variées et à des niveaux de bruit différents, le plaçant comme une solution robuste pour les prévisions énergétiques à long terme.

Enfin, toutes ces études démontrent que Prophet est un outil puissant pour les prévisions énergétiques, adapté à divers contextes. Ses principaux avantages incluent :

- **Précision élevée** : Un RMSE et un R^2 compétitifs par rapport aux modèles traditionnels.
- **Flexibilité** : Intégration aisée des jours fériés, gestion des tendances multiples, et personnalisation des paramètres.
- **Robustesse** : Résistance au bruit et adaptabilité aux changements brusques de tendance.

Cependant, Prophet nécessite une configuration minutieuse pour exploiter pleinement ses capacités, ce qui peut représenter un défi pour les utilisateurs moins expérimentés.

2.2.9. Synthèse de la revue sur les modèles

Les différents travaux recueillis de part et d'autre dans la littérature ont permis de réaliser le tableau 2.1 qui synthétise les forces et faiblesses de plusieurs modèles qui pourraient être utilisés afin de modéliser la demande en énergie électrique.

Tableau 2.1: Cartographie des modèles

Modèle	Forces	Faiblesses
Régression linéaire multiple	<ul style="list-style-type: none"> • Simplicité et accessibilité • Efficacité pour les prévisions à court terme • Bonne précision en conditions stables • Utilisation de variables explicatives 	<ul style="list-style-type: none"> • Incapacité à capturer les effets non-linéaires • Limites dans des environnements instables • Dépendance aux données de qualité suffisante • Nécessité de compléter avec des approches robustes
ARIMA & ARIMAX	<ul style="list-style-type: none"> • Simplicité et efficacité • Prise en compte des variables exogènes (ARIMAX) • Mesure de l'incertitude (ARIMAX avec Bootstrap) • Précision dans des contextes stationnaires 	<ul style="list-style-type: none"> • Dépendance à la stationnarité des données • Limites face aux tendances non linéaires • Sensibilité aux ruptures structurelles • Difficulté à gérer les données manquantes ou bruitées
SARIMA & SARIMAX	<ul style="list-style-type: none"> • Modélisation des effets saisonniers • Flexibilité pour ajuster les paramètres saisonniers • Adaptabilité aux schémas saisonniers complexes • Amélioration de la précision avec SARIMAX 	<ul style="list-style-type: none"> • Dépendance à la qualité des données saisonnières • Difficulté avec les tendances non linéaires • Sensibilité aux données de mauvaise qualité • Complexité d'ajustement des paramètres • Limitations en cas de ruptures structurelles

Modèle	Forces	Faiblesses
LSTM	<ul style="list-style-type: none"> • Capture des relations temporelles complexes • Gestion des dépendances longues • Meilleure performance à long terme • Adaptabilité aux séries temporelles variées • Capacité d'amélioration avec des LSTM bidirectionnels (BLSTM) • Bonne performance avec des données de faible qualité 	<ul style="list-style-type: none"> • Besoin de grandes quantités de données • Complexité et demandes en puissance de calcul élevées • Difficulté à gérer des séries très irrégulières ou bruitées • Sensibilité aux hyperparamètres
GAM	<ul style="list-style-type: none"> • Adaptabilité aux situations variées • Précision accrue dans des scénarios complexes • Gestion des interactions complexes entre variables • Prise en compte des spécificités régionales • Personnalisation pour des conditions extrêmes 	<ul style="list-style-type: none"> • Complexité du modèle • Exigences en termes de données et de ressources • Risque d'overfitting • Dépendance à des données de qualité et à des connaissances spécialisées
Lissage exponentiel	<ul style="list-style-type: none"> • Simplicité et robustesse • Amélioration des prévisions avec des approches hybrides • Performance sur des données de qualité • Adaptabilité aux séries relativement régulières 	<ul style="list-style-type: none"> • Dépendance à la qualité des données • Coût de calcul élevé • Sensibilité aux ruptures structurelles • Limitation face aux changements structurels rapides • Adaptation insuffisante aux scénarios complexes
GARCH	<ul style="list-style-type: none"> • Modélisation efficace de la volatilité • Précision élevée dans les prévisions • Adaptabilité aux séries temporelles volatiles • Capacité à gérer les asymétries et les chocs 	<ul style="list-style-type: none"> • Dépendance à la qualité des données • Incapacité à capturer des transformations structurelles • Limites des modèles standards • Complexité et calculs intensifs • Limites face à des événements imprévus
Modèles long terme et approche multisectorielle	<ul style="list-style-type: none"> • Vision globale et intégrée • Prise en compte des divers facteurs économiques et industriels • Projections diversifiées avec scénarios énergétiques • Adaptabilité aux spécificités locales • Flexibilité dans l'intégration des énergies renouvelables 	<ul style="list-style-type: none"> • Dépendance aux hypothèses économiques et politiques • Sensibilité aux perturbations externes • Complexité des scénarios • Dépendance aux données historiques et à leur qualité • Limitations face aux évolutions technologiques rapides
Prophet	<ul style="list-style-type: none"> • Flexibilité : gestion des jours fériés, saisonnalités et tendances multiples. • Précision élevée et performances compétitives. • Robustesse face aux anomalies et aux changements soudains. • Rapidité de calcul et intégration facile. 	<ul style="list-style-type: none"> • Dépendance à la qualité des données (sensibilité au bruit). • Configuration minutieuse des paramètres nécessaire. • Complexité dans l'intégration des changepoints multiples. • Expertise avancée requise pour une optimisation optimale.

2.3. DIFFERENTS TYPES D’HORIZONS TEMPORELS DE PREVISIONS

Plusieurs chercheurs dans la littérature ont orienté leurs travaux de recherche à différents horizons de temps pour l’évaluation des modèles de prévisions. Cette littérature a approuvé que dans les prévisions de charge électrique il existe trois types d’horizons temporels tels que l’horizon à court, moyen et long terme. Ces horizons utilisent des durées spécifiques selon le domaine d’application. Ces durées des horizons [59] sont résumées dans le tableau 2.2 selon les domaines d’application.

Tableau 2.2 : Classification de différents types d’horizons temporels de prévisions

Horizon	Objectif	Durée	Domaine d’application
Court terme	<ul style="list-style-type: none">• Maîtriser la consommation de la facture d’électricité	1min à 24h	Habitat individuel
	<ul style="list-style-type: none">• Planifier les risques de défaillance physique,• Assurer l’équilibre entre l’offre et la demande,• Réaliser les derniers achats et décisions d’effacement	24h à 1 mois	Réseau de distribution
Moyen terme	<ul style="list-style-type: none">• Planifier les investissements pour le renforcement du réseau électrique (entretien et maintenance des lignes et postes électriques)	1 mois à 1 année	Réseau de transport
Long terme	<ul style="list-style-type: none">• Faire le bilan pluriannuel de l’équilibre offre/demande d’électricité,• Planifier, construire et mettre en service des postes électriques et des centrales de production électrique	1 année à quelques dizaines d’années	Réseau de transport

2.4. CONCLUSION PARTIELLE

La revue de littérature a permis de cartographier et de recenser les différents et possibles modèles utilisés dans les multiples études qui ont traité d’un sujet similaire. Le prochain chapitre s’attèle à mettre en œuvre les modèles.

Chapitre 3. Développement d'un modèle de prédiction de la demande d'achat en électricité

3.1. INTRODUCTION PARTIELLE

Ce chapitre aborde la méthodologie utilisée tout au long de la modélisation et du déploiement du modèle. Il présente la description et la présentation des données utilisées.

3.2. DONNEES

3.2.1. Nature et collecte des données

Les données qui ont été utilisées dans le cadre de ce travail sont celles de consommation en énergie électrique en République du Bénin, produites par la SBEE, sur une période allant du 1^{er} janvier 2017 au 31 décembre 2023 et du 1^{er} janvier au 31 mars 2024, pour un cumul de 2556 jours. Chaque jour est représenté par 24 colonnes correspondant aux heures de la journée, de 00h00 à 23h00. Chaque observation indique la consommation d'énergie en Mégawatts (MW).

3.2.2. Transformation des données

Pour une meilleure pertinence, la base de données a été restructurée afin d'obtenir une forme plus adaptée et contextualisée pour les prochaines étapes. Disposer de 24 colonnes représentant les heures et les valeurs de consommation d'énergie n'était pas optimal. Il a donc été nécessaire de réorganiser les données pour obtenir une structure plus cohérente, avec chaque heure associée à son jour respectif.

Après restructuration, la fréquence des données a été définie de manière à créer des lignes pour chaque heure de la journée, conformément au contexte de prévision horaire. Cette étape a permis de mettre en évidence les valeurs manquantes sous-jacentes dans la base de données.

3.2.3. Nettoyage des données

Une première inspection a consisté à tracer l'évolution horaire de la consommation d'énergie électrique sur la durée du jeu de données. Cette approche a mis en évidence l'existence de valeurs négatives et de valeurs nulles, considérées comme aberrantes dans le contexte de la consommation électrique.

Les premières analyses visuelles ont permis de constater des valeurs manquantes, des valeurs négatives et des valeurs nulles. Les analyses ont fait remarquer au total soixante-dix-

sept (77) observations aberrantes dont deux (02) NaN (Not a Number en anglais) et soixante-quinze (75) valeurs aberrantes représentant la somme des valeurs négatives et nulles. Ces observations aberrantes ont été considérées comme des valeurs erronées et sont donc supprimées de la base de données créant ainsi des valeurs manquantes. En effet, dans la distribution de l'énergie électrique les valeurs nulles correspondent à des coupures d'électricité ou l'écroulement total du réseau électrique. Il est donc nécessaire d'appliquer une correction pour ces valeurs aberrantes.

Après la détection de ces observations aberrantes dans ce contexte, la méthode de l'écart interquartile (IQR) a servi à repérer les valeurs extrêmes. L'IQR se définit comme la différence entre le troisième quartile $Q3$ et le premier quartile $Q1$.

Les observations inférieures à $Q1 - 1,5 \times IQR$ ou supérieures à $Q3 + 1,5 \times IQR$ ont été considérées comme des valeurs aberrantes. Après la détection des valeurs extrêmes, elles sont aussi supprimées de la base de données et des valeurs manquantes ont été également observées. Cette méthode a été utilisée parce qu'elle est simple à mettre en œuvre et offre une détection robuste des valeurs extrêmes. Après ce filtrage, un rééchantillonnage a été appliqué pour faire suivre les données à une fréquence horaire en utilisant la fonction `.asfreq("H")`.

La vérification des valeurs manquantes fait constater cinq cent quatre-vingt-quatre (584) valeurs manquantes dans les séries temporelles. Pour remplacer ces valeurs manquantes, la méthode de l'interpolation linéaire simple a été privilégiée. Cette méthode est cohérente avec le comportement progressif de la consommation électrique au fil du temps et assure une continuité adéquate des valeurs.

3.2.4. Analyse exploratoire de la série

Une première démarche a consisté à calculer la fonction d'autocorrélation pour des décalages allant jusqu'à 365 jours. Cette étape visait à détecter la présence d'un pic d'autocorrélation aux abords de 365 jours, suggérant une éventuelle saisonnalité annuelle. Le coefficient d'autocorrélation est donné par la formule suivante $\rho_k = \frac{cov(y_t, y_{t-k})}{\sigma_{y_t} \sigma_{y_{t-k}}}$. Avec k , le décalage par rapport au temps actuel.

En parallèle, la série a été représentée sous forme de boîtes à moustaches en regroupant les données selon une récurrence mensuelle. Cette représentation a pour but de repérer visuellement d'éventuelles variations répétitives d'un mois à l'autre, renforçant l'hypothèse d'une organisation cyclique.

Après cette phase d'inspection, une décomposition saisonnière a été réalisée sur l'ensemble des observations en utilisant la fonction `seasonal_decompose()`. Concrètement, cette étape s'est articulée autour de :

- L'estimation de la tendance, obtenue par un lissage progressif des observations ;
- La mise en évidence de la composante saisonnière, correspondant au motif qui se répète chaque année ;
- L'extraction du résidu, c'est-à-dire la part de la série non expliquée par les deux composantes précédentes.

Pour conforter les résultats et mieux cerner l'évolution de la consommation sur une année type, la décomposition a également été appliquée à un segment d'environ douze mois. L'objectif est d'examiner le profil détaillé de la saisonnalité intra-annuelle et de confirmer la régularité du motif entre les différentes années considérées.

Enfin, les informations recueillies à l'issue de ces étapes ont été utilisées pour orienter les choix de modélisation.

3.2.5. Ingénierie des données

Au regard des différentes analyses menées, de nouvelles variables ont été créées pour améliorer la capacité des modèles à prendre en compte les particularités temporelles de la série et ainsi fournir des prévisions de meilleure qualité. Les initiatives entreprises se résument en trois parties :

- **Partie 1** : Création de la variable **cluster_saison** qui décrit la période de l'année (saisonnalité mensuelle) à laquelle appartient chaque observation, en fonction des résultats de la décomposition saisonnière.
- **Partie 2** : Création de plusieurs variables temporelles telles que **jour_semaine** (jour de la semaine), **est_week_end** (est un jour du week-end) et **est_férié** (est un jour férié), susceptibles d'influencer la consommation d'électricité.
- **Partie 3** : Création de la variable **cluster_puissance** qui indique la gamme de valeurs dans laquelle se situe la consommation en fonction des variables temporelles. Un sous-modèle de classification pourrait être utilisé pour aider le modèle principal à mieux faire ses prévisions.

3.2.5.1. Création de la variable cluster_saison

Pour intégrer la saisonnalité mensuelle dans l'analyse, la variable cluster_saison, qui indique la période de l'année correspondant à chaque observation, a été définie. Cette variable a été créée en utilisant un modèle K-Means appliqué aux données horaires de l'année 2017, choisie pour représenter les cycles observés sur l'ensemble des années.

Les variables utilisées pour cette classification sont le jour de l'année (jour_année) et l'heure de la journée (heure_jour), qui permettent de capter les variations saisonnières et journalières.

Cette approche a permis de segmenter les observations selon des cycles récurrents de consommation. Enfin, les résultats ont été visualisés en associant les clusters à des tendances de consommation énergétique (Puissance).

3.2.5.2. Création de nouvelles variables temporelles

Pour analyser les variations temporelles de la consommation énergétique, les données ont été enrichies avec de nouvelles variables liées au calendrier. Ces variables décrivent les différentes dimensions temporelles, comme les mois, les semaines, ou les jours de l'année.

La variable mois_année a d'abord été ajoutée, et elle indique le mois associé à chaque observation, de janvier (1) à décembre (12). Ensuite, la variable semaine_année a été créée pour diviser l'année en semaines numérotées de 1 à 54, permettant ainsi d'observer des changements hebdomadaires dans les données.

Pour distinguer les jours, la variable jour_semaine a été créée. Elle attribue un chiffre à chaque jour, de 0 (lundi) à 6 (dimanche). Une autre variable, est_week_end, identifie les samedis et dimanches grâce à un encodage binaire, où 1 correspond à un jour de week-end.

Enfin, les jours fériés ont également été pris en compte en définissant une liste des principales fêtes nationales et religieuses. Une variable binaire, est_férié, indique si une observation correspond à l'une de ces dates.

3.2.5.3. Création de la variable cluster_puissance

Les valeurs de Puissance ont été regroupées en 5 classes à l'aide d'une méthode en deux étapes, combinant K-Means et un modèle de classification par arbre de décision. L'objectif étant de structurer les données en classes distinctes et d'assurer une classification précise pour les observations futures.

Le choix du nombre de clusters a été guidé par la méthode du coude (elbow curve, en anglais), une méthode permettant de déterminer le point optimal pour équilibrer l'inertie et

le nombre de groupes. Une fois les clusters définis, chaque observation des données d'entraînement (80 % des observations) a été assignée à un cluster.

