



Full Length Research Paper

Étude Comparative des Performances de Prédiction de la Consommation d'Énergie : Modèle Global vs Modèle d'Intelligence Artificielle.

Sambalaye Diop^{1*}, Ramatou Saré², Papa Silly Traore¹, Issa Zerbo², Mamadou Lamine Ndiaye¹

¹Water, Energy, Environment, Industrial process (LE3PI) Polytechnic school of Dakar (ESP -UCAD) – Dakar, Sénégal

²Joseph KI-ZERBO University; Renewable Thermal Energy Laboratory (L.E.T.RE) – Ouagadougou, Burkina Faso

Received April 2024 – Accepted June 2024



*Corresponding author. sambalayediop7@gmail.com

Author(s) agree that this article remain permanently open access under the terms of the Creative Commons Attribution License 4.0 International License.

Résumé:

Dans le cadre de la demande énergétique, les unités fondamentales pour la planification et le suivi sont la population, le PIB secondaire et le PIB tertiaire. Au Sénégal, les besoins en consommation d'énergie sont estimés par la SENELEC pour desservir les clients, les entreprises, les logements administratifs, etc. Pour garantir un service de fourniture d'énergie continue, plusieurs étapes de prévision de la demande sont nécessaires. D'où l'application du modèle global, basé sur les données historiques et des prévisions économiques, qui utilise des indicateurs spécifiques pour chaque secteur, rendant parfois les prévisions incertaines. Pour pallier cela, nous utilisons un modèle d'intelligence artificielle de type réseau de neurones. Le but est de comparer la précision du modèle par rapport aux différents horizons déjà explorés par le modèle global avec le modèle d'IA. Les résultats obtenus sont d'une grande importance pour les gestionnaires du réseau électrique de la SENELEC ainsi que pour les décideurs, car ils permettent de mieux comprendre l'évolution de la demande d'électricité et les principaux facteurs qui l'influencent. Ils permettront aussi de mieux adapter la production d'électricité pour un équilibre permanent entre consommation et production source d'économie et de stabilité du réseau. Les erreurs quadratiques moyennes et les erreurs absolues moyennes sont respectivement améliorées de 0,6 MWh et 0,8 MWh.

Mots clés: Demande énergétique, population, PIB, SENELEC, modèle global, modèle d'intelligence artificielle.

Cite this article:

Sambalaye Diop, Ramatou Saré, Papa Silly Traore, Issa Zerbo, Mamadou Lamine Ndiaye. (2024). Étude Comparative des Performances de Prédiction de la Consommation d'Énergie : Modèle Global vs Modèle d'Intelligence Artificielle. Revue RAMReS – Sci. Appl. & de l'Ing., Vol. 6(1), pp. 108-115. ISSN 2630-1164.

1. Introduction

La stabilité et la fiabilité du réseau électrique représentent des préoccupations majeures pour les gestionnaires de réseau électriques, particulièrement dans cette situation actuelle de mixte énergétique et de demande croissante. L'un des défis majeurs auxquels ces gestionnaires sont confrontés consiste à maintenir un équilibre constant entre la production et la demande d'énergie afin d'éviter des dysfonctionnements, des variations de tension et de fréquence indésirables, ainsi que des déséquilibres coûteux [1]. Dans ce dynamisme, la compréhension de la relation entre la demande et l'offre d'énergie joue un rôle important pour optimiser l'achat de l'électricité à l'échelle mondiale [2]. En

effet, la demande d'électricité exerce une influence significative sur les prix de l'énergie, lesquels peuvent varier de manière extraordinaire sur des périodes très courtes d'ordre, allant de 15 minutes à 24 heures, entraînant parfois des conséquences graves pour certaines entreprises [2]. Des innovateurs du monde de l'énergie cherchent à atténuer ces risques en isolant les pics de demandes à des moments plus propices ou en déplaçant la consommation électrique des consommateurs vers des périodes où les tarifs sont plus bas [2][3]. Cependant, ces approches nécessitent des connaissances approfondies des habitudes de consommation des utilisateurs, ce qui n'est pas toujours évident à obtenir. En ce qui concerne la

tarification dynamique, bien qu'elle puisse refléter le coût de production de l'électricité et améliorer les bénéfices des fournisseurs, elle ne protège pas toujours les clients contre la volatilité des tarifs [4]. Ainsi, pour anticiper la demande électrique de manière plus précise, il est impératif de recourir à des modèles de prédiction. Plusieurs méthodologies sont disponibles à cet effet, notamment la méthode globale, la méthode analytique et la méthode d'intelligence artificielle, chacune ayant ses avantages en fonction de l'historique des données disponibles et du niveau de développement du réseau électrique [5][6][7]. Cette première méthode, qualifiée de méthode globale, repose sur l'analyse de la relation historique entre la consommation d'électricité et des indicateurs macro-économiques tels que le PIB ou la taille de la population [5]. La prédiction de la demande est effectuée sous l'hypothèse que la corrélation entre les variables restera stable à l'avenir. Cela est un fait qui n'est pas toujours avéré. Elle est appliquée dans les pays où la croissance de leurs demandes est relativement prévisible et que leurs historiques de consommation sont collectés. Parmi les pays qui appliquent cette approche, on peut citer le Bénin, le Burkina Faso, la Côte d'Ivoire, le Ghana, le Mali, le Togo et le Sénégal [5].

