

REPUBLIQUE DU CAMEROUN
Paix-Travail-Patrie

UNIVERSITE DE YAOUNDE I

CENTRE DE RECHERCHE ET DE
FORMATION DOCTORALE EN SCIENCES,
TECHNOLOGIES ET GEOSCIENCES

UNITE DE RECHERCHE ET DE
FORMATION DOCTORALE EN
PHYSIQUES ET APPLICATIONS

B.P 812 Yaoundé
Email: crfd_stg@uy1.uninet.cm



REPUBLIC OF CAMEROON
Peace-Work-Fatherland

THE UNIVERSITY OF YAOUNDE I

POSTGRADUATE SCHOOL OF
SCIENCES, TECHNOLOGY AND
GEOSCIENCES

RESEARCH AND POSTGRADUATE
TRAINING UNIT FOR PHYSICS
AND APPLICATIONS

P.O. Box 812 Yaoundé
Email: crfd_stg@uy1.uninet.cm

Département de Physique
Department of Physics

Laboratoire d'Energie, Système Électronique et Électrique
Laboratory of Energy, Electric and Electronic Systems

**PREVISION DE LA DEMANDE EN ENERGIE
ELECTRIQUE AU CAMEROUN PAR LES
METHODES DE REGRESSIONS ET DES
RESEAUX DE NEURONE ARTIFICIEL**

THÈSE

*Rédigée et Présentée en vue de l'obtention du diplôme de Doctorat/Ph.D. en
Physique*

Option: *Energie et Environnement*

Par

NZOKO TAYO Dieudonné
Matricule: 06W451
Master of Science in Physics

Sous la Supervision de

TCHINDA René, *Professeur (UDs,*



2023

PRÉVISION DE LA DEMANDE EN ÉNERGIE ÉLECTRIQUE AU CAMEROUN PAR LES MÉTHODES DE RÉGRESSION ET DES RESEAUX DE NEURONE ARTIFICIEL

Laboratoire d'Énergie, Systèmes Électriques et Électroniques

Thèse Rédigée et Présentée en vue de l'obtention du diplôme de

Doctorat/Ph.D. en Physique

Option :Énergie et Environnement

Par

NZOKO TAYO Dieudonné

Matricule : 06W451

Master of Science en Physique

Sous la supervision de :

TCHINDA René

Professeur

Université de Dschang

Année :2023

Table des matières

Liste des figures	viii
Liste des tableaux	x
Dédicace	xi
Remerciements	xii
Resumé	xv
Abstract	xvi
Liste des abréviations	xvii
Introduction générale	1
1 Situation énergétique du Cameroun et état de l'art sur les prévisions de la consommation d'énergie électrique	4
1.1 Situation actuelle du secteur électrique au Cameroun	5
1.1.1 Historique de l'énergie électrique	5
1.1.2 Contexte général	7
1.1.3 L'offre et la demande d'énergie électrique	8
1.1.4 La production d'électricité	9
1.1.5 Répartition de la production électrique	9
1.1.6 Répartition des centrales électriques	11
1.1.7 La consommation d'électricité	11
1.1.8 Causes du déficit énergétique	12

1.1.9	Comment réduire le déficit énergétique ?	13
1.2	État de l'art des modèles de prévision de la consommation électrique	14
1.2.1	Les modèles statistiques	15
1.2.1.1	Le modèle Auto-Régressif(AR)	16
1.2.1.2	Le modèle de moyenne mobile(MA)	16
1.2.1.3	Le modèle de moyenne mobile autorégressive ARMA (p,q)	17
1.2.1.4	Le modèle ARIMA(p,q,d)	17
1.2.1.5	L'Algorithme de filtrage de Kalman dans l'espace d'état	18
1.2.1.6	Les modèles grey (GM)	20
1.2.1.7	Le modèle de lissage exponentiel(ES)	22
1.2.1.8	Le modèle VAR/VECM	23
1.2.1.9	Le modèle combiné ou régression linéaire multiple	24
1.2.2	Les modèles d'intelligence artificielle, d'intelligence computationnelle ou d'apprentissage automatique (Machine Learning)	25
1.2.2.1	Le modèle des réseaux de neurones artificiels(ANN)	25
1.2.2.2	Le modèle de logique floue	28
1.2.2.3	L'algorithme génétique(AG)	31
1.2.2.4	Les systèmes experts	33
1.2.3	Les méthodes hybrides et classification complète des modèles de prévision	34
1.2.4	Les horizons de prévision	35
1.3	Brève revue systémique de la littérature sur la prévision de la charge électrique .	38
1.4	Les émissions de CO_2 par La production d'électricité	51

2 Modélisation des consommations de l'énergie électrique à court et à long terme par les méthodes économétriques, d'intelligence artificielle et des modèles hybrides 53

2.1	Définitions	54
2.2	Les méthodologies des modèles économétriques	55
2.2.1	La statistique descriptive	55
2.2.2	Présentation générale de la théorie de corrélation	55
2.2.3	La mesure du coefficient de corrélation	56
2.2.4	La notion de série chronologique stationnaire	58

2.2.5	Les test de racine unitaire	58
2.2.5.1	Le test de Dickey-Fuller augmenté (ADF)	58
2.2.5.2	Le test de Phillips-Perron	60
2.2.5.3	Le test KPSS(1992)	61
2.2.5.4	Le test de co-intégration de Johansen	62
2.2.5.5	Le test F	63
2.3	Les modélisations	64
2.3.1	Le modèle VAR/VECM	64
2.3.2	Le lissage exponentiel de Holt	67
2.3.3	Le modèle hybride	68
2.3.4	Le modèle de régression	72
2.3.5	Les réseaux de neurones artificiels (RNA)	75
2.3.6	Le modèle hybride d'optimisation MLR-ANN-HES	81
2.3.7	Le deep learning ou apprentissage profond	83
2.3.8	La modélisation par la logique floue	86
2.4	Évaluation de la performance des modèles	92
2.5	Avantages et Inconvénients des modèles	94
2.6	Matériels utilisés	96
3	Résultats et discussions	98
3.1	Présentation des résultats	99
3.1.1	Prévisions à long terme	99
3.1.1.1	Présentations des données de Modélisation	99
3.1.1.2	Résultats du modèle VECM	105
3.1.1.2.1	Étape 1 : Tests de stationnarité et test du nombre de retard optimal	105
3.1.1.2.2	Étape 2 : Les résultats de co-intégration de Johansen. .	107
3.1.1.2.3	Étape 3 : Résultats de la dynamique à court et à long terme	109
3.1.1.2.4	Étape 4 : Estimation par la méthode du maximum de vraisemblance du modèle VECM et validation à l'aide des tests usuels	111

3.1.1.3	Résultats du modèle de lissage exponentiel de Holt(HES)	112
3.1.1.4	Résultats du modèle hybride VECM-HES	113
3.1.1.4.1	Influence du pas d'apprentissage (θ) dans l'algorithme du gradient descendant	113
3.1.1.4.2	Résultats expérimentaux et observations	114
3.1.1.4.3	Résultats du modèle hybride et comparaison	115
3.1.1.4.4	Intervalle de confiance	116
3.1.1.4.5	Comparaison des résultats avec ceux des modèles hy- brides similaires	118
3.1.1.5	Résultats du modèle de logique floue (FLS)	120
3.1.1.5.1	Fuzzification	120
3.1.1.5.2	Construction d'une base de règle	123
3.1.1.5.3	Prévision de la charge à base des règles floues établies .	125
3.1.2	Prévisions à court terme	129
3.1.2.1	Présentation et analyse des données	129
3.1.2.2	Résultats du modèle de régression linéaire multiple	130
3.1.2.2.1	Résultats et interprétation de l'estimation des para- mètres du modèle	130
3.1.2.2.2	Résultats et interprétations des tests	132
3.1.2.2.3	Prévisions du modèle de régression linéaire multiple . .	135
3.1.2.3	Résultats du modèle des réseaux de neurones artificiels	135
3.1.2.3.1	Prévision à un pas en avant sur une semaine	136
3.1.2.3.2	Analyse des erreurs d'entraînement, de validation et de test	137
3.1.2.3.3	Analyse de la réponse du réseau	138
3.1.2.4	Résultats du modèle de lissage exponentiel de Holt	139
3.1.2.4.1	paramètres du modèle de lissage exponentiel de Holt .	140
3.1.2.4.2	Comparaison entre les modèles de prédiction MLR, ANN et HES	141
3.1.2.5	Résultats du modèle hybride d'optimisation	142
3.1.2.5.1	Influence du pas d'apprentissage (θ) dans l'algorithme du gradient descendant	142

3.1.2.5.2	Résultats du modèle hybride et comparaison	144
3.1.2.5.3	Comparaison des résultats avec ceux des modèles hy- brides similaires	145
	Conclusion générale et perspectives	149
	Références bibliographiques	156
	Annexes	175
	Liste des publications de la thèse	182

Liste des figures

1.1 Répartition de la production électrique(Source : Rapport annuel ENEO, 2020)[9]	10
1.2 Répartition des centrales électriques(Source : Rapport annuel ENEO,2020)[9]	11
1.3 Evolution de l'offre et de la demande d'énergie électrique entre 2014-2022 (Source : ARCEL, 2021)	12
1.4 Classifications possibles des types de méthodes de prévision de base (source : adaptée par les auteurs)	15
1.5 Un perceptron	26
1.6 Le Perceptron Multi-couche	28
1.7 Diagramme d'un système flou	30
1.8 Une classification complète des modèles de prévision (source :Adapté par les auteurs)	35
1.9 Les différents horizons de prévisions[66]	37
1.10 Les secteurs concernés par la prévision de la charge électrique(source :adaptée par les auteurs)	38
2.1 Stratégie du test de Dickey-Fuller (Source : Hurlin, 2004)	60
2.2 Schéma simplifiée de la stratégie des tests de racine unitaire (test KPSS)[103]	62
2.3 organigramme de la recherche des paramètres du modèle hybride à partir de l'algorithme du gradient descendant	71
2.4 Type de perceptron utilisé	75
2.5 Le perceptron multicouche de prévision	77
2.6 Organigramme de la recherche des paramètres du modèle hybride d'optimisation	82
2.7 Architecture du réseau de neurone profond (DNN) utilisé	84

2.8	Visualisation des CNN pour les séquences avec entrées $I = \{y_{t-1}, y_{t-2}, \dots, y_{t-i}\}$ et les prévisions $\{\hat{Y}_{t-1}, \hat{Y}_{t-2}, \dots, \hat{Y}_{t-i}\}$.	86
2.9	Schéma fonctionnel de la méthode de logique floue utilisée	87
2.10	Fonctions d'appartenances utilisées	88
3.1	Évolution de la population du Cameroun entre 1975 et 2019	100
3.2	Évolution du produit intérieur brut par habitant entre 1975 et 2019	102
3.3	Évolution de la consommation annuelle d'électricité au Cameroun entre 1975 et 2019	104
3.4	Évolution des dépenses de consommation finale des ménages entre 1975 et 2019	105
3.5	Test de stabilité du modèle VECM	111
3.6	Intervalles de confiance et Profil de prévision de la consommation annuelle d'électricité au Cameroun	116
3.7	Courbes des prévisions de la consommation annuelle d'électricité au Cameroun pour chaque modèle étudié	117
3.8	Projection de la demande d'électricité au Cameroun en utilisant le scénario du statu-quo[133]	118
3.9	Fonction d'appartenance triangulaire pour le PIB prévue	121
3.10	Fonction d'appartenance triangulaire pour la variable population	122
3.11	Fonction d'appartenance triangulaire pour la charge électrique prévue	123
3.12	Représentation de la base des règles floues(Matrice de décision)	125
3.13	Représentation graphique des prévisions de la consommation annuelle d'électricités par le modèle FLS	127
3.14	La charge électrique consommée dans la ville de Yaoundé du 1er Janvier au 26 Janvier 2019	129
3.15	Test de CUSUM	134
3.16	Test du CUSUM Squares	134
3.17	Profil de prévision de la consommation d'électricité avec le modèle LRM pour 168h.	135
3.18	Evolution des erreurs d'entraînement, de validation et de test	138
3.19	Analyse de la réponse du réseau	139
3.20	Profil de prévision de la consommation d'électricité avec le modèle HES pour 168 h	141

- 3.21 Courbe comparative des prévisions de la consommation horaire d'énergie électrique dans la ville de Yaoundé sur une période d'une semaine (168 heures) . . . 145

Liste des tableaux

1.1	Parc de production électrique d'AES Sonel [9]	7
1.2	Synthèse comparative des modèles de prévision	49
2.1	Indicateurs de performances RMSE(%)	93
2.2	Indicateurs de performances MAPE (%)Source : Yadav et Chandel 2014	93
2.3	Avantages et inconvénients de chaque modèle	95
3.1	Tendances d'évolution future de la population du Cameroun [117] .	101
3.2	Tests de racine unitaire	106
3.3	Sélection et critère de l'ordre de décalage du modèle VAR	107
3.4	Test de co-intégration	108
3.5	Dynamique de long et de court terme[127]	109
3.6	Évaluation des prévisions	112
3.7	Paramètres du modèle	112
3.8	Variation du pas d'apprentissage en fonction de la précision et des erreurs du modèle	113
3.9	Comparaison du critère d'information d'Akaike (AIC) des différents modèles	114
3.10	Indicateurs de performances des modèles	114

3.11 Prévisions de la consommation électrique annuelle d'électricité au Cameroun(GWh)	115
3.12 Comparaison de l'erreur de prévision avec ceux des modèles hybrides similaires	119
3.13 Comparaison avec les modèles hybrides d'intelligence artificielle récents	119
3.14 Prévisions passées et future générées par le modèle de logique floue développé	126
3.15 Comparaison des résultats avec ceux des études similaires	128
3.16 Corrélations entre les consommations des jours de la semaine . . .	130
3.17 Statistiques de la régression	131
3.18 Tests statistiques, source : auteur à partir d'Eviews 10	133
3.19 Architectures du réseau et erreurs de prévision d'un pas en avant .	137
3.20 Paramètres du modèle, erreur d'apprentissage et validation du lissage	140
3.21 Paramètres des modèles retenus, erreur associée	142
3.22 Influence du pas d'apprentissage et la précision sur les coefficients du modèle hybride	143
3.23 Influence du Pas d'apprentissage et la précision sur les coefficients du modèle hybride	144
3.24 Comparaison de la précision avec ceux des modèles hybrides similaires	146

Dédicace

À

✠ Mes mamans : **KWOWA Gilberte, YONKIO Pauline,**

✠ La famille **NZOKO,**

✠ Toute la famille **NDJONGUE,**

✠ Ma femme **TCHOUSSE Nickel,**

✠ Mes Garçons **FANDIO Ismael et FEUSING Josy-mel,**

✠ Mon mentor **NANA John.**

Qui ont toujours été là pour moi, et qui m'ont donné un magnifique modèle de
labeur et de persévérance. J'espère qu'ils trouveront dans ce travail toute ma
reconnaissance et tout mon amour.

REMERCIEMENTS

Je voudrais adresser mes remerciements aux personnes dont la générosité, la bonne humeur et l'intérêt manifestés à l'égard de ma recherche m'ont permis de progresser.

♣ Je tiens tout d'abord à exprimer mes plus vifs remerciements à mon encadreur **Pr. TCHINDA René**, Directeur de L'UIT de Bandjoun dont son attention et la rigueur scientifique m'ont beaucoup appris. Son encadrement restera le moteur de mon travail de chercheur.

♣ Je voudrais exprimer ma gratitude Au **Dr. ALOYEM KAZE Claude**, Chef de Département à l'ENSET de Kumba. J'adresse ma reconnaissance pour le soutien constant, la gentillesse, la disponibilité sans faille, ainsi que les multiples conseils qu'il m'a prodigués tout au long de ce travail.

♣ J'adresse mes chaleureux remerciements au **Dr. TALA KONTCHOU Armel** Chargé de cours à L'Institut Universitaire de Technologies Fotso Victor de Bandjoun, de l'Université de Dschang, pour l'attention qu'il a porté sur ces travaux, pour ses conseils avisés et son écoute.

♣ J'adresse ma reconnaissance au **Professeur NDJAKA Jean Marie**, Chef du Département de Physique de la Faculté des Sciences de l'Université de Yaoundé I pour les encouragements et les multiples conseils qu'il m'a prodigués, ainsi qu'à tous les enseignants de ce Département pour la qualité de la formation reçue

depuis mon admission à l'Université de Yaoundé I.

♣ J'adresse ma reconnaissance au Chef du Laboratoire d'Energie, le **Professeur SIMO Elie**, pour son soutien et sa contribution administrative.

♣ J'exprime ma gratitude aux enseignants et associés du Laboratoire d'Energie, des Systèmes Electriques et Electroniques (LESEE), notamment les **Professeurs NJOMO Donatien, NGANHOU Jean, KUITCHE Alexis, ESSIMBI ZOBO Bernard, BODO Bertrand, MBIYA MOTTO, AKANA, OBOUNOU Marcel(de regretté mémoire)** pour la qualité des enseignements reçus, leurs conseils et surtout pour leur disponibilité.

♣ J'exprime toute ma reconnaissance **aux Professeurs : NJANDJOCK NOUCK Philippe, DJUIDJE KENMOE Germaine, TCHUEN Ghislain et SIMO Elie, membres du jury de cette thèse**, pour le précieux temps qu'ils ont bien voulu sacrifier afin d'examiner ce présent travail.

♣ Mes plus profonds remerciements vont à mes parents, ma famille qui, tout au long de mon cursus, m'ont toujours soutenu, encouragé et aidé. Ils ont su me donner toutes les chances pour réussir. Qu'ils trouvent, dans la réalisation de ce travail, l'aboutissement de leurs efforts ainsi que l'expression de ma plus affectueuse gratitude.

♣ Mes remerciements vont également à toute ma famille et particulièrement ma femme **TCHOUSI Nickel** pour leur confiance inconditionnelle et leur soutien à toute épreuve. Qu'ils trouvent ici l'expression de ma profonde affection.

♣ J'exprime ma reconnaissance à l'endroit de tous **mes collègues** de service pour leurs multiples conseils et leur soutien sans faille.

♣ J'exprime ma reconnaissance à l'endroit de tous les Etudiants du LESEE/UY1 pour leur disponibilités et échanges que nous avons eus. Je pense notamment à **DJEUDJO TEMENE, FOSSI Rodrigue, SEUKOU, WAKAM Aser**

pour leurs soutiens multiforme.

♣ Je ne saurai oublier de remercier tous mes amis **DJIOJIP AUDREY, GUIMFACK Boris, SAMO Beltus, TANEKEU Vincent, NGAMCHUT GUY, KAMGUEP Joel, BENGUE Peaul**, pour leurs soutiens multiforme.

♣ Pour finir, je souhaiterais donner le plus fort des remerciements à mes frères et soeurs, ma belle-famille. Je pense particulièrement à **KEMAYOU Rodrigue, Rosine NZOKO, Duplex NGONGANG, NGUEMEGNI Sorel, KOUA-MEGNI Michael**. Vous m'avez toujours soutenu et aidé chaque fois que j'ai eu besoin et c'est grâce à vous que je suis à ce stade. "**L'Eternel est mon berger je ne manquerai de rien**".

♣ Je tiens à remercier tous ceux qui, de près ou de loin, m'ont soutenu dans la recherche d'une manière ou d'une autre et dont le nom ne figure dans les remerciements.

RESUMÉ

L'objectif principal de cette thèse est de construire des modèles de prévision et de gestion efficace de l'énergie électrique disponible au Cameroun. Dans cette optique, nous avons proposé des modèles numériques optimaux basés sur les méthodes hybrides d'intelligence artificielle et les méthodes de l'économétrie. Pour les prévisions à long terme, le modèle vectoriel à correction d'erreur (VECM), le lissage exponentiel de Holt (HES), la logique floue (FLS) et le modèle hybride (VECM-HES) ont été utilisés. Dans le cadre des prévisions à court terme, les modèles de régression linéaire multiple (MLR), le lissage exponentiel de Holt (HES), les réseaux de neurones artificiels (ANN), les réseaux de neurones profonds (CNN et DNN) ainsi que le modèle hybride (ANN-LRM-HES) ont été utilisés. Une étude comparative des différents résultats obtenus par les modèles hybrides (VECM-HES) et (ANN-LRM-HES) montrent que, ces modèles affichent une marge d'erreur relativement faible, comparée aux marges d'erreurs obtenues dans la littérature. On conclut donc que ces modèles hybrides proposés sont mieux appropriés pour nos calculs prévisionnels. Pour les prévisions à long terme, les résultats montrent qu'au même titre que l'évolution de la population, la consommation d'énergie électrique a une tendance croissante. Elle va de 7169.031 GWh en 2020 à 8134.772 GWh en 2024 soit une augmentation de 965.741 GWh en cinq ans.

Mots clés : *Électricité; Prévision à long terme; Prévision à court terme; Modèle hybride; Logique floue.*

ABSTRACT

The main objective of this thesis is to build models for forecasting and efficient management of the electrical energy available in Cameroon. With this in mind, we have proposed optimal numerical models based on hybrid methods of artificial intelligence and methods of econometrics. For the long-term forecasts, the vector error correction model (VECM), the exponential smoothing of Hol (HES), the fuzzy logic (FLS) and the hybrid model (VECM-HES) were used. In the context of short-term forecasting, multiple linear regression (MLR) models, Hol exponential smoothing (HES), artificial neural networks (ANN), deep neural networks (CNN and DNN) as well as the hybrid model (ANN-LRM-HES) were used. A comparative study of the different results obtained by the hybrid models VECM-HES and ANN-LRM-HES show that these models display a relatively low margin of error, compared to the margins of error obtained by similar models existing in the literature on the subject. We therefore conclude that these proposed hybrid models are better suited for our forecasting calculations. In continuation for the long-term forecasts, the results obtained also allow us to conclude that in the same way as the evolution of the population, the consumption of electric energy has an increasing tendency. According to our forecasts, it goes from 7169,031 GWh in 2020 to 8134,772 GWh in 2024, an increase of 965,741 GWh in five years.

Keywords : *Electricity ; Long term forecast ; Short-term forecast ; Hybrid model ; Fuzzy logic.*

LISTE DES ABRÉVIATIONS

- AE-BLSTM** :Autoencoder bidirectional long short-term memory ACTIS
- ADF** :Augmented dickey-fuller
- ALUCAM** :Aluminium du Cameroun
- ANN** : Artificiel neural network
- AIC** : Akaike information criterion
- ARIMA** :Autoregressive integrated moving average
- ARDL** :Modèle à correction d'erreur
- AG** :Génération dite accumulée
- ANFIS** :Système adaptatif d'inférence neuronale floue
- ACP** :Analyse des composantes principales
- BP-NN** :Back Propagation Neural Network
- BUCREP** :Bureau central des recensements et des etudes de population
- BT** :Basse tension
- IAG** :Inverse de génération dite accumulée
- CBLSTM-AE** :Bidirectional long short-term memory an auto-encoder
- CIMENCAM** : Cimenteries du Cameroun DEM : dispersion moyenne expliquée
- DRM** :Dispersion résiduelle moyenne
- DRNN** :Diagnostic recurrent neural networks
- DPDC** :Dibamba power development company
- ECP** :Energy consumption prediction

EDC :Electricity development corporation
ELM :Modèle d'apprentissage extrême
ES :Lissage exponentiel
DE :Equation différentielle
DS :Differency stationary
Eneo :Énergie du Cameroun
ENELCAM :Énergie Électrique du Cameroun
EDC :Electricité du Cameroun
EMD :Empirical Mode Decomposition
EMS :Energy Management System GM : mirror grey
GST :Théorie des systèmes grey
GWh :Gigawatt heure
FPE :Final prediction error
HT :Haute tension
HES :exponential smoothing
HQ :Hannan-Quinn information criterion
HFO :Centrales thermiques en fuels lourds
ID3 :Algorithme Iterative Dichotomiser 3
INS :Institut National des Statistiques
KF :Filtre de Kalman EKF : filtre de Kalman étendu
KPSS :Kwiatkowski-phillips-schmidt-shin
KPDC :Kribi power development company
LES :Lissage exponentiel simple
LM :Levenberg-Marquardt
LED :Lissage exponentiel Double
LSTM :Long short-term memory

- LS-SVR** :Least Squares Support Vector Regression
- LSSVR** :Least squares support vector regression
- LR** :Sequential modified LR test statistic (each test at 5% level)
- LFO** :Centrales thermiques en fuels légers
- MAE** : Mean Absolute Error
- MCO** : Moindre carre ordinaire
- MLP** : Perceptron multicouche
- LM** :Multiplicateur de Lagrange
- MAPE** :Mean absolute percentage error
- MCO** :Moindre carre ordinaire
- MT** :Moyenne tension
- MLR** :Multiple linear regression
- MW** :Megawattheure
- MIN** :Reseau interconnecté Nord
- NN** :Neural network
- PIB** :Produit intererieur bruit
- PP** :Philips-perron
- POP** :Population
- PSO** :Particule swam optimization
- PNB** :Produit national bruit
- PTU** :Programme thermique d'urgence
- POWERCAM** :Cameroon electricity corporation
- RF** :Random modele forest
- RMSE** :Root mean squared error
- RBM** :Ratio moving
- SC** :Scharz information

SONEL :Société Nationale d'électricité du Cameroun

SONATREL :Société nationale de transport de l'électricité

SOCATRAL :Société camerounaise de transformation d'aluminium

SIN :Reseau interconnecté du Sud

SVM :Support Vector machines

SVR :Regression Vectorielle de Support

SOM :Self-organizing Map SD : seasonal decomposition

SVR :Support Vecto regression t-statistique : statistique de student

UKF : Filtre de Kalman coefficient

Thiel :Thiel inequality coefficient

TES :Triple lissage exponentiel

VAR :Vector auto regression

VDM :Variational mode decomposition

VECM :Vecto error correction model

XGB :XG Boost.

Introduction générale

La forte croissance économique du Cameroun, depuis plus de dix ans s'accompagne également d'une demande croissante de la consommation électrique car le taux d'accès à l'électricité sur le plan national est estimé à environ 58,1% en 2015, 60,1% en 2016, 62% en 2017 et 63% en 2021 [1]. Cette croissance rapide de la demande d'électricité qui est due essentiellement au développement industriel, à la croissance démographique, à l'utilisation des biens électroménagers, ainsi qu'à l'urbanisation de plus en plus des villes et des campagnes, devrait continuer d'augmenter au cours des prochaines décennies [2]. Pour soutenir cette croissance économique et répondre aux futures demandes d'électricité, la prévision de la charge est devenue une tâche très importante pour la gestion et la planification de l'énergie électrique. La plupart des études de recherche sur la prévision de la demande d'énergie vise à fournir une prévision d'électricité suffisante pour une planification précise des investissements dans la production et la distribution d'électricité. Plusieurs techniques ont été utilisées pour accomplir cette tâche. De la statistique descriptive aux techniques de l'intelligence artificielle, chacune avec ses avantages et ses inconvénients [3, 4]. Mais les spécialistes du domaine continuent de chercher un modèle stable qui minimise au plus l'erreur de prévision. En effet, les erreurs de prévisions peuvent, occasionner des coûts opérationnels importants [5]. D'après Hobbs et al., une réduction de l'erreur moyenne de prévision de 1% peut épargner des milliers, voir même des millions de dollars dans une unité

de production d'électricité [6]. Soares et Medeiros, citent l'estimation effectuée en 1984 dans une installation électrique au Royaume-Uni, où un accroissement de 1% de l'erreur de prévision avait causé un accroissement annuel des coûts opérationnels de 10 millions de livres sterling [7]. Lorsque le secteur de l'électricité est fortement régulé, les opérateurs en situation de monopole utilisent la prévision à court terme pour assurer la fiabilité de l'offre [8]. Ainsi, selon cet auteur, du point de vue de l'opérateur, prévoir la consommation d'électricité est nécessaire pour la constitution d'outils d'aide à la décision et pour minimiser les coûts de sur/sous-production qui ne sont pas facilement transférables dans les prix. Une étude approfondie de la littérature nous a permis de constater que très peu de travaux ont été publiés sur ce sujet. Ces travaux, pour la plupart, parlent de la modélisation de la production d'énergie électrique à partir des scénarios. Peu d'auteurs se sont focalisés sur la modélisation de la demande d'énergie électrique à partir des méthodes d'intelligences artificielles et des modèles économétriques. En effet, nous avons remarqué que dans plusieurs villes et villages du Cameroun, les populations souffrent du manque d'énergie électrique pour plusieurs raisons :

- le nombre croissant des délestages observés au quotidien qui désorganise la vie économique et sociale ;
- l'inefficacité de la planification de la production, la production et la distribution vers les consommateurs ;
- l'insuffisance des réseaux électriques installés [9].

Le Cameroun étant suffisamment riche en ressources naturelles et énergies renouvelables, il serait intéressant d'examiner et de proposer des solutions aux problèmes de planification et de gestion efficace d'énergie électrique disponible, en développant un modèle numérique optimal basé sur les méthodes hybrides d'intelligences artificielles et des modèles économétriques.

La prévision de la charge peut être classée en trois catégories [10, 11] :

- La prévision à long terme, utilisée pour prédire jusqu'à une période de 50 ans cela dans le but de faciliter la planification de l'expansion du réseau énergétique ;
- La prévision à moyen terme, quant à elle, utilisée pour prédire les pics hebdomadaires, mensuels et annuels jusqu'à une période d'une année, de sorte qu'une planification opérationnelle efficace puisse être effectuée ;
- La prévision à court terme, permettant une prévision allant jusqu'à une semaine dans le but de minimiser le fonctionnement quotidien et les frais d'envoi sur le réseau [12].

En plus de ces trois catégories de prévisions de la charge, une quatrième catégorie a émergé ces dernières années ; le moyen-long terme, dans laquelle l'unité de temps considérée est le mois et l'année. Elle se place naturellement entre le moyen et le long terme.

Pour contribuer à la réduction de l'erreur de prévision, aux besoins de planification, d'estimation de potentiels d'économies d'énergie ou de la gestion de la demande d'énergie électrique, nous nous proposons, dans cette thèse, d'effectuer des modélisations plus fines de la consommation d'énergie électrique, à partir des outils classiques de l'économétrie des séries temporelles et les méthodes de l'intelligence artificielle. Le travail est organisé en trois grands chapitres. Le premier présente d'abord la situation actuelle du secteur électrique au Cameroun, puis donne ensuite une vision globale des modèles à disposition pour étudier la consommation d'électricité dans un but de prévision ; enfin, il propose une revue de littérature des travaux récents dans le domaine. Le deuxième chapitre, présente de manière détaillée les modèles retenus pour modéliser la consommation d'électricité. Le chapitre trois présente les résultats obtenus ainsi que les discussions et recommandations associées.

SITUATION ÉNERGÉTIQUE DU CAMEROUN ET ÉTAT DE L'ART SUR LES
PRÉVISIONS DE LA CONSOMMATION D'ÉNERGIE ÉLECTRIQUE

Introduction

Il existe de nombreux intérêts de modélisation de la consommation électrique dans le dimensionnement, la planification, le fonctionnement du réseau électrique. Plus récemment, avec la croissance rapide de la demande d'électricité, des problématiques comme l'estimation des potentiels d'économie d'énergie et la gestion de la demande sont apparues et sont traitées à l'aide d'outils de modélisation de la charge électrique ; ce qui mène aujourd'hui à un nombre de modèles existants conséquents. De façon générale, tous ces modèles cherchent à comprendre certains aspects de la consommation électrique pour différents buts. D'où une forte segmentation des modèles dans la littérature, même dans les articles d'étude bibliographique. Dans ce chapitre, avant de nous intéresser aux prévisions de la consommation d'énergie électrique, nous présenterons d'abord la situation actuelle du secteur électrique au Cameroun, ensuite nous présenterons un état de l'art des modèles de prévision de la consommation électrique, enfin une brève revue systématique de la littérature sur les résultats des prévisions de la charge électrique.