Ensuite, un modèle de classification basé sur un arbre de décision a été entraîné pour prédire les clusters en utilisant les valeurs de Puissance comme entrée.

3.3. OUTILS ET MATERIELS

Le présent travail a été réalisé en utilisant plusieurs ressources numériques. Ces ressources sont illustrées par la figure 3.1. Elles consistent en un ensemble de logiciels (VS Code, Streamlit), de langages de programmation (Python) et de bibliothèques (Tensorflow, Numpy, Keras, Matplotlib, pandas, Seaborn, learn, Python Datetime).



Figure 3.1: Liste des outils utilisés pour la construction du modèle de prédiction

L'objectif est de disposer d'un environnement robuste et cohérent pour mener l'ensemble des étapes de recherche : de la collecte et du nettoyage des données au déploiement du modèle finalement retenu pour la prédiction.

3.3.1. Langage de programmation Python

L'intégralité des codes a été développée avec Python, un langage privilégié dans le domaine de la science des données et de l'apprentissage automatique. Ce choix s'est imposé grâce à la présence d'une syntaxe claire et accessible, favorisant la lisibilité et la maintenance du code, mais également en raison du très vaste écosystème de bibliothèques spécialisées. D'un point de vue pratique, Python a servi de socle pour toutes les opérations importantes de ce travail : la manipulation initiale des données, l'exploration préliminaire des séries temporelles, la mise en œuvre des différents modèles identifiés après la revue de littérature.

3.3.2. Environnement de développement

Afin de structurer et d'organiser le travail, Visual Studio Code a été choisi comme environnement de développement principal. Cet éditeur, développé par Microsoft, se distingue par ses performances, son interface ergonomique et sa modularité. Dans le cadre de ce projet, l'installation d'extensions dédiées à Python a permis d'optimiser à la fois la saisie (grâce à la complétion automatique et l'analyse statique du code) et la phase de débogage (via le débogueur intégré).

De plus, l'intégration native de Git a facilité le suivi des modifications et la gestion des versions du code, assurant ainsi la traçabilité des évolutions. L'usage de Visual Studio (VS Code) a de surcroît rendu possible un paramétrage rapide de l'environnement virtuel Python, ce qui a permis de gérer finement les dépendances et de maintenir la cohérence entre les différentes librairies installées.

3.3.3. Bibliothèques Python utilisées

Le recours à Python pour l'analyse et la modélisation de données se concrétise surtout par l'exploitation d'un ensemble de bibliothèques spécialisées. En premier lieu, *NumPy* a constitué l'outil principal utilisé pour les opérations numériques sur la base de données. Son principal intérêt repose sur sa capacité à manipuler efficacement des tableaux multidimensionnels, ce qui s'avère indispensable lorsque l'on travaille avec de grandes quantités de mesures horaires ou journalières.

L'organisation et la transformation des données ont été réalisées avec *pandas*. Cette bibliothèque offre une structure de données de haut niveau, appelée *DataFrame*, adaptée au regroupement et à la mise en forme des informations. Dans le cadre de cette étude, *pandas* a été mobilisé pour assurer différentes tâches essentielles : lecture des fichiers contenant les données, gestion des valeurs manquantes, et manipulation de formats temporels spécifiques. Ainsi, la variable Puissance a pu être rééchantillonnée aisément, par exemple pour passer de pas horaire à un pas quotidien, ou pour générer des indicateurs statistiques sur des intervalles temporels personnalisés.

Pour la partie dédiée à l'analyse des séries temporelles et à la modélisation, *statsmodels* a joué un rôle clé. Son module d'analyse des séries temporelles inclut en effet des méthodes de lissage exponentiel, des modèles ARIMA, ainsi que des outils de diagnostic tels que la fonction d'autocorrélation. Dans ce travail, *statsmodels* a permis de vérifier la présence d'une saisonnalité annuelle, de tester différents ordres de modèles et d'évaluer la qualité des

ajustements à travers des statistiques d'erreur et des graphiques de résidus. Les fonctionnalités de visualisation de la saisonnalité ou de la tendance ont par ailleurs facilité l'interprétation des phénomènes observés dans la consommation électrique.

En ce qui concerne les visualisations et les représentations graphiques, cette étude s'est servie de *Matplotlib* et de *seaborn*. Les graphiques générés ont permis de retracer l'évolution de la consommation sur des périodes longues, tandis que les boîtes à moustaches ont mis en évidence la distribution et l'amplitude de la consommation selon diverses périodes de l'année.

En complément, *Streamlit*, en raison de sa simplicité, a été utilisée pour concevoir l'interface dont se servira l'utilisateur du modèle développé pour prédire la future demande d'achat électrique.

Par ailleurs, *TensorFlow* et *keras* ont été envisagées pour l'exploration de modèles de type deep learning, notamment du CNN et LSTM adaptés à la prévision de séries temporelles. Même si l'approche basée sur SARIMA ou des modèles de lissage peut se montrer satisfaisante dans bien des contextes, *TensorFlow* offre la souplesse nécessaire lorsque le phénomène à modéliser présente des non-linéarités plus prononcées ou des interactions complexes.

Enfin, la bibliothèque *scikit-learn* a servi à plusieurs étapes de l'apprentissage automatique, même si son utilisation demeure principalement complémentaire des approches précédentes. En particulier, la fonctionnalité `train_test_split` a simplifié la scission des données en ensembles d'apprentissage et de test, et diverses méthodes de mise à l'échelle ont été testées pour uniformiser les distributions de variables d'entrées avant d'alimenter un modèle de régression. À travers ses nombreuses fonctions d'évaluation, *scikit-learn* a aussi permis de comparer la performance des modèles.

3.4. MODELISATION ET CHOIX D'UN MODELE DE PREVISION DE LA DEMANDE EN ENERGIE ELECTRIQUE

La modélisation constitue une étape clé pour atteindre l'objectif de prévision de la demande en électricité. Elle repose sur des approches méthodiques visant à traduire les dynamiques observées dans les données en modèles capables de produire des prévisions fiables. Cette section détaille les modèles retenus, les étapes de leur mise en œuvre, ainsi que les critères utilisés pour évaluer et comparer leurs performances. Le tableau 3.1 présente les différents modèles qui sont mis en œuvre dans le cadre de ce travail de recherche.

Tableau 3.1 : Cartographie des modèles de prévision d'énergie électrique retenus

N°	Modèle
1	ARIMA-LSTM
2	GAM
3	GARCH
4	ARIMA
5	Lissage Exponentiel
6	Prophet
7	CNN
8	CNN-LSTM
9	GRU
10	CNN-GRU
11	LSTM

3.4.1. Mise en œuvre des modèles retenus

Cette section présente la méthodologie utilisée pour chaque modèle mis en œuvre dans le cadre de ce travail.

3.4.1.1. Modèle ARIMA

Le modèle ARIMA a été implémenté comme une approche naïve pour la prévision de la consommation énergétique. Le choix des paramètres (1, 1, 1) reflète une structure minimale, avec une composante autorégressive d'ordre 1 (AR), une différenciation pour assurer la stationnarité (I), et un terme de moyenne mobile d'ordre 1 (MA).

Les données ont été divisées en deux : un ensemble pour l'entraînement (01 janvier 2017 au 31 décembre 2022) et un ensemble pour le test (à partir du 1er janvier 2023 au 31 décembre 2023). Une fois entraîné, il a été utilisé pour générer des prévisions sur la période de test. Le modèle a été évalué avec la MAE, le RMSE, le MAPE et le R^2 . Ces métriques MAE, RMSE, MAPE et R^2 ont été largement utilisées dans la littérature passée pour l'évaluation des modèles.

3.4.1.2. Modèle Additif Généralisé (GAM)

Contrairement aux modèles paramétriques classiques, les GAMs permettent de modéliser des relations non linéaires grâce à des fonctions lissées, ce qui en fait une option pertinente pour capturer des variations temporelles complexes.

Dans cette implémentation, une variable explicative, indice temporel (time_index, colonne index contenant la date et l'heure), a été générée pour servir d'entrée unique au modèle. Le GAM, composé d'un seul terme lissé sur cette variable, a été entraîné sur les données couvrant la période du 01 janvier 2017 au 31 décembre 2022. Les prévisions ont ensuite été générées pour l'ensemble de test, correspondant aux observations du 01 janvier 2023 au 31 décembre 2023.

3.4.1.3. Lissage exponentiel

Le lissage exponentiel implémenté dans le contexte de ce travail s'appuie sur deux hypothèses : une tendance additive pour suivre l'évolution générale de la consommation électrique et une saisonnalité additive qui permet de capturer les fluctuations journalières récurrentes, définies sur un cycle de 24 heures.

Le modèle a été entraîné sur les données couvrant la période du 01 janvier 2017 au 31 décembre 2022, avant de générer des prévisions pour l'ensemble de test correspondant à l'année 2023.

3.4.1.4. Modèle LSTM

Face à la complexité croissante des dynamiques temporelles présentes dans les données, l'utilisation d'un modèle basé sur des réseaux de neurones récurrents, comme le LSTM, s'est imposée comme une alternative pertinente. Les LSTM, conçus pour capturer les dépendances à long terme dans des séries chronologiques, offrent une flexibilité exceptionnelle pour modéliser les relations temporelles non linéaires et les fluctuations complexes.

La première étape de cette implémentation a consisté à normaliser les données en les transformant dans une plage [0,1] à l'aide du MinMaxScaler de la librairie scikit-learn de bibliothèque Python. Cette normalisation est essentielle pour améliorer la convergence du modèle et optimiser son entraînement.

Une fenêtre glissante de 24 observations a été utilisée pour créer les ensembles d'entrée et de sortie, représentant ainsi un cycle journalier complet. Les données ont ensuite été divisées en deux ensembles : 80 % pour l'entraînement et 20 % pour le test.

Le modèle LSTM a été construit avec une couche récurrente comprenant 150 unités et une activation ReLU, suivie d'une couche dense à une sortie pour prédire la consommation énergétique. Le modèle a été entraîné sur 150 époques avec un batch size de 32, utilisant

l'algorithme d'optimisation Adam et une fonction de perte basée sur l'erreur absolue moyenne. La figure 3.2 illustre la constitution du modèle LSTM implémenté.




Figure 3.2 : Constitution du modèle LSTM implémenté

3.4.1.5. Modèle GARCH

Dans cette approche, les données ont été segmentées en ensemble d'entraînement (80 %) et de test (20 %). Le modèle a été importé grâce à la librairie arch et paramétré avec deux termes autorégressifs ($p=2$) et trois termes de moyenne mobile ($q=3$), visant à expliquer les variations récurrentes dans la volatilité. L'ajustement, réalisé par maximisation de la vraisemblance, a permis d'estimer les coefficients du modèle, chaque itération affinant progressivement la représentation de la dynamique sous-jacente.

3.4.1.6. Modèle CNN

Pour préparer les données, une normalisation a été appliquée pour les ramener sur une échelle de 0 à 1, suivie d'une segmentation en séquences glissantes de 24 heures. Chaque séquence, associée à une cible représentant la consommation énergétique suivante, a été remodelée pour s'adapter aux entrées requises par le modèle, sous la forme [échantillons, longueur de séquence, 1]. Cette structure permet au modèle de traiter efficacement les données temporelles tout en identifiant les motifs pertinents.

Le modèle CNN développé comprend une couche de convolution avec 64 filtres et une taille de noyau de 3, utilisant une activation ReLU pour détecter les motifs locaux dans les séquences temporelles. Cette couche est suivie d'une opération de MaxPooling avec `pool_size 2` pour réduire la dimensionnalité et conserver les informations essentielles. Les sorties convolutives sont ensuite aplaties avant d'être traitées par une couche dense de 50 unités, permettant de capturer des interactions complexes. Enfin, une couche de sortie dense génère les prédictions de consommation énergétique. L'ensemble du modèle comprend 35 557 paramètres entraînaables, optimisés avec l'algorithme Adam et une fonction de perte basée sur l'erreur quadratique moyenne.

Les performances du modèle ont été évaluées après un entraînement sur 50 époques et de `batch_size 32`, avec une division des données en 80 % pour l'entraînement et 20 % pour le test. La figure 3.3 présente la constitution du modèle CNN implémenté.




Figure 3.3 : Constitution du modèle CNN implémenté

3.4.1.7. Modèle CNN-LSTM

Le modèle CNN-LSTM représente une approche hybride innovante pour la prévision de séries temporelles, combinant les atouts des réseaux convolutionnels et du LSTM. Cette architecture permet d'exploiter simultanément les motifs locaux présents dans les données tout en capturant les dépendances séquentielles sur des périodes étendues, rendant ce modèle particulièrement adapté aux séries complexes comme celles de la consommation énergétique.

La préparation des données s'est faite par une normalisation couplée à une transformation en séquences glissantes de 24 heures. Chaque séquence encapsule les variations journalières et est associée à une cible représentant la consommation énergétique prévue. Ces séquences, restructurées pour s'adapter aux exigences des couches CNN et LSTM, ont ensuite été divisées en ensembles d'entraînement (80 %) et de test (20 %). Cette structuration garantit une séparation rigoureuse des données pour l'évaluation.

Le modèle utilise d'abord une couche Conv1D avec 64 filtres et une taille de noyau de 3 pour extraire les motifs locaux à partir des séquences d'entrée. Une opération de MaxPooling1D suit, condensant les informations pertinentes tout en réduisant la dimensionnalité. Les sorties convolutives sont ensuite acheminées vers une couche LSTM, dotée de 50 unités. Cette couche permet de capturer des dépendances temporelles sur des échelles variées, combinant ainsi la compréhension locale et globale des données. Enfin, une couche dense unique produit la prévision de consommation énergétique. La figure 3.4 illustre la constitution du modèle hybride CNN-LSTM implémenté.




Figure 3.4 : Constitution du modèle CNN-LSTM hybride implémenté

3.4.1.8. Modèle ARIMA-LSTM

Le modèle hybride ARIMA-LSTM a été conçu pour exploiter les forces combinées de l'ARIMA, destiné à modéliser les relations linéaires et les tendances globales dans les séries

temporelles, et de LSTM, qui excelle dans l'identification des relations non linéaires et des dépendances à long terme. Cette combinaison vise à pallier les faiblesses inhérentes à chaque modèle lorsqu'ils sont appliqués indépendamment.

La première étape de l'approche consiste à ajuster un modèle ARIMA sur les données normalisées de consommation énergétique, afin de capter les tendances globales et les structures linéaires. Les prédictions générées par ARIMA sont ensuite comparées aux valeurs réelles pour calculer les résidus. Ces résidus, représentant des informations non expliquées par l'ARIMA, sont une composante critique puisqu'ils contiennent les schémas non linéaires complexes qui échappent à une modélisation linéaire classique.

Les résidus, après transformation en séquences temporelles sur une fenêtre glissante de 24 heures, sont utilisés comme données d'entrée pour un modèle LSTM. L'architecture LSTM est construite autour de deux couches successives, chacune composée de 20 unités, suivies d'une couche dense pour produire les prédictions finales. L'idée sous-jacente est que l'ARIMA capture la structure globale, tandis que le LSTM affine les prédictions en tenant compte des dynamiques non linéaires contenues dans les résidus.

3.4.1.9. Modèle Prophet

Pour préparer les données, l'index temporel a été transformé en une colonne date et heure nommée *ds*, et la variable cible Puissance a été renommée *y*, conformément aux exigences du modèle Prophet. Plusieurs variables explicatives ont été créées : le mois de l'année, le jour de la semaine, une indication binaire pour différencier les week-ends des jours ouvrables, ainsi qu'une colonne identifiant les jours fériés du Bénin, comme la Pâques, la fête des religions endogènes et de l'indépendance. La liste des jours fériés a été générée pour la période d'étude (2017-2023) en combinant des dates fixes et des calculs dynamiques pour des événements mobiles comme Pâques.