La seconde purement analytique procède à une décomposition de la demande d'électricité en fonction des secteurs d'activité et des zones géographiques, avant d'agréger ces données au niveau national [5]. C'est une approche mise en œuvre dans quelques pays comme la Gambie, la Guinée, la Guinée-Bissau, le Libéria, le Niger et le Sierra Leone [5]. Bien que cette méthode permette une prédiction précise de la demande, elle est complexe en raison de la diversité des données à traiter et de la segmentation spécifique requise pour chaque modèle. Face à la complexité de ces deux modèles et à la remise en question parfois observée de leur précision, l'utilisation de modèle d'IA se révèle être une alternative prometteuse pour la prédiction de la demande énergétique. Un modèle d'IA dédié à la prédiction de la consommation électrique est un système informatique basé sur l'apprentissage automatique et les réseaux de neurones, qui s'appuie sur des données historiques [8][9]. Ces modèles jouent un rôle essentiel en l'optimisant la production et la distribution d'électricité, en améliorant la planification et en permettant une réponse proactive aux variations de la demande [9][10][11]. De nombreuses plateformes de big data font désormais appel aux modèles d'IA pour améliorer la gestion des réseaux électriques [12][13]. Des résultats prometteurs ont été obtenus dans la détection des surtensions dans les réseaux de basse tension (BT) et de moyenne tension (MT) [12]. Des études menées au Sénégal sur la prédiction de la puissance et de l'énergie solaire et éolienne, ont permis d'obtenir des performances impressionnantes, avec des erreurs absolues moyennes de 0.0223kWh et 0.003 kWh en erreur quadratique moyennes [14][15]. En ce qui concerne la prédiction de la charge électrique à très court terme, l'IA a démontré son efficacité en matière de prévention et de la détection des pannes du réseau, assurant ainsi une alimentation électrique stable, même

face à des variations rapides de la demande [16][17][18]. En comparant aux modèles traditionnelles, les résultats de certaines études ont montré une amélioration significative de la précision avec une réduction d'erreur MAE de 0.12 kWh [16]. Malgré les progrès réalisés dans le domaine d'IA, au Sénégal, seule la méthode globale est expérimentée pour prédire la demande d'énergie électrique. Ce travail vise à évaluer la demande d'énergie au niveau national du Sénégal, en tenant compte du PIB de la population Sénégalaise. L'objectif est d'évaluer la précision du modèle par rapport aux différents horizons déjà explorés par le modèle global. Les résultats obtenus seront une grande importance pour les gestionnaires du réseau électrique de la SENELEC ainsi que pour les décideurs, car ils permettront de mieux comprendre l'évolution de la demande d'électricité et les principaux facteurs qui l'influencent. En d'autres termes, la prédiction de la demande d'électricité en horizon annuelle grâce à la méthode de l'IA permet aux décideurs politiques, aux fournisseurs d'électricités et même aux utilisateurs de prendre des décisions éclairées en matière d'achat d'électricité, de politique énergétique, etc. Pour mener à bien ce travail, nous suivons le plan suivant : La méthodologie est présentée dans la section suivante. Elle est suivie par la présentation des données et méthodes dans la troisième section, tandis que la quatrième section fournira une discussion détaillée de ces résultats. Enfin, la cinquième section conclura l'étude.

2. Matériels et méthodes

La population Sénégalaise est passée de 7 millions en 1990 à 18 millions en 2024, ce qui a entraîné une augmentation significative de la consommation électrique, passant de 902 GWh en 1990 à 6000 GWh en 2021 [19]. Cela a également entraîné une augmentation de la production électrique par la Senelec, comme illustré dans la figure 1




Figure 1 : Evolution de la consommation et de la production électrique

La production d'électricité dépasse constamment la consommation, ce qui entraîne des effets néfastes sur le plan économique, environnemental et sur la stabilité du réseau électrique. En effet, ce déséquilibre affecte

fréquemment la fréquence du réseau électrique. Il est donc nécessaire d'anticiper la consommation pour éviter ces problèmes.

Pour prédire la consommation électrique future, un modèle global était utilisé, applicable dans plusieurs pays tels que le Bénin, le Burkina Faso, la Côte d'Ivoire, le Ghana, le Mali, le Togo et le Sénégal. Ce modèle repose sur l'hypothèse que la corrélation entre les variables pertinentes restera stable dans le futur, permettant ainsi des prévisions fiables.