1.1 Situation actuelle du secteur électrique au Cameroun

1.1.1 Historique de l'énergie électrique

L'historique du secteur de l'énergie électrique au Cameroun relève de nombreux faits majeurs depuis 1929, faits retraçables ainsi qu'il suit :

- En 1929 : les premières centrales hydroélectriques de Libermann et Malale (privées) sont inaugurées pour fournir l'électricité dans la région de Muyuka, essentiellement dans les domiciles et les usines des colons britanniques.

- Avant la deuxième guerre mondiale, dans la partie francophone du Cameroun, les premiers foyers d'électricité de Nkongsamba, Douala et Yaoundé ont été créés par l'administration et exploités en gérance par des sociétés privées ou directement par elles mêmes.

- 1946 : création d'un service public dans la partie britannique pour la fourniture de l'électricité qui a racheté la plupart des centrales privées installées par les colons.

- 1948 : la société d'économie mixte, Énergie Électrique du Cameroun (ENELCAM), est créée et chargée d'aménager l'usine hydroélectrique d'Edéa I(22MW) sur la Sanaga pour l'alimentation électrique de Douala et Edéa en 1953.

- Après l'indépendance, la Cameroon Electricity Corporation (POWERCAM) est fondée en 1962 au Cameroun Occidental, et en 1963 la société d'économie mixte électricité du Cameroun (EDC) est créée, avec la majorité du capital social détenue par l'État du Cameroun Oriental et les collectivités publiques. Elle prend en charge toutes les distributions publiques d'énergie électrique, ainsi que les moyens de production et de transport subséquents, à l'exception des centrales d'Edéa gérées par ENELCAM.

- 1974 : création de la Société Nationale d'Électricité du Cameroun (SONEL)

par fusion des sociétés ENELCAM et EDC. SONEL a en outre pour mission de prendre en charge les distributions publiques dans l'ex-Cameroun Occidental. En 1975, elle absorbe la POWERCAM et la centrale hydroélectrique de Song-loulou (388MW) est mise en service.

- 17 juillet 2001 : Privatisation de la SONEL au bénéfice de AES-Sirocco Limited, une filiale de AES Corporation qui contrôle 51% du capital; l'État du Cameroun conserve 44% et le personnel reçoit 5%.

- 23 mai 2014 : Le gouvernement du Cameroun signe l'accord qui octroie à ACTIS 56% des parts d'AES-SONEL et de ses soeurs KPDC et DPDC. Le 12 septembre 2014, le nouveau nom de l'entreprise est dévoilé : ENEO Cameroun S.A.

- L'année 2015 est marquée par la réforme qui prévoit désormais la possibilité de faire exercer par les acteurs différents les fonctions de production, de transport et de distribution de l'énergie électrique. C'est ainsi qu'est née la société en charge du transport de l'énergie électrique SONATREL.

En résumé, depuis 1929, trois centrales électriques ont été mises sur pieds notamment Edéa (276 MW), Song-loulou (384 MW) et Lagdo (72 MW). La société de distribution de l'énergie électrique a connu des mutations à savoir : de ENELCAM à SONEL suite à la réunification, de SONEL à AES-SONEL suite à la privatisation de l'énergie électrique et enfin de AES-SONEL à ENEO suite à la volonté de l'État Camerounais d'améliorer le secteur de l'électricité et de l'ouvrir à la concurrence. La société de production et distribution en 2018 ENEO-Cameroun n'est pas le seul acteur de l'électricité au Cameroun, d'autres acteurs ayant des rôles différents existent et feront l'objet d'une étude particulière.

1.1.2 Contexte général

Le Cameroun possède le deuxième plus grand potentiel hydroélectrique d'Afrique subsaharienne (19,7 GW) après la République démocratique du Congo, où le potentiel hydroélectrique estimé est de 23 GW [13]. Cependant, seulement 5% environ de cette ressource naturelle est exploitée en raison de plusieurs obstacles naturels et du faible taux de développement des infrastructures de production. En fait, environ 73,2% de l'électricité publique disponible dans le pays est produit par seulement trois centrales hydroélectriques : SongLoulou (384 MW) et Edea(276,2 MW) connectées au Réseau interconnecté du sud(SIN), et Lagdo(72 MW) connectée au Réseau Interconnecté Nord (NIN) [13]. Le reste de 26,8% de la production supplémentaire à la même date est indiqué dans le tableau 1.1 ci-dessous.

Tableau 1.1 – Parc de production électrique d'AES Sonel [9]

Réseau interconnecté	Hydroélectrique (puissance installée)	Production thermique	Barrage de retenue d'eau
Sud	Edea : 263 MW	Yassa (Dibamba) :85,35 MW	
	Song Loulou :394 MW	Limbe :85 MW	
		Oyomabang : 35 MW	
		Bassa : 20 MW	Mbakaou : 2, 6.10 ⁹ m ³
		Logbaba : 18 MW	Mapé : 3, 2.10 ⁹ m ³
		Bafoussam :14 MW	Bamendjin : 1, 8.10 ⁹ m ³
		Mbalmayo (PTU) :10 MW	
		Bamenda (PTU) :20 MW	
		Ebolowa (PTU) :10 MW	
		Ahala (PTU) :60 MW	
	Kribi (PTU) :216 MW		
Nord	Lagdo :72MW	Djamboutou :17MW	
		Kousseri :4,66MW	
EST		Bertoua : 8,6 MW	
TOTAL	729 MW	603,61 MW	

Les multiples tentatives de l'État camerounais pour répondre à la demande

d'électricité au regard de ces investissements restent insuffisantes. En fait, tous les secteurs dépendant de l'énergie électrique sont confrontés à des pannes quasi permanentes, ralentissant les activités de production de biens et affaiblissant la qualité de vie des gens. Le taux d'accès à l'électricité dans les zones urbaines est à peine de 65%, contre 14% dans les zones rurales [14]. Seulement 20% de la population a accès aux réseaux électriques [15], une grande majorité des communautés des zones rurales n'étant pas connectée [16]. En conséquence, il y a une augmentation de l'utilisation des générateurs et du kérosène pour l'auto-production d'électricité et d'éclairage [17]. Le non-respect des délais de mise en oeuvre des différents projets d'électrification en cours ne permet pas à l'État camerounais de combler le déficit offre-demande [16]. Cela peut également avoir un impact sur le secteur industriel, où le manque d'électricité dans les industries entraîne un ralentissement de 2% de la croissance économique chaque année et un manque à gagner en devises de plus de 12 millions de dollars par an [18].

1.1.3 L'offre et la demande d'énergie électrique

Le secteur de l'électricité au Cameroun est une activité économique caractérisée par une offre peu abondante par rapport au potentiel électrique camerounais et une demande grandissante. La croissance démographique rend les efforts du gouvernement insatisfaisants. En effet, moins de 5% du potentiel en électricité est exploité pour la production de l'électricité au Cameroun, tandis que la demande en énergie électrique croît d'environ 7,5% par an (Ministère de l'Eau et de l'Energie, 2015) [19]. Ainsi, l'équilibre entre l'offre et la demande en énergie électrique est peu garanti. Afin de comprendre le fonctionnement du secteur de l'énergie électrique il est nécessaire d'étudier son offre et sa demande.

1.1.4 La production d'électricité

La production d'électricité au Cameroun peut être de deux types, à savoir la production publique et l'auto production. Aujourd'hui, la production publique de l'électricité est assurée par ENEO et les entreprises telles que KPDC, EDC et DPDC. Elle est effectuée principalement par les trois centrales hydroélectriques de Lagdo, Edéa et Song Loulou. L'électricité publique est également produite par des centrales thermiques, les centrales à gaz de Kribi et de Yassa. L'auto production, quant à elle, est assurée en majorité par les vendeurs de groupes électrogènes et par les entreprises de production d'énergies renouvelables. En 2014, ENEO Cameroun, KPDC et DPDC sont les principaux producteurs d'électricité car leur production représentait plus de 65% de la production totale contre moins de 1% pour les auto-producteurs (Ministère de l'Eau et de l'Energie, 2015). La production d'électricité, malgré de nombreuses difficultés, se veut apte à répondre non seulement aux besoins des populations camerounaises mais également, à ceux des multiples entreprises installées sur le triangle national. Cette consommation n'a cessé de croître et a atteint, en 2014, environ 6.9GWh.

1.1.5 Répartition de la production électrique

Le parc de production de l'énergie électrique au Cameroun nous renseigne que la capacité installée était de l'ordre de 1529MW en 2020. Elle est répartie entre les centrales hydroélectriques (61,7%) MW, thermiques (24,1%), à gaz (14,1%) et les champs des panneaux solaires (0,1%). En 2021, la puissance installée est passée à 1540 MW pour un taux d'accès à l'énergie de 63% : soit 93% en zone urbaine et 24% en zone rurale.

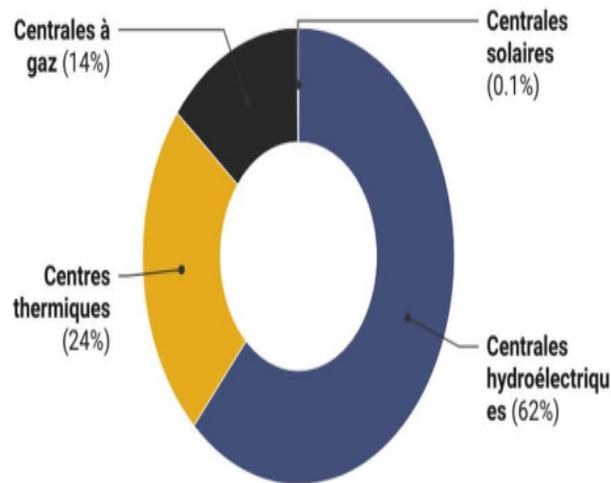


FIGURE 1.1 – Répartition de la production électrique(Source : Rapport annuel ENEO, 2020)[9]

Les centrales thermiques consommant les fuels lourds et légers représentent la deuxième plus grande source de production d'énergie au Cameroun aussi bien dans les réseaux interconnectés qu'isolés. Elles permettent non seulement de compenser le déficit d'énergie non couvert par les centrales hydroélectriques en activité, mais également d'améliorer les profils de tension. La carte ci-après dresse l'état de la répartition des centrales électriques du Cameroun.

1.1.6 Répartition des centrales électriques

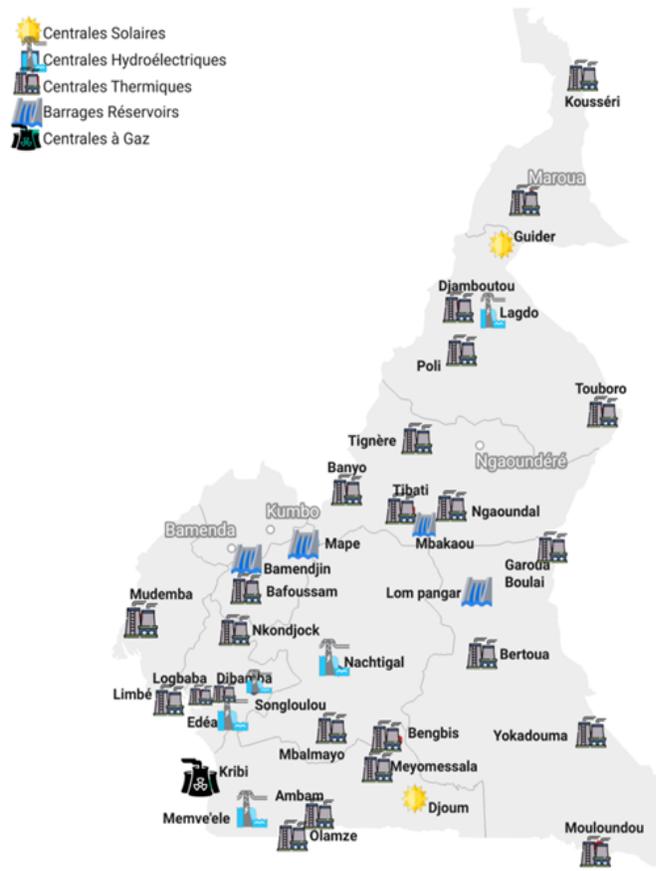


FIGURE 1.2 – Répartition des centrales électriques (Source : Rapport annuel ENEO, 2020) [9]

La problématique du déficit énergétique se pose alors que 63,5% de la population camerounaise a accès à l'électricité. La demande est estimée à 1540MW en 2021, pour une offre de 1047MW, soit un déficit d'environ 493MW. La croissance de la demande est estimée à 7,5% par an.

1.1.7 La consommation d'électricité

La consommation d'électricité au Cameroun est de trois types, à savoir la consommation basse tension, la consommation moyenne tension et la consommation haute tension. Les consommations basse tension et moyenne tension sont du

ressort des ménages, des petites et moyennes entreprises tandis que la consommation haute tension est réservée aux grandes entreprises ayant des traitements particuliers avec ENEO-Cameroun. Ces grandes entreprises sont appelées clients spéciaux dans le jargon de l'électricité. Les clients spéciaux sont : ALUCAM, SOCATRAL, CIMENCAM et DANGOTE (Ministère de l'Eau et de l'Energie, 2015). En 2014, la consommation d'électricité (ventes) de la clientèle basse et moyenne tension s'élevait à 2.79 GWh et celle de la clientèle haute tension s'élevait à 1.57 GWh. La figure (1.3) représente l'évolution de l'offre et de la demande d'énergie électrique entre 2014-2021.

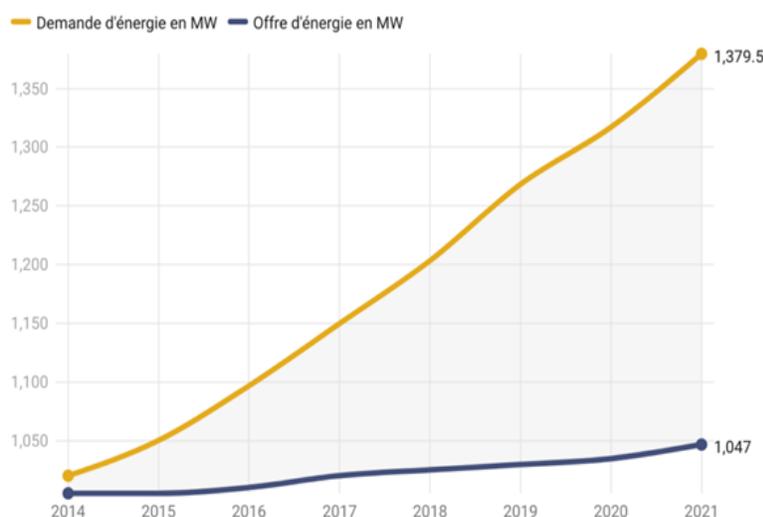


FIGURE 1.3 – Evolution de l'offre et de la demande d'énergie électrique entre 2014-2022 (Source : ARCEL, 2021)

1.1.8 Causes du déficit énergétique

- L'ensemble du système électrique, dans ses segments production, transport et distribution, connaît des contraintes. Ceci entraîne un déficit énergétique qui est accentué par deux principaux facteurs : la saturation du réseau de transport et la limitation de la production dans certaines centrales, soit pour maintenance, contraintes d'approvisionnement en combustibles, ou du fait de l'étiage ;

- Au-delà de l'étiage qui affecte la disponibilité de l'eau dans les centrales hydroélectriques et du taux de disponibilité du réseau de transport d'énergie, le déficit d'approvisionnement des centrales thermiques en fuels lourds (H FO) et légers (LFO) pourrait accentuer davantage ce déficit énergétique. Ainsi, la survenance d'un choc pétrolier entraînant la hausse du prix du baril pourrait exacerber le déficit de production de l'énergie électrique au Cameroun.

1.1.9 Comment réduire le déficit énergétique ?

La nécessité de réduire la dépendance du Cameroun aux produits pétroliers transformés importés s'impose. À long terme, une piste de solution serait d'opter pour la reconstruction, voire l'extension de la SONARA, tel que préconisée dans "l'étude de positionnement stratégique du secteur de la chimie au Cameroun", commandée par le BMN, et menée par le cabinet KB SAP Consulting. Cette action permettrait d'atteindre une capacité de production annuelle de 5 millions de tonnes de produits pétroliers transformés.

De même, le pays présente un très grand potentiel hydroélectrique, progressivement mis en valeur par la construction de grandes centrales hydroélectriques (MEMVE'ELE, et autres), dont la production est affectée par l'étiage. La centrale de Nachtigal d'une capacité installée de 420MW en fin de construction, devrait apporter un nouveau souffle au système. Par ailleurs, afin de pallier les problèmes d'étiage, il serait opportun d'accentuer la politique de construction des mini centrales hydroélectriques, à l'image de la centrale de MBAKAOU mise en service en Décembre 2021.

Enfin, le pays dispose d'énormes potentialités en termes d'énergie solaire, où l'insolation moyenne est de l'ordre de $5,8 \text{ kWh}/\text{m}^2/\text{jour}$ dans sa partie septentrionale et $4 \text{ kWh}/\text{m}^2/\text{jour}$ dans la partie sud. Pour ce qui est de la partie septen-

trionale, on y rapporte la mise en service récente de la centrale solaire modulaire de Guider, d'une capacité installée de 15 MW. Cette dernière devrait participer à résorber le déficit dans le Réseau Interconnecté Nord (RIN). Seuls 03 MW sont débités jusqu'à ce jour. Les contraintes de stockage et de transport d'énergie rendent toutefois cette solution non optimale, malgré son potentiel. L'installation d'une usine de fabrication des plaques solaires pour un usage direct par les ménages serait donc une solution compatible avec notre environnement.

1.2 État de l'art des modèles de prévision de la consommation électrique

La prévision de la charge est fondamentalement définie comme étant la science ou l'art de prédire la charge future sur un système donné, pour une période de temps déterminée à l'avance. Ces prédictions peuvent être justes pour une période d'une heure à des fins d'exploitation, ou jusqu'à 20 ans ou plus dans le futur à des fins de planification. Les premiers modèles de prévision de la charge électrique étaient presque entièrement limités aux modèles statistiques traditionnels. Mais avec les progrès de la science moderne, les modèles de prévision basés sur des théories d'apprentissage automatique se sont développés et sont devenus de plus en plus populaires contrairement aux modèles statistiques [20]. Cette section définit et décrit les modèles de prévision de charge les plus couramment utilisés, qu'ils soient traditionnels ou modernes. Une illustration de la classification plus précise des modèles de prévision de base les plus utilisés est donnée dans la figure 1.4 ci-dessous.

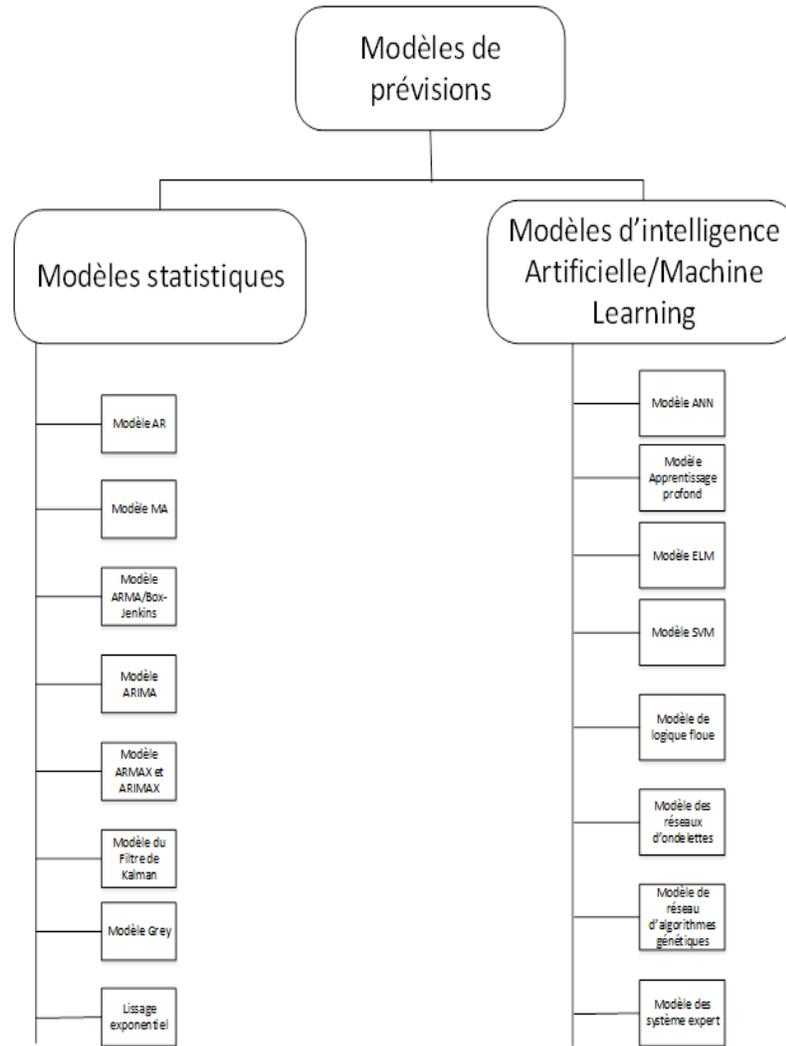


FIGURE 1.4 – Classifications possibles des types de méthodes de prévision de base (source : adaptée par les auteurs)

1.2.1 Les modèles statistiques

Le modèle statistique est un modèle mathématique qui incarne un ensemble d'hypothèses statistiques concernant la génération d'échantillons de données. Le modèle statistique est généralement défini comme une relation mathématique entre une ou plusieurs variables aléatoires et d'autres variables non aléatoires. Les modèles statistiques les plus utilisés à des fins de prévisions, sont les suivants :

1.2.1.1 Le modèle Auto-Régressif(AR)

Le modèle autorégressif suppose que Y_t est une fonction linéaire des valeurs précédentes (équation 1.1) [21].

$$Y_t = \mu + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \phi_3 Y_{t-3} + \varepsilon_t, \quad (1.1)$$

où ϕ_1 à ϕ_n sont les paramètres d'auto-régression, ε_t est un bruit blanc et n est l'ordre du modèle et μ est une constante du modèle. La validité d'un modèle autorégressif est sous l'hypothèse que la série temporelle étudiée est stationnaire. Aussi, pour certains effets internes cumulatifs, le processus autorégressif est stable quand la valeur du paramètre ϕ est dans un intervalle bien défini. Le calcul des paramètres du modèle autorégressif peut être réalisé via différentes méthodes, mais celle des moindres carrés est la plus utilisée.

1.2.1.2 Le modèle de moyenne mobile(MA)

Le modèle à moyenne mobile suggère que la série présente des fluctuations autour d'une valeur moyenne. On considère alors que la meilleure estimation est représentée par la moyenne pondérée d'un certain nombre de valeurs antérieures. Ceci revient en fait à considérer que l'estimation est égale à la moyenne vraie, à laquelle on rajoute la somme pondérée des erreurs ayant entaché les valeurs précédentes (équation 1.2) [21].

$$Y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \theta_3 \varepsilon_{t-3}. \quad (1.2)$$

Littéralement, chaque observation est contient une composante d'erreur aléatoire(choc aléatoire, ε) et d'une combinaison linéaire des erreurs aléatoires passées. Les constantes θ_1 , θ_2 et θ_3 sont les coefficients de moyenne mobile du modèle.

1.2.1.3 Le modèle de moyenne mobile autorégressive ARMA (p,q)

Un tel modèle, appelé autorégressif-moyenne mobile ARMA, est caractérisé par le paramètre p de la partie autorégressive et le paramètre q de la partie moyenne mobile. La notion de processus ARMA réunit celles de processus autorégressif et de processus moyenne mobile. Dans les modèles ARMA, la valeur prise au temps t par la variable étudiée est une fonction linéaire de ses valeurs passées et des valeurs actuelles augmenté du bruit blanc. La forme générale d'un modèle ARMA (p,q) se présente ainsi :

$$Y_t - \phi_1 Y_{t-1} - \phi_2 Y_{t-2} - \dots - \phi_p Y_{t-p} = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}. \quad (1.3)$$

Le modèle peut être écrit sous une forme réduite comme suit :

$$\phi(B)Y_t = \theta(B)\varepsilon_t, \quad (1.4)$$

où B est un opérateur de retard, ϕ et θ sont des polynômes et Y la variable appliquée. Le modèle ARMA contient $(p + q + 2)$ paramètres à estimer, il est généralement suffisant de prendre une valeur pour p et q inférieure ou égale à 2. La combinaison des deux méthodes AR et MA nous permet de représenter des séries temporelles avec moins de paramètres qu'un modèle AR [22].

1.2.1.4 Le modèle ARIMA(p,q,d)

Dans la pratique, les séries temporelles ne sont pas stationnaires, contrairement aux modèles cités plus haut. Cependant, un modèle ARMA peut être modifié pour les séries non stationnaires, qu'on appelle ARIMA "Autoregressive Integrated Moving Average". Le terme "Integrated" représente le fait que le modèle est produit suite à une somme du processus ARMA. Une convention a été établie pour définir la structure d'un modèle ARIMA(p,q,d), où p représente le nombre de paramètres autorégressifs, q le paramètre de la moyenne mobile et d est le nombre de passes à

réaliser. Pour résumer, le modèle ARIMA revient à appliquer un modèle ARMA sur le processus différentiel. L'équation d'un modèle ARIMA(p,q,d) est donc donnée par l'équation :

$$\phi(B)\Delta_d Y_t = \theta(B)\varepsilon_t, \quad (1.5)$$

où ε_t est le bruit blanc, Δ l'opérateur de retard, ϕ et θ sont deux polynômes de degrés respectifs p et q, ϕ et θ n'ont pas de racines communes et leurs racines sont de modules > 1 [22].

1.2.1.5 L'Algorithme de filtrage de Kalman dans l'espace d'état

La prévision, en particulier celle à long terme, se caractérise par un niveau élevé d'incertitude en raison de sa forte dépendance vis-à-vis des facteurs socio-économiques. Pour cette raison, un niveau d'erreur jusqu'à 10% est acceptable [23]. Dans cet esprit, l'application d'un algorithme de filtrage de Kalman peut réduire considérablement la moyenne de l'erreur du modèle au carré. Le filtre de Kalman(KF) est un ensemble d'équations mathématiques dans l'espace d'états qui peut fournir un moyen de calcul efficace (récursif) pour estimer l'état d'un processus observé. Le filtre Kalman porte le nom de Rudolph E. Kalman, qui a publié son célèbre article en 1960, décrivant une solution récursive au problème de filtrage linéaire de données discrètes. Le Kalman filter a été largement engagé pour le suivi dans l'infographie interactive. Il a été utilisé pour la prédiction de mouvement, et il est également utilisé pour la fusion multi-capteurs (inertie-acoustique). De plus, ce filtre est très puissant dans plusieurs autres aspects : il prend en charge les estimations des états passés, présents et futurs. Ainsi, il peut le faire même lorsque la nature précise du système modélisé est inconnue. Un filtre de Kalman est également un outil puissant lorsqu'il s'agit de contrôler les systèmes bruyants dans lesquels les puissances électriques des systèmes peuvent sans aucun doute

être attribuées [24]. Selon Gaur et ses collègues [25], les principaux éléments qui affectent le comportement de la charge électrique peuvent être classés en cinq facteurs.

a. La météo : Ce facteur est l'extrême le plus essentiel. Il comprend l'humidité, la vitesse du vent, la température, les précipitations, etc. Les variations de ces facteurs conduisent directement à l'ajustement des habitudes d'appareils tels que les radiateurs, les climatiseurs, les refroidisseurs, etc.

b. Le temps : Ce facteur a un impact sur la charge électrique à différentes périodes de la journée, en semaine et le week-end, les vacances et les saisons de l'année. Ici, la variation de charge électrique en fonction du temps peut refléter le mode de vie des personnes, comme leurs horaires de travail, leurs loisirs, leurs habitudes de sommeil, etc.

c. L'économie : Ce facteur est important dans le marché dérégulé, reflétant la variation de l'électricité prix, tandis que la politique de gestion de la charge a un impact important sur la croissance de la charge électrique ou tendance à la baisse.

d. Les perturbations aléatoires : L'arrêt ou le démarrage des charges énormes telles que l'aciérie ou le vent tunnels vont conduire aux impulsions de la courbe de charge. Les autres événements anormaux qui sont antérieurement connus mais ayant un effet incertain sur la charge, entrent également dans la catégorie des perturbations aléatoires.

e. Les facteurs client : Ces facteurs comprennent le type de consommation (commercial, résidentiel, agricole, ou industriel), la taille des bâtiments, le nombre d'employés, ainsi que le nombre d'utilisation électrique.

Les facteurs mentionnés ci-dessus peuvent être injectés en tant qu'entrées dans le filtre de Kalman (KF). Puisqu'il est extrêmement difficile de traiter les entrées

complexes (**c.,d.,e.**), les facteurs météorologiques et temporels sont généralement inclus dans le KF [25]. Le KF est généralement regardé à travers les yeux du système dynamique linéaire à temps discret. Ce dernier a le vecteur d'espace d'état latent

$$X^T(K) = [x_1(k)x_2(k)...x_n(k)]. \quad (1.6)$$

Il signifie le vecteur des états cachés des appareils, ainsi que le vecteur d'observation $Y(k)$ démontrant le relevé des compteurs intelligents(SMD). Ici, k représente les moments discrets. Le retard de l'estimateur produit les estimations d'état $X^T(K|K-1)$ et estimations de production $X(K|K-1)$ en appliquant la mesure uniquement jusqu'à la $(k-1)$ -ème sortie $Y(k-1)$. Le mécanisme du KF fonctionne en un processus à deux temps, c'est-à-dire l'étape de prédiction(PS) et l'étape de correction(CS). Dans le PS, le KF estime l'état actuel de la charge sur la base de son état précédent, ainsi que son incertitude de covariance. Une fois que la nouvelle mesure du SMD est observée, le vecteur d'état estimé est mis à jour en déployant une moyenne pondérée, où le poids le plus élevé est attribué à l'estimation avec une certitude plus élevée. D'une certaine manière, les étapes PS et CS continuent de se dérouler de manière récursive. Étant donné que le KF linéaire ne peut souvent pas satisfaire les exigences de rigueur de la précision des prévisions dans le cas de non-linéarités graves du problème donné, plusieurs de ses variantes non linéaires ont été développées. Ainsi, afin d'explorer les non-linéarités cachées du problème, le filtre de Kalman étendu(EKF), ainsi les filtres de Kalman non parfumés(UKF) sont parfois utilisés.

1.2.1.6 Les modèles grey (GM)

La théorie des systèmes grey(GST) a été introduite pour la première fois par Deng en 1982 [26]. Cette théorie peut traiter les systèmes observés qui ont des

paramètres partiellement inconnus, tandis que les modèles gris n'ont besoin que d'une quantité limitée de données pour estimer le comportement du système inconnu. La tâche principale de la GST est d'extraire des lois gouvernantes convaincantes du système observé sur la base des données disponibles, quelle que soit leur complexité ou leur chaotité [19]. Le modèle gris GM(1,1) est l'un des modèles gris les plus utilisés, qui peuvent produire des prévisions des futurs points de données primitifs. Le GM(1,1) est un modèle de prévision de séries chronologiques avec équation différentielle (DE) dont la variation dépend du temps. En déployant la génération dite accumulée (AG), il devient possible de lisser et ainsi diminuer l'intensité de l'incertitude dans le système. Lorsque le DE est résolu, la valeur prédite n step ahead du système peut être obtenue. Basé sur l'utilisation de ce dernier, l'inverse AG (IAG) peut être appliqué pour extraire les valeurs prédites des données d'origine [26]. Selon Feng et al. [27], les modèles de prévision grise basés sur la théorie des systèmes gris sont régulièrement utilisés dans les réseaux, étant donné que les modèles sont capables d'utiliser des variations aléatoires comme la quantité de gris, qui est modifiée dans un certain intervalle. L'équation différentielle du modèle de Gray est ici essentielle puisqu'elle fournit la charge prédite de puissance. Lorsque le modèle dérivé est testé avec succès par rapport à la fiabilité, la stabilité, la précision, il peut être déployé pour prévoir la charge future. Les modèles gris conviennent aux trois types de prévision de charge, c'est-à-dire pour la prévision à court, à moyen et à long terme [27]. L'un des principaux avantages des GM est qu'ils peuvent être développés sans tenir compte de la répartition de la charge et de la tendance de la charge modifiée [28]. Cependant, leur défaut est qu'ils ne conviennent que pour résoudre efficacement les problèmes avec la croissance exponentielle qui prévaut [29].