Ces variables ont ensuite été intégrées comme régressions dans le modèle Prophet, en complément de sa capacité native à identifier des tendances et des cycles temporels. Une saisonnalité mensuelle a été ajoutée au modèle à l'aide de la fonction *add_seasonality*, avec une période de 30,5 jours et un ordre de Fourier fixé à 5. Cette personnalisation visait à améliorer la capacité du modèle à comprendre les variations cycliques propres aux données.

Le modèle a ensuite été entraîné sur l'ensemble des données couvrant la période de 2017 à 2022 et testé sur la période de 2023 pour les prévisions. Les résultats ont été obtenus en fusionnant les prévisions (*yhat*) avec les valeurs historiques.

3.4.1.10. Modèle GRU

Les modèles GRU ont été conçus sur la base des réseaux de neurones. Ils sont conçus comme les modèles LSTM et sont capables de capturer les dépendances à long terme dans les séries temporelles. Compte tenu de la complexité des données il est important de mettre en évidence les modèles GRU.

L'implantation du modèle GRU nécessite une normalisation des données en utilisant le MinMaxScaler pour les ramener sur une échelle de 0 à 1. Ceci permet d'améliorer sa convergence et d'optimiser son entraînement.

Une fenêtre glissante de 24 observations a été utilisée pour créer les ensembles d'entrée et de sortie, représentant ainsi un cycle journalier complet. Les données ont ensuite été divisées en deux ensembles : 80 % pour l'entraînement et 20 % pour le test.

Le modèle GRU a été construit avec une couche récurrente comprenant 100 unités et une activation ReLU. Cette couche a la fonction Dropout pour éviter le surapprentissage, suivie ensuite d'une couche dense à une sortie pour prédire la consommation énergétique. Le modèle a été entraîné sur 50 époques avec un batch size de 32, utilisant l'algorithme d'optimisation Adam. La figure 3.5 présente la constitution du modèle GRU implémenté.




Figure 3.5 : Constitution du modèle GRU implémenté

3.4.1.11. Modèle CNN-GRU

Le modèle CNN-GRU représente une approche hybride avancée pour la prévision de séries temporelles. Il combine les atouts des réseaux convolutionnels et du GRU. C'est une architecture permettant d'exploiter simultanément les motifs locaux présents dans les données tout en capturant les dépendances séquentielles sur des périodes étendues. Il rend ce modèle particulièrement adapté aux séries complexes comme celles de la consommation électrique.

La préparation des données s'est faite par une normalisation couplée à une transformation en séquences glissantes de 24 heures. Chaque séquence encapsule les variations journalières et est associée à une cible représentant la consommation énergétique prévue. Ces séquences, restructurées pour s'adapter aux exigences des couches CNN et GRU, ont ensuite été divisées en ensembles d'entraînement (80 %) et de test (20 %). Cette structuration garantit une séparation rigoureuse des données pour l'évaluation.

Le modèle utilise d'abord une couche Conv1D avec 64 filtres et une taille de noyau de 2 pour extraire les motifs locaux à partir des séquences d'entrée. Une opération de MaxPooling1D suit, condensant les informations pertinentes tout en réduisant la dimensionnalité. Les sorties convolutives sont ensuite acheminées vers une couche GRU, dotée de 100 unités. Cette couche permet de capturer des dépendances temporelles sur des échelles variées, combinant ainsi la compréhension locale et globale des données. Une opération de Dropout () est ensuite appliquée pour la réduction de surapprentissage. Une couche dense unique fait la prédiction de consommation électrique. La figure 3.6 décrit la constitution du modèle CNN-GRU hybride implémenté




Figure 3.6 : Constitution du modèle CNN-GRU hybride implémenté

3.4.2. Sélection d'un modèle pour la prévision

La sélection du modèle le plus approprié pour la prévision de la consommation énergétique représente une étape cruciale de ce travail. Il ne s'agit pas uniquement de choisir un modèle basé sur des métriques de performance. Mais la décision repose également sur des critères pratiques, tels que la simplicité d'utilisation et la capacité du modèle à être intégré efficacement dans les systèmes opérationnels de la SBEE. En effet, un modèle performant mais difficile à comprendre, maintenir ou déployer risque de ne pas répondre aux besoins réels de l'organisation.

3.4.3. Les métriques d'évaluation des modèles

Parmi les métriques les plus utilisées pour évaluer les modèles de prévision dans le domaine de l'énergie électrique figurent des indicateurs de performance comme l'Erreur Quadratique Moyenne (MSE en anglais), la Racine Carrée de l'Erreur Quadratique Moyenne (RMSE en anglais), l'Erreur Absolue Moyenne (MAE en anglais), le Coefficient de Détermination (R^2) et l'Erreur Absolue Moyenne en Pourcentage (en anglais MAPE).

3.4.4. Erreur Quadratique Moyenne (MSE, Mean Squared Erreur en anglais)

Le MSE mesure la moyenne des carrés des écarts entre les valeurs observées y_i et les valeurs prédites \hat{y}_i . Il met l'accent sur les grandes erreurs, car les écarts sont élevés au carré. Cela en fait une métrique sensible aux valeurs aberrantes. L'objectif principal du MSE est

de minimiser l'impact global des erreurs en attribuant un poids plus élevé aux écarts importants.

Utilisé pour évaluer la précision globale des modèles, le MSE est particulièrement adaptée lorsqu'il est crucial de pénaliser fortement les grandes erreurs, par exemple, dans la gestion des ressources énergétiques, où de grandes erreurs pourraient entraîner des décisions coûteuses.

Le MSE est donné par la formule
$$MSE = \frac{1}{N} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (1)$$

3.4.5. Erreur Absolue Moyenne EAM (MAE, Mean Absolute Error en anglais)

Le MAE est une métrique fondamentale utilisée pour évaluer la performance des modèles prédictifs. Il quantifie la moyenne des écarts absolus entre les valeurs observées y_i et les valeurs prédites \hat{y}_i , offrant une mesure directe et interprétable de l'erreur moyenne en unités des données d'origine.

Contrairement au MSE, le MAE ne pénalise pas de manière disproportionnée les grandes erreurs, attribuant à chaque écart un poids identique. Cette propriété confère au MAE une utilité particulière dans les contextes où l'objectif principal est d'obtenir une évaluation globale des écarts sans biais introduite par les valeurs aberrantes. Il est couramment employé dans des domaines tels que les prévisions énergétiques, où une interprétation intuitive de l'erreur moyenne est essentielle pour guider les décisions.

Bien que le MAE soit moins sensible aux écarts extrêmes, cette caractéristique peut s'avérer limitative dans des situations où les grandes erreurs représentent des risques critiques. Néanmoins, sa simplicité de calcul et sa capacité à fournir une évaluation uniforme des erreurs en font un outil précieux pour comparer la performance des modèles prédictifs.

Le MAE est donné par la formule
$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

3.4.6. Racine de l'Erreur Quadratique Moyenne (RMSE, Root Mean Squared Error, en anglais)

Le RMSE est la racine carrée de la MSE, exprimant ainsi l'erreur moyenne dans la même unité que les données observées. Cette caractéristique rend le RMSE particulièrement intuitif et facile à interpréter. Contrairement au MSE, il réduit légèrement l'impact des grandes erreurs tout en conservant leur poids relatif.

Le RMSE est très utile pour comparer différents modèles ou scénarios en termes d'erreur absolue moyenne. Il est fréquemment utilisé dans des contextes où les unités des

données sont cruciales pour interpréter les erreurs, comme la consommation énergétique exprimée en kilowattheures.

Le RMSE est donné par la formule $RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$ (3)

3.4.7. Coefficient de détermination (R^2)

Le coefficient de détermination R^2 mesure la proportion de la variance des valeurs observées expliquées par le modèle. Une valeur de R^2 proche de 1 indique que le modèle capture efficacement la variabilité des données, tandis qu'une valeur proche de 0 signifie qu'il est moins performant.

Le R^2 est couramment utilisé pour évaluer la qualité d'ajustement des modèles de régression. Il aide à quantifier dans quelle mesure les fluctuations des données sont expliquées par les variables du modèle.

Le R^2 est donné par la formule $R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$ (4)

3.4.8. Erreur Absolue Moyenne en Pourcentage EAMP (MAPE, Mean Absolute Percentage Error en anglais)

Le MAPE calcule la moyenne des erreurs absolues exprimées en pourcentage des valeurs observées. Cette mesure permet de comparer facilement les performances des modèles sur différents ensembles de données ou échelles.

Le MAPE est particulièrement adapté aux contextes où les erreurs relatives sont plus pertinentes que les erreurs absolues, comme dans la planification énergétique, où les pourcentages d'erreur relatifs à la consommation totale sont critiques. Il est généralement utilisé pour évaluer les modèles sélectionnés pour la prédiction dans le domaine de distribution et du transport de l'énergie électrique et prime sur l'utilisation de la métrique MAE [41]. Malgré cela cette métrique comporte des inconvénients qui empêchent son utilisation lorsque des observations proches de 0 se trouvent dans la base de données [30].

Le MAPE est donné par la formule $MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$ (5)

3.4.9. Synthèse des métriques de performance d'évaluation des modèles utilisés dans la régression

Dans les revues utilisées, plusieurs auteurs ont présenté des métriques de performance d'évaluation les plus adaptées dans le contexte de la prévision de l'énergie électrique. Le tableau 3.2 présente les métriques de performance d'évaluation et leurs marges [41].

Tableau 3.2 : Indicateurs de performance d'évaluation des modèles en régression

Métriques de performance d'évaluation		Marges d'erreur
Erreur relative	MAPE (%)	1 à 3
Erreur absolue	MSE	Plus faible possible
	MAE	
	RMSE	
Coefficient de détermination	R ²	Entre 0,95 et 1

Les indicateurs tels que le MAE, le RMSE, le MAPE, le MSE et le coefficient de détermination R² mentionnés dans le tableau 3.2 sont couramment utilisés comme critères d'évaluation des modèles de régression dans la littérature. Ce tableau précise les conditions dans lesquelles ces indicateurs sont jugés satisfaisants. L'utilisation des onze (11) modèles implémentés (ARIMA, GAM, Lissage Exponentiel, Facebook Prophet, GARCH, LSTM, CNN, GRU, ARIMA-LSTM, CNN-LSTM et CNN-GRU) a fourni les indicateurs comme MAE, RMSE, MAPE et R² pour les données de test. Toutefois, cette étude a retenu principalement le MAE et le MAPE comme critères de comparaison. Les modèles sélectionnés pour la validation finale sont ceux présentant une MAE faible que possible et une MAPE compris entre 1 et 3 %.

3.5. DESCRIPTION DE LA PLATEFORME DEVELOPPEE POUR LE DEPLOIEMENT

Cette section décrit la plateforme et son utilisation pour la prédiction de la demande d'achat à la SBEE.

3.5.1. Entrée de la plateforme

La plateforme reçoit un modèle pré-entraîné qui s'appuie sur les 24 heures de données traitées pour prédire les 24 heures prochaines de la puissance électrique. Le modèle est construit avec un MinMaxScaler de 24 valeurs. Cette plateforme prend également une base de données « csv » disposant une colonne « Date » au format %d/%m/%Y %H : %M et une colonne « Puissance (MW) » au pas horaire. Via l'interface homme-machine, l'utilisateur sélectionne la date de début de prédiction avec un horizon parmi les trois horizons de temps

(24 heures, 48 heures, 72 heures). Il exécute la prédiction avec le bouton nommé « Exécuter la prédiction ».

3.5.2. Sortie de la plateforme

Ici la plateforme génère sous forme de base de données des prévisions horaires de la puissance électrique téléchargeable. Un graphique des prévisions réalisé avec la librairie plotly s'affiche.

3.6. CONCLUSION PARTIELLE

Ce chapitre a permis de présenter les bibliothèques de python, de décrire la méthodologie utilisée ainsi que la plateforme développée pour le déploiement. Le chapitre 4 annonce les résultats obtenus à l'issue des traitements de données et de l'application des modèles en vue de la prédiction à court terme de la demande d'achat de l'énergie à la SBEE.

Chapitre 4. Résultats et discussions

4.1. INTRODUCTION GENERALE

Ce chapitre présente l'ensemble des résultats obtenus aussi bien au niveau du traitement des données que de la partie modélisation. Les résultats ont également fait l'objet de discussions.

4.2. NETTOYAGE DES DONNEES

Les graphiques de la figure 4.1 et de la figure 4.2 illustrent l'évolution de la consommation horaire sur l'ensemble de données utilisées (données de l'entraînement, de test et les données de prévisions sur des horizons temporels).




Figure 4.1: Evolution de la consommation en énergie électrique du 1^{er} janvier 2017 au 31 décembre 2023




Figure 4.2 : Evolution de la consommation en énergie électrique du 1^{er} janvier au 31 mars 2024

Le jeu de données présente des valeurs aberrantes, comme l'indiquent les premières analyses visuelles. Il existe des valeurs égales à 0, ainsi que des valeurs négatives, ce qui, en soit, pose un problème dans le contexte de ce travail.

En effet, il s'agit de la consommation d'énergie électrique par la population. Par conséquent, les valeurs de la variable puissance ne peuvent descendre en dessous de 0. Les valeurs égales à 0 quant à elles, peuvent indiquer des périodes de coupure d'électricité. La

technique de l'intervalle interquartile a été utilisée pour repérer d'autres valeurs aberrantes. Ces valeurs sont représentées avec la figure 4.3 et la figure 4.4.




Figure 4.3: Consommation d'énergie avec des anomalies




Figure 4.4 : Consommation d'énergie avec des anomalies du 1^{er} janvier au 31 mars 2024

Dans l'un ou l'autre des cas, ces valeurs aberrantes sont susceptibles de fausser les analyses ultérieures et doivent être corrigées. Elles ont d'abord été remplacées par des valeurs manquantes.

Le remplacement des valeurs aberrantes dans le jeu de données a entraîné la création de valeurs manquantes qu'il convient maintenant de corriger. Puisqu'il s'agit d'une problématique de séries temporelles et au vu des caractéristiques du jeu de données, l'interpolation linéaire simple apparaît comme la méthode la plus appropriée. La figure 4.5 et la figure 4.6 présentent les données avec les valeurs imputées.




Figure 4.5: Consommation d'énergie avec les données manquantes remplacées




Figure 4.6 : Consommation électrique avec les données manquantes interpolées du 1er janvier au 31 mars 2024

4.3. ANALYSE EXPLORATOIRE DES DONNEES

L'analyse de la fonction d'autocorrélation sur une période de 365 jours des données du 1^{er} janvier 2017 au 31 décembre 2023 a révélé visuellement une tendance annuelle parfaitement distincte. Cette observation indique une saisonnalité claire au cours de l'année, avec un motif récurrent qui se manifeste une fois par an, formant un cycle sinusoïdal. La figure 4.7 présente l'autocorrélogramme de cette série. Les ordonnées représentent la corrélation de la série au temps actuel et la même série à un temps t dans le passé. Par exemple, pour un retard de 1, il montre une corrélation entre le temps actuel et le temps -1 de 0,80. Cela indique une forte corrélation. Cette forte corrélation explique une forte dépendance temporelle dans les données. Dans le temps, la consommation électrique présente une évolution de façon cohérente. Elle a un caractère saisonnier et oriente vers l'utilisation des modèles plus complexe.