Cette approche globale est particulièrement adaptée aux pays où la croissance de la demande est relativement prévisible et où des données historiques de consommation sont disponibles. Cependant, avec l'avènement du Big Data, la quantité de données collectées a considérablement augmenté, soulignant la nécessité de développer des modèles plus performants. Par conséquent, l'intégration de modèles d'intelligence artificielle (IA) est de plus en plus essentielle pour améliorer la précision des prévisions de la demande énergétique. Ces modèles d'IA sont capables de traiter et d'analyser de vastes ensembles de données, offrant des perspectives plus détaillées et adaptées aux besoins spécifiques de chaque pays.

2.1. Présentation du modèle d'intelligence artificielle (IA).

Le modèle d'IA utilisé est de type réseau de neurone composé de plusieurs couches :

- ✓ Quatre (4) couches d'entrées : composée de 16 neurones avec des variables explicatives telles que le PIB, la population, la température et la date de prise en mesure. Aucun calcul n'est effectué dans ces couches.
- ✓ Plusieurs couches cachées déterminant le cœur des calculs pour l'optimisation des paramètres du modèle.
- ✓ Et une couche de sortie qui générera la consommation annuelle en électricité du Sénégal que nous voulons prédire.

Mathématiquement, une couche peut être exprimée par les expressions suivantes [Eq. 1], [Eq. 2] et [Eq. 3] [20]:

$$\sum_{j=1}^n (Y_j W_{ij}) + b_k = H \quad [\text{Eq. 1}]$$

$$g \sum_{i=1}^p (X_i W_{ij}) = Y(i) \quad [\text{Eq. 2}]$$

$$f \sum_{j=1}^p (Y_j W_{ij}) = C(t) \quad [\text{Eq. 3}]$$

Où :

- H : variable de la couche de sortie.
- Y_j: variable de sortie de la couche.
- X_j: variable d'entrée de la couche.
- W_{ij}: poids synaptiques.
- b_k: biais du neurone.

- f et g: fonction d'activation respective de la première couche et de la couche de sortie.

Ces fonctions d'activation sont des portiers pour les différents neurones. Elles décident si les neurones doivent être allumés ou éteints. Il y a plusieurs fonctions d'activations qu'on peut utiliser pour le processus de simulation de l'algorithme de réseau de neurone. On peut citer [21] :

- ✓ la fonction sigmoïde qui active ou désactive le neurone en fonction de l'entrée. Si l'entrée est supérieure au seuil, la fonction sigmoïde donne un poids de 1 et le contraire génère un poids de valeur 0 ;
- ✓ la fonction softmax prend en compte les sorties de tous les neurones d'une couche pour enfin choisir le neurone le plus influence à sa sortie terminale. Pour effectuer ce travail, elle se base sur les probabilités ;
- ✓ la fonction ReLu est plus sophistiquée justifiant d'ailleurs son emploi dans presque tous les algorithmes de réseau de neurones. Si la donnée d'entrée est supérieure à zéro, elle libère la même valeur positive activant le neurone, dans le cas contraire la fonction ReLu génère la valeur 0 pour éteindre le neurone.

Le réseau de neurone Récurrent de type Neural Fusion Shareware utilisé dans ce travail est illustré par la figure 2. Étant donné que les séquences de données sont aléatoires, nous allons étudier l'impact des variables utilisées pour une meilleure prévision.




Figure 2 : Réseaux multicouches [14].

Avec ce modèle on peut aussi appliquer la prédiction de la consommation d'électricité. Pour ce faire la technique visera à établir la relation entre la consommation d'électricité (variable dépendante) et celui des indicateurs macro-économiques tel le produit intérieur brut (PIB) ou la taille de la population (variables indépendantes). L'expression mathématique peut être formulée comme suite en [Eq. 4] [5] :

$$c(t) = a_0 + a_1 \times \text{PIB}(t) + a_2 \times \text{POP}(t) \quad [\text{Eq. 4}]$$

Où :

- ✓ c(t) représente la consommation d'électricité du pays pour l'année t.

- ✓ PIB(t) représente le PIB du pays pour l'année t.
- ✓ POP(t) représente la population du pays pour l'année t.