1.2.1.7 Le modèle de lissage exponentiel(ES)

Le lissage exponentiel est une approche de prévision pragmatique, dans laquelle la prévision peut être réalisée à partir de la moyenne pondérée exponentiellement des observations passées [30, 31, 32]. Le plus haut poids est donné à l'observation actuelle, un poids inférieur à celui qui précède immédiatement mesure, un poids encore plus faible à la mesure précédente, ainsi de suite(c'est-à-dire que nous avons affaire avec la décroissance exponentielle de l'influence des données historiques passées) [32]. Les modèles ES font partie les méthodes de prévision statistique les plus courantes et les plus répandues en raison de leur précision, simplicité, robustesse et le faible coût [33]. Ils sont également cruciaux pour une prévision de charge dans les systèmes d'alimentation. Comme le soulignent Peirong et ses collègues [34], la précision du modèle dépend surtout des coefficients de lissage du modèle EF. Cette étude montre également comment rechercher les meilleurs coefficients de lissage. En général, il existe trois techniques différentes de lissage exponentiel : le simple lissage exponentiel(SES)(méthode de Brown), le double lissage exponentiel(DES)(méthode de Holt), et le triple lissage exponentiel(TES)(méthode Holt-Winters). Le modèle SES nécessite un peu de calcul, et il est utilisé lorsque le modèle de données n'a pas de variation cyclique ou saisonnière, ni la tendance dans les données historiques. D'autre part, les modèles DES, particulièrement utilisés dans l'économie, activent les valeurs prévues avec une tendance incluse. Enfin, les modèles TES (Holt-Winters) ont deux modes de calcul possibles : l'additif et le multiplicatif. Le modèle additif est utilisé si les données originales montrent des fluctuations saisonnières stables. Inversement, le modèle multiplicatif est utilisé lorsque les données originales reflètent les variations importantes de la saisonnalité [35]. Selon les preuves empiriques, la méthode de base

de Holt-Winters a tendance à produire des supervisions ou des sous-prévisions, en particulier pour les horizons de prévision plus longs [36, 37]. Pour cette raison, en 1989, Gardner et McKenzie ont déployé un nouveau paramètre φ associé à la tendance de la composante. De cette façon, la tendance est amortie à une ligne plate, lorsque l'avenir devient plus lointain. Par conséquent, nous pouvons obtenir le modèle Holt-Winters Damped Additive sous la forme suivante, y compris les quatre paramètres $\alpha, \beta, \gamma, \phi$.

$$\text{Niveau : } l(t) = \alpha.(y(t) - s(t - m)) + (1 - \alpha).[l(t - 1) + \phi.b(t - 1)], \quad (1.7)$$

$$\text{Croissance : } b(t) = \beta.[l(t) - l(t - 1)] + (1 - \beta).\phi.b(t - 1), \quad (1.8)$$

$$\text{Saisonnalité : } s(t) = \gamma.(y(t) - l(t - 1) - \phi.b(t - 1)) + (1 - \gamma).s(t - m), \quad (1.9)$$

$$\text{Prévisions : } \hat{y}(t + h|t) = l(t) + \phi_h.b(t) + s(t - m + h_m^+), \quad (1.10)$$

où $\phi_h = \phi + \phi^2 + \dots + \phi^h$, $h_m^+ = [(h - 1) \bmod m] + m$ -numero de saison/an, h , les points temporels de l'horizon futur et y les séries chronologiques observées.

1.2.1.8 Le modèle VAR/VECM

Le modèle vectoriel autorégressif (VAR) est un outil couramment utilisé pour la prévision des séries temporelles stationnaires à plusieurs variables qui sont déterminées simultanément [31]. La particularité du modèle VAR est que chaque variable est une fonction linéaire des décalages passés d'elles-mêmes et les décalages passés des autres variables. La forme généralisée d'une représentation VAR(p) s'écrit sous forme matricielle suivante :

$$Y_t = A_0 + A_1 Y_{t-1} + A_2 Y_{t-2} + \dots + A_p Y_{t-p} + \varepsilon, \quad (1.11)$$

où A_0, A_i sont des matrices des coefficients et Y_t un vecteur constitué des variables du problème à résoudre. Ce modèle peut s'écrire en différences premières de deux

manières suivantes :

$$\begin{aligned} \Delta Y_t = & A_0 + (A_1 - I)\Delta Y_{t-1} + (A_2 + A_1 - I)\Delta Y_{t-2} + \dots \\ & + (A_{p-1} + \dots + A_2 + A_1 - I)\Delta Y_{t-p+1} + \pi Y_{t-p} + \varepsilon. \end{aligned} \quad (1.12)$$

ou encore en fonction de Y_{t-1} :

$$\Delta Y_t = A_0 + B_1 \Delta Y_{t-1} + B_2 \Delta Y_{t-2} + \dots + B_{p-1} \Delta Y_{t-p+1} + \pi Y_{t-1} + \varepsilon, \quad (1.13)$$

les matrices B_i étant des fonctions des matrices A_i et

$$\pi = \left(\sum_{i=1}^p A_i - I \right). \quad (1.14)$$

1.2.1.9 Le modèle combiné ou régression linéaire multiple

En statistique, la régression linéaire multiple est une méthode de régression mathématique étendant la régression linéaire simple pour décrire les variations d'une variable endogène associée aux variations de plusieurs variables exogènes [38].

Étant donné un échantillon $(Y_i, X_{i1}, \dots, X_{ip})$, $i \in 1, n$, on cherche à expliquer, avec le plus de précision possible, les valeurs prises par Y_i , dite variable endogène, à partir d'une série de variables explicatives X_{i1}, \dots, X_{ip} . Le modèle théorique, formulé en termes de variables aléatoires, prend la forme

$$Y_i = a_0 + a_1 X_{i1} + a_2 X_{i2} + \dots + a_p X_{ip} + \varepsilon_i, \quad i = 1, \dots, n \quad (1.15)$$

où ε_i est l'erreur du modèle qui exprime, ou résume, l'information manquante dans l'explication linéaire des valeurs de Y_i à partir des X_{i1}, \dots, X_{ip} (problème de spécifications, variables non prises en compte, etc.). Les coefficients a_0, a_1, \dots, a_p sont les paramètres à estimer.

1.2.2 Les modèles d'intelligence artificielle, d'intelligence computationnelle ou d'apprentissage automatique (Machine Learning)

Les modèles statistiques traditionnels sont limités et peuvent parfois conduire à des solutions insatisfaisantes. La raison est le nombre trop élevé de possibilités de calcul conduisant à des temps de résolution importants et la complexité de certains modèles de données non linéaires. Par conséquent, l'apprentissage automatique et les techniques basées sur l'intelligence artificielle offrent une alternative prometteuse et attrayante [39, 40].

1.2.2.1 Le modèle des réseaux de neurones artificiels(ANN)

L'approche des réseaux de neurones artificiels (ANN) a été découverte en 1990 par Warren McCulloch et Walter Pitts comme mécanisme alternatif à la prévision des séries chronologiques. Les ANN ont été appliqués avec succès dans de nombreux domaines à des fins de prévision et de classification. Les modèles ANN ont été utilisés et étudiés de manière intensive en tant qu'outils utilisés pour les prévisions de la charge électrique et ont gagné en popularité au cours des dernières décennies [40]. Fondamentalement, le réseau de neurones est un circuit non linéaire capable d'effectuer un ajustement de courbe non linéaire. Il représente une information paradigme de traitement qui a été inspiré par la façon dont les systèmes biologiques de l'homme tels que le cerveau sont capables de traiter une certaine information. L'élément de base d'un réseau de neurones est le neurone, dont l'utilisation n'a pas changé depuis sa création par Widrow et Hoff [41] en 1960. Ces derniers ont considéré le perceptron comme un élément adaptatif ressemblant à un neurone biologique.

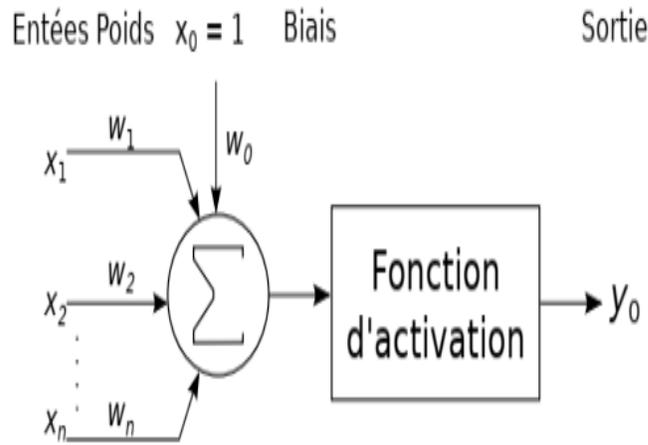


FIGURE 1.5 – Un perceptron

Le perceptron a trois constituants :

- Un noyau, nommé perceptron, représenté par une somme et une fonction d'activation.
- Un signal multiple d'entrées X_i qui sont connectées via ce qu'on appelle des poids W_i .
- Un signal de sortie Y_0 . Une entrée additionnelle W_0 qui est nommée biais, qui fait office de seuil. Le signal de sortie est défini dans l'équation 1.16.

$$Y_0 = f\left(\sum_{i=1}^n W_i X_i + W_0\right). \quad (1.16)$$

Le choix de la fonction d'activation est crucial pour le perceptron. Block, en 1962 [42, 43], a sélectionné la fonction binaire, mais elle fut remplacée par la fonction d'activation sigmoïdale et cette dernière est considérée comme un approximateur universel :

$$f(x) = \frac{1}{1 + \exp(-x)}. \quad (1.17)$$

Le perceptron peut apprendre par le biais d'un algorithme d'apprentissage basé sur un ensemble de données. Pendant la phase d'apprentissage, le perceptron ajuste ses poids en accord avec les données présentées en entrée. Widrow et Hoff [41], en

1960, ont proposé l'algorithme règle delta. Puis, dans les années 90, Rumelhart [43] a popularisé l'algorithme rétro-propagation du gradient qui est le plus utilisé de nos jours. Même si les algorithmes d'apprentissage sont en majorité efficaces en terme de rapidité de convergence, un perceptron seul ne peut apprendre suffisamment pour résoudre des problèmes complexes (non-linéaires), ceci étant dû à sa structure simpliste. Afin de palier ce problème, une structure multicouche nommée MultiLayer Perceptron (MLP) ou perceptron multicouche (Figure 1.6), qui, en plus des couches d'entrée et de sortie, contient une couche cachée insérée entre les deux. Les algorithmes ANN communément utilisés pour la prévision de la charge électrique ou des séries temporelles sont :

- les réseaux de neurones feed-forward (FF) ;

- Réseaux de neurones NARX (autorégressifs non linéaires avec entrées exogènes) ;

- les réseaux de neurones à rétro-propagation (BP) ;

- réseaux de neurones à fonction de base radiale (RBF) ;

- les réseaux de neurones aléatoires ;

- réseaux de neurones récurrents ;

- réseaux de neurones compétitifs auto-organisés ;

- self-organizing competitive neural networks.

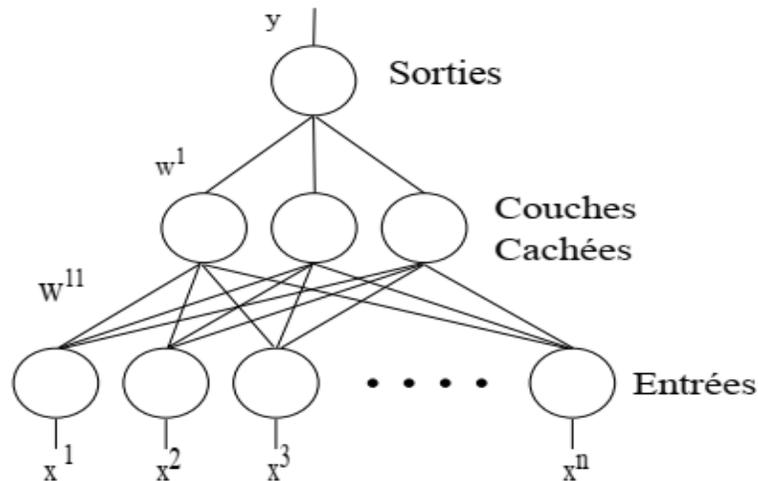


FIGURE 1.6 – Le Perceptron Multi-couche

Selon Weron et al [31], les modèles ANN proposés pourraient être classés en deux groupes principaux :

- Le premier groupe comprend les ANN qui n'ont qu'un seul nœud de sortie. Il est utilisé pour prévoir la prochaine charge de l'heure, la charge de pointe du lendemain ou la charge totale du jour suivant.

- Le deuxième groupe implique des modèles qui ont plusieurs nœuds de sortie pour prévoir une séquence de charges horaires, généralement 24 nœuds, dans le but de prédire le profil de charge complète du lendemain. Basé sur [44, 45], le deuxième groupe a une forte robustesse et une forte capacité d'apprentissage. Cependant, le ANN tombe rapidement dans le minimum local en raison de la restriction de la capacité de généralisation et ne peut pas utiliser pleinement les informations à cause de la petite taille de l'échantillon sélectionné. Par ailleurs, l'apprentissage et la vitesse de convergence sont lentes.

1.2.2.2 Le modèle de logique floue

Le terme "flou" a été introduit par Zadeh en 1965 dans son article intitulé "Fuzzy sets" sur les ensembles flous. Ainsi, la discipline mathématique nommée

"logique floue" qui est basée sur les ensembles flous a été présentée. La logique proposée vise à soutenir la présentation et l'examen des notions inexactes ou imprécises par des ensembles flous. Dans la logique floue, un objet ou une variable définie dans un domaine peut partiellement appartenir à plusieurs ensembles flous simultanément. La principale idée dans la théorie des ensembles flous est la fonction d'appartenance, qui sert à mesurer le degré auquel plusieurs éléments flous appartiennent à un certain ensemble flou. Par conséquent, un vrai ou faux n'est pas nécessaire pour définir cette propriété, mais peut être défini comme partiellement vrai. En utilisant la fonction d'appartenance m , on peut définir un ensemble flou F dans un univers de définition U comme suit :

$$\mu_F(x) : U \rightarrow [0, 1]. \quad (1.18)$$

Cette fonction est juste un *mapping* de l'univers de définition U vers l'intervalle $[0; 1]$. $mF(x)$ représente le degré d'appartenance de x à l'ensemble flou F . Le concept de la fonction d'appartenance permet à n'importe quel élément de l'univers d'appartenir partiellement à deux ensembles flous mais avec des degrés différents. Les ensembles flous, les variables linguistiques et la logique floue ont une relation directe avec les systèmes de logique floue. Ces derniers sont uniques dans le sens où ils peuvent traiter simultanément des données numériques et des connaissances linguistiques. D'un point de vue mathématique, un système de logique floue est un *mapping* non-linéaire d'un vecteur de caractéristiques (données) vers une sortie scalaire. Le diagramme d'un système flou est représenté dans la figure 1.7 à partir de laquelle on peut déduire que le système de logique floue prend une valeur X ; ensuite, il la convertit en un degré d'appartenance à un ou plusieurs ensembles flous définis. On appelle cette étape la "fuzzification". Par la suite, un système d'inférence floue va utiliser des règles floues, préalablement définies, afin de produire une sortie floue qui sera finalement défuzzifiée pour donner une sortie

Y. N'importe quel système peut être décrit par une collection de règles IF-THEN, aussi connues sous le nom de règle floue. Les systèmes de logique floue sont basés sur ces règles qui sont généralement sous la forme : IF préposition THEN conséquence, et sur leur système d'inférence. Dans la pratique, les systèmes d'inférence floue suivants ont été le plus souvent utilisés et ont le plus souvent fait l'objet d'études théoriques :

- Le système d'inférence de type Mamdani.
- Le système d'inférence de type Takagi-Sugeno.
- Le système flou relationnel (Pedrycz).

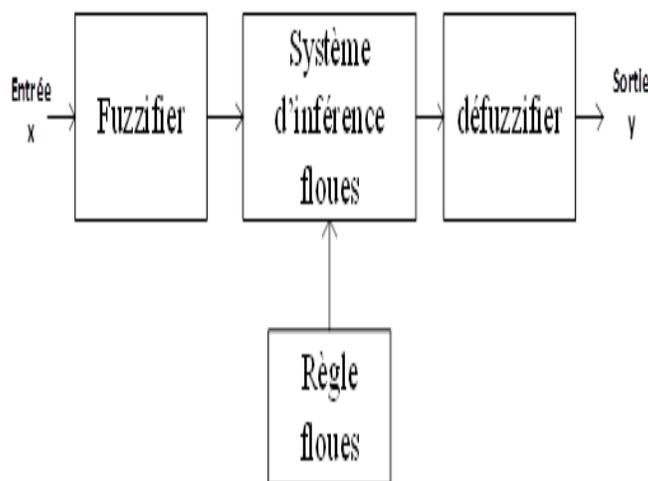


FIGURE 1.7 – Diagramme d'un système flou

La théorie floue est souvent associée à d'autres méthodes pour obtenir de bons résultats de prédiction [44]. En bref, la logique floue peut être utilisée dans de tels cas [46] :

- Le modèle mathématique n'existe pas, ou il existe mais est trop difficile à encoder ;
- Le modèle mathématique est trop complexe pour être évalué assez rapidement pour un fonctionnement en temps réel ;
- Le modèle mathématique inclut trop de mémoire sur l'architecture de la puce

désignée ;

-L'expert est disponible qui peut spécifier les règles sous-tendant le comportement du système et les ensembles flous qui représentent les caractéristiques de chaque variable ;

-Le système a des incertitudes dans ses entrées ou sa définition.

-Les systèmes sont : trop compliqués, trop non linéaires ou avec trop d'incertitude pour être mis en oeuvre à l'aide les techniques traditionnelles.

Cependant, nous devons éviter d'utiliser la logique floue pour les systèmes dans lesquels les équations de contrôle conventionnelles et les modèles sont déjà optimaux ou tout à fait adéquats [46]. Dans le domaine de la prévision de la charge électrique, il existe dans la littérature plusieurs documents qui sont consacrés à la modélisation et à la prédiction avec un accent particulier sur les approches informatiques et d'intelligence artificielle, y compris les modèles de logique floue [47, 48, 49].

1.2.2.3 L'algorithme génétique(AG)

Dans les années 1950 et 1960, il n'y avait pas d'informaticiens, qui avaient étudié indépendamment systèmes évolutionnaires avec l'idée que l'évolution pourrait être utilisée comme un outil d'optimisation pour résoudre problèmes d'ingénierie. L'idée dans tous ces systèmes était de développer une population de solutions possibles à un problème donné à l'aide d'opérateurs, qui miment une variation génétique et la sélection naturelle [50]. John Holland a été le premier à introduire des algorithmes génétiques et à développer son idée dans un livre intitulé "*Adaptation dans les systèmes naturels et artificiels*". David Goldberg a finalement popularisé le GAs en 1989. Les algorithmes génétiques sont devenus l'une des techniques de calcul évolutif [51]. Les GA représentent une pléthore de tech-

niques d'optimisation et de recherche basée sur le principe de la génétique et de la sélection naturelle. Ils permettent de composer la population de plusieurs individus exposés à des règles de sélection spécifiques qui maximisent le succès de la solution ("fitness") ou qui minimisent la fonction de coût. Holland a présenté GA comme une méthode heuristique (métaheuristique) basée sur le principe de "la survie des meilleurs". Cela a fait des GA un outil pratique pour résoudre les problèmes graves d'optimisation [51]. Pour résumer, l'algorithme génétique représente un type d'optimisation pour trouver la ou les solutions optimale(s) à un problème de calcul donné qui maximise ou minimise une fonction critère. Il représente une branche importante du domaine de l'évolution calcul [52]. Au cours des deux dernières décennies, les GA ont été largement utilisés et appliqués avec succès à divers types de problèmes d'optimisation [53]. Les composantes de base des algorithmes génétiques sont [52, 54] :

a) Une fonction de fitness pour l'optimisation; la fonction que l'algorithme essaie d'optimiser, et c'est une des parties les plus essentielles de l'algorithme.

b) Une population de chromosomes; le chromosome faisant référence à des valeurs qui représentent une solution candidate au problème que nous essayons de résoudre. Un algorithme génétique commence par un ensemble choisi au hasard de chromosomes, qui sert de première génération ou de population initiale. Ensuite, chaque chromosome de la population est évaluée par la fonction de fitness pour tester dans quelle mesure elle résout le problème.

c) Une sélection des chromosomes qui se reproduiront; basée sur une distribution de probabilité définie par l'utilisateur.

d) Un croisement pour produire la prochaine génération de chromosomes; l'opérateur de croisement rassemble le croisement biologique et la recombinaison des chromosomes dans la méiose cellulaire.

e) Une mutation aléatoire des chromosomes dans la nouvelle génération qui retourne au hasard des bits individuels dans les nouveaux chromosomes.

Dans le domaine de la prévision de la charge électrique ou de tout type de prévision, les GA ont été largement utilisés. Il en résulte qu'ils sont souvent bien adaptés aux systèmes non linéaires et ils effectuent une optimisation basée sur la sélection naturelle des solutions optimales trouvées parmi un large éventail de prévision des populations de candidats modèles [55]. Ce type d'optimisation basée sur GA est généralement déployé lors de la procédure de sélection du modèle lorsque les paramètres les plus appropriés du modèle de prévision doivent être trouvés. Par exemple, dans le travail [55], les AG ont été appliqués pour trouver les paramètres optimaux p , d et q du modèle ARIMA. En ce qui concerne la prévision ELF, Aquino et al. [56] ont utilisé les GA pour développer un modèle de prévision de charge basé sur un réseau de neurones. Gupta et Sarangi [57] ont utilisé la méthode de rétropropagation basée sur GA pour une prévision ELF efficace. Khan et al. [58] ont rapporté des prévisions de charge à très court terme à l'aide de la génétique cartésienne, programmation évoluée des réseaux de neurones récurrents. De plus, la prévision ELF basée sur GA est discutée dans de nombreux autres travaux, tels que, ceux de Li et al., Silva-Ortega et al. [59, 60].

1.2.2.4 Les systèmes experts

D'après Weron, le système expert est un programme informatique qui a la capacité d'expliquer, de comprendre, et d'élargir sa base de connaissances à mesure que de nouvelles informations deviennent disponibles [61]. Les systèmes experts combinent règles et procédures utilisées par les experts humains. Les connaissances d'un expert doivent être pratiques pour codification en règles logicielles. En particulier, les experts doivent être en mesure d'expliquer leur décision pro-

cessus aux programmeurs. Cette connaissance est ensuite codifiée sous forme de faits et d'énoncés SI-ALORS. Ceci constitue un ensemble de relations entre les variations de la charge du système et les variations des facteurs exogènes qui affectent la charge. Au fil du temps, certaines règles ne changent pas, tandis que d'autres doivent être continuellement mis à jour.

1.2.3 Les méthodes hybrides et classification complète des modèles de prévision

Les modèles et méthodes hybrides ou combinés peuvent obtenir de meilleures performances de prévision que les modèles uniques en intégrant les avantages de différents modèles de prévision uniques. Ces modèles hybrides sont largement utilisés dans de nombreux domaines de prévision. En ce sens, il existe de nombreuses prévisions disponibles; méthodes, algorithmes d'optimisation et techniques de traitement de données pour développer différents modèles hybrides [62, 63]. Ainsi, des études récentes ont transféré leur objectif principal de recherche sur le développement de modèles hybrides efficaces dans l'espoir d'améliorer les performances de prédiction [64]. En conséquence, il est raisonnable de trouver des méthodes hybrides modernes, présentées afin de couvrir les nouveaux cadres technologiques [65]. Cependant, il n'y a pas de références avouées sur la façon de sélectionner différentes méthodes pour construire un modèle hybride [63]. Tous les modèles de prévision de charge électrique largement utilisés qui ont été mentionnés ci-dessus et discutés dans les deux sous-sections précédentes sont illustrés à la figure 1.8.

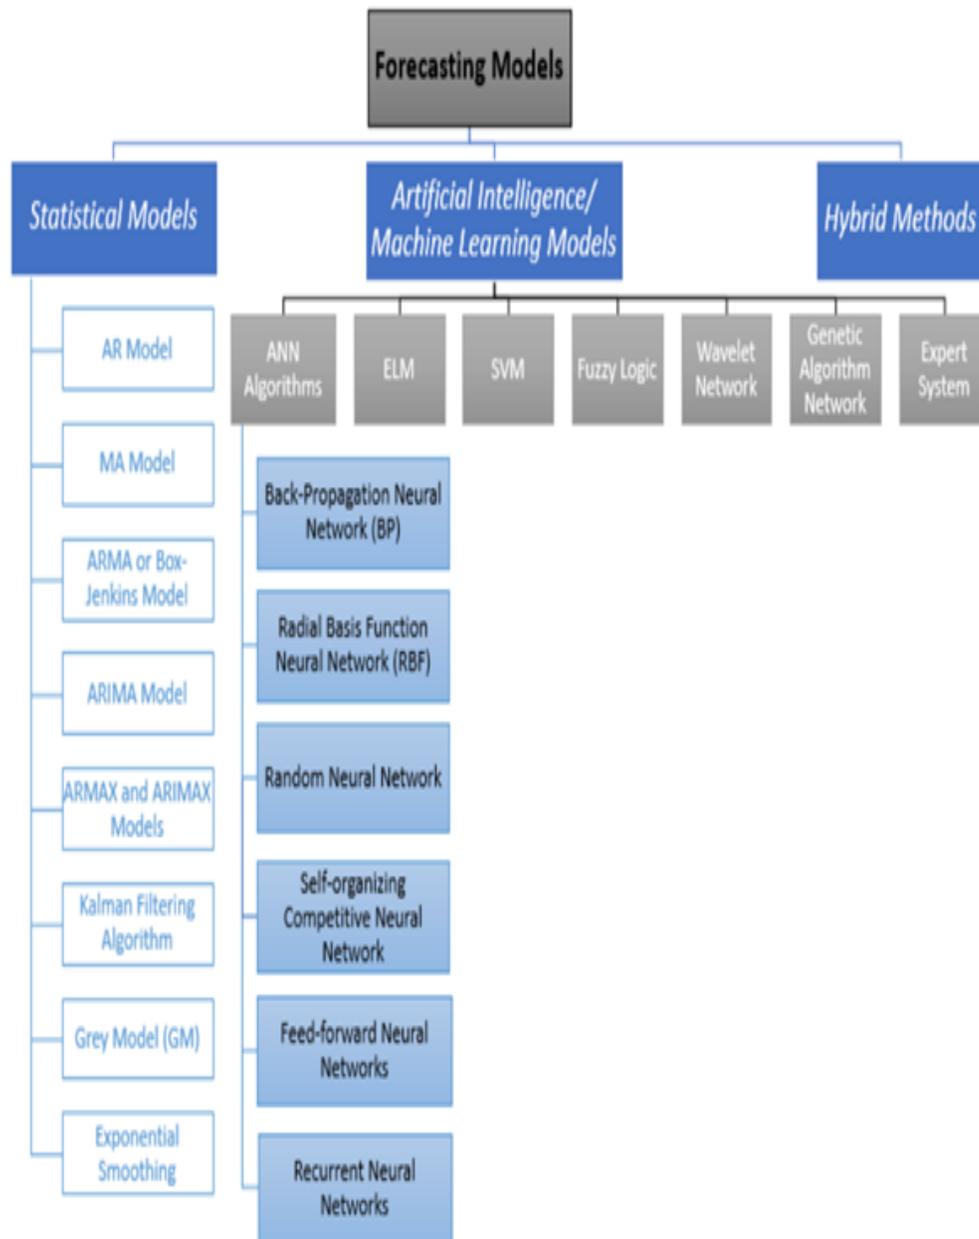


FIGURE 1.8 – Une classification complète des modèles de prévision (source :Adapté par les auteurs)

1.2.4 Les horizons de prévision

La prévision de la charge est l'estimation des valeurs futures. Elle aide les industries énergétiques dans la prise de décisions en ce qui concerne le planning,

la production électrique, et le développement des infrastructures. La prévision de la charge peut être classée en trois catégories [66] :

- La prévision à long terme ; utilisée pour prédire jusqu'à une période de 50 ans, dans le but de faciliter la planification de l'expansion du réseau énergétique.

- La prévision à moyen terme ; quant à elle, est utilisée pour prédire les pics hebdomadaires, mensuels et annuels jusqu'à une période d'une année, de sorte qu'une planification opérationnelle efficace puisse être effectuée.

- La prévision à court terme ; permettant une prévision allant jusqu'à une semaine dans le but de minimiser le fonctionnement quotidien et les frais d'envoi sur le réseau. En plus de ces trois catégories de prévisions de la charge, une quatrième catégorie a émergé ces dernières années ; le moyen-long terme (Figure 1.9), dans laquelle l'unité de temps considérée est le mois et l'année, elle se place naturellement entre le moyen et le long terme. Le moyen-long terme est très important pour la gestion et la planification du réseau, spécialement pour les pays en développement où la demande énergétique augmente avec un taux de croissance dynamique. Aussi, la prévision à moyen-long terme comme celle à long terme est toujours difficile à prévoir et cela est dû aux facteurs affectant la charge électrique.

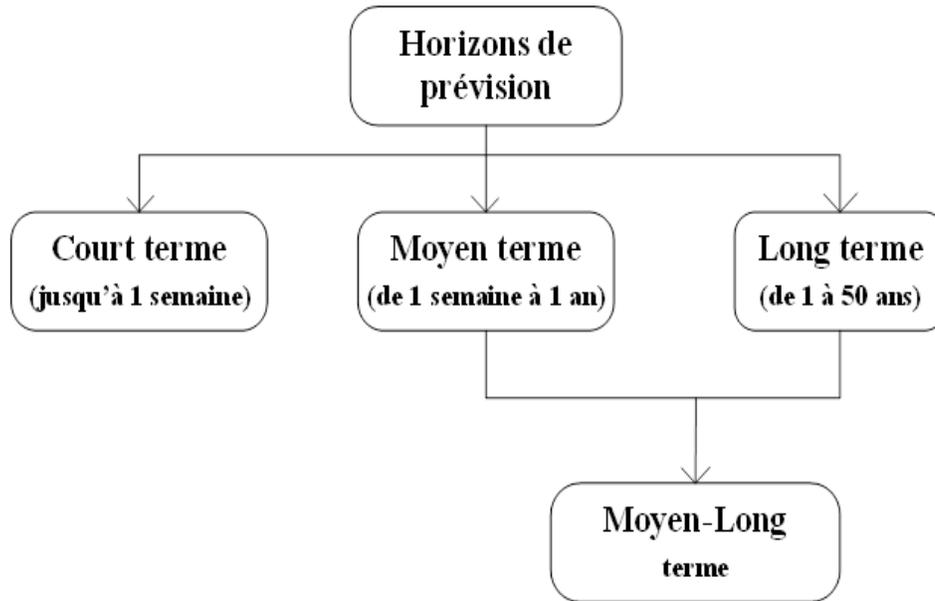


FIGURE 1.9 – Les différents horizons de prévisions[66]

On considère trois secteurs(Figure1.10) pour ce qui concerne la prévision de la charge électrique. Premièrement le secteur résidentiel qui a un taux de croissance annuel uniforme et des fluctuations saisonnières importantes. Ces dernières sont une conséquence de l'utilisation des appareils tels que les climatiseurs et le chauffage. Deuxièmement, le secteur commercial a aussi des fluctuations saisonnières identiques à celles du secteur résidentiel. Troisièmement, le secteur industriel qui est un secteur de base ayant peu de variations dépendantes du climat.