Figure 4.7: Autocorrélogramme

La figure 4.8 met en lumière l'évolution de la puissance consommée par mois tout au long d'une année. Cette puissance consommée par année suit l'allure d'une fonction sinusoïdale dans la série temporelle. La consommation électrique dans l'année connaît une baisse dans le mois de janvier. Elle augmente en février et mars, rechute à partir du mois de mai jusqu'en septembre puis reprend de façon ascendante dans le mois d'octobre jusqu'au mois de décembre. On remarque ainsi une saisonnalité claire dans les données au cours d'une année.

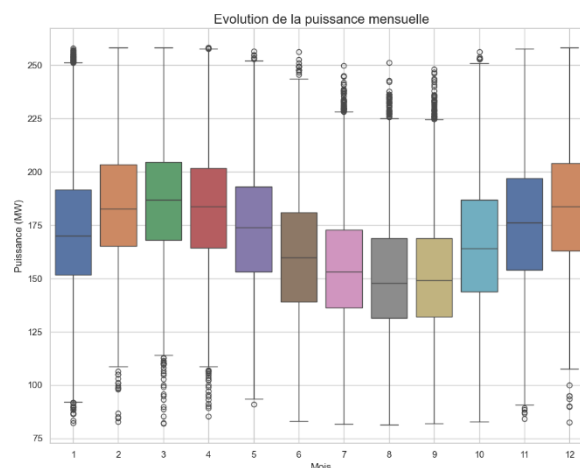


Figure 4.8: Boîte à moustache représentant la série

Une décomposition saisonnière a permis de rendre la saisonnalité plus perceptible. La figure 4.9 indique de la saisonnalité dans les données.




Figure 4.9: Décomposition de la saisonnalité de la série sur la période 2017 - 2023

En analysant la figure 4.9, on remarque une saisonnalité annuelle parfaitement identifiable, ainsi qu'une tendance haussière au fil des années.

La population béninoise tend à consommer l'électricité de manière similaire à des moments précis dans l'année, de façon répétitive, avec des besoins croissants au fil des années, probablement en raison de la croissance démographique ou de l'utilisation accrue d'appareils électroniques.

Cela suggère qu'une première piste de modélisation pourrait être l'utilisation de modèles de séries temporelles plus complexes, excluant ainsi les modèles linéaires tels que l'ARIMA au profit de modèles plus complexe tels que SARIMA ou les réseaux de neurones.

Les variations ont été examinées à une échelle plus petite, une année, afin d'obtenir une meilleure compréhension des motifs récurrents au sein de la saisonnalité annuelle identifiée précédemment. La figure 4.10 illustre la saisonnalité sur une année.




Figure 4.10: Décomposition de la saisonnalité sur une année (2017)

On remarque en effet la présence d'un schéma saisonnier au sein de chaque année, avec, en suivant la courbe de tendance sur les figures 4.9 et 4.10, puis l'allure de la fonction autocorrélation et la boîte à moustache sur les figures 4.7 et 4.8. Ces variations, associées à une augmentation globale, suggèrent l'utilisation des modèles comme ARIMA, LSTM, CNN et GRU pour capturer à la fois la saisonnalité et la tendance.

4.4. INGENIERIE DES DONNEES

Le degré d'inertie a permis de tracer le nombre de groupes (clusters) afin de classifier de profils de consommation avec les données du 1^{er} janvier au 31 décembre 2023. Ceci permet d'identifier le comportement de consommation électrique sur le réseau électrique. C'est le graphique de la figure 4.11 qui a été utilisé pour appliquer la méthode du coude (ou *elbow method* en anglais) afin de déterminer le nombre idéal de groupes (clusters).

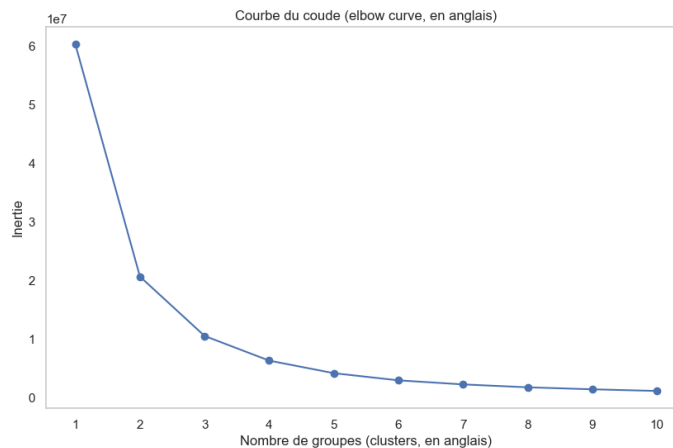


Figure 4.11 : Niveau d'inertie selon le nombre de groupes (clusters en anglais)

Cinq groupes (clusters, en anglais) ont été définis grâce au modèle K-Means. Ensuite, un modèle de classification basé sur un arbre de décision a été entraîné pour prédire les groupes (clusters) en utilisant les valeurs de puissance comme entrée. Lors de l'évaluation sur les données de test, le modèle a obtenu un score de précision égale à 1.0, indiquant qu'il a parfaitement prédit les groupes (clusters) des observations de test.

Ce résultat montre que la segmentation des données par K-Means était bien définie et que le modèle de classification a appris efficacement à distinguer les gammes de valeurs de puissance. Un tel score reflète l'absence d'ambiguïté dans les classes et confirme que le modèle peut être utilisé pour attribuer des groupes (clusters) aux valeurs de puissance dans l'ensemble du jeu de données.

Deux visualisations ont été utilisées pour analyser la répartition des valeurs de puissance selon les groupes (clusters) définis. La figures 4.12 et la figure 4.13 présentent les cinq (05) profils de consommation




Figure 4.12 : Visualisation sur 7 ans des groupes (clusters) de la variable Puissance par groupe (cluster) créé




Figure 4.13 : Visualisation sur l'année 2017 des groupes (clusters) de la variable puissance par groupe (cluster) créé

Ces deux (02) graphiques montrent la répartition des valeurs de puissance en fonction du temps, classées en cinq (05) clusters distincts (0 à 4). La classe rouge regroupe les valeurs les plus basses, correspondant à des périodes de faible activité énergétique. Ces moments de consommation minimale sont réguliers tout au long des années et pourraient représenter des phases de faible activité économique.

Les plages verte et bleue représentent des niveaux de consommation intermédiaires. Ces plages sont dominantes sur l'ensemble de la période des 7 ans et traduisent une consommation stable et régulière, associée aux usages énergétiques standards. Leur répartition uniforme dans le temps suggère une régularité dans les cycles de demande énergétique.

La plage orange regroupe des valeurs plus élevées, marquant des périodes de forte consommation. À partir de 2021, cette plage devient plus visible, indiquant une montée en puissance des besoins énergétiques.

Enfin, la plage violette représente les valeurs maximales. Ces pics de consommation restent rares avant 2022, mais deviennent plus fréquents par la suite, signalant un changement structurel important. Il s'agit d'une possible conséquence des politiques publiques mises en œuvre ces dernières années. La figure 4.14 présente la distribution de puissance par groupe(cluster).




Figure 4.14 : Histogramme de la variable puissance catégorisée par groupe (cluster)

Cet histogramme empilé montre la répartition des valeurs de puissance, segmentées en plusieurs plages de couleurs correspondant aux clusters. La forme globale de la distribution suggère une distribution normale, où les valeurs se concentrent autour d'une moyenne, avec une symétrie

- Rouge (75 à ~125) : Cette plage correspond aux valeurs faibles. La faible fréquence observée aux extrémités inférieures de la distribution est caractéristique de la queue gauche d'une distribution normale.
- Vert et Bleu (125 à ~175) : Ces plages représentent le centre de la distribution, où les valeurs de Puissance sont les plus fréquentes. Cela indique que ces niveaux correspondent à des périodes typiques ou habituelles de consommation énergétique.
- Orange (175 à ~225) : Cette plage se situe dans la partie droite du centre de la distribution. Bien qu'elle soit moins dense que le cœur (bleu et vert), elle reste significative et reflète des niveaux de consommation modérément élevés.
- Violet (225 à ~250) : Cette plage correspond aux valeurs les plus élevées, qui diminuent progressivement en fréquence vers la queue droite de la distribution. Cela

indique que ces pics de consommation énergétique sont moins fréquents, mais non négligeables.

Les données ont également été segmentées selon les saisons. Deux clusters ont été identifiés, conformément à la figure 4.15.




Figure 4.15 : Tendances de consommation par cluster de saison créé

Sur la figure 4.12, on distingue une phase de :

- Janvier à août, associée à une consommation généralement stable et élevée, caractérisée par le groupe (cluster) 0,
- Septembre à décembre, représentée par le cluster 1 et caractérisée par une consommation plus variable.

Cette alternance régulière traduit une saisonnalité marquée dans les comportements énergétiques et justifie l'intérêt de cette approche.

4.5. RESULTATS DES MODELES MIS EN ŒUVRE

Cette section se concentre sur l'application de diverses techniques de modélisation pour prédire la consommation énergétique à partir d'une série temporelle complexe. L'objectif a été de mettre en œuvre une gamme étendue de modèles, allant des approches traditionnelles bien établies aux méthodes plus sophistiquées reposant sur l'apprentissage profond. Chaque méthode a été rigoureusement construite, tenant compte des spécificités de la série analysée, et adaptée pour capturer les différents types de relations temporelles, qu'elles soient linéaires ou non linéaires.

4.5.1. Comparaison des performances obtenues avec les données de 20% de test

Cette section vise à comparer les performances obtenues des onze modèles implémentés (ARIMA, GAM, Lissage exponentiel, Facebook Prophet, GARCH, LSTM,

CNN, GRU, ARIMA-LSTM, CNN-LSTM et CNN-GRU) en deux étapes. La première étape consiste à choisir les meilleurs modèles sur les données de test. Quant à la deuxième étape, elle permet de sélectionner le meilleur modèle sur la base des prévisions réalisées sur trois horizons (24 heures, 48 heures et 72 heures) considérés avec les données du 1^{er} janvier au 31 mars 2024 fournies également par la SBEE.

4.5.2. Modèle ARIMA

Les mesures de l’erreur du modèle ARIMA évalué sur les 20% de test a révélé les performances résumées dans le tableau 4.1.

Tableau 4.1 : Comparaison des mesures de performance pour le modèle ARIMA implémenté

Modèle	MAE	RMSE	MAPE (%)	R ²
ARIMA	22,8054	27,6569	11,52	-0,00120

Ces mesures MAE, RMSE et MAPE sont largement éloignées des indicateurs de performance jugés satisfaisants dans le tableau 3.2. La MAPE de 11,52% dépasse 3% démontrant le non performant du modèle ARIMA avec les MAE et RMSE très grandes. Le coefficient de détermination R² légèrement négative (-0,00120), indiquant que le modèle n’explique pas la variance de la série mieux qu’une prédiction basée sur la moyenne. La figure 4.16 illustre la modélisation de la demande électrique entre la période d’entraînement et la période de test.




Figure 4.16 : Modélisation de la demande en énergie électrique avec le modèle ARIMA implémenté

La visualisation des résultats met en évidence que le modèle présente des limites dans sa capacité à représenter les variations. Ces écarts peuvent être attribués à des non-linéarités ou à des relations temporelles que l’approche ARIMA n’est pas conçue pour traiter, ce qui avait été soupçonnée dès les premières visualisations.

4.5.3. Modèle Additif Généralisé (GAM)

Les performances obtenues lors de la période de test sur 20% de données figurent dans le tableau 4.2.

Tableau 4.2 : Comparaison des mesures de performance pour le modèle GAM implémenté

Modèle	MAE	RMSE	MAPE (%)	R ²
GAM	46,9471	55,4612	25	-3,0260

Les résultats obtenus montrent des performances médiocres d'un MAE de 46,95 et un RMSE de 55,46 traduisent des écarts importants entre les prévisions et les valeurs réelles. De plus, un MAPE de 25%, largement supérieur à 3% indique que le modèle est moins performant. Le R² négatif (-3,03) révèle que le modèle ne parvient pas à expliquer la variance de la série.

Ces résultats indiquent une inadéquation du GAM dans ce cas précis, probablement en raison d'une grande difficulté à intégrer les fluctuations rapides ou des dépendances non prises en compte par une seule variable temporelle. La figure 4.17 indique l'écart d'erreur entre la prévision de la consommation d'énergie sur le test et des vraies valeurs.




Figure 4.17 : Modélisation de la demande en énergie électrique avec le modèle GAM

L'analyse graphique met également en évidence des écarts notables entre les prévisions et les valeurs observées, en particulier dans les variations.

4.5.4. Modèle GARCH

Le tableau 4.3 présente les valeurs de performance de test du modèle GARCH.

Tableau 4.3 : Comparaison des mesures de performance pour le modèle GARCH implémenté

Modèle	MAE	RMSE	MAPE (%)	R ²
GARCH	41,76	48,73	19,81	-1,20

Les résultats obtenus suscitent des interrogations. Avec un MAE de 41,76 et un RMSE de 48,73, les prévisions du modèle restent éloignées des valeurs réelles, indiquant des erreurs non négligeables. Le MAPE, à 19,81 %, met en évidence une erreur relative importante, tandis qu'un R² négatif de -1,20 révèle que le modèle ne parvient pas à expliquer la variance mieux qu'une prédiction basée sur une moyenne constante. Ces métriques traduisent un écart significatif entre la conception théorique du modèle et sa performance pratique dans ce cas précis. La figure 4.18 étale les résultats du modèle.

```

Optimization terminated successfully (Exit mode 0)
Current function value: 221324.5874564375
Iterations: 22
Function evaluations: 180
Gradient evaluations: 18
Constant Mean - GARCH Model Results
=====
Dep. Variable:          Power      R-squared:          0.000
Mean Model:            Constant Mean  Adj. R-squared:    0.000
Vol Model:             GARCH         Log-Likelihood:   -221325.
Distribution:           Normal        AIC:              442663.
Method:                Maximum Likelihood  BIC:              442725.
No. Observations:      49075
Date:                  Mon, Dec 16 2024  Df Residuals:    49074
Time:                  21:27:15           Df Model:         1
                               Mean Model
=====
               coef    std err          t      P>|t|      95.0% Conf. Int.
-----+-----+-----+-----+-----+-----
mu             164.1166      0.311     528.013      0.000 [1.635e+02, 1.647e+02]
Volatility Model
=====
               coef    std err          t      P>|t|      95.0% Conf. Int.
-----+-----+-----+-----+-----+-----
omega          150.7287      16.107      9.358  8.143e-21 [1.192e+02, 1.823e+02]
alpha[1]        0.7685  7.263e-03    105.816      0.000 [ 0.754, 0.783]
alpha[2]        0.0192  8.654e-02      0.222    0.825 [-0.150, 0.189]
beta[1]         1.1599e-06    0.113  1.030e-05      1.000 [-0.221, 0.221]
beta[2]         5.8839e-10    9.437e-03    6.235e-08      1.000 [-1.850e-02, 1.850e-02]
beta[3]         2.2466e-09    4.552e-03    4.936e-07      1.000 [-8.921e-03, 8.921e-03]
=====
Covariance estimator: robust

```

Figure 4.18 : Résultats du modèle GARCH

L'analyse des coefficients renforce cette observation. Bien que le terme alpha[1] (0,7685) illustre une contribution notable des chocs récents à la volatilité, la faiblesse des coefficients beta met en lumière une incapacité du modèle à intégrer une persistance significative dans les variations conditionnelles. En d'autres termes, la volatilité semble réactive à court terme mais manque de structure sur le long terme. La figure 4.19 atteste l'incapacité du modèle à intégrer une persistance significative dans les variations conditionnelles.