Le modèle neuronal utilisera les données historiques de la consommation d'électricité, le PIB et la population du pays à l'instant initial pour effectuer des prévisions annuelles dans le pays appliqué. Cependant, pour mieux anticiper les fluctuations de la demande d'électricité à différentes échelles de temps, facilitée ainsi une planification plus précise de la production et de la distribution d'électricité, des horizons annuelle et mensuelles peuvent être explorés pour la demande énergétique en basse tension (BT) et celle en moyenne tension (MT) au Sénégal. Dans le cadre de la demande d'énergie en basse tension (DE_BT), le modèle prend en compte la population, le PIB secondaire et le PIB tertiaire. L'expression mathématique est donnée en [Eq.5] par [5].

$$DE_BT = -226,38 + 12,562 \times POP + 0,208 \times PIB_SEC + 0,255 \times PIB_TER \quad [Eq. 5]$$

Où POP représente la population en millions d'habitants, PIB_SEC représente le PIB secondaire en milliards de FCFA de l'année considérée, et PIB_TER représente le PIB tertiaire en milliards de FCFA de l'année considérée.

L'application de cette équation permet de prédire la demande d'énergie en basse tension en fonction de la croissance de la population et du développement économique dans les secteurs secondaire et tertiaire. Quant à la demande d'énergie en moyenne tension (DE_MT), il prendra en compte le nombre de ménages, le PIB primaire et le PIB secondaire. L'équation [Eq.6] est utilisée pour exprimer son application [10]:

$$DE_MT(GWh) = -64,02 + 0,054 \times NB_MENAGES + 0,097 \times PIB_PRIM + 0,137 \times PIB_SEC \quad [Eq. 6]$$

Où NB_MENAGES : représente le nombre de ménages en milliers, PIB_PRIM : représente le PIB primaire en milliards de FCFA de 1999, et PIB_SEC : représente le PIB secondaire en milliards de FCFA de 1999.

Cette expression mathématique nous permet de prédire la demande d'énergie en moyenne tension en fonction du nombre de ménages ainsi que du développement économique dans les secteurs primaire et secondaire. Les données historiques utilisées par notre modèle seront fournies par la banque mondiale et la FMI.

Une technique sera applicable pour voir l'impact de ces variables utilisées pour la prédiction de la consommation électrique.

2.2. Technique de sélection des variables.

Plusieurs approches sont couramment utilisées pour la sélection de variables. Parmi lesquels on peut citer les méthodes basées sur la sélection de modèles offrent

l'avantage d'une automatisation complète, car elles identifient automatiquement les variables à retenir. Toutefois, leurs implémentations actuelles, qui reposent souvent sur des stratégies de sélection avant-arrière (forward-backward), peuvent limiter leur utilisation avec des données de très haute dimension. Et les méthodes utilisant des pénalisations de type lasso se distinguent par leur rapidité et leur efficacité, même lorsqu'elles sont appliquées à des ensembles de données de très grande dimension. Dans la figure 3, nous présentons l'impact des variables indépendantes utilisées pour prédire la consommation d'électricité, qui est la cible illustrée dans la figure 3.




Figure 3 : Techniques de sélection des variables importantes.

L'évaluation de l'impact des variables explicatives dans la figure 3 est parfaitement conforme à la matrice de corrélation présentée dans la figure 4. Le PIB a le plus fort impact positif sur la prédiction de la consommation, avec une corrélation estimée à 0,99 dans la matrice. Il est suivi par la variable population avec une corrélation de 0,96, puis la température à 0,94, et enfin la variable Date à 0,38.




Figure 4 Matrice de corrélation des variables explicatives en fonction de la cible à prédire.

Une fois les variables pertinentes pour la prédiction de la consommation électrique sélectionnées, nous procéderons à la subdivision des données.

2.3. Création des lots de données

La création des lots de données est une étape importante pour la mise en place d'un modèle d'IA. Elle permet d'organiser les données en ensemble d'entraînement, de validation, et de test. En divisant les données de manière adéquate, on peut éviter le sous-apprentissage (underfitting) et le sur-apprentissage (overfitting) afin de mieux s'assurer que le modèle généralise bien sur des données qu'elle n'a jamais vues. Dans la figure 5, nous pouvons observer la subdivision de notre base de données en deux parties : 80 % pour l'entraînement et 20 % pour le test. Cette répartition a été appliquée une fois que le taux d'erreur était jugé satisfaisant.

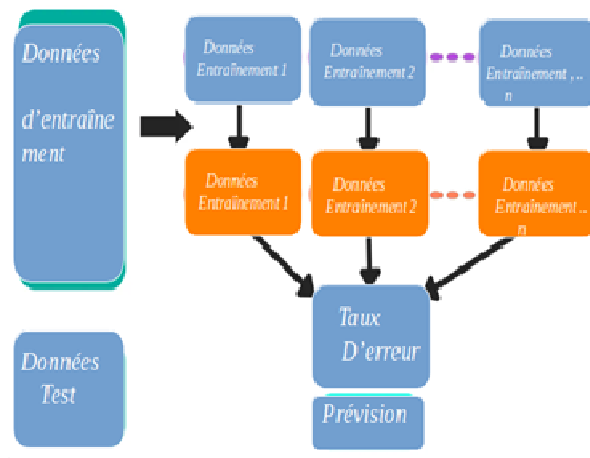


Figure 5 : Schéma de séparation des lots de données

Ces étapes sont aussi cruciales pour évaluer la performance du modèle.