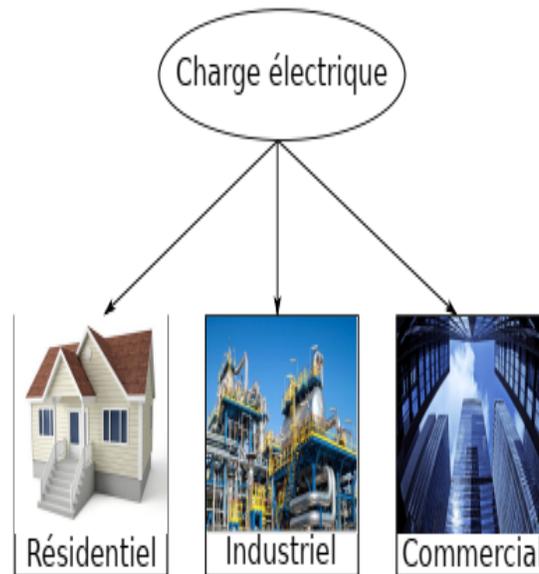


FIGURE 1.10 – Les secteurs concernés par la prévision de la charge électrique (source : adaptée par les auteurs)

Chaque secteur a des besoins énergétiques spécifiques ainsi que des infrastructures de transport et de distribution adaptées aux besoins du secteur. La prévision de chaque secteur sur les horizons mentionnés plus haut est possible en intégrant dans l'étude les caractéristiques des secteurs respectifs. Nous allons nous intéresser dans le prochain paragraphe aux travaux réalisés dans la littérature pour la prévision à moyen et à long terme de la charge électrique qu'elle soit par secteur ou globale, par région ou par pays.

1.3 Brève revue systémique de la littérature sur la prévision de la charge électrique

Pendant des années, les problèmes d'amélioration de la précision de la prévision des charges en énergie électrique ont été un sujet de recherche important. Récemment, les recherches dans ce domaine ont abouti au développement de nombreuses méthodes de prévision [67, 68]. Ces méthodes sont principalement

classées en deux catégories : les approches classiques et les techniques basées sur l'intelligence artificielle (IA). Les approches classiques sont basées sur diverses méthodes de modélisation statistique telles que les séries chronologiques, la régression, le lissage exponentiel, le modèle de Box-Jenkins et les filtres de Kalman. Cependant, ces méthodes classiques ne peuvent pas représenter correctement les relations non linéaires complexes qui existent entre la charge et la série de facteurs qui l'influencent [69].

À partir des années 1990, les chercheurs ont commencé à utiliser différentes approches de prévision autres que l'approche classique. L'accent a été porté sur la mise en œuvre de diverses techniques d'IA pour les prévisions à court terme. Des techniques d'IA telles que le réseau neuronal, la logique floue et les systèmes experts ont été appliquées pour faire face à la non-linéarité, aux grands ensembles de données nécessaires à la mise en œuvre des prévisions à court terme et à d'autres difficultés de modélisation des méthodes classiques utilisées pour l'application [67, 69]. Parmi les techniques d'IA disponibles, différents modèles de réseau neuronal ont reçu beaucoup d'attention de la part des chercheurs dans le domaine des prévisions à court terme en raison de sa flexibilité dans la modélisation des données. Park [70] faisait partie du premier groupe de chercheurs à avoir utilisé l'approche ANN pour les prévisions à court terme.

Les réseaux de neurones artificiels (ANN) sont un moyen puissant pour la prévision de séries chronologiques parce que dans de nombreuses études, les méthodes de prévision des réseaux de neurones artificiels (ANN) se sont avérées plus exactes que les méthodes statistiques traditionnelles [69, 71]. Par conséquent, de nombreuses recherches ont été effectuées pour introduire le réseau neuronal dans les réseaux intelligents afin de traiter des problèmes tels que la prédiction, la planification, la gestion et la détection des fraudes [72, 73]. Srinivasan, Liew

et Chen [74], ont utilisé un ANN basé sur la rétropropagation pour la prévision et ont montré sa supériorité par rapport aux méthodes traditionnelles. Chen et Tzeng [75] ont développé un modèle basé sur ANN supervisé pour les prévisions à court terme et évalué les performances du modèle en appliquant les données de charge réelles du réseau électrique national du Kenya. Amera, Lamya et Sozan [76] ont analysé et discuté d'une approche globale pour STLF utilisant ANN. Leurs architectures proposées ont été formées et testées en utilisant les données de charge réelles des deux années précédentes obtenues à partir du contrôle Duhuk ELC en Irak. Dans leur étude, quatre modèles ANN ont été mis en œuvre et validés avec une précision raisonnable sur des données de sortie de génération de charge électrique réelle.

Forderer et al.(2018) [72] ont conclu que nous avons besoin de plus de couches cachées qui apprennent avec la méthode de descente de gradient pour réduire les pertes. Samsher et Unde [61] ont réalisé les prévisions à court terme pour P.D.V.V.P COE, campus du collège Ahmednager en utilisant la technique ANN et ont été mis en œuvre sur MATLAB-10. Adepoju, Ogunjuyigbe et Alawode [77] ont utilisé des réseaux de perceptrons multicouche (MLP) avec rétropropagation pour ajuster les poids du réseau neuronal. Le réseau neuronal a été formé à l'aide des données de la compagnie d'électricité nigériane. Mohammed et Sanusi [78] ont développé un modèle ANN multicouche de rétroaction pour la sous-station 132/33KV, Kano, Nigeria en utilisant la technique d'optimisation de Levenberg-Marquardt pour former le réseau. Slobodan et al., [79] ont présenté une méthode basée sur l'ANN ciblée pour être utilisée dans un système à grande échelle comme système de gestion de la distribution (DSM). Le système comprend une unité de prétraitement (PPU) et une annulation directe ordonnée dans une séquence. La fonctionnalité de la méthode proposée a été testée sur des données enregistrées

de la compagnie d'électricité serbe. Les ANN ont été intégrés à plusieurs autres techniques pour améliorer leur précision.

Nima et Farshid [80] ont présenté une hybridation d'un réseau neuronal avec une nouvelle technique de recherche stochastique pour les prévisions à court terme. Zohreh, hadi et Mahdi [81] ont utilisé le système adaptatif d'inférence neuronale floue (ANFIS) pour étudier la conception de systèmes STLF pour l'est de l'Iran. Pour éviter le sur-ajustement, les auteurs de Din et Marnerides [82] ont utilisé des données météorologiques et de charge électrique ISO-Nouvelle-Angleterre sur 5 ans avec une sélection de caractéristiques temps-fréquence pour former les modèles DNN proposés à l'aide d'une fonction d'activation unique. Dans Almalaq et Edwards [78], les auteurs ont mis en lumière l'étude de DNN pour STLF en proposant deux architectures à la pointe de la technologie, concluant sur la nécessité d'un grand ensemble de données pour explorer une meilleure structure DNN. Ryu et al. [83] concluent que la méthode Machines Boltzmann restreintes (RBM) et réseaux de neurones à action directe avec plusieurs couches dans la prévision des charges des consommateurs est très lente à entraîner et nécessite beaucoup de puissance. Les réseaux de neurones avec de nombreuses couches peuvent être formés efficacement pour donner de meilleures prévisions. Ford et al., Chen et al. [84, 85] concluent que même avec l'augmentation du nombre de couches cachées, il existe le problème de la disparition des gradients ou du sur-ajustement sévère. Pour résoudre ce problème, nous avons besoin d'une architecture profonde optimale et le problème de sur-ajustement est traité par une quantité croissante de données. Cependant, ces modèles sont de plus en plus difficiles à former au fur et à mesure que le nombre de couches augmente, ainsi le nombre de couches cachées est souvent considérablement petit (par exemple, 2 à 5 couches), ce qui limite les performances des modèles. Dans leurs travaux précédent, Mohammed et al. [86]

ont utilisé l'algorithme de rétropropagation de Levenberg-Marquardt (LM) pour former deux réseaux ayant huit caractéristiques d'entrée et deux couches cachées, les résultats ont montré sa haute fiabilité avec moins d'erreurs. La performance était bonne pour les cas ayant une faible erreur, mais le modèle présente une généralisation moins étendue. Pour atteindre une meilleure généralisation, nous avons besoin de plus de paramètres d'entrée dont l'impact est élevé sur la consommation de la charge électrique.

P.Lakshmi Priya et al. [87] ont proposé un modèle de logique floue pour les Prévisions de la demande d'électricité à court terme en inde. Ils ont établi que les systèmes flous utilisent des règles compréhensibles comme connaissances préalables pour obtenir des résultats avec une précision aussi proche de celle du réseau de neurones, mais ils manquent d'auto-apprentissage.

Danladi Ali et al. proposent un modèle de logique floue pour la prévision de la charge à long terme en fonction des paramètres météorologiques (température et humidité) et des données historiques de charge pour la ville de Mubi dans l'état d'Adamawa au Nigeria. Le modèle de logique floue prévoyait une charge pour l'année à venir avec un MAPE de 6,9%. Le résultat obtenu révèle que le modèle proposé est capable de prédire la consommation annuelle avec une plus grande efficacité que les modèles statistiques [88].

Sun-Youn Shin et al. Ont comparé trois algorithmes d'apprentissage automatiques différents, à savoir le Random Modèle Forest (RF), modèle XGBoost (XGB) et modèle Long Short-Term Memory (LSTM) pour les Prévision de la consommation d'énergie en Corée. Les résultats ont donc suggéré l'applicabilité de l'apprentissage automatique pour prévoir la consommation d'énergie et a également démontré que les approches économétriques traditionnelles peuvent surpasser l'apprentissage automatique lorsqu'il y a moins d'irrégularités inconnues dans la série

chronologique, mais que l'apprentissage automatique peut mieux fonctionner avec données de séries chronologiques irrégulières inattendues [89].

Taher M. Ghazal, Sajida Noreen et al. ont proposé un compteur intelligent utilisant une machine à vecteurs de support et des techniques d'apprentissage automatique profondes pour une gestion professionnelle de l'énergie. Les résultats obtenus ont montré que la fusion décisionnelle appliquée aux ensembles de données pour prédire la consommation d'énergie via des compteurs intelligents a permis d'atteindre une très bonne précision que celles des techniques précédentes [90].

Zhang et Wang [91] ont utilisé dans leur étude un Back Propagation Neural Network (BP-NN) avec une Analyse des Composantes Principales (ACP) afin de réduire le problème de précision et de généraliser les modèles de prévision. Ayant la capacité d'éliminer la corrélation existante entre les variables, l'ACP a non seulement été utilisée pour réduire le nombre de variables mais également pour garantir l'originalité des informations. En effet, elle a permis d'optimiser la structure du réseau de neurones. Ce dernier nommé PCA-BPNN a été utilisé pour prédire la charge électrique annuelle de certaines zones urbaines. Les auteurs ont expérimenté le modèle PCA-BPNN sur la charge électrique de 2003 à 2005 en tenant compte de la demande électrique et des facteurs qui influencent tels que : la population, le produit national brut PNB, ainsi que le produit brut des industries primaires, secondaires et tertiaires. Ce modèle a donné une meilleure précision.

Zhang et Liu [92] ont développé un ensemble des règles floues obtenues via les algorithmes génétiques dans le Système de logique floue pour la prévision de la charge à moyen-long terme. Le choix de cette méthode a été motivé par le fait que les systèmes flous proposent de meilleures formes pour l'expression de règles, que la logique floue offre la possibilité d'un raisonnement logique équivalent à la

pensée humaine et, enfin, les algorithmes génétiques proposent une exploitation intelligente d'une recherche aléatoire dans un espace de recherches défini pour la résolution de problèmes. L'expérimentation proposée par Zhang et Liu a été réalisée sur les données du réseau électrique de Hebei en Chine et les résultats confirment que cette nouvelle combinaison est efficace. En effet, elle augmente la vitesse et la précision de la prévision de la charge électrique.

Plusieurs études se sont inspirées des avantages de la théorie Grey pour la prévision de la charge électrique. Ainsi, Shao et al [93] ont proposé une approche basée sur la méthode Grey qu'ils ont vérifiée en utilisant l'historique des données de la consommation énergétique de 1999 à 2005 de la ville de Pékin. Dans leur étude, ils ont amélioré le modèle Grey ou en anglais Grey Model (GM) via les méthodes Smoothly Processing et Background Value Processing. Après que la charge électrique entre dans le modèle, cette dernière passe par deux étapes : La première consiste à effectuer le lissage des données et à obtenir la meilleure valeur pour la méthode Background Value. Quant à la seconde, elle se base sur la prévision de la charge électrique. Les résultats obtenus ont démontré que le nouveau modèle présente un avantage clair en termes de précision et atteint une erreur moyenne relative de 1.19% en comparaison avec le modèle Grey classique qui, lui, arrive à une erreur de 1.39%.

Wang et al. [94], ont proposé un modèle pour prédire la consommation d'énergie hydroélectrique de la Chine, qui est basé sur une décomposition saisonnière ou Seasonal Decomposition (SD) avec l'algorithme X12-ARIMA et Least Squares Support Vector Regression (LS-SVR). Le modèle nommé SD(M)-LSSVR-LSSVR décompose premièrement l'énergie hydroélectrique en trois composantes, qui sont par la suite prédites via 3 modèles LSSVRs. Ensuite, un dernier LSSVR combine les trois prédictions des composantes pour obtenir la prévision finale de la consom-

mation de l'énergie hydroélectrique de la Chine. Les auteurs ont prouvé l'efficacité de la méthode X12-ARIMA en la comparant avec d'autres méthodes de décomposition comme Ratio Moving Average (RMA) et Empirical Mode Decomposition (EMD). L'étude montre que les performances du modèle SD(M)-LSSVR-LSSVR diminuent quand l'horizon de prévision est grand, mais le modèle est le plus performant par rapport aux autres modèles de cette étude.

Ding [95] a utilisé une méthode basée sur les arbres décisionnels pour l'extraction de règles if-then, clarifiant de ce fait les relations existantes entre la charge électrique et les variables exogènes relatives. L'auteur a utilisé, dans la phase d'expérimentation, les données économiques de 1978 à 2004 collectées du "Official Statistical Almanac" et les données de la charge électrique via Energy Management System (EMS). Les données de 1978 à 2001 ont quant à elles été utilisées pour construire l'arbre de décisions avec l'algorithme Iterative Dichotomiser 3 (ID3), 14 facteurs ont été pris en considération par l'auteur. La phase de test a montré que l'arbre décisionnel donne une erreur moyenne de 1.45 qui reste le meilleur résultat en comparaison avec d'autres modèles tels que le modèle Grey, l'arbre de décisions traditionnel, la régression linéaire multiple, et bien d'autres.

Delevad et al. [96] ont proposé une étude dans laquelle la charge électrique iranienne a été prédite à long terme grâce à un réseau de neurones artificiels. Les auteurs ont pris en considération les facteurs économiques où la température n'a pas été prise en compte dans leur étude pour prévenir d'éventuels bruits, douze facteurs ont été sélectionnés à l'instar de : le Produit Intérieur Brut (P.I.B), le Produit National Brut (PNB), le prix du pétrole iranien, entre autres. Ces facteurs représentent les entrées du réseau de neurones, avec dix-neuf neurones en couche cachée et une sortie. La phase d'apprentissage s'est faite en utilisant l'algorithme de rétro-propagation du gradient. Les données de 1990 à 2003 ont été utilisées pour

la phase d'apprentissage ; quant à celles de 2004 à 2006, elles ont été utilisées pour la phase de test suite à laquelle le réseau de neurones arrive à une erreur Mean Squared Error (MSE) de 0.95% pour l'année 2006, ce qui a été jugé satisfaisant par les auteurs.

Carpinteiro et al. [97] proposèrent un réseau de neurones hybride hiérarchique pour le problème de la prévision de la charge électrique à long terme. En effet, ils ont utilisé deux réseaux de neurones de type Self-Organizing Map (SOM) l'un sur l'autre et une couche de perceptron. Les auteurs ont comparé le modèle proposé avec un perceptron multicouche ou MLP, l'expérimentation s'est faite sur les données électriques de l'amérique du nord pour la période de 1985 à 1991. Les résultats de cette étude démontrent que le modèle présenté est supérieur en termes de performance, et cela est justifié par sa topologie hiérarchique. Ce nouveau modèle est considéré comme très prometteur.

Man-Wen Tian et al. [98] ont proposé un nouveau modèle en utilisant une approche floue récurrente pour les prévisions à court terme de la charge électrique de la ville de Kermanshah. Dans cette approche, une nouvelle combinaison de réseaux de neurones (NN) et de réseaux flous de type 2 (T2FSs) est utilisée en ajoutant rétroaction au réseau neuronal flou. Les résultats de la simulation ont prouvé l'efficacité de cette méthode de prévision de la charge électrique. Les auteurs découvrent qu'il est possible de prédire avec précision la charge électrique de la ville pour le lendemain avec une précision de 98%. Les auteurs estiment que ce nouveau modèle améliore, augmente la précision des prévisions et donne la possibilité d'entrée de nouvelles données dans le modèle sans toutefois reprendre les calculs depuis le début.

Mohammed Jamil et Mohamed Maaroufi [99] ont développé un modèle ARIMA pour modéliser la prévision de la demande d'électricité au Maroc en utilisant l'ap-

proche des séries chronologiques de Box-Jenkins. Les données historiques pour les périodes annuelles de 1971 à 2020 ont été utilisées pour développer plusieurs modèles, et le meilleur modèle a été sélectionné selon quatre critères de performance : SBC, AIC, erreur standard et maximum de vraisemblance. Les auteurs concluent après études que ARIMA (1,1,1) est le modèle qui minimise les quatre critères précédents. Les résultats obtenus prouvent que ce modèle peut être utilisé pour modéliser et prévoir la future demande d'électricité au Maroc. Les principaux résultats de cette projection révèlent la tendance à la hausse de la demande d'électricité, qui devrait passer de 37741,24 GWh en 2021 à 46614,04 GWh en 2030. Ce scénario promet une augmentation de près de 34,54% en cas de développement démocratique du pays et l'intensification de l'électrification du secteur domestique, ainsi qu'un développement industriel et agricole. Les résultats obtenus pourraient aider à planifier le développement à moyen et à long terme du réseau électrique et la production d'énergie dans le pays. Ils pourraient également créer, développer et trouver l'énergie appropriée.

Afin d'améliorer la précision des prévisions, Feng Gao et al. ont proposé un nouveau modèle hybride avec des données de recherche en ligne pour la prévision de la consommation d'électricité résidentielle [100]. Le modèle est implémenté en deux principales étapes à savoir : l'analyse de corrélation des différences temporelles, le test de cointégration et le test de causalité de Granger qui sont utilisés pour étudier la relation entre les données de recherche en ligne, la consommation d'électricité résidentielle et la recherche qualifiée des mots-clés. Elles sont sélectionnées pour servir de prédicteurs. Un modèle de machine d'apprentissage extrême optimisé par l'algorithme Jaya, ainsi que les mots-clés de recherche sélectionnés à la première étape, sont proposés pour prédire la consommation d'électricité résidentielle. De plus, les données mensuelles de consommation d'électricité résidentielle en Chine

sont utilisées pour valider l'efficacité du modèle proposé. Les résultats expérimentaux montrent que l'incorporation de données de recherche en ligne dans le modèle peut améliorer considérablement la précision des prévisions. Après avoir intégré les données de recherche en ligne, les taux d'amélioration de tous les modèles de prévision dépassent 10%. De plus, le modèle proposé a la meilleure performance de prévision par rapport à la moyenne mobile intégrée autorégressive saisonnière (SARIMA(X)), à la régression vectorielle de support (SVR), au réseau de neurones à rétropropagation (BPNN) et au modèle d'apprentissage extrême (ELM). On note également une réduction de l'erreur de prévision (RMSE et MAPE) par rapport à d'autres modèles de référence. Une revue détaillée de l'utilisation de ces méthodes est présentée dans le tableau 1.2 ci-dessous.

Tableau 1.2 – Synthèse comparative des modèles de prévision

Modèles de prévision	Ref.	Année	Méthodes	Périodes	Variabes	Description
Modèles Statistiques	[18]		MLR	année	PIB, POP, PIB/habitant	Prévisions de la consommation d'électricité en Italie par des modèles de régression linéaire et recherche l'effet des variables économiques et démographiques qui sont les consommation, population, PIB (produit intérieur brut) par habitant et PIB sur la consommation annuelle d'électricité en Italie. Ils concluent que le PIB et la population influencent sur la consommation d'électricité
	[19]	2018	Forêt aléatoire	Horaire, mensuellement, annuellement	PIB, POP, PIB/habitant	Prévision horaire de la consommation d'énergie d'un bâtiment à l'aide de RF entraînée avec différents réglages des paramètres. Ils ont également étudié l'impact du changement de comportement sur la précision des prédictions.
	[21]	2017	Multiple LR, RF, gradient boosting		Temperature Humidité	Ont analysé l'influence de la température et la pression atmosphérique à l'aide de différents modèles statistiques. Les résultats montrent qu'il est important d'inclure la pression atmosphérique dans les modèles de prévision énergétique et pour la modélisation des performances des bâtiments.
Modèles d'apprentissage machine	[22]	2019	SVR	Hourly	Consommation horaire passées	Un SVR basé sur le champ vectoriel pour ECP est proposé en rapprochant la non-linéarité élevée entre l'entrée et la sortie de la linéarité. Les résultats indiquent que la méthode proposée atteint de meilleures performances que les méthodes couramment utilisées en ce qui concerne la précision, la robustesse et la capacité de généralisation.
	[23]	2019	Réseau de neurones	Court terme : horaire, jour, hebdomadaire	Consommation électriques passées	Proposent un réseau de neurones à rétropropagation sur les données de consommation d'énergie avec des moments statistiques.
Modèles d'apprentissage profond	[24]	2018	Deep extreme learning machine	hebdomadaire, mensuellement	Consommation électriques passées	Les auteurs ont exploré la machine d'apprentissage extrême profonde (DELIM), le système d'inférence neuro-floue adaptative (ANFIS) et ANN. Ils ont proposé DELIM pour la prévision de la consommation d'énergie (ECP) en raison de ses performances sur ANN et ANFIS.
	[25]	2017	Pooling-based DRNN	—	Consommation des passées des menages	Résout le sur-ajustement des performances de prévision à l'aide d'un DRNN mutualisé, testant leur solution sur de vrais compteurs communicants en Irlande. Les résultats obtenus montrent que le modèle pourrait traiter le problème du sur-ajustement en valorisant la diversité et le volume des données.

Suite du tableau 1.2

Modèles de prévision	Ref.	Année	Méthodes	Périodes	Variables	Description
Modèles Hybrides	[26]	2022	CBLSTM	MAE	POP, Prix d'électricité, conditions météorologiques, Niveau confort	Présente un cadre hybride d'apprentissage en profondeur pour prédire avec précision la consommation d'énergie de différents types de bâtiments, commerciaux et domestiques, dans plusieurs pays. Les résultats montrent une amélioration des performances dans temps de calcul et erreur de prévision. Le modèle se généralise bien à des données et des contraintes variables.
	[27]	2022	PSO-LSSVR		PIB, POP, PIB/habitant, Consommation des ménages	La cointégration et Les tests de causalité de Granger sont utilisés Pour découvrir les facteurs influençant la demande énergétique en Chine. Les principaux résultats sont les suivants. le produit intérieur brut (PIB), la population totale au fin d'année (POP), le ratio de consommation de charbon dans l'énergie et les niveaux de consommation des ménages sont des indicateurs dominants de la demande énergétique en Chine. De plus, le modèle PSO-LSSVR améliore à une supériorité significative sur les autres modèles dans la prévision de la demande d'énergie.
	[28]	2021	VAR-CNN-LSTM		Consommation des ménages, conditions météorologiques, nombre de menages	Ce papier présente une approche évolutive et hybride pour prévoir la puissance de la charge à partir des modèles Vector Auto Régression (VAR) et techniques hybrides d'apprentissage en profondeur comme La mémoire à court terme (LSTM) et réseau neuronal convolutif (CNN). Les resultats montre que l'hybride VAR-CNN-LSTM(VACL) proposé prévoit mieux que les méthodes d'apprentissage en profondeur plus récentes comme le perceptron multi-couche (MLP), CNN, LSTM. L'erreur de prévision est améliorée.
	[29]	2022	Hybride	Heures	Consommation des ménages, conditions météorologique, nombre de menages	Le but de cette étude est de proposer les modèles de prévision pour prédire la consommation horaire maximale d'électricité avec plus de précision que la prévision de charge officielle de slovaque compagnie. Différents modèles sont proposés et comparés. Les résultats montrent que le modèle hybride offre les meilleurs résultats selon les métriques de performance mesurées.

Suite du tableau 1.2

Modèles de prévision	Ref.	Année	Méthodes	Périodes	Variabiles	Description
Cette étude		2022	Hybride VECM- HES	Année	POP-PIB, Dépenses des ménages	Modélisation de la consommation de l'énergie électrique et optimisation de l'erreur de prévision à partir d'un modèle hybride des méthodes économétriques et de l'algorithme de gradient. Les résultats obtenus montrent bien que le nouveau modèle hybride a permis de minimiser l'erreur de prévision.

1.4 Les émissions de CO_2 par La production d'électricité

Comme toute énergie, la production d'électricité génère également des émissions de CO_2 . Le poids de ces émissions de CO_2 est difficile à établir puisqu'il existe plusieurs sources de production de l'électricité au Cameroun et les émissions de CO_2 varient énormément d'une source à l'autre.

Sotamenou Joël et Nanko Cyrille ont examiné les liens de court et long terme entre la consommation d'énergie, la croissance économique et les émissions de CO_2 au Cameroun entre 1975 et 2013, à partir d'un modèle à correction d'erreur (ARDL). Les résultats montrent qu'il n'existe pas de relation à long terme entre la consommation d'énergie et les émissions de CO_2 . À court terme par contre, la consommation d'énergie fossile, d'une part, et celle électrique, d'autre part, contribuent positivement aux émissions de CO_2 . La croissance économique a également un effet négatif sur la dégradation de l'environnement. Afin de réduire les effets nocifs des émissions de CO_2 , le Cameroun a ratifié, la Convention cadre sur les changements climatiques en Juin 1992 et l'accord de Paris en 2016 [101].

Conclusion

Dans ce chapitre, nous avons commencé par présenter l'historique et la situation actuelle du secteur électrique au Cameroun. De cette présentation, il res-

sort que le Cameroun possède le deuxième plus grand potentiel hydroélectrique d'Afrique subsaharienne (19,7 Gw) après la république démocratique du Congo. Cependant, seulement 5% environ de cette ressource naturelle est exploitée en raison de plusieurs obstacles naturels et du faible taux de développement des infrastructures de production. Nous avons continué par une analyse de l'offre et la demande d'énergie électrique au Cameroun. Sur ce point, on a conclu qu'il est caractérisé par un déséquilibre remarquable. Nous avons ensuite présenté les capacités de production d'énergie électrique au Cameroun, la répartition de la production des centrales électriques, les causes du déficit énergétique ainsi que les solutions envisagées pour réduire ce déficit énergétique. La deuxième articulation a été consacrée à la présentation des méthodes et concepts utilisés dans la littérature pour prédire la production et la consommation des charges électriques. Il en ressort que deux grandes familles existent : les méthodes issues de la statistique et celles de l'intelligence artificielle, ceci est une liste de méthodes non exhaustive dans laquelle nous avons présenté les plus importantes et surtout celles touchées dans les études que nous avons proposées dans cette thèse. Nous avons terminé par un état de l'art des travaux qui traitent de la prévision de la charge électrique dans le moyen et le long terme.

MODÉLISATION DES CONSOMMATIONS DE L'ÉNERGIE ÉLECTRIQUE À
COURT ET À LONG TERME PAR LES MÉTHODES ÉCONOMÉTRIQUES,
D'INTELLIGENCE ARTIFICIELLE ET DES MODÈLES HYBRIDES

Introduction

Au fil des années, différentes techniques ont été développées pour modéliser la charge d'électricité autant avec les outils classiques de l'économétrie des séries temporelles qu'avec les méthodes de l'intelligence artificielle. Certaines études se concentrent sur la comparaison de modèles spécifiques à l'une de ses approches, alors que d'autres comparent ces deux classes de modèles. Dans le chapitre précédent, nous avons donné une vision globale de l'ensemble des modèles disponibles pour étudier la consommation d'électricité dans un but de prévision. Dans l'actuel chapitre, après avoir défini la notion de modèle et série temporelle, nous présenterons tout d'abord les notions de théorie de corrélation et de stationnarité ; ensuite nous présenterons de façon détaillée les différentes étapes de modélisation des modèles statistiques, d'intelligence artificielle et les modèles hybrides retenus pour mener à bien nos travaux ainsi que les indicateurs de performances et les tests statistiques associés permettant d'approuver la validité de ces modèles.

2.1 Définitions

Il est délicat de fournir une définition unique de la notion de modèle. Dans le cadre de l'économétrie, nous pouvons considérer qu'un modèle consiste en une présentation formalisée d'un phénomène sous-forme d'équations dont les variables sont des grandeurs économiques. L'objectif du modèle est de représenter les traits les plus marquants d'une réalité qu'il cherche à styliser. Le modèle est donc l'outil que le modélisateur utilise lorsqu'il cherche à comprendre et à expliquer des phénomènes. Pour ce faire, il émet des hypothèses et explicite des relations.

Une série temporelle (ou encore une série chronologique) est une suite finie (X_1, \dots, X_n) de données indexées par le temps. L'indice temps peut être, selon les cas, la minute, l'heure, le jour, l'année etc. Le nombre "n" est appelé la longueur de la série. Il est la plupart du temps bien utile de représenter la série temporelle sur un graphe construit de la manière suivante : en abscisse le temps, en ordonnée la valeur de l'observation à chaque instant. Pour des questions de lisibilité, les points ainsi obtenus sont reliés par des segments de droite. Le graphe apparaît donc comme une ligne brisée. De telles suites de variables aléatoires peuvent être exprimées mathématiquement afin d'en analyser le comportement, généralement pour comprendre son évolution passée et pour en prévoir le comportement futur. Une telle transposition mathématique utilise le plus souvent des concepts de probabilités et de statistique.

2.2 Les méthodologies des modèles économétriques

2.2.1 La statistique descriptive

L'objectif de la statistique descriptive est d'organiser et d'analyser les données en mettant les points importants en évidence. L'étude descriptive des données, résume et représente graphiquement les données disponibles. Ainsi, toutes les analyses des données nécessitent une connaissance des phénomènes pouvant décrire le comportement de la série chronologique. Puisqu'il est difficile de faire une description parfaite d'une série chronologique, l'on va fournir toutes les informations disponibles sur les données étudiées en moins de chiffres et en moins de mots possible. Tout ceci dans le but de connaître les paramètres pouvant perturber l'étude prévisionnelle de la consommation d'énergie. L'on va également présenter les corrélations qui existent entre l'évolution du temps et des données des consommations d'énergie électrique. Ces relations sont définies à l'aide du coefficient de corrélation r_p présent ci-dessous dans l'équation (2.1).

2.2.2 Présentation générale de la théorie de corrélation

Lorsque deux phénomènes ont une évolution commune, nous disons qu'ils sont corrélés. La corrélation simple mesure le degré de liaison existant entre ces deux phénomènes représentés par des variables. Si nous cherchons une relation entre trois variables ou plus, nous ferons appel à la notion de corrélation multiple. Nous pouvons distinguer la corrélation linéaire, lorsque tous les points du couple de valeurs (x, y) des deux variables semblent alignées sur une droite, de la corrélation non linéaire lorsque le couple de valeurs se trouve sur une même courbe d'allure quelconque. Deux variables peuvent être :

-En corrélation positive : on constate alors une augmentation (ou diminution,

ou constance) simultanée des valeurs des deux variables dans le même sens ;

-En corrélation négative : lorsque les valeurs d'une des variables augmentent tandis que les valeurs de l'autre diminuent ;

-Non corrélées, il n'y a aucune relation entre les variations des valeurs de l'une des variables et les valeurs de l'autre.