Figure 4.19 : Modélisation de la demande en énergie électrique avec le modèle GARCH

Le graphique de la figure 4.19 met en lumière la discordance entre les prévisions issues du modèle GARCH (en rouge) et les valeurs réelles de consommation énergétique (en vert) sur la période de test. Les données observées présentent une variabilité marquée, révélant des fluctuations complexes et des dynamiques sous-jacentes non linéaires, tandis que les prévisions se manifestent sous la forme d'une ligne constante. Cette absence de réactivité aux variations des données reflète une limitation fondamentale du modèle dans sa capacité à représenter les comportements réels de la série temporelle.

Le modèle GARCH, bien qu'efficace pour modéliser la volatilité conditionnelle, semble inadapté à capturer les aspects dynamiques et récurrents de la consommation énergétique dans cet ensemble de données. Cette rigidité dans les prévisions peut être attribuée à la conception intrinsèque du modèle, qui se concentre principalement sur la modélisation de la variance et non sur la prédiction des valeurs absolues ou des tendances complexes. De plus, les fluctuations observées dans les données réelles, liées à des cycles temporels ou des événements spécifiques, échappent manifestement à la portée du modèle.

4.5.5. Lissage exponentiel

Le tableau 4.4 illustre les résultats obtenus pendant le test avec le modèle lissage exponentiel.

Tableau 4.4 : Comparaison des mesures de performance pour le modèle lissage exponentiel implémenté

Modèle	MAE	RMSE	MAPE (%)	R ²
Lissage Exponentiel	21,5831	27,0786	10,40	0,0403

Les performances obtenues, bien qu'encourageantes, soulignent des forces et des limites. Avec un MAE de 21,5831 et un RMSE de 27,0786, les prévisions se rapprochent

étroitement des valeurs réelles. Un MAPE de 10,40 % supérieur à 3% atteste que le modèle est moins performant et un R^2 de 0,0403 montre que le modèle parvient à expliquer une partie de la variance, bien que très faible. Cependant, ces résultats témoignent également d'une marge d'amélioration pour des fluctuations plus fines. La figure 4.20 met en lumière la moins performance du modèle.




Figure 4.20 : Modélisation de la demande en énergie électrique avec le modèle du lissage exponentiel

L'analyse visuelle renforce cette observation : le modèle suit avec fluidité la tendance et la saisonnalité globales, mais montre des écarts dans certaines transitions rapides ou anomalies locales. Cela pourrait être dû à la rigidité relative à des termes saisonniers et de tendance fixée par le lissage exponentiel.

4.5.6. Modèle Prophet

Les performances du modèle ont été évaluées à l'aide des métriques présentées dans le tableau 4.5.

Tableau 4.5 : Comparaison des mesures de performance pour le modèle Prophet implémenté

Modèle	MAE	RMSE	MAPE (%)	R^2
Prophet	12,2406	15,9123	7,52	0,7424

Un MAE de 12,2406, un RMSE de 15,9123 et un MAPE (%) de 7,52, supérieur à 3% montre que la performance du modèle n'est pas idéale. Mais ces résultats témoignent d'une bonne capacité du modèle à représenter la tendance globale et les variations saisonnières, bien que certaines fluctuations n'aient pas été entièrement capturées, comme le montre la figure 4.21.




Figure 4.21 : Modélisation de la demande en énergie électrique avec le modèle prophet

4.5.7. Modèle LSTM

Les performances du modèle LSTM sont listées dans le tableau 4.6.

Tableau 4.6 : Comparaison des mesures de performance pour le modèle LSTM implémenté

Modèle	MAE	RMSE	MAPE (%)	R ²
LSTM	5,4588	9,1822	2,89	0,9216

Les résultats obtenus montrent des performances remarquables. Un MAE de 5,4588 indique des écarts très faibles entre les valeurs prédites et les observations réelles. Un MAPE de 2,89%, inférieur à 3% atteste de la précision relative à des prévisions et un R² de 0,9219 reflète une capacité exceptionnelle du modèle à expliquer la variance de la série. Ces performances surpassent nettement celles des approches précédentes, démontrant l'efficacité du LSTM dans ce contexte. La figure 4.22 atteste la meilleure performance du modèle à travers la courbe de prévision sur les 20% des données de test et la courbe des vraies valeurs.

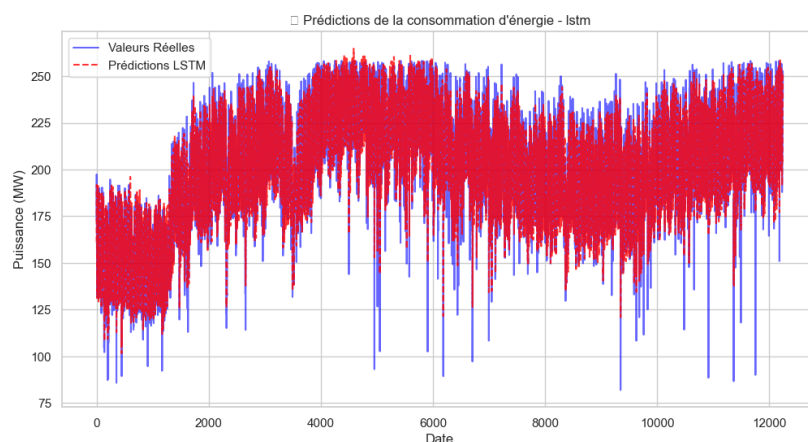


Figure 4.22 : Modélisation de la demande en énergie électrique avec le modèle LSTM

La visualisation des résultats confirme cette analyse. Les prédictions suivent fidèlement la tendance et les fluctuations des données réelles. Cela illustre la capacité des LSTM à capturer non seulement les motifs temporels globaux mais aussi les détails plus subtils présents dans les séries chronologiques.

4.5.8. Modèle CNN

Les performances du modèle CNN sont présentées dans le tableau 4.

Tableau 4.7 : Comparaison des mesures de performance pour le modèle CNN implémenté

Modèle	MAE	RMSE	MAPE (%)	R ²
CNN	6,5563	10,0489	3,34	0,9064

Les résultats obtenus révèlent une précision notable, avec un MAE de 6,5563, un RMSE de 10,0489, un MAPE de 3,34 % et un R² de 0,9064. Ces métriques démontrent la capacité du modèle à prédire la consommation énergétique avec une grande fiabilité, expliquant environ 90,64 % de la variance des données observées. Les prédictions montrent une forte proximité avec les valeurs réelles, témoignant de l'efficacité du modèle à capturer les dépendances locales. La figure 4.23 illustre la performance du modèle sur la prévision avec les données de test.




Figure 4.23 : Modélisation de la demande en énergie électrique avec le modèle CNN

Malgré ces résultats encourageants, certaines limitations subsistent. Bien que le modèle soit performant pour détecter des motifs locaux, il pourrait être enrichi. Des extensions potentielles incluent l'ajout de mécanismes d'attention ou la combinaison avec d'autres architectures, comme les LSTM, pour exploiter les dépendances globales.

4.5.9. Modèle GRU

Le tableau 4.8 comporte le bilan des mesures de performance du modèle GRU.

Tableau 4.8 : Comparaison des mesures de performance pour le modèle GRU implémenté

Modèle	MAE	RMSE	MAPE (%)	R ²
GRU	6,1519	9,8432	3,23	0,9099

Un MAE de 6,1519 est relativement faible avec un MAPE de 3,23%, proche de 3% démontrent que le modèle fait partie des modèles performants. La visualisation des valeurs réelles et des prédictions faites par le modèle illustre sa capacité à expliquer les dépendances globales dans les séries chronologiques. La figure 4.24 donne l'allure des vraies valeurs et des prévisions.

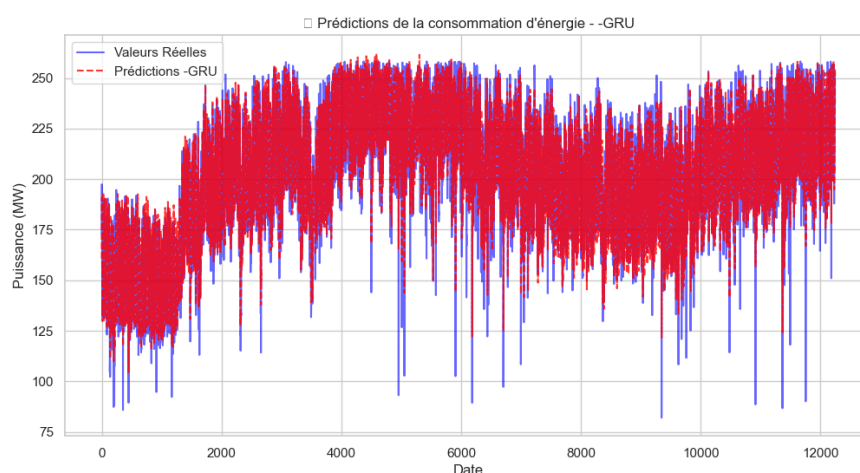


Figure 4.24 : Modélisation de la demande en énergie électrique avec le modèle GRU

4.5.10. Modèle ARIMA-LSTM

Les résultats du modèle lors de l'implémentation du modèle sont consignés dans le tableau 4.9.

Tableau 4.9 : Comparaison des mesures de performance pour le modèle ARIMA-LSTM implémenté

Modèle	MAE	RMSE	MAPE (%)	R ²
ARIMA-LSTM	22,0999	29,2664	11,62	-0,1293

Les écarts d'erreur du modèle hybride tels que MAE = 22,0999 et RMSE = 29,2664 très grands prouvent l'incapacité de l'association du modèle LSTM avec le modèle ARIMA. Le MAPE de 11,62%, supérieur à 3% démontre que le modèle est moins performant. La figure 4.25 issue de la visualisation des prévisions réalisées avec les consommations réelles confirme que le modèle n'est pas idéal dans ce contexte.




Figure 4.25 : Modélisation de la demande en énergie électrique avec le modèle ARIMA-LSTM

4.5.11. Modèle CNN-LSTM

Le tableau 4.10 récapitule les indicateurs de performance du modèle CNN-LSTM lors du test.

Tableau 4.10 : Comparaison des mesures de performance pour le modèle CNN-LSTM implémenté

Modèle	MAE	RMSE	MAPE (%)	R ²
CNN-LSTM	6,1786	9,7154	3,17	0,9125

Après 50 époques d'entraînement, les performances sur l'ensemble de test sont intéressantes. Les métriques affichent un MAE de 6,1786, faible devant un RMSE de 9,7154, un MAPE de 3,17 % proche de 3%, et un R² de 0,9125, indiquant une forte précision et une excellente capacité explicative. Ces résultats suggèrent que le modèle est non seulement précis, mais qu'il capte efficacement la dynamique de la série, comme l'indique la figure 4.26.

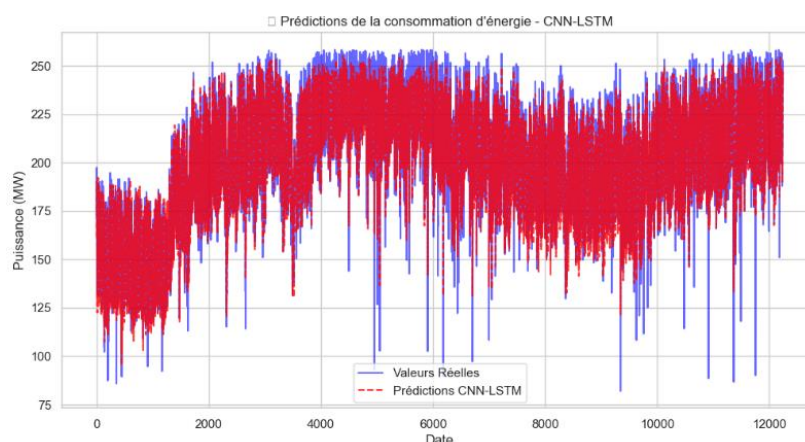


Figure 4.26 : Modélisation de la demande en énergie électrique avec le modèle CNN-LSTM

4.5.12. Modèle CNN-GRU

Les indicateurs de performance du modèle CNN-GRU sont présentés dans le tableau 4.11 illustrant sa bonne performance sur les données de test.

Tableau 4.11 : Comparaison des mesures de performance pour le modèle CNN-GRU implémenté

Modèle	MAE	RMSE	MAPE (%)	R ²
CNN-GRU	6,3449	9,8073	3,28	0,9108

Disposant un MAE de 6,3449 relativement faible et un MAPE de 3,28% proche de 3%, le modèle démontre sa capacité à capturer les dépendances de la série temporelle. La figure 4.27 indique aussi que le modèle arrive à suivre la même trajectoire que la tendance de la série.




Figure 4.27 : Modélisation de la demande en énergie électrique avec le modèle CNN-GRU

4.5.13. Synthèse des modèles performants sur les données de test

Le tableau 4.12 fait le résumé des modèles implémentés jugés performants sur les données de test.

Tableau 4.12 : Résumé des modèles jugés performants

N°	Modèle	MAE	RMSE	MAPE (%)	R ²
01	LSTM	5,4588	9,1822	2,89	0,9219
02	CNN-LSTM	6,1786	9,7154	3,17	0,9125
03	GRU	6,1519	9,8432	3,23	0,9099
04	CNN-GRU	6,3449	9,8073	3,28	0,9108
05	CNN	6,5563	10,0489	3,34	0,9064

4.5.14. Comparaison des modèles performants choisis

Dans cette section, il s'agit principalement de sélectionner un meilleur modèle parmi les cinq premiers modèles (LSTM, CNN-LSTM, GRU, CNN-GRU et CNN) validés sur les données de test. Cette sélection se base sur des trois horizons différents (24 heures, 48 heures et 72 heures) de prévisions avec les données du 1^{er} janvier au 31 mars.

4.5.15. Analyse de l'horizon de temps idéal pour les prédictions

Dans le cadre de cette recherche, les performances des cinq modèles mentionnés dans le tableau 4.12 ont été examinés pour des horizons de prévisions allant de 24 heures (1 jour) à 72 heures (3 jours). L'objectif était d'identifier l'horizon le plus pertinent pour des prévisions énergétiques fiables, en se concentrant sur l'Erreur Absolue Moyenne en Pourcentage (MAPE) et l'Erreur Absolue Moyenne (MAE). La MAPE constitue la base de cette analyse comparative étant la métrique la plus pratique dans la prévision énergétique.

4.5.15.1. Modèle LSTM

Les résultats des métriques utilisées pour évaluer le modèle LSTM pour tous les différents horizons de temps sont présentés dans cette section. Le tableau 4.13 récapitule des métriques de performance de LSTM pour les différents horizons de temps choisis.

Tableau 4.13 : Récapitulatif des métriques de performance de LSTM pour les différents horizons de temps

Horizon (heures)	MAE	RMSE	MAPE (%)	R ²
24	4,8583	5,8833	2,05	0,9322
48	4,6765	5,9106	1,91	0,9292
72	4,1490	5,3930	1,68	0, 9313

Les valeurs des métriques obtenues pour chaque horizon montrent des variations significatives, reflétant l'évolution des performances avec l'augmentation de l'horizon temporel.

➤ **Horizon 24 heures**

Cet horizon initial affiche un MAE de 4,8583 et un RMSE de 5,8833, soulignant une capacité solide à gérer les prévisions à court terme. Avec un MAPE de 2,05%, le modèle montre une précision relative très satisfaisante, et un R² de 0,9322 révèle que la majorité de la variabilité des données est expliquée. Cela fait de cet horizon un choix fiable pour des décisions opérationnelles immédiates, telles que l'optimisation des ressources sur une journée.