2.4. Paramètres d'Évaluation des performances

Dans le cadre de ce travail, nous avons utilisé la normalisation min-max qui a été déjà appliquée dans les travaux précédentes [14] pour mettre nos données à l'échelle comprise entre 0 et 1. La formule mathématique utilisée est donnée comme suite en [Eq. 7]:

$$\frac{X - X_{\min}}{X_{\max} - X_{\min}} = X_{\text{norm}} \quad [\text{Eq. 7}]$$

$$X \in [X_{\min}, X_{\max}]$$

X et X_{norm} représentent respectivement les données réelles de l'énergie et les données normalisées.

X_{\min} et X_{\max} désignent respectivement les valeurs minimales et maximales de nos variables d'entrée du modèle. Après la normalisation, nous procéderons à l'application des paramètres de performances pour évaluer notre prédiction. Les équations mathématiques

employées sont présentées en [Eq. 8], [Eq. 9], [Eq. 10] et [Eq. 11] [14-15], [22] :

$$\frac{1}{N} \sum_{i=1}^N |Y_i - Y_t| = \text{MAE} \quad [\text{Eq. 8}]$$

$$\sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - Y_t)^2} = \text{RMSE} \quad [\text{Eq. 9}]$$

$$\frac{1}{N} \sum_{i=1}^N (Y_i - Y_t)^2 = \text{MSE} \quad [\text{Eq. 10}]$$

$$1 - \frac{\sum_{i=1}^N (Y_i - Y_t)^2}{\sum_{i=1}^N Y_i^2} = R^2 \quad [\text{Eq. 11}]$$

Toutes ces équations évaluent les paramètres de performances utilisés pour mesurer la précision de la consommation prédite par l'algorithme d'IA. Lors de la modélisation, le nombre d'époques est utilisé pour permettre au modèle neuronal de voir l'intégralité des données. Ce nombre d'époques forme le réseau de neurones pour effectuer des prédictions permettant d'aboutir aux résultats attendus.

3. Résultats

La connaissance en temps réel de la consommation électrique du Sénégal est cruciale pour maintenir l'équilibre entre la production et la demande à tout moment. La précision de ces données impacte directement la stabilité et la fiabilité du réseau électrique.

3.1. Prédiction de la consommation avec le modèle d'intelligence.

Les premières prévisions du modèle d'IA sont représentées dans les figures 6 et 7. La ligne rouge en pointillés ($y=x$) représente la situation idéale où les valeurs prédites correspondent parfaitement aux valeurs observées. Pour la figure 6 appliquée dans les données d'entraînement, les points violets représentant les prédictions se trouvent majoritairement alignés le long de la ligne de référence. Cela indique que le modèle a une bonne capacité prédictive sur l'ensemble des données d'entraînement. Nous avons observé aussi une performance positive presque similaires sur les données de test matérialisée par la figure 7. Les points verts représentant les valeurs prédites par le modèle se rapproche parfaitement à la situation idéale représentée en pointillés rouge. Cette proximité est un indicateur de précision de prédiction du modèle.

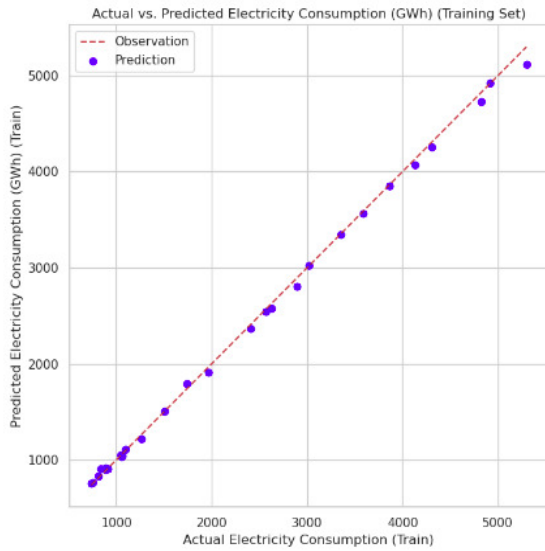


Figure 6 : Consommation Électrique observée avec celle Prédite (Ensemble d'Entraînement)