2.2.3 La mesure du coefficient de corrélation

La représentation graphique ne donne qu'une impression de la corrélation entre deux variables sans donner une idée précise de l'intensité de la liaison. C'est pourquoi nous calculons une statistique appelée coefficient de corrélation linéaire simple, noté $r_{(x,y)}$. Il est égal à :

$$\begin{aligned} r_{(x,y)} &= \frac{Cov(x, y)}{\sigma_x \sigma_y} \\ &= \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}, \end{aligned} \quad (2.1)$$

où $Cov(x, y)$ est la covariance entre x et y , σ_x et σ_y , les écarts type de x et y , n le nombre d'observations. On peut démontrer que, par construction, ce coefficient reste compris entre -1 et 1 :

- proche de 1, les variables sont corrélées positivement ;
- proche de -1, les variables sont corrélées négativement ;
- proche de 0, les variables ne sont pas corrélées.

Dans la pratique, ce coefficient est rarement très proche de l'une de ces trois bornes et il est donc difficile de proposer une interprétation fiable à la simple lecture de ce coefficient. Ceci est surtout vrai en économie où les variables sont toutes plus ou moins liées entre elles. De plus, il n'est calculé qu'à partir d'un échantillon d'observations et non pas sur l'ensemble des valeurs. On appelle $\rho_{x,y}$ ce coefficient empirique qui est une estimation du coefficient vrai $r_{(x,y)}$. La théorie

des tests statistiques nous permet de lever cette indétermination. Soit à tester l'hypothèse $H_0 : r_{(x,y)} = 0$, contre l'hypothèse $H_1 : r_{(x,y)} \neq 0$. Sous l'hypothèse H_0 , nous pouvons démontrer que $\frac{\rho_{x,y}}{\sqrt{\frac{(1-\rho_{x,y}^2)}{n-2}}}$ suit une loi de Student à $n-2$ degrés de liberté. Nous calculons alors une statistique, appelée le t^* de Student empirique :

$$t^* = \frac{|\rho_{x,y}|}{\sqrt{\frac{(1-\rho_{x,y}^2)}{n-2}}}. \quad (2.2)$$

Si $t^* > t_{(n-2)}^{a/2}$ valeur lue dans une table de Student au seuil $a = 0,05(5\%)$ à $n-2$ degrés de liberté, nous rejetons l'hypothèse H_0 , le coefficient de corrélation est donc significativement différent de 0, dans le cas contraire, l'hypothèse d'un coefficient de corrélation nul est acceptée. La loi de Student étant symétrique, nous calculons la valeur absolue du t empirique et nous procédons au test par comparaison avec la valeur lue directement sur la table. Si le nombre d'observations n est supérieur à 30, on peut approximer la loi de Student par une loi normale, soit $t^{a/2} \approx 1,96$.

Afin d'atteindre nos objectifs, nous avons adopté pour chaque partie une approche méthodologique rigoureuse. La première partie est constituée de trois étapes : la première consistant à vérifier les propriétés des séries chronologiques telles que la stationnarité et l'ordre d'intégration à l'aide des tests de racine unitaire de Dickey-Fuller Augmenté (ADF) et de Phillips-Perron (PP), la deuxième utilisant la technique de cointégration développée par Pesaran et al. (2001) [102] pour examiner la relation d'équilibre de long terme entre les variables retenues dans notre modèle. La troisième étape consistera à estimer les coefficients de court terme et de long terme afin d'étudier l'impact des variables explicatives sur la consommation d'énergie électrique au Cameroun.

2.2.4 La notion de série chronologique stationnaire

La notion de stationnarité des séries chronologiques est importante pour leur étude ; c'est un concept clé pour la validité externe d'une régression sur ces séries. Une définition simple et intuitive de la stationnarité est que la série chronologique possède une moyenne et une variance constantes à travers le temps. Par ailleurs, la dépendance entre deux observations de la série est reliée à la distance qui les sépare dans la série et non à leurs positions absolues. La stationnarité d'une série chronologique dit donc que d'un point de vue statistique, le passé est comparable au présent et au futur.

La plupart des séries étudiées présentent un trend, une tendance, elles sont donc non stationnaires. Nous allons présenter dans ce qui suit les tests de non stationnarité (tests de racine unitaire) des séries chronologiques et la démarche préconisée pour les rendre stationnaires, processus indispensable avant toute modélisation.

2.2.5 Les test de racine unitaire

Les tests de racine unitaire permettent de détecter la présence d'une racine unitaire dans une série. Trois tests de racine unitaire sont usuellement utilisés, à savoir le test de Dickey-Fuller augmenté (ADF), celui de Phillips-Perron(PP) et le test de Kwiatkowski, Phillips, Schmidt et Shin (1992) (noté KPSS).

2.2.5.1 Le test de Dickey-Fuller augmenté (ADF)

Le test ADF (1979,1981) consiste à vérifier l'hypothèse nulle contre l'hypothèse alternative :

-l'hypothèse nulle $H_0 : \phi = 1$, non stationnaire (Differency Stationary (DS))
ou encore présence d'une racine unitaire,

-l'hypothèse alternative $H_1 : |\phi| < 1$, stationnaire ou encore absence d'une racine unitaire. Les modèles considérés sont les suivants :

✠ Le modèle 1 : processus sans trend ; sans constante ;

$$\Delta X_t = \phi X_{t-1} + \varepsilon_t, \quad (2.3)$$

✠ Le modèle 2 : processus sans trend ; avec constante ;

$$\Delta X_t = \phi X_{t-1} + C + \varepsilon_t, \quad (2.4)$$

✠ Le modèle 3 : processus sans trend ; sans constante ;

$$\Delta X_t = \phi X_{t-1} + C + \beta t + \varepsilon_t. \quad (2.5)$$

On cherche à tester l'hypothèse de racine unitaire :

$$H_0 : \phi = 1 \text{ et } H_1 : |\phi| < 1. \quad (2.6)$$

Le principe général de la stratégie de tests est le suivant : il s'agit de partir du modèle le plus général, d'appliquer le test de racine unitaire en utilisant les seuils correspondants à ce modèle, puis de vérifier par un test approprié que le modèle retenu était le bon. En effet, si le modèle n'était pas le bon, les seuils utilisés pour le test de racine unitaire ne sont pas valables. On risque alors de commettre une erreur de diagnostic sur la stationnarité de la série. Il convient, dans ce cas, de recommencer le test de racine unitaire dans un autre modèle, plus contraint. Et ainsi de suite, jusqu'à trouver le bon modèle, les bons seuils et bien entendu les "bons" résultats. Le déroulement de la stratégie de test est reporté sur la figure 2.1 suivante : On commence par tester la racine unitaire à partir du modèle le plus général, à savoir le modèle 3.

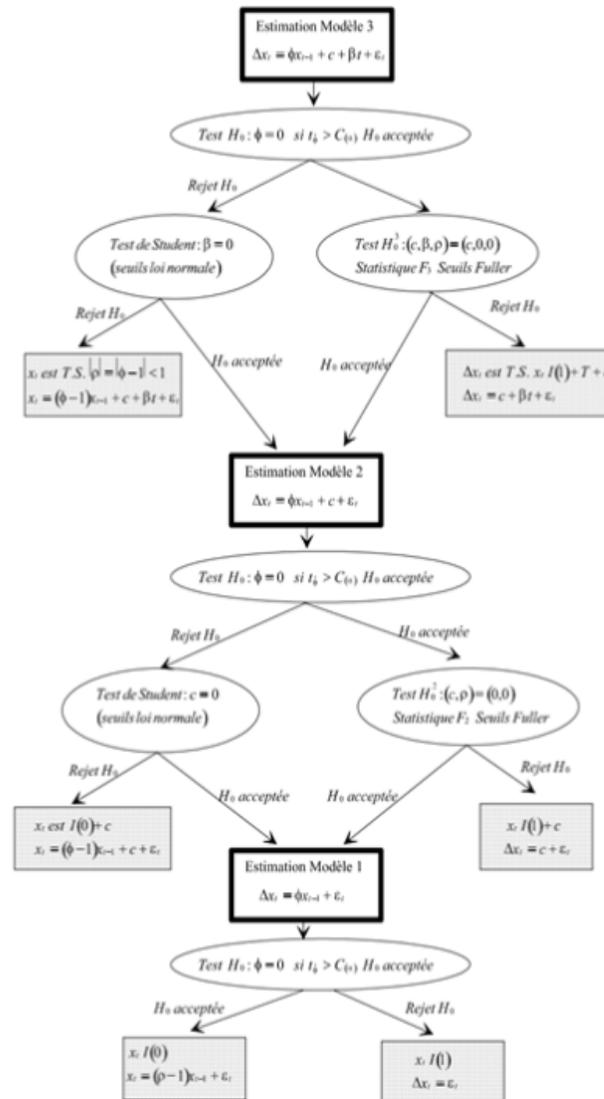


FIGURE 2.1 – Stratégie du test de Dickey-Fuller (Source : Hurlin, 2004)

2.2.5.2 Le test de Phillips-Perron

Le test de Phillips-Perron (1988) est construit sur une correction non paramétrique de la statistique de Dickey-Fuller pour prendre en compte des erreurs hétéroscédastiques. Il se déroule en deux étapes : on estime par MCO les trois modèles de base du test de Dickey-Fuller et on calcule les statistiques associées, puis on estime un facteur correctif établi à partir de la structure de covariance des résidus de telle sorte que les transformations réalisées conduisent à des distributions identiques à celles du Dickey-Fuller standard. Ce test se ramène donc au test

de Dickey-Fuller simple dans le cas où les erreurs seraient homoscédastiques. Ce test est non paramétrique car aucune modélisation du processus générateur des aléas n'est formulée, il est plus robuste à une autocorrélation (mais également à une hétéroscédasticité) de forme inconnue. La mise en oeuvre du test est identique à celle du test de Dickey-Fuller : on suit la même procédure séquentielle descendante. Cette statistique de Phillips-Perron est à comparer aux valeurs critiques de la table de MacKinnon.

2.2.5.3 Le test KPSS(1992)

Kwiatkowski et al.(1992) proposent d'utiliser un test du multiplicateur de Lagrange (L M) fondé sur l'hypothèse nulle de stationnarité. Après estimation des modèles (2) ou (3), on calcule la somme partielle des résidus : $S_t = \sum_{i=1}^t e_i$ on estime la variance de long terme (S_t^2) comme pour le test de Phillips et Perron. Le schéma simplifié de la stratégie des tests KPSS est donné par la figure 2.2 ci-dessous.

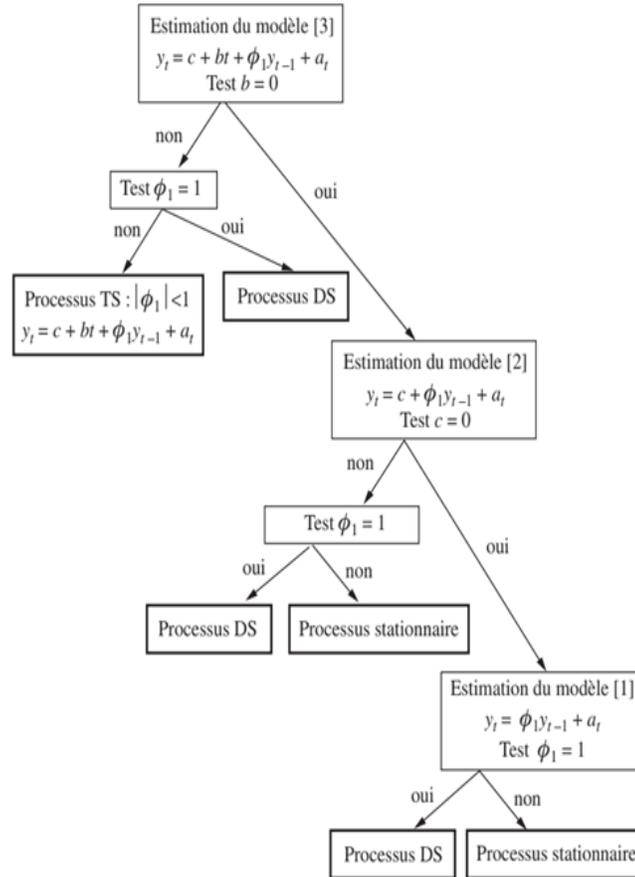


FIGURE 2.2 – Schéma simplifiée de la stratégie des tests de racine unitaire (test KPSS)[103]

La statistique est alors

$$LM = \frac{1}{S_t^2} \frac{\sum_{t=1}^n S_t^2}{n^2}. \tag{2.7}$$

On rejette l'hypothèse de stationnarité si cette statistique est supérieure aux valeurs critiques lues dans une table élaborée par les auteurs. Il est à noter que le logiciel Eviews utilisé dans ce travail permet directement son utilisation.

2.2.5.4 Le test de co-intégration de Johansen

Il s'agit d'un test qui n'est approprié que si les variables testées dans la première étape sont stationnaires en différence première (intégrées d'ordre 1). L'analyse de la cointégration au sens de Johansen consiste ainsi à étudier l'indépendance entre deux variables sans faire d'hypothèse a priori sur les valeurs des coefficients qui

les reliant. Dans un modèle à correction d'erreurs, cette relation est la suivante :

$$Y_{t-i} = AY_{t-1} + \sum_{i=1}^p \alpha_i \Delta Y_{t-i} + \varepsilon_i, \quad (2.8)$$

avec : Y_t le vecteur des variables dont on veut connaître la dynamique, α_i un nombre matriciel et A une matrice dont la direction correspond à celle de Y_t et dont le rang détermine le nombre de relations de cointégration. Δ représente l'opérateur de différence première.

Selon Keho (2008) le test de cointégration de Johansen sur un échantillon réduit est très sensible au choix d'un certain nombre de paramètres de nuisance. Il s'agit notamment du nombre de retards et de présence ou non de tendances déterminites dans l'espace de cointégration et dans le modèle vectoriel auto-agressif (VAR). Le risque d'une sous-paramétrisation du modèle VAR sous-jacent à la procédure de test et la perte de degrés de liberté introduisent des distorsions de niveau qui affaiblissent l'efficacité du test de cointégration. Ainsi, il a été montré que la statistique du test de Johansen est biaisée dans le sens d'un rejet trop fréquent de l'hypothèse nulle d'absence de cointégration. C'est à cause de ces biais potentiels que la validité des résultats d'études empiriques utilisant l'approche séquentielle peut être questionnée (Keho,2008).

2.2.5.5 Le test F

Le test F (analyse de la variance) permet d'intégrer la taille de l'échantillon dans l'appréciation de la qualité de la régression :

$$F = \frac{\frac{\sum_{i=1}^n (\hat{Y} - \bar{Y})^2}{k}}{\frac{\sum_{i=1}^n (\hat{Y} - Y_i)^2}{n-k-1}} = \frac{DEM}{DRM} = \frac{R^2/k}{(1 - R^2)/(n - k - 1)}, \quad (2.9)$$

Où n est la taille de l'échantillon, DEM est la dispersion moyenne expliquée, DRM est la dispersion résiduelle moyenne. Cette valeur doit être comparée à

celle qui est lue dans la table de Fisher-snédecure (F^*) pour k degré de liberté au numérateur et $n - k - 1$ degré de liberté au dénominateur à un seuil de confiance α . Si $F < F^*$ alors on conclut que le modèle est globalement explicatif.

2.3 Les modélisations

2.3.1 Le modèle VAR/VECM

Le modèle vectoriel autorégressif (VAR) est un outil couramment utilisé pour la prévision des séries temporelles stationnaires à plusieurs variables qui sont déterminées simultanément [104]. Dans le cadre de notre étude, nous envisageons modéliser une représentation VAR dans laquelle on considère quatre variables, à savoir la consommation annuelle d'électricité ($y(t)$) et ses variables explicatives telles que le PIB ($X_{pI}(t)$), la population ($X_{po}(t)$), et les dépenses de consommation finale des ménages ($X_{Dm}(t)$). La particularité du modèle VAR est que chaque variable est une fonction linéaire des décalages passés d'elle-même et les décalages passés des autres variables. En effet, dans le cadre de modèle spécifié en séries temporelles, les relations entre les variables ne sont pas toujours synchrones mais peuvent être décalées dans le temps. Nous pouvons concevoir que la consommation de l'année t est expliquée par le revenu de l'année " $t - 1$ " et non celui de l'année t . Pour lever cette ambiguïté, il est d'usage d'écrire le modèle en le spécifiant à l'aide d'un indice de temps : $C_t = a_0 + a_1 Y_{t-1}$. La variable Y_{t-1} est appelée "variable endogène retardée". La forme généralisée d'une représentation VAR(p)

avec ordre de décalage p à $K = 4$ variables s'écrira sous forme matricielle :

$$\begin{pmatrix} y(t) \\ X_{po}(t) \\ X_{pI}(t) \\ X_{Dm}(t) \end{pmatrix} = \begin{pmatrix} a_{0,1} \\ a_{0,2} \\ a_{0,3} \\ a_{0,4} \end{pmatrix} + \begin{pmatrix} a_{1,1}^1 & a_{1,2}^1 & a_{1,3}^1 & a_{1,4}^1 \\ a_{2,1}^1 & a_{2,2}^1 & a_{2,3}^1 & a_{2,4}^1 \\ a_{3,1}^1 & a_{3,2}^1 & a_{3,3}^1 & a_{3,4}^1 \\ a_{4,1}^1 & a_{4,2}^1 & a_{4,3}^1 & a_{4,4}^1 \end{pmatrix} \begin{pmatrix} y(t-1) \\ X_{po}(t-1) \\ X_{pI}(t-1) \\ X_{Dm}(t-1) \end{pmatrix} \\
 + \begin{pmatrix} a_{1,1}^2 & a_{1,2}^2 & a_{1,3}^2 & a_{1,4}^2 \\ a_{2,1}^2 & a_{2,2}^2 & a_{2,3}^2 & a_{2,4}^2 \\ a_{3,1}^2 & a_{3,2}^2 & a_{3,3}^2 & a_{3,4}^2 \\ a_{4,1}^2 & a_{4,2}^2 & a_{4,3}^2 & a_{4,4}^2 \end{pmatrix} \begin{pmatrix} y(t-2) \\ X_{po}(t-2) \\ X_{pI}(t-2) \\ X_{Dm}(t-2) \end{pmatrix} + \dots \\
 + \begin{pmatrix} a_{1,1}^p & a_{1,2}^p & a_{1,3}^p & a_{1,4}^p \\ a_{2,1}^p & a_{2,2}^p & a_{2,3}^p & a_{2,4}^p \\ a_{3,1}^p & a_{3,2}^p & a_{3,3}^p & a_{3,4}^p \\ a_{4,1}^p & a_{4,2}^p & a_{4,3}^p & a_{4,4}^p \end{pmatrix} \begin{pmatrix} y(t-p) \\ X_{po}(t-p) \\ X_{pI}(t-p) \\ X_{Dm}(t-p) \end{pmatrix} + \begin{pmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \\ \varepsilon_{4,t} \end{pmatrix} \quad (2.10)$$

Sous forme matricielle, l'équation(2.10) peut encore s'écrire :

$$Y_t = A_0 + A_1 Y_{t-1} + A_2 Y_{t-2} + \dots + A_p Y_{t-p} + \varepsilon \quad (2.11)$$

avec Y_t : vecteur de dimension (4×1) constitué des 4 variables $(y(t), X_{po}(t), X_{pI}(t), X_{Dm}(t))$, A_0 : vecteur de dimension (4×1) constitué des constantes du modèle matriciel, A_i : matrice de dimension (4×4) constitué des coefficients des variables du modèle matriciel. Ce modèle peut s'écrire en différences premières de deux manières suivantes :

$$\begin{aligned} \Delta Y_t &= A_0 + (A_1 - I)\Delta Y_{t-1} + (A_2 + A_1 - I)\Delta Y_{t-2} + \dots \\ &+ (A_{p-1} + \dots + A_2 + A_1 - I)\Delta Y_{t-p+1} + \pi Y_{t-p} + \varepsilon \end{aligned} \quad (2.12)$$

ou encore en fonction de Y_{t-1} :

$$\Delta Y_t = A_0 + B_1 \Delta Y_{t-1} + B_2 \Delta Y_{t-2} + \dots + B_{p-1} \Delta Y_{t-p+1} + \pi Y_{t-1} + \varepsilon \quad (2.13)$$

Δ est l'opérateur de retard, les matrices B_i étant des fonctions des matrices A_i et $\pi = (\sum_{i=1}^p A_i - I)$. La matrice π peut s'écrire sous la forme $= \alpha\beta'$ où le vecteur α est la force de rappel vers l'équilibre et β le vecteur dont les éléments sont les coefficients des relations de long terme des variables. Chaque combinaison linéaire représente donc une relation de co-intégration.

-Si tous les éléments de π sont nuls (le rang de la matrice π est égal à 0 et donc $A_{p-1} + \dots + A_2 + A_1 = I$, alors nous ne pouvons pas retenir une spécification à correction d'erreur, nous estimons un VAR classique en différences premières afin d'éliminer les tendances.

-Si le rang de π est égal à k , cela implique alors que les variables sont toutes $I(0)$ et le problème de la cointégration ne se pose donc pas, il convient d'estimer un modèle VAR en niveau.

-Si le rang de la matrice π (noté r) est compris entre 1 et $k - 1$ ($1 \ll r \ll k - 1$), alors il existe r relations de co-intégration et la représentation VECM est valide soit :

$$\Delta Y_t = A_0 + B_1 \Delta Y_{t-1} + B_2 \Delta Y_{t-2} + \dots + B_{p-1} \Delta Y_{t-p+1} + \alpha e_{t-1} + \varepsilon \quad (2.14)$$

avec

$$e_t = \beta' Y_t. \quad (2.15)$$

synthèse de la procédure d'estimation

les grandes étapes relatives à l'estimation d'un modèle VECM.

Étape 1 : Détermination du nombre de retards p du modèle (en niveau ou en Log) selon les critères AIC ou SC [104].

Étape 2 : Estimation de la matrice π et test de Johansen permettant de connaître le nombre de relations de cointégration (les logiciels proposent un certain

nombre de spécifications alternatives, telles que l'existence d'un terme constant dans la relation de cointégration, contraindre $A_0 = 0$, l'existence d'une tendance déterministe, etc.).

Étape 3 : Identification des relations de cointégration, c'est-à-dire des relations de long terme entre les variables.

Étape 4 : Estimation par la méthode du maximum de vraisemblance du modèle vectoriel à correction d'erreur et validation à l'aide des tests usuels : significativité des coefficients¹ et vérification que les résidus sont des bruits blancs (test de Ljung-Box), tests d'exogénéité faible. Enfin, nous pouvons vérifier que l'estimation par les MCO de la relation de long terme fournit des résultats à peu près similaires (en termes de significativité et de valeurs estimées des coefficients) à ceux obtenus par la méthode du maximum de vraisemblance.

2.3.2 Le lissage exponentiel de Holt

Les méthodes de lissage exponentiel permettent de prolonger une série chronologique en vue de réaliser une prévision à court terme. On emploie le lissage exponentiel simple (LES) lorsqu'il n'existe aucune tendance. Mais, bien souvent, il en existe une, et ce sont le lissage double (HES) et surtout le lissage de Holt qui viennent à notre rescousse, voire le lissage de Winters s'il y a une saisonnalité. Dans ce travail, nous privilégierons le lissage de Holt, car nos données corroborent plutôt l'hypothèse d'une variance de la consommation horaire d'électricité relativement stable dans le temps.

Pour le prévisionniste, le lissage de Holt est une version améliorée du HES (on peut aussi considérer que le HES est un cas particulier du lissage de Holt).

Soit y_t la consommation annuelle d'électricité à la date t , Pour un horizon h ,

une prévision établie à l'instant t s'écrit :

$$\hat{y}_t(h) = b_t + a_t h. \quad (2.16)$$

Où b_t est le niveau et a_t est la pente donnés respectivement par les équations (2.17) et (2.18). Niveau :

$$b_t = \alpha Y_t + (1 - \alpha)(b_{t-1} + \alpha_{t-1}), \quad (2.17)$$

Pente :

$$a_t = \gamma(b_t - b_{t-1}) + (1 - \alpha)a_{t-1}. \quad (2.18)$$

Les coefficients alpha (α) et gamma (γ) sont choisis empiriquement. Le niveau ici est une moyenne pondérée entre deux estimations de constante au moment de l'établissement de la prévision : d'une part celle qui est issue de la dernière observation, d'autre part celle qui avait été prévue. Le premier paramètre alpha à choisir (compris entre 0 et 1) est donc celui qui va pondérer ces deux niveaux. La pente est également une moyenne pondérée entre deux estimations, soit une deuxième relation de récurrence. On détermine un coefficient gamma (γ), compris entre 0 et 1, puis on applique cette pondération à la dernière estimation de pente observée, c'est-à-dire à la différence des deux niveaux en t et $t - 1$. Il nous reste $1 - \gamma$ de pondération à appliquer à notre précédente estimation de pente, bien sûr...

2.3.3 Le modèle hybride

La construction de la structure du modèle hybride VECM-HES est conditionnée par les caractéristiques des résidus respectifs de chacun des modèles [32]. Si leurs résidus sont mutuellement les signes opposés, et si ceux du modèle VECM sont normalement distribués, alors il est statistiquement possible de construire le

modèle hybride tel que défini par l'équation (2.19).

$$\hat{Y} = \alpha_0 Y_1 + \alpha_1 Y_2. \quad (2.19)$$

L'objectif ici est de trouver un couple (α_0, α_1) optimal tel que \hat{Y} soit le plus proche possible de Y (valeur qu'on essaie de prédire) et ce pour tous les couples (Y_1, Y_2) qui forment notre ensemble de données d'apprentissage. Trouver le meilleur couple (α_0, α_1) revient à minimiser le coût global des erreurs unitaires définies par l'équation (2.20)

$$\sum_{i=1}^m e_i^2 = \sum_{i=1}^m (\hat{Y} - Y)^2 \quad (2.20)$$

Où m est la taille du training set. La fonction de coût est définie par l'équation (2.21)

$$J(\alpha_0, \alpha_1) = \frac{1}{2m} \sum_{i=1}^m (\hat{Y} - Y)^2 = \frac{1}{2m} \sum_{i=1}^m (\alpha_0 Y_1 + \alpha_1 Y_2 - Y)^2 \quad (2.21)$$

Les valeurs de α_0 et α_1 qui sont au minimum global de $J(\alpha_0, \alpha_1)$ seront les meilleures valeurs pour notre hypothèse.

$$\frac{\partial J(\alpha_0, \alpha_1)}{\partial \alpha_0} = \frac{1}{m} \sum_{i=0}^m Y_1 (\alpha_0 Y_1 + \alpha_1 Y_2 - Y) = \frac{Y_1}{m} \sum_{i=0}^m (\alpha_0 Y_1 + \alpha_1 Y_2 - Y), \quad (2.22)$$

$$\frac{\partial J(\alpha_0, \alpha_1)}{\partial \alpha_1} = \frac{1}{m} \sum_{i=0}^m Y_2 (\alpha_0 Y_1 + \alpha_1 Y_2 - Y) = \frac{Y_2}{m} \sum_{i=0}^m (\alpha_0 Y_1 + \alpha_1 Y_2 - Y). \quad (2.23)$$

Le couple (α_0, α_1) peut se calculer à partir de l'algorithme interactif du gradient descent amélioré qui va changer à chaque interaction les valeurs de α_0 et α_1 pour un pas donné et une précision imposée jusqu'à trouver le meilleur couple possible. La synthèse des étapes de cet algorithme se résume par les étapes suivantes :

Étape 1 : Collecte des données historiques et procéder à une analyse statistique de stationnarité et corrélation ;

Étape 2 : Évaluer les prévisions de chaque modèle retenu (VECM et HES). Puis, vérifier que les résidus suivent une loi normale et s'assurer que la tendance

de croissance exponentielle des résultats obtenus par chaque modèle retenu est efficace. En fait, YUAN C et al. [105] ont prouvé en 2016 à partir du modèle GM (1,1) que les meilleurs résultats de prévision sont obtenus lorsque l'entrée des données de consommation d'énergie montre une tendance de croissance exponentielle. Cette idée est conservée dans ce travail comme une condition sine-qua-non à l'exécution du modèle hybride. Une fois la tendance exponentielle des paramètres établie, nous passons à l'étape suivante.

Etape 3 : Vérifier la validité des modèles VECM et HES à l'aide des indicateurs statistiques RMSE, MAPE, et R^2 . Puis entrer ces données dans le modèle.

Etape 4 : Définir la fonction de coût et calculer les dérivées partielles de $J(\alpha_0, \alpha_1)$ par rapport à α_0 et α_1 .

Etape 5 : Initialiser aléatoirement les valeurs de α_0 et α_1 .

Etape 6 : Rechercher le pas optimal pour une précision fixée et mettre à jour des valeurs de α_0 et α_1 , à l'aide du block d'instruction de l'organigramme ci-dessous :

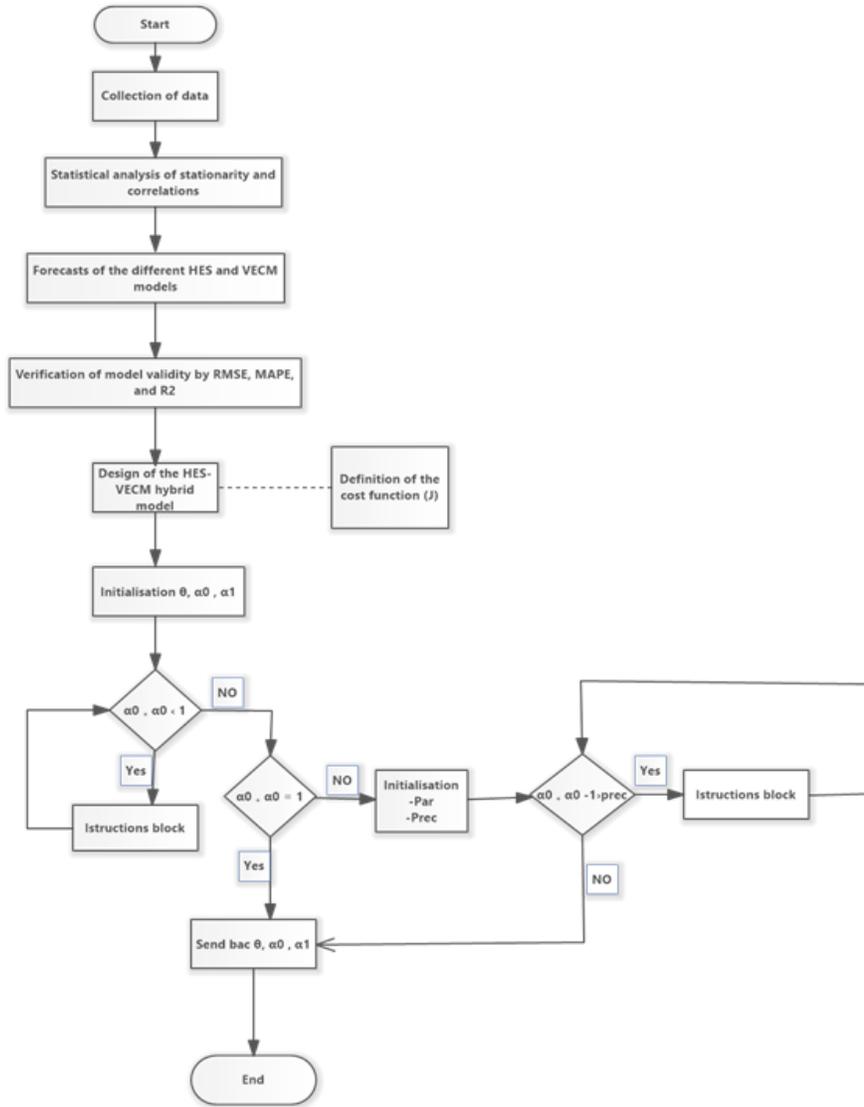


FIGURE 2.3 – organigramme de la recherche des paramètres du modèle hybride à partir de l’algorithme du gradient descendant

Le bloc d’instruction de la figure 2.3 est donné par l’algorithme suivant : répéter jusqu’à convergence au minimum global de la fonction de coût. Pour $J \in N, \Lambda \forall j \in [0, 1]$

$$\alpha_{0j} = \alpha_{0j} - \theta \frac{\partial J(\alpha_0, \alpha_1)}{\partial \alpha_{0j}}, \quad (2.24)$$

$$\alpha_{1j} = \alpha_{1j} - \theta \frac{\partial J(\alpha_0, \alpha_1)}{\partial \alpha_{1j}}, \quad (2.25)$$

retourner α_0 et α_1 ,

fin algorithmique. Le terme θ est appelé le Learning rate. Il fixe la grandeur du pas de chaque interaction.