➤ *Horizon 48 heures*

À mesure que l'horizon s'étend à 48 heures, les performances du modèle diminuent. Le MAE à 4,6765 et le MAPE à 1,91 traduisant une diminution globale des erreurs, confirme une précision accrue, avec le R^2 de 0,9292 souligne une continuité dans la capacité explicative du modèle. Ces résultats placent cet horizon comme une solution adaptée pour des prévisions nécessitant une anticipation modérée dans la prévision à court terme.

➤ *Horizon 72 heures*

Pour cet horizon, le MAE et le MAPE sont améliorés davantage avec de valeurs respectivement de 4,1490 et de 1,68, traduisant un gain de précision. Cet horizon conserve un sens d'amélioration considérable. La figure 4.28 montre l'évolution des métriques de performant du modèle LSTM.




Figure 4.28 : Evolution des métriques de performance avec LSTM

L'analyse de la figure 4.28 montre que la précision des prévisions reste dans le sens s'améliore au fur et à mesure que l'horizon s'élargit. Les trois horizons 24 heures, 48 heures et 72 heures se distinguent comme les plus performants en termes de MAE et de MAPE. Les figures 4.29, 4.30 et 4.31 aussi attestent la précision du modèle LSTM avec ces données utilisées.




Figure 4.29 : Evolution de prévisions de la consommation d'électricité avec le modèle LSTM sur l'horizon 24 heures




Figure 4.30 : Evolution de prévisions de la consommation d'électricité avec le modèle LSTM sur l'horizon 48 heures




Figure 4.31 : Evolution de prévisions de la consommation d'électricité avec le modèle LSTM sur l'horizon 72 heures

4.5.15.2. Modèle CNN-LSTM

Ici est présentée l'analyse comparative des performances du modèle CNN-LSTM sur les horizons de temps 24 heures, 48 heures et 72 heures. Le tableau 4.14 met en lumière les métriques du CNN-LSTM.

Tableau 4.14 : Récapitulation des métriques de performance de CNN-LSTM pour différents horizons de temps

Horizon (heures)	MAE	RMSE	MAPE	R ²
24	6,0622	7,9730	2,53	0,8754
48	5,5830	7,5231	2,28	0,8854
72	4,7463	6,6724	1,92	0,8948

A première vue, les métriques dans le tableau sont intéressantes. Pour obtenir une analyse approfondie, ce travail s’est attelé à analyser la performance pour chaque horizon.

➤ *Horizon 24 heures*

Cet horizon initial affiche une MAE de 6,0622 et un RMSE de 7,9730, soulignant une capacité solide à gérer les prévisions à court terme. Avec un MAPE de 2,53%, le modèle montre une précision relative très satisfaisante, et un R² de 0,8754 révèle que la majorité de la variabilité des données est expliquée. Cela fait de cet horizon un choix fiable pour des décisions opérationnelles immédiates, telles que l’optimisation des ressources sur une journée.

➤ *Horizon 48 heures*

À mesure que l’horizon s’étend à 48 heures, le modèle améliore ses performances. La MAE descend à 5,5830, et le RMSE à 7,5231, traduisant une réduction globale des erreurs. Le MAPE, abaissé à 2,28%, confirme une précision accrue, tandis que le R² maintenu à 0,8854 souligne une continuité dans la capacité explicative du modèle. Ces résultats placent cet horizon comme une solution adaptée pour des prévisions nécessitant une anticipation modérée, par exemple, dans la planification de la chaîne logistique.

➤ *Horizon 72 heures*

Sur trois jours, le modèle atteint son pic de performance. Le MAE chute à 4,7463, le RMSE descend à 6,6724, et le MAPE est réduit à 1,92%, démontrant une précision remarquable pour un horizon étendu. La figure 4.32 confirme l’évolution des métriques d’évaluation du modèle CNN-LSTM.




Figure 4.32 : Evolution des métriques de performance de CNN-LSTM pour différents horizons de temps

La stabilité des performances et l'amélioration progressive des métriques (MAE, RMSE, MAPE) à mesure que l'horizon s'allonge, montrent une maturité technique qui inspire confiance pour une utilisation. Les figures 4.33, 4.44 et 4.35 confirment le degré de précision du modèle.




Figure 4.33 : Evolution de prévisions de la consommation d'électricité avec le modèle CNN-LSTM sur l'horizon 24 heures




Figure 4.34 : Evolution de prévisions de la consommation d'électricité avec le modèle CNN-LSTM sur l'horizon 48 heures




Figure 4.35 : Evolution de prévisions de la consommation d'électricité avec le modèle CNN-LSTM sur l'horizon 72 heures

4.5.15.3. Modèle CNN

Cette section présente l'analyse comparative des différents horizons de temps avec le modèle CNN. Le tableau 4.15 récapitule des métriques de performance du modèle CNN pour les différents horizons de temps.

Tableau 4.15 : Récapitulation des métriques de performance de CNN pour les différents horizons de temps

<i>Horizon (heures)</i>	<i>MAE</i>	<i>RMSE</i>	<i>MAPE (%)</i>	<i>R²</i>
24	5,1781	6,2640	2,16	0,9231
48	5,4333	6,9654	2,20	0,9017
72	4,9923	6,3578	2,00	0,9045

Les résultats ont fait l'objet d'une analyse comparative selon qu'il s'agit de l'horizon 24, 48 ou 72 heures.

➤ Horizon 24 heures

Avec un MAE de 5,1781, cet horizon présente une erreur moyenne satisfaisante, traduisant sa capacité à gérer une prévision à court terme. Le MAPE de 2,16% confirme la meilleure précision du modèle CNN. Pour un R² de 9231%, l'horizon indique que le modèle explique très bien de la variance observée dans les données.

➤ Horizon 48 heures

Pour cet horizon, le MAE de 5,4333 et le MAPE de 2,20% montrent une légère augmentation par rapport à la MAE de 24 heures, mais reste dans un écart satisfaisant pour les prévisions à court terme.

➤ Horizon 72 heures

Sur ces trois jours, le modèle atteint sa limite de performance avec la MAE 4,9923 et le MAPE 2,00. Cet horizon peut être envisagé pour combiner précision et stratégie. En effet,

si des commandes sur 72 heures présentent des avantages financiers pour la SBEE, cet horizon se comme une option pertinente. La figure 4.36 présente l'évolution des métriques de performance du modèle CNN pour différents horizons de temps.




Figure 4.36 : Evolution des métriques de performance de CNN pour différents horizons de temps

L'analyse de la figure 4.30 montre que, après les 24 heures et 48 heures, la précision des prévisions augmente à mesure que l'horizon s'élargit. L'horizon de 72 heures se distingue comme le plus performant en termes de $MAE = 4,9923$ et de $MAPE = 2,00\%$. Les figures 4.37, 4.38 et 4.39 indiquent la moins sympathie de l'évolution de prévisions de consommation par rapport à la réalité sur les trois horizons de temps.




Figure 4.37 : Evolution de prévisions de la consommation d'électricité avec le modèle CNN sur l'horizon 24 heures




Figure 4.38 : Evolution de prévisions de la consommation d'électricité avec le modèle CNN sur l'horizon 48 heures




Figure 4.39 : Evolution de prévisions de la consommation d'électricité avec le modèle CNN sur l'horizon 72 heures

4.5.15.4. Modèle GRU

Dans cette section, le tableau 4.16 présente l'analyse comparative des performances du modèle GRU sur les horizons de temps 24 heures, 48 heures et 72 heures.

Tableau 4.16 : Récapitulatif des métriques de performance de GRU pour différents horizons de temps

Horizon (heures)	MAE	RMSE	MAPE (%)	R ²
24	6,3963	7,3612	2,69	0,8938
48	5,7480	6,8657	2,35	0,9045
72	4,9838	6,2474	2,02	0,9078

Les résultats se trouvant dans le tableau ont nécessité une analyse comparative suivant les horizons 24 heures, 48 heures ou 72 heures utilisés.

➤ Horizon 24 heures

Le MAE de valeur 6,3963 pour cet horizon présente une erreur notable, traduisant une précision modérée à courte échéance. Le RMSE de 7,3612 confirme une importance de précision et un R² de 89% indique que le modèle explique bien de la variance observée dans les données. Il fait partie des modèles de précision avec la MAPE de 2,69.

➤ Horizon 48 heures

Le MAE diminue à 5,7480 et le RMSE de valeur 6,8657, indiquant une augmentation de performances par rapport à l'horizon précédent. Ce résultat est sanctionné par une MAPE de 2,35% que l'erreur relative est toujours dans la marge de meilleure précision. De plus, la valeur du R² de 90% démontre que le modèle fait meilleur pour une moyenne constante. Ces résultats indiquent que cet horizon est fiable pour des décisions opérationnelles précises.

➤ Horizon 72 heures

Pour cet horizon, le modèle atteint son pic de performances. Le MAE chute à 4,9838, le RMSE descend à 6,2474 et le MAPE est réduit à 2,02%, démontrant une précision remarquable pour un horizon étendu. Le R² de 90% reste largement acceptable.

La figure 4.34 indique l'évolution des métriques de performance de GRU pour différents horizons de temps.




Figure 4.40 : Evolution des métriques de performance de GRU pour différents horizons de temps

L'analyse de la figure 4.40 montre que la précision des prévisions augmente après 24 heure et les horizons de 48 heures et de 72 heures se distinguent comme le plus performant en termes de MAE, avec des erreurs de 5,7480, de 4,9838 et de MAPE de 2,35% et de 2,02%. Les figures 4.41, 4.42 et 4.43 mettent en lumière le degré de qualité de GRU.




Figure 4.41 : Evolution de prévisions de la consommation d'électricité avec le modèle GRU sur l'horizon 24 heures




Figure 4.42 : Evolution de prévisions de la consommation d'électricité avec le modèle GRU sur l'horizon 48 heures




Figure 4.43 : Evolution de prévisions de la consommation d'électricité avec le modèle GRU sur l'horizon 72 heures

4.5.15.5. Modèle CNN-GRU

Ici, il s'agit de l'analyse comparative des différents horizons de temps avec le modèle CNN-GRU. Le tableau 4.17 contient les résultats de la validation de CNN-GRU.

Tableau 4.17 : Récapitulation des métriques de performance du modèle avancé CNN-GRU pour les différents horizons de temps de prévisions

Horizon (heures)	MAE	RMSE	MAPE (%)	R ²
24	6,1835	7,4426	2,58	0,8915
48	5,8026	7,0917	2,36	0,8981
72	5,0598	6,4910	2,05	0,9004

Les résultats mentionnés dans le tableau 4.7 sont intéressants. Pour obtenir une analyse approfondie, ce travail s'est attelé à analyser la performance pour chaque horizon.

➤ Horizon 24 heures

Le MAE, le MAPE enregistrée sont respectivement de 6,1835 et de 2,58%. Cela indique des erreurs modérées pour les prévisions journalières. Cet horizon est particulièrement efficace pour des besoins opérationnels immédiats, comme la gestion quotidienne de la demande. Les autres métriques, telles qu'un RMSE de 7,4426 et un R² de 0,8915 confirment la robustesse du modèle sur ce court intervalle.

➤ Horizon 48 heures

Avec un MAE de 5,8026, et un MAPE de 2,36%, cet horizon présente le plus faible erreur moyenne, suggérant qu'il s'agit du point optimal pour les prévisions à court terme. Il montre une amélioration marginale de la précision par rapport à l'horizon de 24 heures. Les performances de cet horizon ont augmenté, avec un RMSE réduit de 7,0917 et un R² évolué de 0,8981 qui explique de la variance dans les données.

➤ Horizon 72 heures

Pour cet horizon, le MAE est amélioré de 5,0598, traduisant un gain de précision. Cet horizon conserve un sens d'amélioration avec un RMSE de 6,4910, un MAPE de 2,05% et un R^2 de 0,9004. La figure 4.35 illustre l'évolution des métriques de performance de CNN-GRU pour les différents horizons de temps.




Figure 4.44 : Evolution des métriques de performance de CNN-GRU pour différents horizons de temps

Les performances s'améliorent progressive avec des métriques (MAE, RMSE, MAPE) à mesure que l'horizon s'allonge et montrent la capacité du modèle pour des horizons élargi. Les figures 4.45, 4.46 et 4.47 présentent l'évolution de prévisions de la consommation avec le modèle sur les horizons de temps ciblés.




Figure 4.45 : Evolution de prévisions de la consommation d'électricité avec le modèle CNN-GRU sur l'horizon 24 heures




Figure 4.46 : Evolution de prévisions de la consommation d'électricité avec le modèle CNN-GRU sur l'horizon 48 heures




Figure 4.47 : Evolution de prévisions de la consommation d'électricité avec le modèle CNN-GRU sur l'horizon 72 heures

4.5.16. Sélection finale

L'analyse comparative des performances des modèles (LSTM, CNN, GRU, CNN-LSTM et CNN-GRU) révèle des différences notables selon les horizons temporels. Les figures 4. 48 et 4.49 présentent le graphique des MAPE et MAE pour ces modèles validés par horizon de temps.




Figure 4.48 : Comparaison des MAPE pour différents modèles validés avec de nouvelles données

Les MAPE des modèles sélectionnés pour des prévisions sur des horizons temporels (24 heures, 48 heures et 72 heures) sont tous inférieurs à 3% et montrent que ces modèles sont performants. Toutefois, les MAPE du modèle LSTM sur les trois horizons de temps restent inférieurs aux MAPE des autres modèles.




Figure 4.49 : Comparaison des MAE pour différents modèles validés avec de nouvelles données

Le graphique de la figure 4.49 atteste également que les MAE du modèle LSTM sont inférieurs aux MAE des autres modèles utilisés sur ces horizons de temps. Enfin, sur les horizons de 24 heures, 48 heures et 72 heures (3 jours), le modèle LSTM demeure le modèle le plus performant parmi les modèles sélectionnés démontrant ainsi sa capacité à offrir des prévisions précises.

4.6. DEPLOIEMENT DU MODELE RETENU AU TRAVERS D'UNE APPLICATION

L'application développée, utilisant le *framework Streamlit*, a pour objectif d'offrir une interface intuitive et efficace pour l'exploitation du modèle de prévision énergétique. Cette interface est conçue pour permettre à l'utilisateur de charger des données, d'explorer les résultats, de générer des prédictions et de visualiser les résultats obtenus. L'architecture de l'interface repose sur plusieurs éléments fonctionnels, organisés de manière logique pour guider l'utilisateur tout au long du processus.

4.6.1. En-tête de l'interface

La figure 4.50 est l'interface de l'application de déploiement du modèle.



Figure 4.50 : Interface de l'application de déploiement du modèle

L'en-tête de l'application contient le bouton "**Déployer**". Ce bouton centralise l'action de déploiement des résultats des prévisions. Une fois les données traitées et les prédictions effectuées, l'utilisateur peut cliquer sur ce bouton pour générer des rapports détaillés, exporter des visualisations interactives ou encore intégrer les résultats dans un système tiers. Cette fonctionnalité est cruciale pour les utilisateurs cherchant à mettre en œuvre les prévisions dans un contexte opérationnel.

4.6.2. Menu latéral gauche

Le menu latéral constitue l'élément principal de la navigation dans l'application.

- **Chargement des données** : Cette section permet à l'utilisateur de charger les données à utiliser. En cliquant sur cette option, l'utilisateur peut importer un fichier CSV contenant les données historiques sur lesquelles le modèle sera appliqué. Des options telles que le **glisser-déposer** et la fonction **parcourir les fichiers** sont disponibles pour simplifier le processus de chargement. La figure 4.51, la figure 4.52 et la figure 4.38 montrent la fonctionnalité de l'application.



Figure 4.51 : Fonctionnalité chargement des fichiers application de déploiement

- **Exploration et Analyse** : Une fois les données chargées, cette section permet à l'utilisateur d'explorer les données. Des statistiques descriptives et des graphiques permettant d'observer la série temporelle originale, la tendance, la saisonnalité, les résidus et anomalies des séries temporelles sont générés automatiquement.