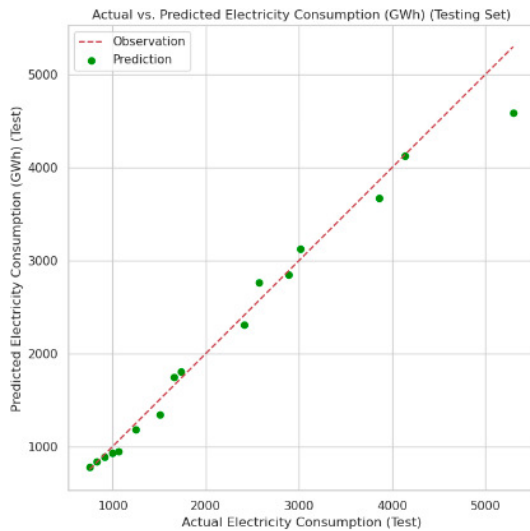


Figure 7 : Consommation Électrique observée avec celle Prédite (Ensemble Test)

Pour mieux comprendre les prévisions apportées par le modèle d'IA, nous allons visualiser la consommation électrique réelle du Sénégal à celle prédite à partir des figure 8 et 9. La figure 8 montre une augmentation générale de la consommation électrique au fil des années, avec des fluctuations notables, notamment autour des années 2000. Ces variations peuvent refléter des événements économiques ou des changements dans les infrastructures énergétiques. Malgré cela, la courbe des prédictions (en pointillés jaunes) suit de très près la courbe des valeurs réelles (en bleu). Cette proximité indique que le modèle d'IA capture bien les tendances historiques de la consommation électrique dans l'ensemble des données d'entraînement (Fig. 8). Cependant, Il existe quelques écarts mineurs entre les courbes, particulièrement dans les périodes de changements (par exemple, autour des années 2000 et

2019). Mais ces écarts semblent relativement faibles, ce qui suggère une bonne performance globale du modèle sur les données d'entraînement.




Figure 8 : Consommation Électrique observée contre celle Prédite de 1990 à 2020 (Ensemble d'Entraînement)

La forte correspondance entre les courbes de la figure 8 montre que le modèle est bien ajusté aux données d'entraînement, capable de prédire avec précision la consommation électrique basée sur les variables d'entrée (PIB, population, température et la date). Cette performance positive est confirmée par les résultats du modèle appliqués aux données de test comme on peut le voir à la figure 9. Le modèle d'IA montre une forte capacité à reproduire les tendances historiques de la consommation électrique du Sénégal, avec une correspondance étroite entre les valeurs réelles et prédites sur l'ensemble des données test. Cela prouve la robustesse et la généralisation du modèle qu'on peut s'attendre à d'autres types de données qu'elle n'a jamais vue.

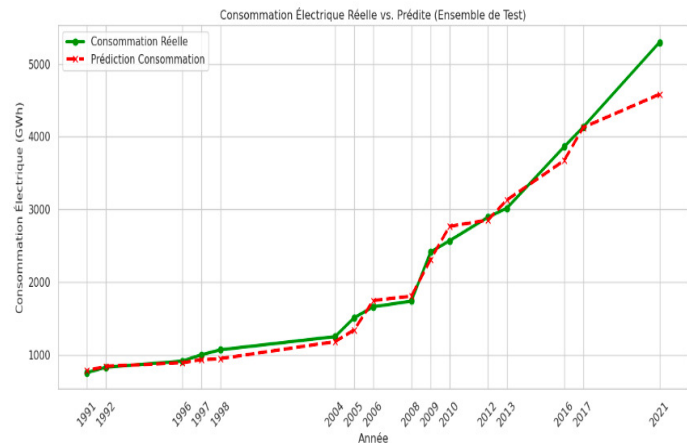


Figure 9 : Consommation Électrique observée contre celle Prédite de 1991 à 2021 (Ensemble Test)

3.1. Prédiction de la consommation avec le modèle globale.

La figure 10 compare la consommation électrique réelle et prédite au Sénégal de 1990 à 2021 en utilisant un modèle global basé sur la régression linéaire. La courbe rouge représente la consommation réelle, tandis que la courbe bleue montre les prédictions du modèle. Le coefficient de détermination (R^2) est de 0,87, ce qui indique que le modèle explique 87 % de la variance des données observées. Cependant, il y a des écarts notables entre les prédictions et les valeurs réelles, particulièrement après 2005, où les prédictions semblent sous-estimer ou surestimer la consommation réelle, ce qui suggère des limitations du modèle à capturer les variations non linéaires et les tendances complexes dans les données. Ces résultats mettent en évidence que, bien que le modèle global fournisse une approximation raisonnable, il pourrait bénéficier de l'intégration de techniques plus sophistiquées pour améliorer la précision des prévisions.