Inconvénient de la méthode :

- le choix du point initial et du pas reste empirique ;
- l'algorithme peut converger vers un minimum local.

2.3.4 Le modèle de régression

La régression est un outil mathématique qui permet d'étudier la relation entre les variables observées. L'objectif principal est d'estimer et de prédire les valeurs d'une variable en prenant en considération les valeurs d'autres variables dites exogènes. Cependant, avant d'utiliser cette technique pour la prévision d'une variable, les variables exogènes reliées à cette dernière doivent être identifiées. Trois types de régressions peuvent être utilisés :

- Régression simple ;
- Régression multiple ;
- Régression non linéaire.

Dans le cadre de notre étude, nous nous intéresserons aux prévisions via la régression multiple. La régression linéaire multiple est une généralisation, à p variables explicatives, de la régression linéaire simple. Elle décrit les variations d'une variable endogène associée aux variations de plusieurs variables exogènes. Le problème consiste à déterminer quelle valeur doit être attribuée à la variable endogène lorsque nous connaissons les valeurs des variables exogènes.

Si nous désignons par Y_t la consommation horaire d'électricité au temps t et Y_{kt-p} la consommation horaire des heures précédentes la formule multilinéaire adaptée à notre étude est donnée par l'équation suivante :

$$Y_t = \hat{a}_0 + \hat{a}_1 Y_{1t-1} + \hat{a}_2 Y_{2t-2} + \dots + \hat{a}_k Y_{kt-p} + \varepsilon_i. \quad (2.26)$$

La prévision pour la donnée $t+h$ est donnée par :

$$\hat{Y}_{t+h} = \hat{a}_0 + \hat{a}_1 Y_{1t-1+h} + \hat{a}_2 Y_{2t-2+h} + \dots + \hat{a}_k Y_{kt-p+h} + \varepsilon_{i+h} \quad (2.27)$$

Le résidu e_{t+h} est obtenu en faisant la différence entre le modèle réel et le modèle estimé comme indiquée dans l'équation (2.47)

$$e_{t+h} = Y_{t+h} - \hat{Y}_{t+h}, \quad (2.28)$$

où ε_i est l'erreur du modèle qui exprime, ou résume, l'information manquante dans l'explication linéaire des valeurs de \hat{Y}_{t+h} à partir des Y_{kt-i} . a_0, a_1, \dots, a_p sont les paramètres à estimer. La méthode utilisée ici pour estimer les paramètres du modèle de régression est la méthode des moindres carrés. Après l'estimation des paramètres du modèle, certains tests de validation des hypothèses sont nécessaires pour vérifier non seulement la bonne spécification des modèles mais aussi la stabilité des coefficients [106]. Dans le premier cas, il s'agit du test d'autocorrélation des erreurs, du test de normalité des résidus, du test de spécification et du test d'hétéroscédasticité. Dans le deuxième cas, il s'agit du test de stabilité des paramètres du CUSUM et du carré du CUSUM.

a) Tests de spécifications du modèle

Test de normalité des résidus :

Pour tester la normalité des résidus, le test J-B dit de JARQUE et BERA a été utilisé. Ce test suit une distribution de Chi-deux à deux degrés de liberté. Il formule l'hypothèse nulle de distribution normale des résidus et cette hypothèse n'est acceptée que si la statistique J-B est inférieure à la valeur critique = 5,99. Cette normalité des résidus est aussi conclue lorsque la probabilité critique est supérieure au seuil de 5%.

Test d'autocorrélation des résidus :

L'autocorrélation des résidus a été testée à l'aide du test du multiplicateur de Lagrange de Breusch-Godfrey pour l'autocorrélation des résidus d'ordre n . Sous l'hypothèse nulle, toutes les autocorrélations sont statistiquement nulles. L'acceptation de l'hypothèse nulle revient à prouver la non-autocorrélation des résidus. Cette décision est prise si la statistique de Breusch-Godfrey calculée est inférieure à la valeur critique (5,99). La même conclusion est prise si la probabilité critique de cette statistique est supérieure au seuil de significativité de 5%.

Test d'hétéroscédasticité :

L'identification de l'hétéroscédasticité peut être faite à l'aide de plusieurs tests, par exemple le test de Breusch-Pagan, le test de Goldfeld, le test de Gleisjer et le test de White. Dans notre étude, nous utilisons le test de Breusch-Pagan pour tester l'hétéroscédasticité. Les critères de décision sont les suivants [43] :

- H_0 : homoscedasticité ;
- H_1 : hétéroscédasticité.

Si la probabilité associée au test est inférieure à 5%, on rejette l'hypothèse d'homoscédasticité (H_0). En revanche, si la probabilité est supérieure à 5%, l'hypothèse nulle est vérifiée et nous pouvons supposer l'homoscédasticité des résidus.

b) Test de stabilité des coefficients

Afin de mener à bien notre étude, il est important de tester si les relations de court terme et de long terme précédemment trouvées sont stables sur toute la période de l'étude. Pour ce faire, nous devons tester la stabilité des paramètres du modèle. La méthode que nous utilisons ici est basée sur la somme cumulée (CUSUM) et la somme cumulée carrées (CUSUMSQ) proposée par Brown et al. (1975). Si les parcelles du CUSUM et du carré du CUSUM restent dans les limites critiques du niveau de significativité de 5%, l'hypothèse nulle selon laquelle tous les coefficients sont stables ne peut être rejetée. Les avantages de cette méthode

sont suivantes : elle peut prendre en compte les interactions entre les variables, fournit des intervalles de confiance sur les résultats.

2.3.5 Les réseaux de neurones artificiels (RNA)

L'élément de base d'un réseau de neurones est le neurone, dont l'utilisation n'a pas changé depuis sa création par Widrow et Hoff [107] these nazzer p21 en 1960. Ces derniers ont considéré le perceptron comme un élément adaptatif ressemblant à un neurone biologique(Figure2.4).

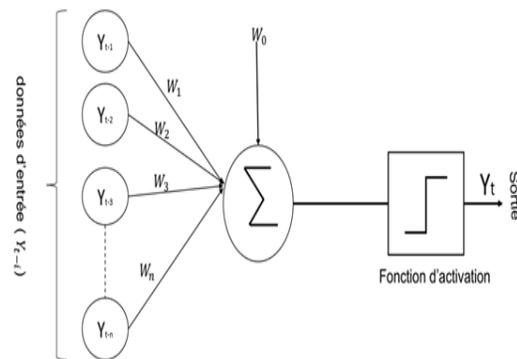


FIGURE 2.4 – Type de perceptron utilisé

Le perceptron est constitué de :

- Un noyau, nommé perceptron, représenté par une somme et une fonction d'activation ;
- Un signal multiple d'entrées x_i qui sont connectées via ce qu'on appelle des poids W_i ;
- Un signal de sortie Y_p .

Une entrée additionnelle W_0 nommée biais, qui fait office de seuil. La description du modèle des Réseaux de neurones artificiels utilisé dans ce travail est répartie en plusieurs étapes à savoir :

a)Analyse des données

Après une analyse des corrélations entre les variables explicatives et la variable expliquée afin de s'assurer qu'il existe un lien de causalité positif entre les deux variables, les données sont divisées en trois ensembles, pour assurer une bonne estimation et vérification des méthodes de prédiction.

- Ensemble d'apprentissage : il sert à calculer les poids du réseau.
- Ensemble de validation : il sert à éviter le sur-apprentissage
- Ensemble de test : il sert à évaluer les performances du réseau obtenu.

Afin d'assurer une homogénéisation des valeurs propagées dans le réseau, toutes les entrées $X_p = Y_{t-i}$ et les variables $Y_p = Y_t$ en sortie sont normalisées entre $[-1, +1]$ selon la fonction suivante :

$$X_p = X_{min} + \frac{x_i - x_{min}}{x_{max} - x_{min}}(X_{max} - X_{min}) \quad \text{et} \quad Y_p = Y_{min} + \frac{y_i - y_{min}}{y_{max} - y_{min}}(Y_{max} - Y_{min}), \quad (2.29)$$

où $x_{min} \leq x_i \leq x_{max}$ et $y_{min} \leq y_i \leq y_{max}$; X_p et Y_p sont respectivement l'entrée et la sortie normalisée.

b) Architecture du réseau de neurone

Selon Jain et al. [108], les réseaux de neurones les plus adaptés à la prévision sont de type perceptron multicouche. La structure du perceptron multicouche adopté dans le cadre de notre étude est constituée d'une couche d'entrée, une couche de sortie et une couche cachée. La couche cachée est composée de plusieurs neurones qui sont connectés aux neurones de la couche d'entrée et de sortie. À chaque connexion correspond un poids et chaque neurone possède une fonction de transfert ou d'activation. Le signal de sortie Y_{ij} peut-être décrit comme suit :

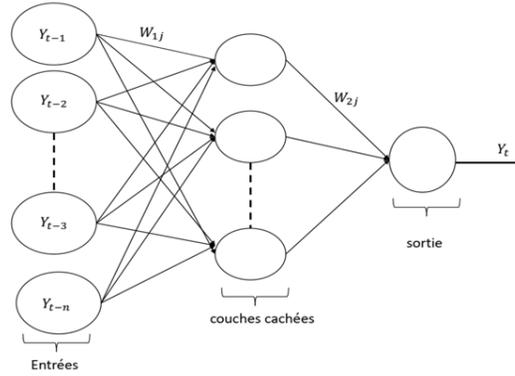


FIGURE 2.5 – Le perceptron multicouche de prévision

$$Y_{ij} = f(\text{net}) = f(b_{ij} + \sum_{j=1}^n X_{ij}W_{ij}), \quad (2.30)$$

où i est l'indice de la couche ; j est l'indice des neurones ; b_{ij} est le biais associé à chaque neurone, W_{ij} le poids synaptique et f la fonction d'activation.

Le choix de la fonction d'activation est crucial pour le perceptron. Block en 1962 [25], a sélectionné la fonction binaire mais elle fut remplacée par la fonction d'activation sigmoïdale (equation 2.31) et cette dernière est considérée comme un approximateur universel.

$$f(x) = \frac{1}{1 + \exp(-x)}. \quad (2.31)$$

Le perceptron peut apprendre par le biais d'un algorithme d'apprentissage basé sur un ensemble de données. Pendant la phase d'apprentissage, le perceptron ajuste ses poids en accord avec les données présentées en entrée. Widrow et Hoff [107] en 1960 ont proposé l'algorithme règle delta. Puis, dans les années 90 Rumelhart [109] a popularisé l'algorithme de rétro-propagation du gradient qui est le plus utilisé de nos jours. Même si les algorithmes d'apprentissage sont en majorité efficaces en terme de rapidité de convergence, un perceptron seul ne peut apprendre suffisamment pour résoudre des problèmes complexes (non linéaires) et ceci est dû à sa structure simpliste. Afin de palier ce problème, une structure multicouche

nommée MultiLayer Perceptron (MLP) ou perceptron multicouche (figure 2.5) est introduite. Le MLP en plus des couches d'entrée et de sortie, contient une couche cachée insérée entre les deux.

c) Apprentissage du réseau de neurones

Le processus d'apprentissage du réseau de neurones consiste à rechercher dans l'espace des paramètres du réseau, "le jeu de poids" optimal qui permet une bonne adéquation avec la cible. Le but de l'apprentissage est d'ajuster le jeu de poids de sorte que cette erreur soit la plus petite possible. On effectue alors une minimisation de l'erreur [110]. Pour cela, nous commençons par faire varier le nombre de couches cachées ainsi que le nombre de neurone des couches pour déterminer la configuration qui minimise au mieux l'erreur. Ensuite, pour avoir des résultats encore plus précis, nous faisons varier l'algorithme d'apprentissage question de déterminer celui qui donne un résultat plus optimal. Dans ce travail, nous avons utilisé principalement trois algorithmes d'apprentissage performants à savoir l'algorithme d'apprentissage du gradient, de quasi-Newton et de de Levenberg-Marquardt. Les principes de ces algorithmes utilisés sont les suivants :

✂ La méthode de la descente du gradient

Cette méthode a pour but de converger de manière itérative vers une configuration optimisée des poids synaptiques. Dans l'espace des poids synaptiques, on part d'un point initial et on construit les points suivants en prenant la direction de la plus grande pente sur une distance appelée pas de la descente.

$$W^{n+1} = W^n - \eta \frac{\partial M}{\partial W^n}, \quad (2.32)$$

où M est l'erreur modifiée. L'algorithme de rétropropagation estime la dérivée partielle de la fonction erreur par rapport à chaque poids.

✂ La méthode du gradient conjugué

Cette méthode utilise un algorithme pour que la direction de recherche soit optimisée. La direction dépend non seulement du gradient au point w_n mais aussi du gradient au point W_{n-1} .

$$W_{n+1} = W_n + \delta_n \left(-\frac{\partial M}{\partial W_n} + \rho_n \frac{\partial M}{\partial W_{n-1}} \right), \quad (2.33)$$

✠La méthode de quasi-Newton

Cette méthode fait appel aux dérivées partielles du second ordre de l'erreur par rapport aux poids. Les itérations pour l'actualisation des poids sont de la forme :

$$W_{n+1} = W_n - \eta H_e M(W_n), \quad (2.34)$$

où H_e est la matrice hessienne de $M(\Omega)$.

✠La méthode de Levenberg-Marquardt

Cette méthode choisit de façon automatique est un compromis entre la direction du gradient et la direction de Newton ce qui permet d'éviter les problèmes liés au choix du pas et au nombre d'itérations.

$$W_{n+1} = W_n - [H_e n + \lambda_n I]^{-1} \nabla J_n, \quad (2.35)$$

λ_n est un paramètre permettant de réduire le pas si celui-ci est trop grand, I la matrice identité, J la fonction de coût, égale à l'erreur quadratique moyenne sur les exemples de l'ensemble d'apprentissage.

L'algorithme de Levenberg-Marquardt permet de pallier les inconvénients du choix du pas et du nombre d'itérations, car elle choisit automatiquement un compromis entre la direction du gradient et la direction de Newton. Nous choisissons une valeur initiale de λ_0 (Bishop propose $\lambda_0 = 0.1$) qui est modifiée durant l'optimisation. À chaque itération, on calcule la fonction de coût $J(w)$ avec la valeur de λ précédente ; si la fonction de coût diminue, on effectue la modification des paramètres et on diminue λ (par exemple, diviser par 10) ; si la fonction de coût

croit, on cherche à se rapprocher du gradient et on augmente λ (multiplier par 10) jusqu'à ce que le coût diminue.

En les confrontant sur plusieurs problèmes, il apparaît qu'aucune de ces deux méthodes ne prend un avantage considérable sur l'autre. Avec la première méthode, il est nécessaire de régler plusieurs paramètres (choix du pas et du nombre d'itérations pour le gradient et les critères d'arrêt pour quasi-Newton). En revanche, avec la méthode de Levenberg-Marquardt, il suffit de spécifier les critères d'arrêt et l'algorithme adapté λ . Typiquement, on constate qu'en début d'optimisation, λ augmente (la direction de descente est presque celle de Newton). Cette souplesse se paie par un temps de calcul sensiblement supérieur à celui de la méthode de quasi-Newton.

En résumé, chaque algorithme d'optimisation possède des avantages et des inconvénients. La méthode de Levenberg-Marquardt présente un intérêt pratique car elle peut être utilisée sans avoir à choisir le pas; elle est néanmoins plus lente, en général, que les méthodes qui utilisent les algorithmes d'optimisation du Gradient, et de quasi-Newton.

Bien entendu, aucun algorithme ne conduit à coup sûr au minimum global. Il convient donc de se placer dans les conditions où les minima locaux sont aussi peu nombreux que possible. En pratique, il suffit de réaliser plusieurs apprentissages en choisissant des paramètres initiaux différents. En procédant de la sorte, on possède une plus grande chance de trouver le minimum global. Lorsque la performance souhaitée est atteinte, l'apprentissage est arrêté. Les valeurs des poids et les biais sont ensuite stockés et les valeurs de Y_i sont dénormalisées :

$$\hat{Y}_t = Y_{min} + \frac{Y_i - Y_{min}}{Y_{max} - Y_{min}}(y_{max} - y_{min}). \quad (2.36)$$

Une fois que le réseau a été formé, nous l'utilisons pour calculer les sorties réseau souhaitées, les erreurs et les performances globales à l'aide d'un code.

2.3.6 Le modèle hybride d'optimisation MLR-ANN-HES

La construction de la structure du modèle hybride MLR-ANN-HES est conditionnée par les caractéristiques des résidus respectifs de chacun des modèles [111]. Si leurs résidus sont mutuellement les signes opposés, et si ceux des modèles MLR et HES sont normalement distribués, alors il est statistiquement possible de construire le modèle hybride tel que défini par l'équation ci-dessous.

$$\hat{Y} = C_1 Y_1 + C_2 Y_2 + C_3 Y_3, \quad (2.37)$$

où Y_1 , Y_2 et Y_3 représentent respectivement les prévisions des modèles de réseaux de neurone artificiel, régression linéaire multiple et lissage exponentiel de Holt. \hat{Y} la prévision du modèle hybride. L'objectif ici est de trouver à partir d'un algorithme amélioré d'optimisation du gradient les coefficients C_1 , C_2 et C_3 optimaux tels que \hat{Y} soit le plus proche possible de Y (valeur qu'on essaie de prédire) et ce pour tous les couples (Y_1, Y_2, Y_3) qui forment notre ensemble de données d'apprentissage. Trouver les meilleurs coefficients $(C_1, C_2$ et $C_3)$ revient à minimiser le coût global des erreurs unitaires définies par,

$$\sum_{i=1}^m e_i^2 = \sum_{i=1}^m (\hat{Y} - Y)^2, \quad (2.38)$$

où m est la taille du training set. La fonction de coût est définie par l'équation (2.39)

$$J(C_1, C_2, C_3) = \frac{1}{2m} \sum_{i=1}^m (\hat{Y} - Y)^2 = \frac{1}{2m} \sum_{i=1}^m (C_1 Y_1 + C_2 Y_2 + C_3 Y_3 - Y)^2, \quad (2.39)$$

les valeurs C_1 , C_2 et C_3 qui sont au minimum global de $J(C_1, C_2, C_3)$ seront les meilleures valeurs pour notre hypothèse. Ces coefficients peuvent se calculer à partir de l'algorithme interactif du gradient descent amélioré qui va changer à chaque interaction les valeurs de C_1 , C_2 et C_3 pour un pas donné et une précision imposée

jusqu'à trouver les meilleurs coefficients possibles. La synthèse des étapes de cet algorithme se résume par l'organigramme de la figure 2.6. Le bloc d'instruction est donné par l'algorithme suivant :

répéter jusqu'à convergence au minimum global de la fonction de coût.

Pour $J \in N, \Lambda \forall \in [0, 1]$

$$C_{1j} = C_{1j} - \theta \frac{\partial J(C_1, C_2, C_3)}{\partial C_{1j}}, \quad (2.40)$$

$$C_{2j} = C_{2j} - \theta \frac{\partial J(C_1, C_2, C_3)}{\partial C_{2j}}, \quad (2.41)$$

$$C_{3j} = C_{3j} - \theta \frac{\partial J(C_1, C_2, C_3)}{\partial C_{3j}}, \quad (2.42)$$

retourner C_1, C_2 et C_3 , fin algorithme.

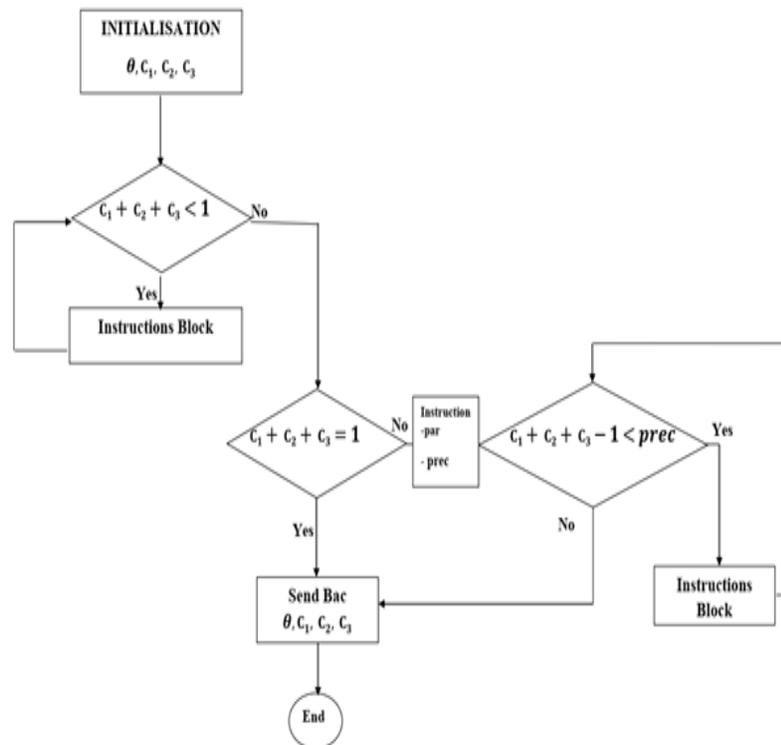


FIGURE 2.6 – Organigramme de la recherche des paramètres du modèle hybride d'optimisation

2.3.7 Le deep learning ou apprentissage profond

Le deep learning est un ensemble de méthodes d'apprentissage automatique qui modélise avec un haut niveau d'abstraction des données grâce à des architectures articulées de différentes transformations non linéaires. Étant donné que les profils de charge électriques ont des caractéristiques non linéaires en raison des divers facteurs qui affectent la consommation électrique, il est recommandé d'utiliser les méthodes d'apprentissage automatique plus adaptées telle que RNN, FFNN, DNN et CNN pour les prévisions à court terme. Parmi ces méthodes nous nous intéressons particulièrement aux méthodes DNN et CNN.

✚Architecture du réseau DNN

Un DNN est un réseau de neurones artificiels supervisés avec plusieurs couches cachées, et une couche de sortie softmax. L'architecture des réseaux de neurones est principalement déterminée par le nombre de couches et de neurones dans chaque couche. Les numéros des neurones d'entrée et des neurones de sortie sont automatiquement fixés par les caractéristiques des dimensions des données d'entraînement et la période de prévision respectivement. Cependant, dans le cas des DNN, il n'est pas possible de tester toutes les combinaisons possibles des couches et des neurones puisque nous devons tenir compte à la fois de la largeur et de la profondeur du réseau. Nous avons sélectionné 6 neurones dans la couche d'entrée, douze neurones dans chaque couche cachée et un neurone pour la couche de sortie qui donne des prévisions horaires. La fonction d'activation des couches cachées est la fonction ReLU décrite ci-dessous tandis que la couche de sortie a une fonction d'activation linéaire [112]. L'algorithme d'optimisation utilisé pour la mise à jour des poids et biais est celle de Levenberg-Marquardt décrite précédemment. La fonction ReLU est donnée par : $f(y) = \max(0, y)$. C'est la fonction d'activation

la plus utilisée dans DNN. Il évite et corrige le problème de fuite de gradient. La figure (2.7) ci-dessous présente l'architecture du DNN utilisé.

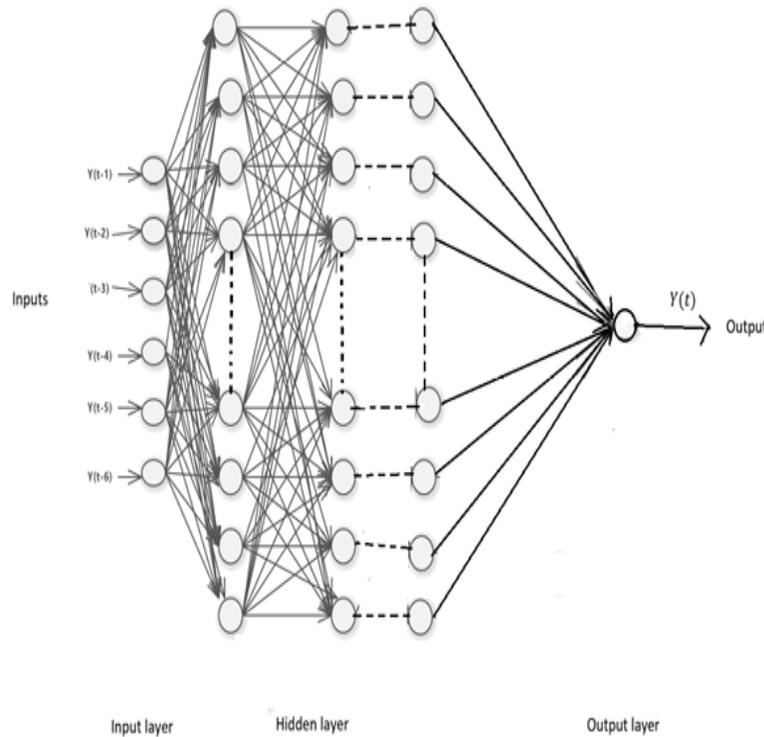


FIGURE 2.7 – Architecture du réseau de neurone profond (DNN) utilisé

où les y_{t-i} représentent les données horaires de consommation extérieur au temps $(t - i)$ et Y_t la consommation horaire prédite au temps t .

✂ Architecture du Réseaux de neurones convolutifs (CNN)

Les réseaux neuronaux convolutifs (CNN) sont l'une des variantes des réseaux neuronaux très peu exploitées dans le domaine des prévisions énergétiques. Il tire son nom du type de couches cachées dont il est constitué.

CNN s'applique en ne connectant que des neurones localement proches à un neurone la couche suivante, au lieu de connecter complètement tous les neurones. Ceci est accompli grâce à l'utilisation d'une opération linéaire appelée convolution, qui opère sur deux fonctions telles que $s(i) = (x * w)(i)$, où $*$ désigne l'opération de convolution définie comme une opération sur deux fonctions sur des valeurs

réelles . Ici, x est la fonction d'entrée et w la fonction de pondération, aussi appelée noyau ou filtre dans CNN et est entraîné comme des poids réguliers dans ANN. Alors s est la sortie de l'opération appelée feature map. Cette opération convolutive ne s'applique que sur une petite zone, appelée champ récepteur (receptive field), produisant le résultat en seulement un neurone de la feature map. En déplaçant la convolution sur tout l'espace d'entrée, la carte de caractéristiques est créée. Après avoir traité les entrées dans la feature map, une fonction d'activation, par exemple. L'unité linéaire rectifiée (ReLU), est appliquée. Ensuite, un pooling-layer est utilisé pour réduire la dimensionnalité en comprimant les sous-régions de feature en une seule valeur. Par exemple, l'opération max-pooling ne prend que le maximum valeur de chaque sous-région et ignore les autres valeurs. A la fin, une ou plusieurs couches entièrement connectées traitent ensuite la sortie des couches convolutionnelles. Celles-ci peuvent être comprises comme un extracteur de caractéristiques et les couches entièrement connectées comme un ANN régulier formé sur les fonctionnalités extraites. La figure 2.8 montre comment CNN est appliqué pour notre série chronologique de prévision. Pour ce problème unidimensionnel, l'opération de convolution peut être écrite ainsi :

$$S(i) = (I * K)(i) = \sum_{l=1}^L I(l)K(i - l). \quad (2.43)$$

Ici, i est le pas courant dans la série, c'est-à-dire une heure. Les entrées sont $I = y_{t-1}, y_{t-2}, \dots, y_{t-i}$, L est le nombre de filtres appliqués, K est la fonction noyau et S est la feature map résultante. La figure (2.8) ci-dessous montre les couches convolutionnelles, les couches entièrement connectées, la sortie qui en résulte et qui représente la prévision recherchée.

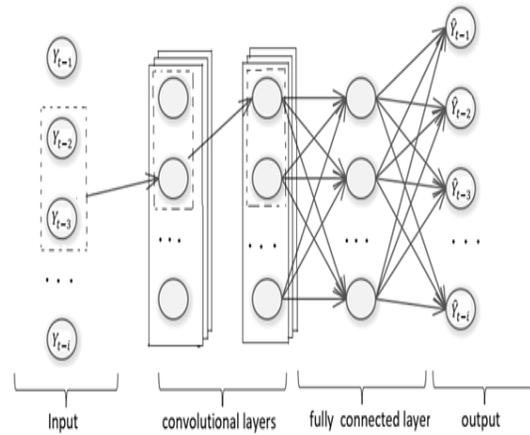


FIGURE 2.8 – Visualisation des CNN pour les séquences avec entrées $I = \{y_{t-1}, y_{t-2}, \dots, y_{t-i}\}$ et les prévisions $\{\hat{Y}_{t-1}, \hat{Y}_{t-2}, \dots, \hat{Y}_{t-i}\}$.

En conclusion, l'Apprentissage profond est une technique puissante, qui permet aux machines d'effectuer des tâches complexes, d'analyser des quantités importantes de données et prendre des décisions avec une précision et une rapidité qui surpassent les capacités humaines. Bien que son utilisation soit complexe, elle offre de nombreux avantages à ceux qui souhaitent apprendre à l'utiliser pour des applications pratiques telles que les prévisions.

2.3.8 La modélisation par la logique floue

Cette section présente une méthode moderne de contrôle, la logique floue. La logique floue diffère de la logique classique parce qu'elle permet des définitions partielles ou "floues" de règles de contrôle. La puissance de la logique floue vient de sa capacité à décrire un phénomène ou processus particulier de façon linguistique, puis de représenter ce phénomène par un faible nombre de règles. Les connaissances dans un système flou sont contenues dans les règles et dans les ensembles flous, qui contiennent des descriptions générales des propriétés du phénomène en question. Dans les paragraphes suivants, nous présentons de manière plus détaillée les étapes de la modélisation du modèle de logique floue conçu ainsi que la dé-

marche adoptée pour estimer les règles floues.

Etape 1 :Collecte des données

Les données historiques utilisées dans cette étude sont celles de la consommation annuelle d'énergie électrique au Cameroun, le produit intérieur brut et la population. Ces données ont été obtenues auprès d'ENEO Cameroun pour les périodes allant de 1975 à 2019.