Figure 4.52 : Fonctionnalité de prévisualisation et analyse de données de l'application

- **Prédictions** : Cette option active les outils de prévision, permettant à l'utilisateur de lancer le modèle de prédiction et d'obtenir les résultats pour des horizons temporels donnés. Les prédictions peuvent être visualisées sous forme de courbes ou de tableaux.

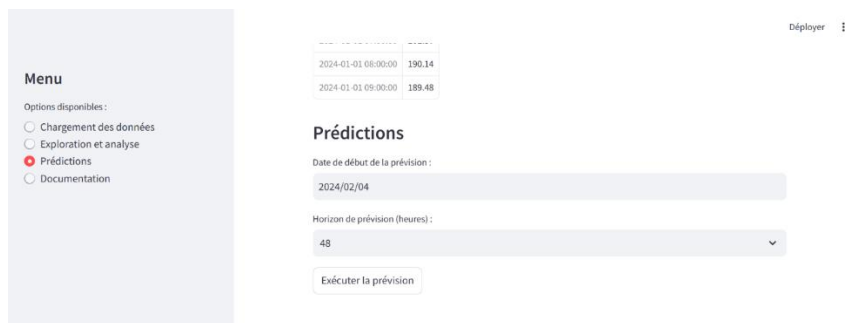


Figure 4.53 : Fonctionnalité prédiction de l'application

- **Documentation** : Cette section est dédiée à fournir des informations détaillées concernant l'utilisation de l'application, ainsi que des explications sur les formats de fichiers acceptés, les types de modèles disponibles et des exemples pratiques d'application.

4.6.3. Zone centrale et interactivité

La zone centrale de l'application est dynamique et change selon l'option choisie dans le menu latéral. Lors de l'importation des données, elle se divise en plusieurs sous-sections interactives :

- **Importer un fichier CSV** : L'utilisateur peut télécharger ses données en sélectionnant un fichier CSV directement depuis son appareil. La limite de taille des fichiers est de 200 Mo, garantissant la prise en charge des fichiers de taille raisonnable.

- **Faire glisser et déposez le fichier ici** : Cette fonctionnalité permet un chargement rapide et intuitif des fichiers par simple glisser-déposer, ce qui rend l'interface plus accessible, notamment pour des utilisateurs moins expérimentés.

- **Parcourir les fichiers** : Une méthode traditionnelle permettant à l'utilisateur de sélectionner un fichier à l'aide de l'explorateur de fichiers standard, ce qui garantit une compatibilité maximale avec tous les systèmes d'exploitation.

4.7. CONCLUSION PARTIELLE

Ce chapitre a permis, à l'issue de l'analyse des résultats d'identifier que le modèle LSTM est l'idéal pour la prévision des données futures en énergie, au regard de la configuration des données obtenues auprès de la SBEE. Les résultats ont également révélé que ce modèle est performant pour prédire les futures valeurs sur plusieurs horizons de temps, notamment 24h, 48h et 72h. L'équipe en charge de la prévision pourra donc obtenir des valeurs fiables pour prévoir la demande en énergie électrique, aussi bien pour une gestion journalière que pour une gestion sur 3 jours.

CONCLUSION GENERALE ET PERSPECTIVES

Ce mémoire s'est attaqué à une problématique, d'une importance capitale pour le développement énergétique du Bénin, qui est celle de la prévision précise de la demande d'achat d'électricité sur le court terme. Le défi principal était de proposer un modèle prédictif fiable, capable de répondre aux exigences techniques et opérationnelles de la SBEE sur les horizons temporels de 24 heures, 48 heures et 72 heures. Dans un pays où les ressources sont limitées et où une mauvaise gestion de la demande peut entraîner des coupures coûteuses et des perturbations socio-économiques, disposer d'un modèle performant représente un levier stratégique pour le développement.

Après avoir présenté le secteur de l'électricité au Bénin, ce travail a conduit une revue de littérature sur la prévision de la demande d'achat d'électricité. Cette revue a permis d'identifier les onze (11) modèles qui sont : ARIMA, LSTM, Facebook Prophet, GAM, ARIMA-LSTM, CNN, GARCH, CNN-LSTM, GRU, CNN-GRU et le lissage exponentiel. Ces modèles ont été implémentés, sur des données obtenues auprès de la SBEE et couvrant la période janvier 2017 à décembre 2023, en utilisant le langage Python. Les performances de ces modèles ont été évaluées en utilisant comme métriques de performances la MAE et le MAPE.

Enfin, ce mémoire illustre le rôle central des modèles prédictifs modernes dans la gestion énergétique, non seulement comme outils d'optimisation, mais aussi comme moteurs de transformation pour répondre aux défis actuels et futurs. Ce travail, en combinant rigueur scientifique et pragmatisme opérationnel, constitue une base solide pour des initiatives futures visant à renforcer la résilience et la durabilité des systèmes énergétiques. Par exemple, une étude additionnelle pourrait essayer de déterminer l'infrastructure cloud qui optimiserait la consommation du modèle déployé en puissance de calcul sous contraintes de maintenir au moins le niveau de performance actuel. Dans un monde où l'énergie est au cœur des enjeux de développement, continuer à perfectionner ces approches représente une voie incontournable pour garantir un avenir énergétique équitable et durable. Toutefois, le modèle sélectionné n'étant pas à 100% performant il est important d'avoir des centrales en réserve froide afin de combler le déficit en cas de besoin.

Il est aussi souhaitable que les recherches continuent en considérant les deux (02) saisons de consommation détectées et des variables exogènes afin d'améliorer davantage les indicateurs de performances.

Par ailleurs, ce travail ouvre des horizons prometteurs. L'application de ce modèle dans d'autres pays de la sous-région pourrait renforcer la pertinence de cette méthodologie. En tenant compte des spécificités locales, une adaptation régionale pourrait non seulement consolider les réseaux électriques, mais aussi encourager une collaboration plus étroite entre les acteurs énergétiques du continent.

REFERENCES

-
- [1] I. Ibikunle et F. H. Q. Jack, « Direction de la Planification énergétique, de l'Électrification rurale et de la Règlementation », 2023.
- [2] J. ZOHOON, « L'Energie Electrique au Bénin:Etat des lieux et perspectives de développement selon le Dr Philippe Hounkpatin », 24 HEURES AU BENIN. Consulté le: 4 juillet 2024. [En ligne]. Disponible sur: <https://24haubenin.info/?L-Energie-Electrique-au-Benin-Etat-des-lieux-et-perspectives-de-developpement-2007-2007-2007-2007>
- [3] A. W. HOUNSA, « ETUDE TECHNICO ECONOMIQUE DU RACCORDEMENT D'UNE CENTRALE EOLIENNE AU RESEAU ELECTRIQUE DE LA SBEE : CAS DE LA LOCALITE DE KANDI ». 6 octobre 2011.
- [4] admin, « An 5 du MCA Bénin II : 90% d'exécution globale, plus de 1000 Km de lignes électriques réalisées », L'économiste du Bénin. Consulté le: 18 mai 2024. [En ligne]. Disponible sur: <https://leconomistebenin.com/an-5-du-mca-benin-ii-90-dexecution-globale-plus-de-1000-km-de-lignes-electriques-realisees/>
- [5] « Bénin : le branchement au réseau électrique de la SBEE passe de 85.000 à 20.000 FCFA », TRIOMPHE MAG. Consulté le: 15 mars 2024. [En ligne]. Disponible sur: <https://trionphemag.com/benin-le-branchement-au-reseau-electrique-de-la-sbee-passe-de-85-000-a-20-000-fcfa/>
- [6] Site de la SBPE, « Société Béninoise de Production d'Électricité - République du Bénin », Société Béninoise de Production d'Électricité - République du Bénin. Consulté le: 3 octobre 2024. [En ligne]. Disponible sur: <https://sbpe.bj>
- [7] J. SOLUTIONS, « Société Béninoise de Production d'Électricité - République du Bénin », Société Béninoise de Production d'Électricité - République du Bénin. Consulté le: 28 mars 2025. [En ligne]. Disponible sur: <https://sbpe.bj>
- [8] « Société béninoise d'énergie électrique », *Wikipédia*. 10 octobre 2024. Consulté le: 28 mars 2025. [En ligne]. Disponible sur: https://fr.wikipedia.org/w/index.php?title=Soci%C3%A9t%C3%A9_b%C3%A9ninoise_d%27%C3%A9nergie_%C3%A9lectrique&oldid=219344044
- [9] A. Moussa *et al.*, « PROJET DE RESTRUCTURATION ET D'EXTENSION DU SYSTÈME DE RÉPARTITION ET DE DISTRIBUTION DE LA SBEE (PRESRDI) », p. 22.
- [10] B. AYADI, « Code_Reseau_SBEE_HT-MT ». 19 septembre 2020.
- [11] L. Rédaction, « Gestion déléguée de la Sbee : Une option améliorative de performances », LE MATINAL. Consulté le: 12 juillet 2024. [En ligne]. Disponible sur: <https://lematinal.bj/gestion-deleguee-de-la-sbee-une-option-ameliorative-de-performances/>
- [12] C. M. M. HOUNSOU, « Mot du Directeur Général – SBEE ». Consulté le: 10 juin 2024. [En ligne]. Disponible sur: <https://sbee.bj/site/sbee/mot-du-directeur/>
- [13] des F. Ministère de l'Economie et, « ANALYSE DE LA SITUATION DE L'ENERGIE ELECTRIQUE AU BENIN ET SES IMPLICATIONS SUR L'ECONOMIE NATIONALE ». 2020.
- [14] « Révision des conditions tarifaires de la SBEE ». Consulté le: 27 décembre 2024. [En ligne]. Disponible sur: https://are.bj/wp-content/uploads/2019/10/document_de_revision_consultation_publicue_are.pdf
- [15] « Présentation de l'EEEOA », ECOWAPP. Consulté le: 27 décembre 2024. [En ligne]. Disponible sur: <https://www.ecowapp.org/fr/content/pr%C3%A9sentation-de-l%E2%80%99eeeo>
- [16] WATHI, « Présentation du Système d'Echanges d'Energie Electrique Ouest Africain (EEEOA) », WATHI. Consulté le: 27 décembre 2024. [En ligne]. Disponible sur:
-

- https://www.wathi.org/debat_id/organisations-regionales/wathinote-organisations-regionales/presentation-systeme-dechanges-denergie-electrique-ouest-africain-eeeo/
- [17] WATHI, « Présentation de l’Autorité de Régulation Régionale du secteur de l’Electricité de la CEDEAO (ARREC) », WATHI. Consulté le: 27 décembre 2024. [En ligne]. Disponible sur: https://www.wathi.org/debat_id/organisations-regionales/wathinote-organisations-regionales/presentation-de-lautorite-de-regulation-regionale-secteur-de-lelectricite-de-cedeao-arrec/
- [18] « Directive-sur-la-sécurisation-des-échanges-transfrontaliers-d’énergie-électrique-du-Marché-Régional-de-l’Electricité.pdf ». Consulté le: 27 décembre 2024. [En ligne]. Disponible sur: <https://www.erera.arrec.org/wp-content/uploads/2020/03/Directive-sur-la-s%C3%A9curisation-des-%C3%A9changes-transfrontaliers-d%C3%A9nergie-%C3%A9lectrique-du-March%C3%A9-R%C3%A9gional-de-l’Electricit%C3%A9.pdf>
- [19] « Organisation et Fonctionnement », ERERA. Consulté le: 27 décembre 2024. [En ligne]. Disponible sur: <https://www.erera.arrec.org/fr/organisation-et-fonctionnement/>
- [20] C. DANGBEDJI, « CONTRIBUTION A LA MODELISATION NUMERIQUE DE LA PREVISION DE LA DEMANDE EN ELECTRICITE : CAS DU BENIN », Master, Université d’Abomey-calavi, 2011.
- [21] « Décret N° 2021-542 du 27 octobre 2021 », Secrétariat général du Gouvernement du Bénin. Consulté le: 27 décembre 2024. [En ligne]. Disponible sur: <https://sgg.gouv.bj/doc/decret-2021-542/>
- [22] « Ministère du Cadre de vie et du Développement durable », *Wikipédia*. 10 juin 2024. Consulté le: 27 décembre 2024. [En ligne]. Disponible sur: https://fr.wikipedia.org/w/index.php?title=Minist%C3%A8re_du_Cadre_de_vie_et_du_D%C3%A9veloppement_durable&oldid=215839206
- [23] « POLITIQUE NATIONALE DE DEVELOPPEMENT DES ENERGIES RENOUVELABLES ».
- [24] L. DOSSOU, « Rapport special budget », MINISTERE DU CADRE DE VIE, DES TRANSPORTS ET DU DEVELOPPEMENT DURABLE (MCVTDD). [En ligne]. Disponible sur: <https://budgetbenin.bj/wp-content/uploads/2023/12/RAPPORT-SPECIAL-BUDGET-MCVTDD.pdf>
- [25] « Loi 2006-16 portant code de l’électricité en République du Bénin », *J. Off. Répub. Bénin*, vol. 18, p. 806-824, mars 2007.
- [26] H. C. S. Yotto, « Modélisation et prédiction de la consommation électrique du Bénin en vue de l’équilibre offre-demande à l’horizon 2030 », p. 281.
- [27] K. K. N’GONIAN, « Analyse de la qualité du produit à la SBEE ». 12 janvier 2024.
- [28] meriem Hammoudi et F. Kouihal, « Prévision de la production d’électricité de type Energies Renouvelables Cas : éolienne et photovoltaïque », Master, Université M’hamed Bougara Boumerdes, Algérie, 2016. [En ligne]. Disponible sur: <http://dlibrary.univ-boumerdes.dz:8080/jspui/bitstream/123456789/3550/1/master.pdf>
- [29] « Mise en œuvre du PAG : La centrale électrique de Maria-Gléta II désormais une réalité », Gouvernement de la République du Bénin. Consulté le: 8 mars 2025. [En ligne]. Disponible sur: <https://www.gouv.bj/article/332/mise-en-%C5%93uvre-du-pag-la-centrale-electrique-de-maria-gleta-ii-desormais-une-realite/>
- [30] M. Méndez, M. G. Merayo, et M. Núñez, « Long-term traffic flow forecasting using a hybrid CNN-BiLSTM model », *Eng. Appl. Artif. Intell.*, vol. 121, p. 106041, mai 2023, doi: 10.1016/j.engappai.2023.106041.
- [31] Mohamed Abd Elmoumen DJABALLAH, « Système de prédiction de la consommation d’énergie basé Deep Learning », Université de 8 Mai 1945 – Guelma, Algerie, 2021.