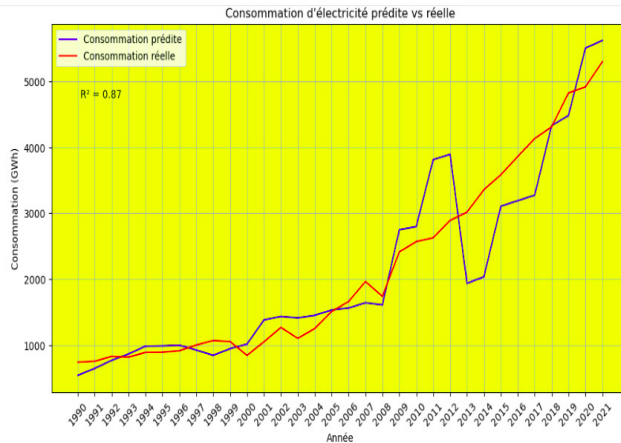


Figure 10: Consommation Électrique observée contre celle Prédite de 1990 à 2021 (Ensemble Test)

Ces écarts dans ces prédictions mettent en lumière l'importance sur l'utilisation des modèles d'IA afin d'améliorer la précision des prévisions. Nous procéderons à une comparaison approfondie des performances des deux modèles dans la section suivante.

3.3. Comparaison des performances des deux modèles.

Le tableau 1 compare les performances du modèle global et celui du modèle d'intelligence artificielle (IA) pour prédire la consommation électrique. Le modèle d'IA surpasse nettement le modèle global, avec un coefficient de détermination (R^2) de 0,998 contre 0,87, indiquant une meilleure précision des prédictions. De plus, le modèle d'IA présente une erreur quadratique moyenne (RMSE) plus faible de 1,9 GWh, ce qui traduit une meilleure qualité de prédiction. L'erreur absolue moyenne (MAE) est également beaucoup plus faible pour le modèle d'IA, à 0,0141 GWh, comparée à

1,205 GWh pour le modèle global. Ces résultats démontrent l'efficacité supérieure du modèle d'IA dans la prédiction de la consommation électrique.

En somme, l'utilisation de l'intelligence artificielle dans ce contexte améliore considérablement la qualité des prévisions de consommation électrique, rendant ce modèle plus adapté pour des applications nécessitant une haute précision.

Tableau 1.: Tableau comparatif des performances sur les types de contraintes

Modèles	Paramètres de performance		
	R^2	RMSE	MAE
Méthode globale	0.87	3.29 GWh	1.205 GWh
Méthode d'intelligence artificielle	0.998	1.9 GWh	0.0141 GWh

4. Conclusion

La prédiction de la consommation électrique joue un rôle crucial dans la stabilité du réseau. En effet, un déséquilibre entre la consommation et la production peut perturber le réseau, ce qui nécessite des méthodes de prévision efficaces pour anticiper les besoins en énergie. C'est dans cette optique que cet article propose un modèle d'intelligence artificielle visant à améliorer la précision des prédictions par rapport au modèle global. Ce modèle d'IA a été entraîné en utilisant des variables telles que le PIB, la population, la température, et la date des mesures, pour prédire la consommation électrique du Sénégal entre 1990 et 2022. Les résultats montrent une amélioration significative de la précision des prédictions. Les coefficients de détermination R^2 sont de 0,998 pour le modèle d'IA, contre 0,870 pour le modèle global. Les valeurs de l'erreur absolue moyenne (MAE) et de la racine carrée de l'erreur quadratique moyenne (RMSE) pour le modèle d'IA sont respectivement de 0,0141 GWh et 1,9 GWh, ce qui souligne le potentiel prometteur de l'IA pour maintenir l'équilibre entre la consommation et la production, garantissant ainsi la stabilité du réseau électrique.

REFERENCES

- [1] M. Dieng, A. Ndoye, M. S. Sow, and A. Wane, "Energy consumption forecasting using artificial neural networks: A case study of Senegal," 2015 IEEE International Conference on Industrial Technology (ICIT), Seville, Spain, 2015, pp. 2432-2437.
- [2] Moglen, Rachel L.; Chanpiwat, Pattanun; Gabriel, Steven A.; Blohm, Andrew (2020). Optimal thermostatically controlled residential demand response for retail electric providers. Energy Systems, (), -. doi:10.1007/s12667-020-00400-0.
- [3] Boroumand, R.H., Goutte, S., Porcher, S., Porcher, T.: Hedging strategies in energy markets: The case of electricity retailers. Energy Economics 51, 503–509 (2015).