Etape 2 : Définition du schéma de modélisation

Le schéma fonctionnel du modèle Fuzzy adopté pour cette modélisation est donné par la figure2.9 ci-dessous :

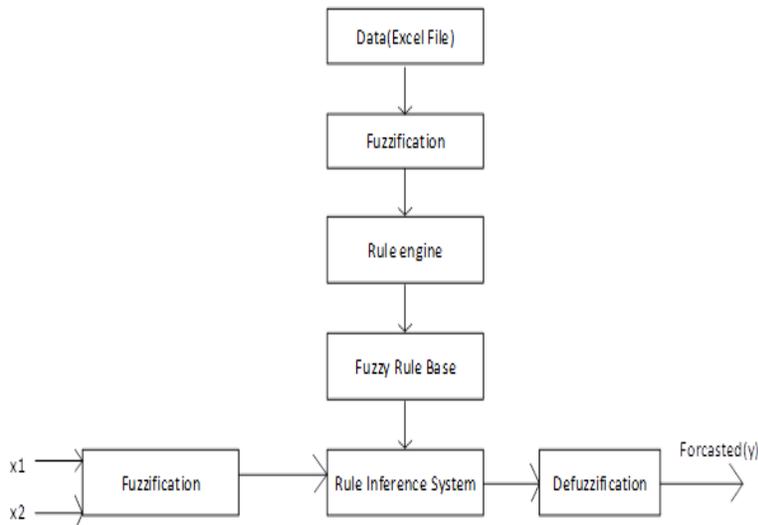


FIGURE 2.9 – Schéma fonctionnel de la méthode de logique floue utilisée

Etape 3 : Fuzzification

a)Construction des régions floues

La construction de ces régions floues dépend en grande partie des compétences de l'expert du domaine. Nos ensembles flous sont construits à partir de la formule ci-dessous :

$$X_K^{i+1} = X_K^i + \nabla X \tag{2.44}$$

Où ∇X est le pas du partitionne qui dépend du choix de l'utilisateur. Plus ce pas

est petit, plus les règles sont fiables. X_K^i sont des abscisses des intervalles flous où i représente le numéro de l'ensemble flou et K le numéro de la variable concernée.

b) Attribution des fonctions d'appartenance aux régions floues

Dans cette section, nous attribuons à chaque région floue une fonction d'appartenance. En effet, il existe plusieurs fonctions d'appartenance, à savoir triangulaire, gaussienne, openrigt, openleft, trapèze, entre autres. Dans le cadre de notre étude, nous utilisons les fonctions openleft, triangulaire et openrigt représentées respectivement par les figures ci-dessous :

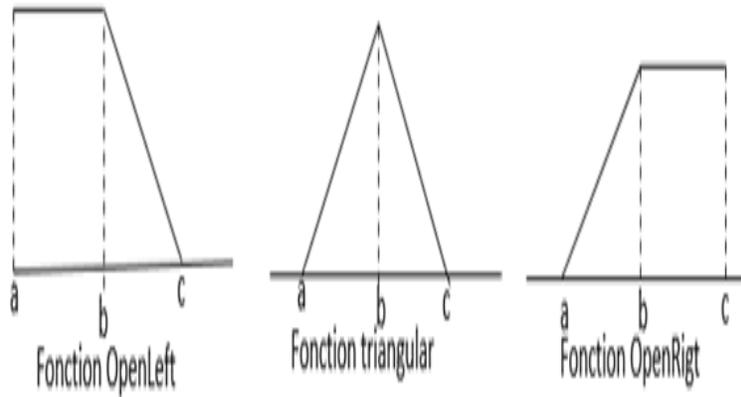


FIGURE 2.10 – Fonctions d'appartenances utilisées

Ces fonctions d'appartenances sont définies par les formules mathématiques ci-dessous :

✠Triangulaire

$$\mu(x, a, b, c) = \begin{cases} \frac{x-a}{b-a} & \text{si } a < x < b, \\ \frac{c-x}{c-b} & \text{si } b < x < c, \\ 0 & \text{si } x > c. \end{cases} \quad (2.45)$$

✠Openleft

$$\mu(x, a, b, c) = \begin{cases} 1 & \text{si } a << x << b, \\ \frac{b-x}{b-a} & \text{si } b < x < c, \\ 0 & \text{si } x > c. \end{cases} \quad (2.46)$$

✠Openright

$$\mu(x, a, b, c) = \begin{cases} \frac{x-b}{b-a} & \text{si } a < x < b, \\ 1 & \text{si } b < x < c, \\ 0 & \text{si } x > c. \end{cases} \quad (2.47)$$

c) Lecture du vecteur flou correspondant à chaque valeur du jeu de données

Pour chaque valeur lue, on utilise la fonction d'appartenance pour déterminer le degré d'appartenance noté $m(x_i)$ qui constitue les éléments du vecteur flou (c'est un vecteur dont les éléments sont les degrés d'appartenance à une région floue) est égale au nombre d'éléments du vecteur flou ainsi qu'au nombre de régions floues.

Etape 4 : construction d'une base de règle floue

Une règle floue est une déclaration de la forme : if X est A alors Y est B où X et Y sont des variables linguistiques, A et B sont des valeurs linguistiques déterminées par les ensembles flous sur les ensembles X et Y . Les étapes de la construction de cette base de règles sont les suivantes :

a) Choix d'une structure de données

Dans cette partie nous modélisons une base de règle par un tableau multidimensionnel. La forme géométrique de ce tableau dépend du nombre de variables d'entrées. Les coefficients du tableau sont constitués des ensembles flous de la variable à prédire.

b) Algorithme de construction du moteur d'inférence

-Assigner à chaque donnée un degré de croyance représenté par un nombre positif ou nul. Ce nombre indique le niveau de d'importance d'une règle.

-Lecture d'une donnée : cette partie consiste à lire une ligne du fichier Excel. par exemple pour la i ème ligne on a (x_1^i, x_2^i, y^i)

-Génération des règles : on détermine le degré d'appartenance de chaque donnée

dans chaque région floue, ensuite on déduit la région d'appartenance de chaque donnée en se basant sur le fait que si une donnée appartient à plusieurs ensembles, on conclut qu'elle appartient à la région de plus grand degré d'appartenance. Cette opération est répétée pour chaque donnée lue et à chaque étape, une règle est générée. L'ensemble des règles générées constitue donc notre base de règle.

Par exemple, si la donnée lue est $(x_1^i, x_2^i, y^i) = (82176.2887, 7837926, 1348)$, nous la partitionnons en cinq ensembles flous (B2, B1, CE, S1, S2) et nous obtenons :

Pour 82176.2887 on a $(0.99, 0.88, 0, 0, 0)$ ce qui permet de conclure que x_1^i appartient à B2. Pour 7837926 on a $(1, 0, 0, 0, 0)$ ce qui permet de conclure que x_2^i appartient à B2. Pour 1348 on a $(0.94, 0.05, 0, 0, 0)$ ce qui permet de conclure que y^i appartient à B2. Nous écrivons donc que $(x_1^i, x_2^i, y^i) \rightarrow [x_1^i(0.99 \text{ in B2, max}), x_2^i(1 \text{ in B2, max}), y^i(0.94 \text{ in B2, max})] \rightarrow \text{Rule 1 : if } x_1 \text{ is B2 and } x_2 \text{ is B2, then } y \text{ is B2.}$

-Stockage des règles : Chaque règle générée est stockée dans notre base de règles. Par exemple, nous avons deux variables d'entrées x_1 et x_2 . Si ces variables ont chacune cinq ensembles flous (B2, B1, CE, S1, S2) notre base de règles est représentée par une matrice.

-Etant donné qu'il peut avoir plusieurs données et que chaque paire de données génère une règle, il est fortement probable qu'il y ait des règles conflictuelles c'est à dire des règles qui ont les mêmes parties if, mais les parties alors différentes. Il convient de trouver un mécanisme de choix des règles optimales. Notre approche pour résoudre ces conflits consiste à assigner à chaque règle générée un degré qui est un nombre calculé. En situation de conflit, la règle de degré maximale est considérée comme optimale. La formule mathématique permettant de calculer le degré d'une règle est donnée par la formule suivante :

$$D(\text{Rule}) = m_A(x_1) * m_B(x_2) * m_C(y), \quad (2.48)$$

où m_A est le degré d'appartenance maximale de la variable x_1 et A la région floue où ce degré d'appartenance est trouvé. En considérons l'exemple du paragraphe 2.2 précédent : Rule 1 : IF x_1 is B2 and x_2 is B2, then y is B2.

$$D(\text{Rule1}) = 0.99 * 1 * 0.94 = 0.9306. \quad (2.49)$$

Dans le cas où on a toujours des conflits, un expert du domaine peut assigner aux données un coefficient (γ) qui représente le degré d'importance d'une règle. Et la nouvelle formule pour le calcul du degré d'une règle devient :

$$D(\text{Rule}) = m_A(x_1) * m_B(x_2) * m_C(y) * \gamma, \quad (2.50)$$

Etape 5 :Defuzzification

Les systèmes basés sur des règles floues évaluent les règles linguistiques si- alors, en utilisant les procédures de fuzzification, l'inférence et la composition. Ils produisent des résultats flous qui doivent généralement être convertis en une sortie nette. Pour transformer les résultats flous en nets, la défuzzification est effectuée. La défuzzification est le processus de conversion d'une sortie fuzzifiée en une seule valeur nette par rapport à un ensemble flou. Les valeurs défuzzifiées dans FLS (Fuzzy Logic Système) représentent les prévisions recherchées. En fonction du problème à résoudre, il existe plusieurs méthodes de défuzzification à savoir :

- Méthode du centre des sommes (COS);
- Méthode du centre de gravité(COG)/centroïde de la zone (COA);
- Méthode du centre de l'aire / de la bissectrice de l'aire (BOA);
- Méthode de la moyenne pondérée;
- Méthodes maximales.

Dans le cadre de notre étude, nous utiliserons la méthode du centre de gravité (COG)/centroïde de la zone (COA). Cette méthode fournit une valeur nette basée sur le centre de gravité de l'ensemble flou. La superficie totale de la distribution de

la fonction d'appartenance utilisée pour représenter l'action de contrôle combinée est divisée en plusieurs sous-domaines. L'aire et le centre de gravité ou barycentre de chaque sous-aire sont calculés, puis la somme de toutes ces sous-zones est prise pour trouver la valeur défuzzifiée pour un ensemble flou discret. Pour la fonction d'appartenance discrète, la valeur défuzzifiée notée Y en utilisant COG est définie par la formule mathématique ci-dessous :

$$Y = \frac{\sum_{i=1}^n X_i \cdot \mu(X_i)}{\sum_{i=1}^n \mu(X_i)}. \quad (2.51)$$

Ici X_i indique l'élément de l'échantillon, $\mu(X_i)$ est la fonction d'appartenance, et n représente le nombre d'éléments dans l'échantillon.

Étape 6 : prévision

Les prévisions passées sont obtenues directement après défuzzification. Cependant, les variables explicatives de la zone des prévisions future n'étant pas disponibles, nous faisons appel aux méthodes statistiques afin d'étendre le domaine de génération des règles floues ce qui permettra d'avoir aisément les prévisions futures recherchées.

2.4 Évaluation de la performance des modèles

La performance du modèle utilisé dans ce travail est évaluée à l'aide des différents indicateurs statistiques suivants : l'erreur quadratique moyenne RMSE et le pourcentage moyen absolu d'erreur MAPE. Soit Y et \hat{Y} sont les valeurs mesurées et estimées de la consommation d'électricité et \bar{Y} leurs valeurs moyennes. L'erreur quadratique moyenne RMSE est donnée par la formule suivante :

$$RMSE = \sqrt{\sum_{i=1}^N (\hat{Y}_i - Y_i)^2 / N} \quad (2.52)$$

Le pourcentage moyen absolu d'erreur $MAPE$ est donné par la formule suivante :

Tableau 2.1 – Indicateurs de performances RMSE(%)

RMSE(%)	Performances
$\leq 10\%$	Haute précision
$10\% < RMSE \leq 20\%$	Bonne
$20\% < RMSE \leq 30\%$	Raisonnable
$> 30\%$	Inexacte

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{Y}_1 - Y_i}{Y_i} \right| \times 100 \quad (2.53)$$

Tableau 2.2 – Indicateurs de performances MAPE (%) Source : Yadav et Chandel 2014

MAPE(%)	Performances
$\leq 10\%$	Haute précision
$10\% < MAPE \leq 20\%$	Bonne
$20\% < MAPE \leq 50\%$	Raisonnable
$> 50\%$	Inexacte

$$\%Error = \frac{actualload - forecastload}{actualload} \times 100 \quad (2.54)$$

t-stat : statistique t. Cet indicateur combine à la fois le RMSE et l'erreur absolue moyenne (MAE). Ce test est largement accepté pour valider les modèles de rayonnement solaire [105].

$$t - stat = \sqrt{\frac{(N - 1)MBE^2}{RMSE^2 - MBE^2}} \quad (2.55)$$

Le coefficient de détermination R^2 : ce facteur est largement utilisé en statistique. Il mesure le degré de prédiction. Lorsque la valeur du coefficient de détermination est proche de 1, cela signifie que le modèle est efficace [113].

$$R^2 = \frac{\sum_{i=1}^n (\hat{Y} - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} = 1 - \frac{\sum_{i=1}^n e_i^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (2.56)$$

En ce qui concerne la question du choix à effectuer entre plusieurs modèles concurrents, c'est-à-dire des modèles dont les variables sont toutes significatives mais qui ne sont pas les mêmes. Le critère de maximisation du R2 consiste à retenir le modèle dont le R2 est le plus élevé. Ce critère présente l'inconvénient de ne pas arbitrer entre la perte de degrés de liberté du modèle et l'ajustement qui en résulte. C'est pourquoi on préfère utiliser les critères de Akaike ou de Schwarz afin de comparer des modèles impliquant un nombre différents de variables explicatives. Nous retenons le modèle qui minimise la fonction de Akaike (Akaike Information Criterion) :

$$AIC = Ln\left(\frac{SCR}{n}\right) + \frac{2K}{n}, \quad (2.57)$$

ou de Schwarz (Schwarz Criterion) :

$$SC = Ln\left(\frac{SCR}{n}\right) + \frac{KLn(n)}{n}, \quad (2.58)$$

avec Ln , le Logarithme népérien, SCR la somme des carrés des résidus du modèle, n le nombre d'observations, K le nombre de variables explicatives. Plus le critère d'information d'Akaike est faible, plus le modèle est performant. Cette procédure est implémentée dans le logiciel Eviews10.

2.5 Avantages et Inconvénients des modèles

La connaissance des avantages et inconvénients des modèles de prévisions étudiées dans ce travail permet aux entreprises en charge de la gestion d'énergie électrique, aux prévisionnistes ainsi qu'aux pouvoirs publics de prendre des décisions plus éclairées qui répondront à leurs objectifs. Le tableau (2.3) ci-dessous présente les avantages et inconvénients de chaque modèle.

Tableau 2.3 – Avantages et inconvénients de chaque modèle

Modèles	Avantages	Inconvénients
<i>HES</i>	<p>méthode souple adaptative et facile à mettre à jour.</p> <p>La méthode ne nécessite pas les variables explicatives</p> <p>L'avantage de cette approche est d'avoir une plus grande flexibilité</p>	<p>Le choix de α et β est arbitraire dans l'intervalle $[0, 1]$.</p> <p>suppose qu'il existe une tendance linéaire</p> <p>Le problème du choix des prévisions initiales, se pose avec autant d'acuité que pour le lissage simple.</p>
<i>MLR</i>	<p>la capacité de déterminer l'influence relative d'une ou plusieurs variables prédictives sur la valeur du critère</p> <p>la capacité d'identifier les valeurs aberrantes ou les anomalies.</p> <p>La régression linéaire est simple à mettre en œuvre et plus facile à interpréter les coefficients de sortie.</p>	<p>Diversement, la régression linéaire qu'il suppose l'existence d'une relation linéaire entre les variables dépendantes et indépendantes. Cela signifie qu'il suppose qu'il existe une relation linéaire entre eux.</p> <p>dans la technique de régression linéaire, les valeurs aberrantes peuvent avoir des effets énormes sur la régression et les limites sont linéaires dans cette technique.</p> <p>La mise à jour est un peu laborieuse car il faut tout recalculer à chaque nouvelle observation.</p>

suite du tableau 2.3

Modèles	Avantages	Inconvénients
<i>ANN</i>	<p>Capacité de représenter n'importe quelle fonction, linéaire ou pas, simple ou complexe</p> <p>Faculté d'apprentissage à partir d'exemples représentatifs, par rétro propagation des erreurs". L'apprentissage (ou construction du modèle) est automatique.</p> <p>Simple à manier, beaucoup moins de travail personnel à fournir que dans l'analyse statistique classique.</p>	<p>L'absence de méthode systématique permettant de définir la meilleure topologie du réseau et le nombre de neurones à placer dans la (ou les) couche(s) cachée(s).</p> <p>Le choix des valeurs initiales des poids du réseau et le réglage du pas d'apprentissage, qui jouent un rôle important dans la vitesse de convergence est aléatoire.</p> <p>Le problème du sur-apprentissage (apprentissage au détriment de la généralisation).</p>
<i>FUZZILOGIC</i>	<p>La puissance de la logique floue vient de sa capacité à décrire un phénomène ou processus particulier de façon linguistique, puis de représenter ce phénomène par un faible nombre de règles.</p> <p>possède l'avantage d'être intuitive et de pouvoir faire fonctionner une quantité importante de systèmes possédant une forte expertise humaine.</p>	<p>Des décisions difficilement ou pas du tout compréhensibles</p> <p>il est impossible de prédire les performances d'un système. méthode ad hoc basée sur le savoir qu'un humain peut acquérir sur un système</p>

suite et fin du tableau 2.3

Modèles	Avantages	Inconvénients
<i>FUZZILOGIC</i>	<p>permet de travailler sur des notions imprécises (intermédiaires entre le vrai et le faux)</p> <p>la maîtrise des systèmes à régler avec un comportement complexe (fortement non linéaire et difficile à modéliser)</p>	<p>le manque de directive précises pour la conception d'un réglage</p> <p>apparition des règles inférences contradictoires possibles</p>
<i>DeepLearning(CNNetDNN)</i>	<p>Le système peut atteindre une meilleure performance que les techniques de machine learning classique</p> <p>Le coût est moindre par rapport aux autres méthodes, car il n'est pas nécessaire de programmer explicitement tous les détails.</p> <p>Les systèmes sont plus rapides et peuvent traiter de grandes quantités de données.</p>	<p>Il nécessite une grande puissance de calcul.</p> <p>Il nécessite beaucoup de données pour l'entraîner, ce qui peut être un défi pour les utilisateurs avec une petite base de données.</p> <p>Les modèles d'apprentissage profond sont complexes et peuvent être difficiles à comprendre ou à déboguer si mal entraînés.</p>

2.6 Matériels utilisés

Les logiciels utilisés pour cette étude sont :

-Le logiciel Excel : Excel est un logiciel de la suite bureautique Office de Microsoft. Il nous a permis d'effectuer les opérations suivantes : la création des tableaux, des calculs automatisés, des plannings, de graphiques et de bases de données. Excel permet également de générer de jolis graphiques pour mieux visualiser les valeurs et les interpréter. C'est un puissant outil de visualisation mathématique. Le choix de ce logiciel est dû en grande partie à son principal avantage qui réside dans le fait qu'il permet de créer facilement des feuilles de calcul totalement personnalisées et adaptées aux besoins spécifiques des entreprises.

-Le logiciel Eviews : pour la modélisation des modèles économétriques, le logiciel Eviews a été indispensable. Eviews offre une analyse sophistiquée des séries chronologiques ou temporelles et certains programmes prédéfinis pour faire une étude prévisionnelle. Eviews permet de développer rapidement des relations statistiques. Il sert à l'analyse scientifique des séries, à l'étude prospective de toute

nature, à la simulation par programmation, à l'écriture des codes et au traçage des graphes.

-MATLAB est un langage de programmation de quatrième génération et un environnement d'analyse numérique. MATLAB permet de faire du calcul matriciel, de développer et d'exécuter des algorithmes, de créer des interfaces utilisateur et de visualiser des données. Avec ses nombreuses fonctions spécialisées pré-codées et ses différentes "tool box" disponibles, MATLAB permet une prise en main rapide et efficace, moyennant une certaine rigueur.

Conclusion

En somme, ce chapitre a présenté les modèles retenus pour la modélisation de la consommation d'énergie électrique à court et long terme au Cameroun ainsi que les différentes étapes de modélisations. Quelques jalons supplémentaires pour la modélisation de la consommation d'énergie électrique au Cameroun ont été posés et présentés à travers les modèles hybrides développés et les modèles d'intelligences artificiels. Après avoir explicité la notion de théorie de la corrélation et de stationnarité, nous avons modélisé la consommation de la charge électrique camerounaise à court terme et à long terme en fonction des données disponibles. Les modèles développés sont les suivants : le modèle VAR/VECM, le lissage exponentiel de Holt, l'analyse régressive, les réseaux de neurones artificiels (RNA), le deep learning, le modèle hybride VECM-HES et le modèle hybride MLR-ANN-HES. Par la suite, les tests statistiques associés permettant d'approuver la validité de ces modèles ont été présentés ainsi que les indicateurs de performances associés. Il sera donc question pour nous par la suite d'appliquer ces modèles aux données historiques de la consommation et la production d'électricité au Cameroun dans le but de faire des prévisions.

Introduction

Les gestionnaires du réseau de distribution utilisent des méthodes de prévision de la consommation électrique future pour dimensionner leur réseau. Elles se basent majoritairement sur des mesures passées et des tendances économétriques ou démographiques. Dans ce chapitre, les modèles de prévisions vues au chapitre deux à savoir : le Modèle VECM, le lissage exponentiel de Holt, le modèle hybride VECM-HES, le modèle de régression linéaire multiple, les Réseaux de neurones artificiels(RNA), le modèle hybride d'optimisation MLR-ANN-HES, le Deep Learning ou apprentissage profond et la modélisation par la logique floue sont appliquées pour la prédiction de la charge électrique au Cameroun à court et à long terme.

Dans un premier temps, nous présenterons les données utilisées, les résultats de la mesure du Coefficient de Corrélacion entre les variables explicatives et les variables expliquées, les tests de stationnarité pour connaître l'ordre d'intégration des différentes variables, les tests de cointégration et de causalité pour connaître les relations de court et long terme entre les variables socio-économiques et la consommation d'électricité. Ces tests nous permettront également de connaître la direction de causalité. Par la suite, nous présenterons les résultats et discussion des prévisions obtenues par les modèles développés à partir des données historiques à

notre disposition ainsi qu'une comparaison des résultats obtenus avec ceux existant dans la littérature sur le sujet. Enfin, nous donnerons des recommandations et perspectives ainsi qu'une conclusion générale.

3.1 Présentation des résultats

3.1.1 Prévisions à long terme

3.1.1.1 Présentations des données de Modélisation

Pour cette étude, les trois types de données utilisées pour la modélisation et prévisions de la consommation annuelle d'énergie électrique au Cameroun sont : le PIB par habitant, l'évolution de la population, les dépenses de consommation finale des ménages et la consommation annuelle d'électricité. Les données de consommation annuelle d'énergie électrique utilisées sont issues de la base des données de l'agence de régulation de l'énergie électrique au Cameroun, le PIB par habitant, l'évolution de la population et les dépenses de consommation finale des ménages sont issus de la base des données de la banque mondiale. Ces données s'étendent sur une période allant de 1975 à 2019. Pour chacune des variables, nous disposons de 46 mesures (une mesure par an). Les figures ci-dessous nous présentent l'évolution des tendances des différentes variables au cours du temps.

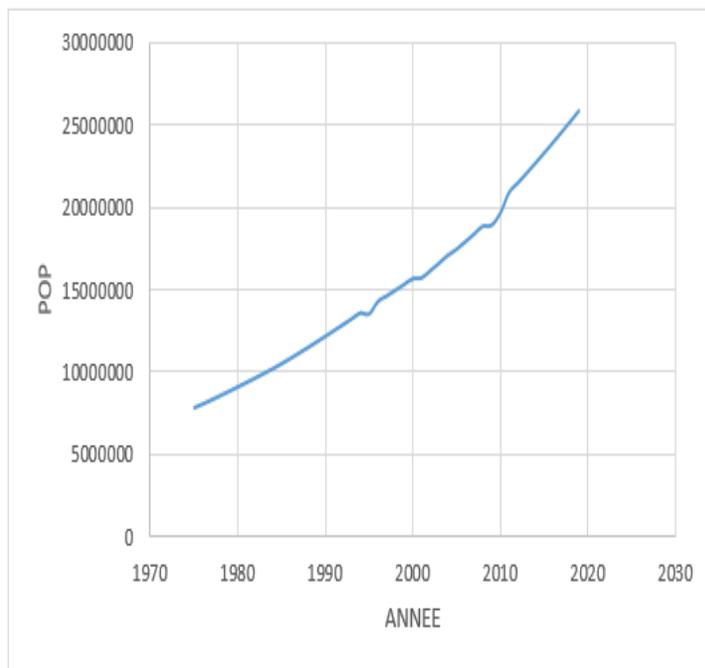


FIGURE 3.1 – Évolution de la population du Cameroun entre 1975 et 2019

Les données statistiques sur la population du Cameroun sont issues de la base de données de l'Institut National des Statistiques (INS). Selon ces données, la population camerounaise était de 8 millions d'habitants en 1977. Le rythme de croissance démographique est important comme dans la plupart des pays sous-développés. Le taux de croissance au Cameroun était de l'ordre de 2,89% dans le début des années 1990. Après le recensement de 1996, on remarque un léger fléchissement du taux de croissance démographique qui tend vers 2,8 % par an. D'après «l'annuaire Statistique du Cameroun 2004», la population tend à plus de 19,249 millions en 2010.

Malgré la diminution du taux de croissance démographique fixée par les Nations Unies à 2% à partir des années 2009, la population du Cameroun ne cesse de croître. Elle est estimée à 27 800 000 habitants en 2022[123]. Cette croissance contrôlée comme le présente les Nations Unies est due à l'amélioration des conditions de vie, l'évolution de la technologie dans le secteur santé et planning

familial, la réduction du taux de mortalité et une augmentation rationnelle du taux de natalité.

Plus on est nombreux, plus on consomme de l'énergie. Ainsi, une augmentation de la demande en énergie électrique est attendue avec la croissance de la population. Il est donc indispensable de faire des prévisions pour satisfaire l'équilibre offre/demande et éviter les désagréments dus à l'insuffisance des capacités de production ou les pertes dues à la surproduction. De ce fait, nous nous intéresserons aux modèles de prévisions dont les courbes représentatives correspondent à l'évolution du profil des données étudiées.

Tableau 3.1 – Tendances d'évolution future de la population du Cameroun [117]

Date	Population	Taux annuel moyen d'accroissement démographique de la période (%)
01/04/1976	7663246	
01/04/1981	8830288	2.9
01/04/1987	10493655	2.9
01/04/1992	12098891	2.9
01/04/1997	13903307	2.8
11/11/2005	17463833	2.7
01/01/2009	18927760	2.7
01/01/2010	19406100	2.6
01/01/2012	20386799	2.5
01/01/2015	21917602	2.5
01/01/2020	24628282	2.4
01/01/2025	27538142	2.3
01/01/2030	30647180	2.2
01/01/2035	33955398	2.1

Le tableau 3.1 présente une baisse du taux de croissance démographique. Cette baisse du taux de croissance démographique peut être justifiée par la baisse relative de la fécondité. Cette tendance de l'évolution future de la population du Cameroun peut être semblable à celle du SRES. Car si le taux de fécondité continue de baisser, le Cameroun aura une population vieillissante d'ici l'horizon 2050. Par conséquent, il y aura augmentation du taux de mortalité et corrélativement baisse de la population.

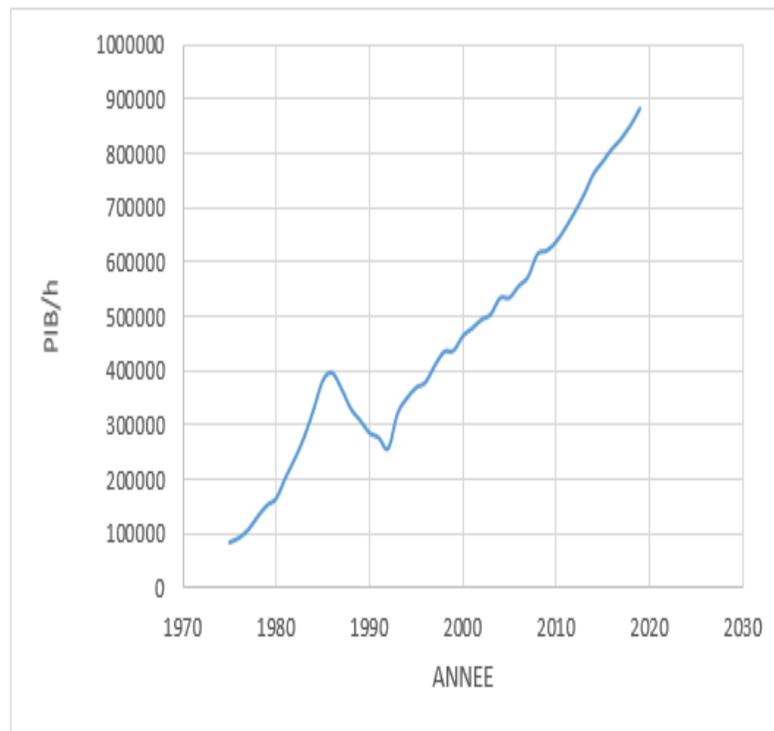


FIGURE 3.2 – Évolution du produit intérieur brut par habitant entre 1975 et 2019

Avec un PIB estimé à 44,1 milliards USD et un PIB par habitants de 1650 USD en 2021, le Cameroun est la 13 ième force économique du continent africain [118, 119]. Le Cameroun fait face à trois grands défis économiques en 2022, à savoir une dette publique importante, des exportations faibles et un déficit d'énergie. Les ralentissements dus à la pandémie à Covid ont pesé sur l'économie camerounaise. Entre 2019 et 2020 le PIB s'est rétracté de 1,5%. Les exportations de pétrole brut

ont par exemple baissé de 22,8% tout comme celles des produits agricoles [14]. La pandémie aurait également entraîné une augmentation du taux de l'extrême pauvreté, passant de 24.5% en 2019 à 25.3% en 2021[120].

Néanmoins, l'économie camerounaise a fait preuve de résilience selon le Fonds Monétaire International (FMI). Elle a résisté face aux crises, notamment grâce à des réformes prônant plus de transparences, une diversification de l'économie des aides sociales ou encore des assouplissements fiscaux [121].

Après la mauvaise période du Covid, la croissance du PIB a été de 3,6% en 2021 et est estimée à 4,6% pour 2022 [122]. Le PIB camerounais devrait atteindre 44,81 milliards USD et 1730 USD par habitants en 2022, un record pour le pays [123]. Les autres éléments positifs de la croissance sont la reprise du secteur non pétrolier et économique mondial général, avant la guerre en Ukraine. Selon la banque britannique Lloyds, cette performance sera portée par les investissements publics dans des projets d'infrastructures tels que des barrages hydroélectriques ou des ports. L'augmentation de l'offre d'électricité, la hausse de la production de gaz naturel liquéfié et les activités liées à la Coupe d'Afrique des Nations, bien que bénéfiques sur un temps limité, soutiennent la croissance économique [124]. Concernant les perspectives économiques, si le conflit dans le NOSO devait perdurer dans cette région, le PIB national pourrait se rétracter de 5%[125].

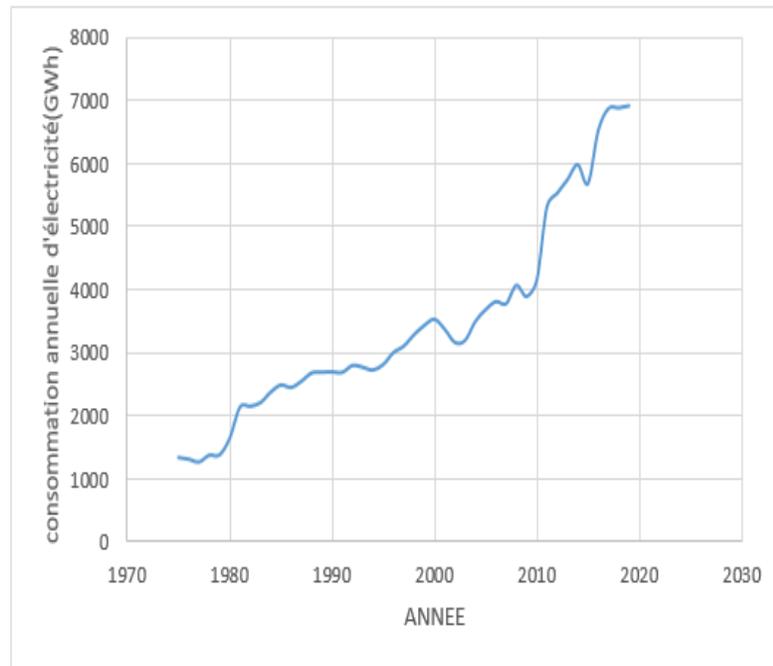


FIGURE 3.3 – Évolution de la consommation annuelle d'électricité au Cameroun entre 1975 et 2019

La consommation d'électricité est constituée de la somme des ventes d'électricité d'AES SONEL, des pertes non techniques communément assimilées aux fraudes et de l'auto production. À partir de cette consommation, l'on déduit une estimation des pertes de distribution.