- [32] V. Lefieux, « Modèles semi-paramétriques appliqués à la prévision des séries temporelles. Cas de la consommation d'électricité. », Université de Rennes, Rennes, 2007. [En ligne]. Disponible sur: <https://theses.hal.science/tel-00179866>
- [33] F. Amara, « Modélisation et prévision de la demande d'électricité résidentielle », 2019, doi: 10.13140/RG.2.2.25179.72481.
- [34] C. Adjamagbo, A. A. Salami, Y. Bokovi, D. Gado et A. S. A. Ajavon « MULTIPLE LINEAR REGRESSION APPROACH FOR SHORT-TERM FORECASTING OF ELECTRIC ENERGY CONSUMPTION IN TOGO », *Int. J. Adv. Res.*, vol. 8, n° 10, p. 22-28, oct. 2020, doi: 10.21474/IJAR01/11818.
- [35] R. Koen et J. Holloway, « Application of multiple regression analysis to forecasting South Africa's electricity demand », *J. Energy South. Afr.*, vol. 25, n° 4, p. 48-58, déc. 2014, doi: 10.17159/2413-3051/2014/v25i4a2238.
- [36] K. Abdulsalam et O. Babatunde, « Electrical energy demand forecasting model using artificial neural network: A case study of Lagos State Nigeria », *Int. J. Data Netw. Sci.*, vol. 3, p. 305-322, mai 2019, doi: 10.5267/j.ijdns.2019.5.002.
- [37] A. DIAGNE, « Modélisation économétrique de la consommation d'électricité au Sénégal de 1999 à 2015 », janv. 2017.
- [38] M. Drame, D. Seck, et B. Ndiaye, « Analysis and Forecast of Energy Demand in Senegal with a SARIMA Model and an LSTM Neural Network », 2023, p. 129-140. doi: 10.1007/978-3-031-42317-8_11.
- [39] T. Dzheria et V. Shevchuk, « FORECASTING ELECTRICITY CONSUMPTION USING NEURAL NETWORKS », *Системи Управління Навігації Та Зв'язку Збірник Наукових Праць*, vol. 2, p. 42-44, juin 2023, doi: 10.26906/SUNZ.2023.2.042.
- [40] « Nigeria Energy Outlook – Analysis », IEA. Consulté le: 13 octobre 2024. [En ligne]. Disponible sur: <https://www.iea.org/articles/nigeria-energy-outlook>
- [41] H. C. S. Yotto, « Modélisation et prédiction de la consommation électrique du Bénin en vue de l'équilibre offre-demande à l'horizon 2030 ».
- [42] J. K. Kuma, « `` MODELISATION HETEROSCEDASTIQUE: LES MODELES ARCH-GARCH `` », avr. 2018.
- [43] M. Nachawati, « Energy Consumption Prediction Using Recurrent Neural Network (LSTM): Multivariate Time Series forecasting », 2023, Consulté le: 6 avril 2025. [En ligne]. Disponible sur: <https://www.theseus.fi/handle/10024/814998>
- [44] S. Hochreiter et J. Schmidhuber, « LONG SHORT-TERM MEMORY », p. 32, 1997.
- [45] A. Nugaliyadde, U. Somaratne, et K. W. Wong, « Predicting Electricity Consumption using Deep Recurrent Neural Networks », 18 septembre 2019, *arXiv*: arXiv:1909.08182. doi: 10.48550/arXiv.1909.08182.
- [46] D. G. Da Silva et A. A. D. M. Meneses, « Comparing Long Short-Term Memory (LSTM) and bidirectional LSTM deep neural networks for power consumption prediction », *Energy Rep.*, vol. 10, p. 3315-3334, nov. 2023, doi: 10.1016/j.egyr.2023.09.175.
- [47] N. A. Khafaf, M. Jalili, et P. Sokolowski, « Application of Deep Learning Long Short-Term Memory in Energy Demand Forecasting », vol. 1000, 2019, p. 31-42. doi: 10.1007/978-3-030-20257-6_3.
- [48] D. L. Marino, K. Amarasinghe, et M. Manic, « Building Energy Load Forecasting using Deep Neural Networks », in *IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society*, oct. 2016, p. 7046-7051. doi: 10.1109/IECON.2016.7793413.
- [49] S. Nosouhian, F. Nosouhian, et A. Kazemi Khoshouei, « A Review of Recurrent Neural Network Architecture for Sequence Learning: Comparison between LSTM and GRU », 12 juillet 2021. doi: 10.20944/preprints202107.0252.v1.

- [50] M. Abumohsen, A. Y. Owda, et M. Owda, « Electrical Load Forecasting Using LSTM, GRU, and RNN Algorithms », *Energies*, vol. 16, n° 5, p. 2283, févr. 2023, doi: 10.3390/en16052283.
- [51] Muhammad Sajjad al., « A Novel CNN-GRU based Hybrid Approach for Short-term Residential Load Forecasting », n° (No. 2019M3F2A1073179)”, p. 12, 2020.
- [52] G. Dudek, P. Pełka, et S. Smył, « A Hybrid Residual Dilated LSTM and Exponential Smoothing Model for Mid-Term Electric Load Forecasting », 29 mars 2020, *arXiv*: arXiv:2004.00508. doi: 10.48550/arXiv.2004.00508.
- [53] A.-B. ADAN, « Projet à rendre Econométrie I & II », p. 48, 2017 2016.
- [54] C. Sigauke, « Forecasting medium-term electricity demand in a South African electric power supply system », *J. Energy South. Afr.*, vol. 28, n° 4, déc. 2017, doi: 10.17159/2413-3051/2017/v28i4a2428.
- [55] L. Yang, R. Ren, X. Gu, et L. Sun, « Interactive Generalized Additive Model and Its Applications in Electric Load Forecasting », 24 octobre 2023, *arXiv*: arXiv:2310.15662. doi: 10.48550/arXiv.2310.15662.
- [56] John Cockerill, « Prédiction de la consommation électrique ».
- [57] F. Fahs, « Analyse des courbes de charge d’électricité et prédiction à court terme dans les secteurs résidentiel et tertiaire ».
- [58] A. I. Almazrouee, A. M. Almeshal, A. S. Almutairi, M. R. Alenezi, et S. N. Alhajer, « Long-Term Forecasting of Electrical Loads in Kuwait Using Prophet and Holt–Winters Models », *Appl. Sci.*, vol. 10, n° 16, p. 5627, août 2020, doi: 10.3390/app10165627.
- [59] I. Ihsane, « Prévision à court terme et gestion des consommations d’énergie électrique dans l’habitat », p. 262, 2022.

TABLE DES MATIERES

DEDICACE	ii
REMERCIEMENTS	iii
LISTE DES SIGLES ET ACRONYMES	iv
LISTE DES TABLEAUX.....	vi
LISTE DES FIGURES.....	vii
RESUME	x
ABSTRACT	xi
SOMMAIRE	xii
INTRODUCTION GENERALE	1
Chapitre 1. Présentation du secteur de l'électricité au Bénin.....	3
1.1. INTRODUCTION PARTIELLE	3
1.2. CADRE INSTITUTIONNEL DU SECTEUR DE L'ELECTRICITE AU BENIN	3
1.2.1. Ministère de l'Énergie de l'Eau et des Mines	3
1.2.1.1. Direction Générale de la Planification Énergétique, de l'Électrification Rurale et de la Réglementation (DGPEERR).....	3
1.2.1.2. Agence de Contrôle des Installations Electriques Intérieures (CONTRELEC)	4
1.2.1.3. Société Béninoise de Production d'Électrique (SBPE)	5
1.2.1.3.1. Présentation de la SBPE	5
1.2.1.3.2. Mission de la SBPE	5
1.2.1.3.3. Structure organisationnelle	6
1.2.1.3.4. Activités	6
1.2.1.4. Société Béninoise d'Énergie Électrique (SBEE)	6
1.2.1.4.1. Présentation de la SBEE	6
1.2.1.4.2. Mission de la SBEE	7
1.2.1.4.3. Structure organisationnelle	7
1.2.1.4.4. Activités de la SBEE	7
➤ Activités d'exploitation	8
➤ Activités commerciales	8
➤ Activités de développement	8
➤ Autres activités	8
1.2.2. Communauté Électrique du Bénin (CEB).....	9

1.2.2.1.	Présentation de la CEB	9
1.2.2.2.	Mission de la CEB.....	9
1.2.2.3.	Structure organisationnelle	9
1.2.2.4.	Les activités de la CEB	10
1.2.3.	Système d'Échanges d'Énergie Électrique Ouest Africain	10
1.2.3.1.	Présentation de l'EEEOA	10
1.2.3.2.	Mission de l'EEEOA	11
1.2.3.3.	Structure organisationnelle	11
1.2.3.4.	Activités.....	11
1.2.4.	Autorité de Régulation Régionale du secteur de l'Électricité de la CEDEAO.....	11
1.2.4.1.	Présentation.....	11
1.2.4.2.	Mission de l'ARREC.....	12
1.2.4.3.	Structure organisationnelle	12
1.2.5.	Autorité de Régulation de l'Électricité (ARE).....	12
1.2.5.1.	Présentation de l'ARE	12
1.2.5.2.	Mission.....	12
1.2.5.3.	Structure organisationnelle	13
1.2.5.4.	Activités de l'ARE.....	13
1.2.6.	Production Indépendant d'Électricité (PIE ou IPP)	13
1.2.6.1.	Mission.....	13
1.2.6.2.	Activités.....	13
1.2.7.	Ministère de l'Industrie et du Commerce	13
1.2.7.1.	Présentation.....	13
1.2.7.2.	Mission.....	14
1.2.7.3.	Structure organisationnelle	14
1.2.8.	Ministère de Cadre de Vie, des Transports en charge du Développement Durable 15	
1.2.8.1.	Présentation.....	15
1.2.8.2.	Missions	15
1.2.8.3.	Structure organisationnelle	16
1.3.	CADRE JURIDIQUE DU SECTEUR DE L'ELECTRICITE AU BENIN.....	16
1.4.	RESEAU ELECTRIQUE BENINOIS.....	16
1.4.1.	Réseau de transport	17
1.4.2.	Réseau de distribution	17
1.5.	MOYENS DE PRODUCTION DE L'ENERGIE AU BENIN.....	18
1.5.1.	Parc national de production	19

1.5.2.	Approvisionnements externes en énergie électrique	20
1.6.	CONCLUSION PARTIELLE	20
Chapitre 2.	Revue de littérature sur les modèles de prévision de la demande d'énergie...	21
2.1.	INTRODUCTION PARTIELLE	21
2.2.	ETAT DE L'ART SUR LES MODELES DE PREVISION DE DEMANDE D'ACHAT EN ELECTRICITE	21
2.2.1.	Méthodes de régression linéaire multiple	21
2.2.2.	Analyse des séries chronologiques.....	22
2.2.3.	Modèles Long Terme et Approche Multisectorielle	23
2.2.4.	Modèles GARCH	24
2.2.5.	Réseaux de Neurones Recurrents	26
2.2.6.	Lissage exponentiel	28
2.2.7.	Modèles Additifs Généralisés (GAM)	29
2.2.8.	Modèle Facebook Prophet	31
2.2.9.	Synthèse de la revue sur les modèles	32
2.3.	DIFFERENTS TYPES D'HORIZONS TEMPORELS DE PREVISIONS	34
2.4.	CONCLUSION PARTIELLE	34
Chapitre 3.	Développement d'un modèle de prédiction de la demande d'achat en électricité	35
3.1.	INTRODUCTION PARTIELLE	35
3.2.	DONNEES.....	35
3.2.1.	Nature et collecte des données.....	35
3.2.2.	Transformation des données.....	35
3.2.3.	Nettoyage des données.....	35
3.2.4.	Analyse exploratoire de la série	36
3.2.5.	Ingénierie des données	37
3.2.5.1.	Création de la variable cluster_saison	38
3.2.5.2.	Création de nouvelles variables temporelles.....	38
3.2.5.3.	Création de la variable cluster_puissance.....	38
3.3.	OUTILS ET MATERIELS.....	39
3.3.1.	Langage de programmation Python	39
3.3.2.	Environnement de développement	40
3.3.3.	Bibliothèques Python utilisées	40
3.4.	MODELISATION ET CHOIX D'UN MODELE DE PREVISION DE LA DEMANDE EN ENERGIE ELECTRIQUE.....	41
3.4.1.	Mise en œuvre des modèles retenus.....	42
3.4.1.1.	Modèle ARIMA.....	42

3.4.1.2.	Modèle Additif Généralisé (GAM)	42
3.4.1.3.	Lissage exponentiel	43
3.4.1.4.	Modèle LSTM	43
3.4.1.5.	Modèle GARCH	44
3.4.1.6.	Modèle CNN	44
3.4.1.7.	Modèle CNN-LSTM	45
3.4.1.8.	Modèle ARIMA-LSTM	45
3.4.1.9.	Modèle Prophet	46
3.4.1.10.	Modèle GRU	47
3.4.1.11.	Modèle CNN-GRU	47
3.4.2.	Sélection d'un modèle pour la prévision	48
3.4.3.	Les métriques d'évaluation des modèles	48
3.4.4.	Erreur Quadratique Moyenne (MSE, Mean Squared Erreur en anglais)	48
3.4.5.	Erreur Absolue Moyenne EAM (MAE, Mean Absolute Error en anglais)	49
3.4.6.	Racine de l'Erreur Quadratique Moyenne (RMSE, Root Mean Squared Error, en anglais)	49
3.4.7.	Coefficient de détermination (R^2)	50
3.4.8.	Erreur Absolue Moyenne en Pourcentage EAMP (MAPE, Mean Absolute Percentage Error en anglais)	50
3.4.9.	Synthèse des métriques de performance d'évaluation des modèles utilisés dans la régression	51
3.5.	DESCRIPTION DE LA PLATEFORME DEVELOPPEE POUR LE DEPLOIEMENT	51
3.5.1.	Entrée de la plateforme	51
3.5.2.	Sortie de la plateforme	52
3.6.	CONCLUSION PARTIELLE	52
Chapitre 4.	Résultats et discussions	53
4.1.	INTRODUCTION GENERALE	53
4.2.	NETTOYAGE DES DONNEES	53
4.3.	ANALYSE EXPLORATOIRE DES DONNEES	55
4.4.	INGENIERIE DES DONNEES	58
4.5.	RESULTATS DES MODELES MIS EN ŒUVRE	61
4.5.1.	Comparaison des performances obtenues avec les données de 20% de test	61
4.5.2.	Modèle ARIMA	62
4.5.3.	Modèle Additif Généralisé (GAM)	63
4.5.4.	Modèle GARCH	63
4.5.5.	Lissage exponentiel	65
4.5.6.	Modèle Prophet	66

4.5.7.	Modèle LSTM.....	67
4.5.8.	Modèle CNN	68
4.5.9.	Modèle GRU	68
4.5.10.	Modèle ARIMA-LSTM	69
4.5.11.	Modèle CNN-LSTM	70
4.5.12.	Modèle CNN-GRU.....	71
4.5.13.	Synthèse des modèles performants sur les données de test.....	71
4.5.14.	Comparaison des modèles performants choisis	72
4.5.15.	Analyse de l’horizon de temps idéal pour les prédictions.....	72
4.5.15.1.	Modèle LSTM	72
➤	Horizon 24 heures	72
➤	Horizon 48 heures	73
➤	Horizon 72 heures	73
4.5.15.2.	Modèle CNN-LSTM.....	74
➤	Horizon 24 heures	75
➤	Horizon 48 heures	75
➤	Horizon 72 heures	75
4.5.15.3.	Modèle CNN.....	77
➤	Horizon 24 heures	77
➤	Horizon 48 heures	77
➤	Horizon 72 heures	77
4.5.15.4.	Modèle GRU.....	79
➤	Horizon 24 heures	79
➤	Horizon 48 heures	79
➤	Horizon 72 heures	79
4.5.15.5.	Modèle CNN-GRU	81
➤	Horizon 24 heures	81
➤	Horizon 48 heures	81
➤	Horizon 72 heures	82
4.5.16.	Sélection finale	83
4.6.	DEPLOIEMENT DU MODELE RETENU AU TRAVERS D’UNE APPLICATION.....	84
4.6.1.	En-tête de l'interface.....	84
4.6.2.	Menu latéral gauche.....	85
4.6.3.	Zone centrale et interactivité	86
4.7.	CONCLUSION PARTIELLE	87

CONCLUSION GENERALE ET PERSPECTIVES	88
REFERENCES	I
TABLE DES MATIERES.....	V
ANNEXES	XI

ANNEXES

A1_Fichier de suivi de charge du réseau électrique



CAMON 30 • 23mm 1/188 1/33s ISO1752

A2_Equipement de distribution HTA