- <https://doi.org/10.1016/j.eneco> .2015.06.021.
<http://www.sciencedirect.com/science/article/pii/S0140988315002170>
- [4] Jin, Ming; Feng, Wei; Marnay, Chris; Spanos, Costas (2017). Microgrid to enable optimal distributed energy retail and end-user demand response. *Applied Energy*, (), S0306261917306062-. doi:10.1016/j.apenergy.2017.05.103.
- [5] MISE À JOUR DU PLAN DIRECTEUR RÉVISÉ DE LA CEDEAO POUR LE DÉVELOPPEMENT DE LA CAPACITÉ DE PRODUCTION ET DE TRANSPORT D'ÉNERGIE ÉLECTRIQUE. TOME 2 : Etat des lieux de la situation actuelle du système électrique et perspectives.
- [6] Bellahsen, A. (2020). L'Intelligence Artificielle Au Service De L'Optimisation De L'Énergie Électrique Dans Un Réseau Intelligent (Doctoral dissertation, Ecole Polytechnique, Montréal (Canada)).
- [7] S. Diop, P. S. Traore and M. L. Ndiaye, "Wind Power Forecasting Using Machine Learning Algorithms," 2021 9th International Renewable and Sustainable Energy Conference (IRSEC), Morocco, 2021, pp. 1-6, Doi: 10.1109/IRSEC53969.2021.9741109.
- [8] Habbak, H., Mahmoud, M., Metwally, K., Fouda, M. M., & Ibrahim, M. I. (2023). Load forecasting techniques and their applications in smart grids. *Energies*, 16(3), 1480.
- [9] Aguiar-Pérez, J. M., & Pérez-Juárez, M. Á. (2023). An Insight of Deep Learning Based Demand Forecasting in Smart Grids. *Sensors*, 23(3), 1467.
- [10] Motamedi, A., Zareipour, H., & Rosehart, W. D. (2012). Electricity price and demand forecasting in smart grids. *IEEE Transactions on Smart Grid*, 3(2), 664-674.
- [11] Muralitharan, K., Sakthivel, R., & Vishnuvarthan, R. (2018). Neural network-based optimization approach for energy demand prediction in smart grid. *Neurocomputing*, 273, 199-208.
- [12] Bozorg, M., Fatemi, N., Pena, C. A., Mousavi, O., & Carpita, M. (2020). L'intelligence artificielle au service des réseaux: le projet Grid Data Digger. *Bulletin. Ch= Fachzeitschrift und Verbandsinformationen von Electrosuisse und VSE= Bulletin SEV/AES: revue spécialisée et informations des associations Electrosuisse et AES*.
- [13] Schaeken Willemaers, J. P. (2023). L'intelligence artificielle et l'énergie: Facteurs d'accomplissement et de réalisation des mutations sociétales. *L'intelligence artificielle et l'énergie*, 1-180.
- [14] Diop, S., Traore, P. S., & Ndiaye, M. L. (2022, October). Power and Solar Energy Predictions Based on Neural Networks and Principal Component Analysis with Meteorological Parameters of Two Different Cities: Case of Diass and Taïba Ndiaye. In 2022 IEEE International Conference on Electrical Sciences and Technologies in Maghreb (CISTEM) (Vol. 4, pp. 1-6). IEEE.
- [15] Diop, S., Traore, P. S., Niang, B., & Ndiaye, M. L. (2022, October). Using multilayer Neural Network to increase the Prediction Accuracy: application in the Taïba Ndiaye Power Plant. In 2022 IEEE International Conference on Electrical Sciences and Technologies in Maghreb (CISTEM) (Vol. 4, pp. 1-6). IEEE.
- [16] A. Dey, S. Kumar, and S. Rajasegarar, "Short-Term Load Forecasting Using LSTM Recurrent Neural Network," in *IEEE Transactions on Industrial Informatics*, vol. 17, no. 11, pp. 7817-7824, Nov. 2021.
- [17] R. Fu, L. Liu, and W. Yu, "Hourly Load Forecasting in Distribution Grids Using a Deep Neural Network Model," in *IEEE Transactions on Industrial Informatics*, vol. 16, no. 11, pp. 7133-7141, Nov. 2020.
- [18] X. Yang, X. Zou, and B. Zhang, "Short-Term Load Forecasting Based on XGBoost Algorithm," in *IEEE Transactions on Industrial Informatics*, vol. 15, no. 9, pp. 5202-5210, Sept. 2019.
- [19] Agence Nationale de Statistiques et de Démographie, 2024; Rapport sur l'Énergie, Organisation Internationale de l'Énergie, 2023
- [20] F.-V. Gutierrez-Corea, M.-A. Manso-Callejo, M.-P. Moreno-Regidor, and M.-T. Manrique-Sancho, "Forecasting short-term solar irradiance based on artificial neural networks and data from neighboring meteorological stations," *Solar Energy*, vol. 134, pp. 119-131, Sept. 2016.
- [21] BOUREK, Yacine (2016) ETUDE DE LA DECHARGE ELECTRIQUE PAR L'INTELLIGENCE ARTIFICIELLE. Doctorat thesis, Université de Batna 2.
- [22] S. Diop, P. S. Traore, M. L. Ndiaye, and I. Zerbo, "Using Artificial Intelligence Models to Predict the Wind Power to be Fed into the Grid," *Journal of Engineering Research and Sciences*, vol. 3, no. 6, pp. 1-09, 2024. Doi: 10.55708/js0306001.