La production totale d'électricité est constituée de la somme des consommations HT, MT, BT et des pertes techniques. AES-SONEL estime les pertes techniques à 12% des émissions (SIE-Cameroun (2011))[126]. Ainsi, l'évolution des pertes présente une hausse de 8% entre 2009 et 2010.

Nous remarquons sur la figure 3.3 une chute considérable de la production totale d'énergie électrique entre les années 1999 à 2005 qui marque la crise énergétique qu'a connue le Cameroun dans cette période et qui se manifestait par des délestages fréquents. Cette crise énergétique était due à l'insuffisance des capacités de production et à la demande croissante en électricité.

D'une façon générale, l'évolution de la consommation et la production de l'énergie électrique ont une tendance croissante qui, comme dans la plupart des pays en développement, est liée à celle de la population qui éprouve le besoin d'améliorer son niveau de vie.

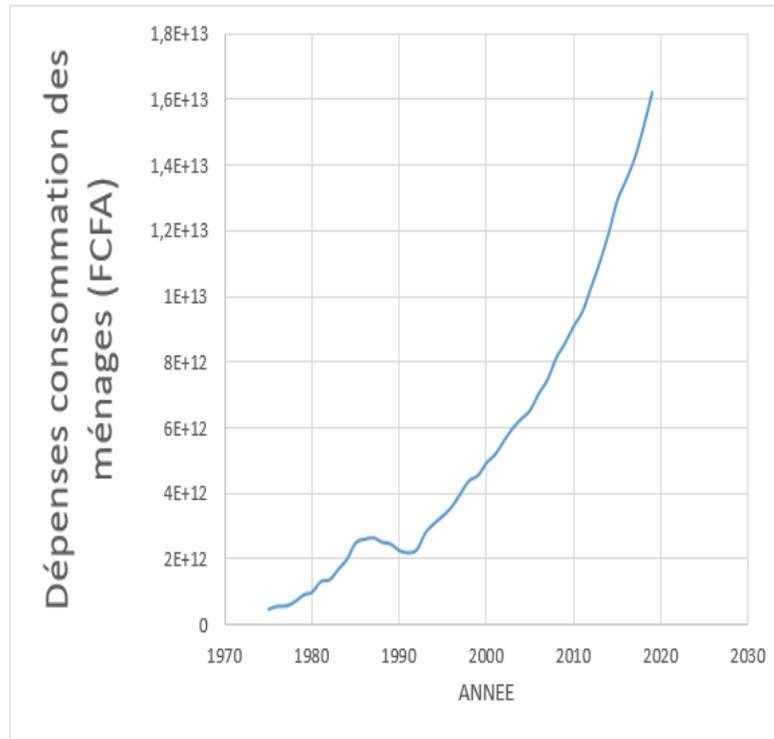


FIGURE 3.4 – Évolution des dépenses de consommation finale des ménages entre 1975 et 2019

3.1.1.2 Résultats du modèle VECM

Nous présentons ici tour à tour les résultats économétriques relatifs à l'analyse de quelques facteurs explicatifs de l'évolution et validité du modèle.

3.1.1.2.1 Étape 1 : Tests de stationnarité et test du nombre de retard optimal

a) Tests de stationnarité

Les principaux résultats des tests de racine unitaire ADF, PP et KPSS sont effectués à partir du logiciel Eviews 10 et présentés dans le tableau 3.2. Ces résultats

indiquant l'ordre d'intégration des séries ainsi que les p-values associées.

Tableau 3.2 – Tests de racine unitaire

Variables	En niveau			En différence première			
	ADF	PP	KPSS	ADF	PP	KPSS	
X_{po}	1,3132 (0.9984)	1.4007 (0.9987)	(0.7907)	-5.8206 (0.0000)	-5.8204 (0.0000)	(0.3480)	I(1)
X_{po}	5.0702 (1.0000)	6.5378 (1.0000)	(0.8484)	-436932 (0.0012)	-4.3857 (0.0011)	(0.76555)	I(1)
X_{pI}	-0.0061 (0.9527)	0.2514 (0.9729)	(0.0834)	-3.7027 (0.0075)	-3.6706 (0.0081)	(0.1200)	I(1)
X_{Dm}	3.6665 (1.000)	8.4486 (1.0000)	(0.8047)	-1.5062 (0.0521)	-1.2610 (0.0638)	(0.7038)	I(1)

Source : auteur sur Eviews 10

Le tableau 3.2 montre que les séries sont intégrées de même ordre I(1). La méthode d'estimation que nous envisageons dans ce cas est la cointégration multivariée de Johansen.

b) Test du nombre de retard optimal

Nous avons utilisé la méthode des critères d'information de Schwarz (SC) et d'Akaike (AIC).

Tableau 3.3 – Sélection et critère de l'ordre de décalage du modèle VAR

Lag	LogL	LR	FPE	AIC	SC	HQ
1	- 2597.753	NA	1.20e+48	124.8930	125.927	125.272*
2	- 2571.388	40.1753*	1.1e+48*	124.828*	126.8966*	125.5862
3	- 2552.233	24.62759	1.75e+48	125.1063	128.2093	126.2437

NB : * indique l'ordre de décalage sélectionné par le critère

Source : auteur sur Eviews 10

D'après les résultats du tableau 3.3 ci-dessus nous remarquons qu'il est possible d'estimer un VAR(2) par conséquent, le nombre de retard optimal retenu pour les model VECM est un Car lorsqu'on a un VAR(P) d'ordre P, en estiment un modèle à correction d'erreur on perd un retard (P-1).

3.1.1.2.2 Étape 2 : Les résultats de co-intégration de Johansen.

Le test de stationnarité à lui seul ne permet pas de voir si les variables sont en relation d'équilibre de long terme et si la corrélation qui existe entre elles n'est pas fausse. Pour le savoir, il est nécessaire de réaliser un test de co-intégration.

Tableau 3.4 – Test de co-intégration

Series : $Y_t, X_{pO}, X_{pI}, X_{Dm}$							
Lags interval (in first differences) : 1 to 1							
Hypothese No. of CE(s)	Eigen value	Unrestricted Cointegration Rank Test (Trace)			Unrestricted Cointegration Rank Test (Maximum Eigenvalue)		
		Trace Statistic	0.05 Critical Value	Prob**	Max- Eigen Statistic	0.05 Critical Value	Prob**
None *	0.577283	58.19384	47.85613	0.0040	37.02527	27.58434	0.0023
At most 1	0.269056	21.16857	29.79707	0.3472	13.47699	21.13162	0.4093
At most 2	0.162912	7.691580	15.49471	0.4990	7.646536	14.26460	0.4158
At most 3	0.001047	0.045044	3.841466	0.8319	0.045044	3.841466	0.8319

Trace test indicates 1 cointegrating eqn(s) at the 0.05 level

Max-eigenvalue test indicates 1 cointegrating eqn(s) at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

** MacKinnon-Haug-Michelis (1999) p-values

Source : Nos estimations à partir d'Eviews 10

Des résultats du tableau 3.4 ci-dessus, il en ressort qu'il existe au plus une relation de co-intégration entre la variable Y_t et les différentes variables explicatives. Cela est confirmé aussi bien par le test basé sur la trace que celui de la valeur propre maximale. De ce fait, nous allons estimer un modèle vectoriel à correction

d'erreur (VECM).

3.1.1.2.3 Étape 3 : Résultats de la dynamique à court et à long terme

Le modèle VECM a ceci de particulier qu'il fournit à la fois les résultats relatifs à la dynamique de court terme et ceux relatifs à la dynamique de long terme. Les résultats obtenus dans le cadre de notre travail sont résumés dans le tableau suivant :

Tableau 3.5 – Dynamique de long et de court terme[127]

Dynamique de long terme		Dynamique de court terme	
Variabes	Coefficients	Variabes	Coefficients
$Y_{(t(-1))}$	1.000000	$Y_{(t(-1))}$	-0.054747 [0.23998] ***
$X_{(po(-1))}$	-0.000169 [-0.38206]***	$X_{(po(-1))}$	0.000307 [1.11249] ***
$X_{(pI(-1))}$	0.007774 [0.90588] ***	$X_{(pI(-1))}$	-0.002917 [-0.90860] ***
$X_{(Dm(-1))}$	1.16E-09 [2.12386]***	$X_{(Dm(-1))}$	3.56E-10 [-0.83745] ***

CointEq1 : -0.007407 [-0.51343]

R-squared : 0.962683

Source : Nos estimations à partir d'Eviews10. Standard errors in and t-statistics in [127].

NB : *, ** et *** traduisent respectivement la significativité des coefficients au seuil de 10%, 5% et 1%. Les valeurs entre crochets représentent les t-statistiques associés aux coefficients. Dans l'interprétation des résultats du tableau 3.5, nous nous attardons aussi bien sur l'aspect économétrique que sur l'aspect économique tant pour les dynamiques de court terme que pour celles de long terme. Dans ce cas, le coefficient de correction d'erreurs est de -0.007407. Celui-ci est négatif et significatif. De ce fait, le modèle VECM estimé est valide. De plus, le coefficient de détermination R² associé aux estimations est de 0.96, ce qui veut dire que la

variance de la variable endogène est expliquée à environ 96% par les variables exogènes du modèle.

a) Interprétation des résultats de la dynamique de long terme

Nous interprétons ici les résultats relatifs aux relations de long terme en nous attachant à chaque fois sur le signe et la significativité des coefficients. A long terme, la consommation annuelle d'électricité dépend positivement du PIB et des dépenses de consommation finale des ménages. Par contre, l'évolution de la population affecte négativement la consommation annuelle d'électricité. Le tableau 3.5 nous montre également que, les influences des variables $X_{pI}(t)$, $X_{(po(t))}(t)$ et $X_{Dm}(t)$ sont significatives pour la stabilité du modèle au seuil de 5%. Ainsi, à long terme, une augmentation de la consommation annuelle d'électricité de 5% au-dessus de la valeur prévue entraînera un déficit d'alimentation en énergie électrique d'une population de 0.0169%, une augmentation de 0.7774% du PIB et une augmentation de $116 \times 10^{-9}\%$ des dépenses de consommation finale des ménages. En d'autres termes ces interprétations signifient simplement qu'une augmentation de la consommation annuelle d'électricité de 5% au-dessus de la valeur prévue entraînera automatiquement une hausse du PIB et des dépenses de consommation finale des ménages, mais un déficit d'alimentation en énergie électrique pour les populations.

b) Interprétation des résultats de la dynamique de court terme

Les résultats de la dynamique de court terme sont ceux obtenus en prenant en compte les variables retardées. Nous nous attarderons tout comme dans les modèles de long terme, tant sur les signes des coefficients que sur leur significativité. À court terme, en dehors de la variable PIB qui varie dans le même sens que la consommation annuelle d'électricité, nous constatons qu'une augmentation de la population et des dépenses de consommation finale des ménages entraîne une

diminution ou un déficit d'énergie prévue. Ceci peut s'expliquer par le fait que l'horizon des prévisions effectuées dans ce travail est annuel. Donc s'il survient des évènements imprévus à court terme qui impliquent un regroupement important des populations et une consommation d'énergie imprévue ceci entrainera une consommation supplémentaire des dépenses finales des ménages par conséquent, un déficit dans la prévision annuelle.

3.1.1.2.4 Étape 4 : Estimation par la méthode du maximum de vraisemblance du modèle VECM et validation à l'aide des tests usuels

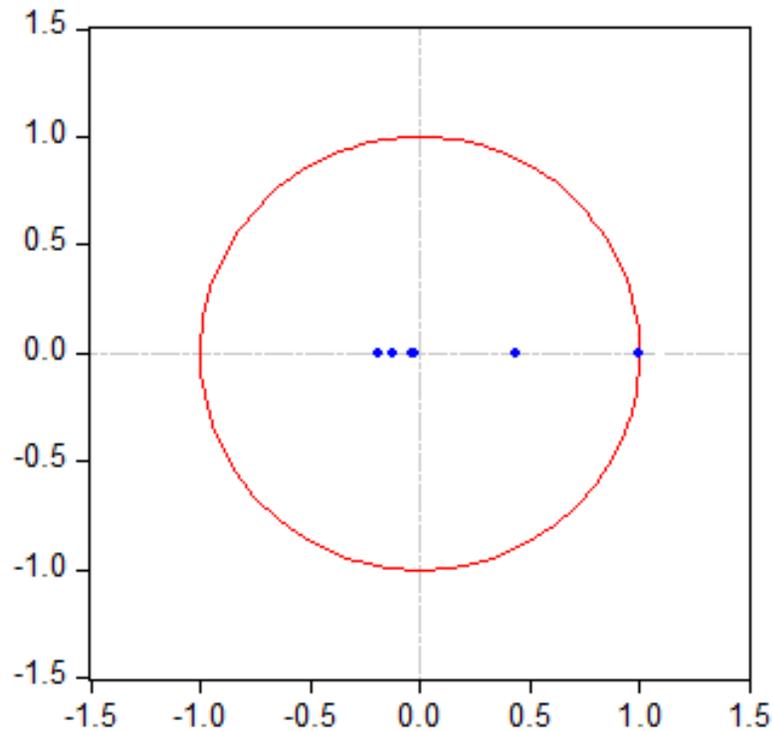


FIGURE 3.5 – Test de stabilité du modèle VECM

En observant cette figure 3.5, nous nous rendons compte que toutes les racines du polynôme de retard sont en module inversement inférieures à 1, chose qui nous permet de conclure sur la stabilité du modèle VECM estimé.

Tableau 3.6 – Évaluation des prévisions

Variable	Inc. obs.	RMSE	MAE	MAPE	Theil
Y_t	45	395.4459	357.6103	12.65098	0.052212
X_{Dm}	45	6.64E+11	5.86E+11	23.45201	0.048320
X_{pI}	45	52154.57	38607.87	12.49685	0.050925
X_{po}	45	439506.4	366584.5	2.298802	0.013587

Nous remarquons à travers le tableau 3.6 que la MAPE est de 12.65% et RMSE est de 3,9544% ce qui traduit le fait que le modèle VECM fournit des résultats relativement bons d'après les critères de performances indiqués dans la méthodologie.

3.1.1.3 Résultats du modèle de lissage exponentiel de Holt(HES)

À partir du logiciel Eviews10, les paramètres optimaux du modèle de prévision obtenu ainsi que l'erreur quadratique moyenne pour une prévision sur quatre ans sont consignés dans le tableau 3.7 ci-dessous.

Tableau 3.7 – Paramètres du modèle

Parameters :	Value
Alpha	1.0000
Beta	0.0600
Sum of Squared Residuals	2361449.
Root Mean Squared Error	229.0778
Jarque-bera	5.188437
Probability	0.074704

Source : nos estimations à partir d'Eviews10.

D'après le tableau 3.7, la jarque-Bera (JB=5.188) est inférieure à la valeur de référence (5.92) donc nous pouvons conclure que les résidus suivent une loi

normale. De plus RMSE est estimé à 229.0778 soit 2.29%. Donc, d'après les critères de performances, on peut conclure que le modèle HES est très bon pour les prévisions de la charge électrique à long terme.

3.1.1.4 Résultats du modèle hybride VECM-HES

Dans cette section, nous présentons d'abord les résultats des prévisions de la consommation nette d'électricité au Cameroun obtenus à partir de l'approche hybride VECM-HES. Puis, nous ferons une comparaison avec les résultats obtenus dans Erasmus Muh et al. [128]. Enfin, nous présentons la comparaison des précisions obtenues avec ceux des modèles hybrides similaires existants.

3.1.1.4.1 Influence du pas d'apprentissage (θ) dans l'algorithme du gradient descendant

Dans cette section nous imposons la précision de l'erreur d'apprentissage souhaitée et l'algorithme d'apprentissage établi nous permet d'obtenir le pas d'apprentissage (θ) optimal ainsi que les meilleurs coefficients α_0 et α_1 du modèle hybride construit.

Tableau 3.8 – Variation du pas d'apprentissage en fonction de la précision et des erreurs du modèle

précisions	pas d'apprentissage (θ)	α_0	α_1	MAPE (%)	RMSE
10^{-1}	23	0.5219	0.5223	4.19	0.076
10^{-2}	22.246	0.5048	0.5052	2.1719	0.0714
10^{-3}	22.047	0.5006	0.5006	2.0064	0.0681
10^{-4}	22.0228	0.4999	0.5002	1.596	0.0676

Nous remarquons à travers le tableau 3.8 que plus la précision souhaitée est faible plus l'erreur de prévision est réduite. Il est donc important de déterminer la valeur optimal de θ , qui réduit au plus l'erreur de prévision. Nous remarquons

également que les coefficients α_0 et α_1 sont tous proches de 0.5, mais nous ne pouvons faire cette approximation car celle-ci induira des erreurs de prévisions qui peuvent, en effet, occasionner des coûts opérationnels importants[129]. D'après Hobbs et al.[130], une réduction de l'erreur moyenne de prévision de 1% peut épargner des milliers, voire même des millions de dollars dans une unité de production d'électricité. Soares et al. [131] citent l'estimation effectuée en 1984 dans une installation électrique au Royaume-Uni, où un accroissement de 1% de l'erreur de prévision avait causé un accroissement annuel des coûts opérationnels de 10 millions de livres sterling.

3.1.1.4.2 Résultats expérimentaux et observations

Tableau 3.9 – Comparaison du critère d'information d'Akaike (AIC) des différents modèles

MODELES	VECM	HES	VECM-HES
AIC	124,828	124,226	121,543

Les résultats du tableau 3.9 montrent que le modèle VECM-HES domine les autres modèles en terme de critère d'information. Par conséquent, il est considéré comme le meilleur modèle en matière de performance prédictive intra et hors échantillon

Tableau 3.10 – Indicateurs de performances des modèles

MODELES	MAPE (%)	RMSE	p-value
VECM	12.65	395.4	0.02
HES	7.32	229	0.07
VECM-HES	1.596	006.74	0.01

Dans le tableau 3.10, les résultats MAPE(%), RMSE et la p-value sont indiqués pour tous les modèles mis en oeuvre dans cette étude. Nous observons

que la MAPE obtenue par l'approche hybride VECM-HES est de 1.596%, ce qui est inférieur à celle des modèles VECM et HES pris séparément. On peut donc conclure que l'approche hybride VECM-HES surpasse les autres modèles dans la prévision de la consommation nette d'électricité et a une valeur MAPE inférieure de 2% par rapport aux MAPE de 12.65% et 7.32% pour les modèles VECM et HES qui sont respectivement bons et excellents. On peut dire que ces niveaux d'erreur dans la formation et le processus de test sont considérés comme de haute précision Selon Yadav et Chandel 2014[132], de plus la p-value du modèle hybride (0.01) est inférieur au seuil de 5% ce qui nous permet de conclure que ce modèle est globalement excellent.

3.1.1.4.3 Résultats du modèle hybride et comparaison

Cette section présente les prévisions par le modèle hybride sur cinq années consécutives ainsi que les résultats obtenu dans [133].

Tableau 3.11 – Prévisions de la consommation électrique annuelle d'électricité au Cameroun(GWh)

Model	2020	2021	2022	2023	2024
VECM	6992,59438	7279,287	7579,044	7892,499	8220,319
HES	7168.403	7338.422	7508.440	7678.458	7848.476
HYBRIDE (VECM- HES)	7169,031	7400,224	7638.0283	7882.7655	8134.772

Les résultats présentés dans le tableau 3.11 nous permettent de conclure qu'au même titre que l'évolution de la population, la consommation d'énergie électrique a une tendance croissante. Elle va de 7169.031 GWh en 2020 à 8134.772 GWh en 2024 soit une augmentation de 965.741 GWh en cinq ans. Cette augmentation considérable est due à la forte croissance économique et démographique du Ca-

meroun depuis plus de dix ans, laquelle s'accompagne d'une demande également croissante de la consommation électrique.

3.1.1.4.4 Intervalles de confiance

Dans cette section, nous associons des intervalles de confiance aux prévisions afin de mieux qualifier le niveau de risque pour prendre des décisions plus éclairées.

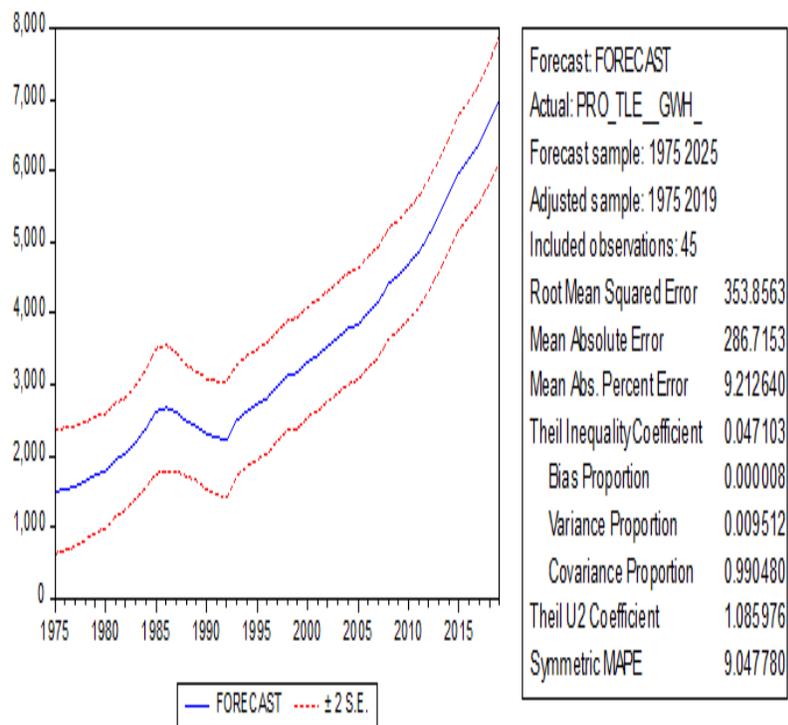


FIGURE 3.6 – Intervalles de confiance et Profil de prévision de la consommation annuelle d'électricité au Cameroun

La figure 3.6 permet de conclure que les intervalles de confiance à 95% associés aux prévisions restent constants au cours du temps ce qui constitue un argument de plus pour confirmer la stabilité du modèle. Les erreurs de prévision associées sont faibles comparativement à celles présentées dans la littérature sur le sujet.

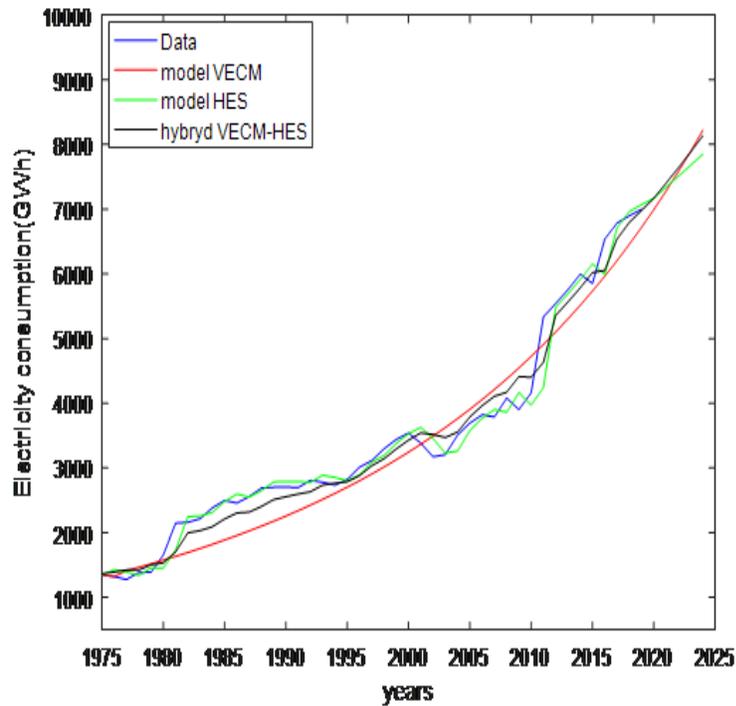


FIGURE 3.7 – Courbes des prévisions de la consommation annuelle d’électricité au Cameroun pour chaque modèle étudié

Les résultats des modèles proposés sont représentés respectivement sur la figure 3.7. On peut aisément constater que toutes les courbes ont une tendance croissante au même titre que les valeurs de consommations réelles. Cette tendance croissante peut être due à la croissance démographique et économique qui influence fortement les consommations futures d’électricité au Cameroun. D’après le tableau 3.10, il est clair que le modèle hybride (HES-VECM) surpasse les autres méthodes en termes d’erreur de mesures. La figure 3.8 présente le Profil de prévision de la consommation d’électricité au Cameroun présente dans FUSS. Cameroon and renewable energy [133].

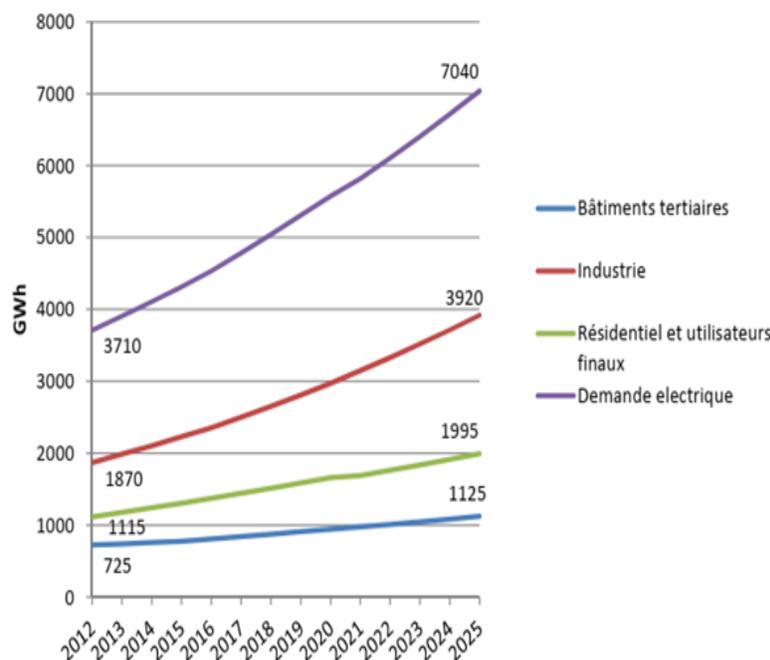


FIGURE 3.8 – Projection de la demande d'électricité au Cameroun en utilisant le scénario du statu-quo[133]

La figure 3.8 indique une prévision de la consommation électrique estimée à 7040 GWh en 2025. Ce qui est largement inférieur aux résultats obtenus par le modèle hybride VECM-HES, de plus cette figure 3.8 indique une prévision de la demande annuelle inférieure à 5000 GWh en 2019 comme indique dans la figure 3.7. Ce qui est très inférieur à la réalité car d'après les données de la banque mondiale et celle de l'agence de régulation de l'énergie électrique au Cameroun, la consommation annuelle en 2019 est estimée à environ 6998.38 GWh. Cette différence peut être due à l'efficacité réduite du modèle de prévision utilisé d'une part, mais aussi au fait que les données utilisées dans FUS [133] sont assez éloignées des années de prévision d'autre part. Ce qui contribue négativement à la justesse des résultats au fil du temps.

3.1.1.4.5 Comparaison des résultats avec ceux des modèles hybrides similaires

Tableau 3.12 – Comparaison de l’erreur de prévision avec ceux des modèles hybrides similaires

MODELS	MAPE (%)	AUTHORS	YEARS
GM(1,1)-ARMA(2,1)	4.39	Xu Weijun et al.	2015
GM(1,1)-ARIMA(2,1,1)	2.30	Yuan C et al.	2016
GM(1,1)-VAR(P)	1.63	Guefano et al.	2020
ARIMA-LSSVM	10.02	Kazil k et al.	2020
VECM- HES	1.596	Nzoko et al.	2021

Au regard des résultats obtenus, nous constatons que la demande annuelle d’électricité au Cameroun continuera de croître au cours des prochaines années comme l’indique la figure 3.3. Le tableau 3.12 permet une comparaison entre nos résultats et ceux obtenus par les autres modèles hybrides similaires au modèle VECM-HES. Compte tenu de leurs MAPE respectives, on peut conclure que le nouveau modèle hybride présenté dans cette thèse offre une meilleure précision et des capacités de prévision plus fiables. Ces résultats intéressants sont dus à l’efficacité de l’algorithme utilisé pour la conception de ce nouveau modèle hybride d’une part et d’autre part au fait que les variables explicatives utilisées sont toutes caractérisées par une tendance de croissance exponentielle. Cette tendance améliore la qualité des prévisions du modèle[134].

Tableau 3.13 – Comparaison avec les modèles hybrides d’intelligence artificielle récents

MODELS	APE (%)	MAPE	RMSE	NS	AUTHORS
VDM-EELM	----	2.960	471.781	----	Niu et al., 2020
VDM-SVM- PSO	----	----	3640,830	0.926	Feny et al., 2020
VDM-SR- SVRCBS	62.3	0.9	85.5	----	Zhang et al., 2020
GM(1,1)- VAR(P)	1.5	1.629	15.5	0.998	Serge G et al.2020
VECM-HES	----	1.596	0.0674	---	Nzoko et al., 2021

Au regard des indicateurs de performances des modèles de prévision présentés dans le tableau3.13 ci-dessus, nous constatons que l’erreur obtenu par le modèle

hybride proposé (VECM-HES) est très proche des erreurs obtenues par les modèles d'intelligence artificielle. Ceci permet de conclure que le modèle hybride proposé (VECM-HES) peut être à la hauteur de certains modèles d'intelligence artificielle récents

3.1.1.5 Résultats du modèle de logique floue (FLS)

Dans cette partie, nous présentons les résultats et discussions des prévisions annuelles obtenus à partir du modèle FLS (Fuzzy Logic système) ainsi que les interprétations associées. Ensuite, nous présentons également une comparaison des résultats avec ceux des modèles similaires.

3.1.1.5.1 Fuzzification

Les entrées du modèles sont la population (x_1), le PIB (x_2) et la sortie y qui représente la consommation annuelle d'électricité prédite. Dans cette étude, chacune des variables utilisées est divisée en cinq intervalles flous comme indiqué dans les figures ci-dessous :

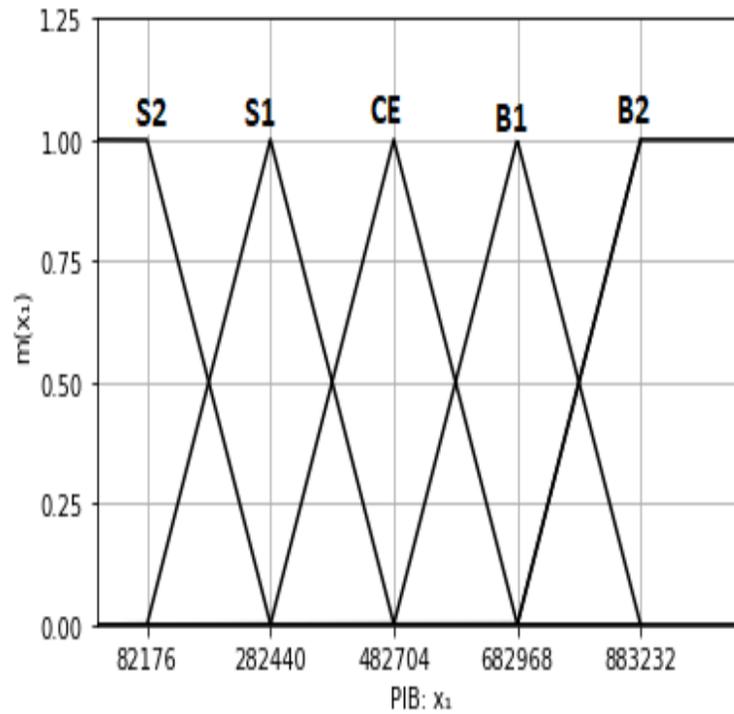


FIGURE 3.9 – Fonction d'appartenance triangulaire pour le PIB prévue

- PIB Très petit (S_2),
- PIB Petit (S_1),
- PIB Moyen CE,
- PIB Grand (B_1),
- PIB Très grand (B_2).

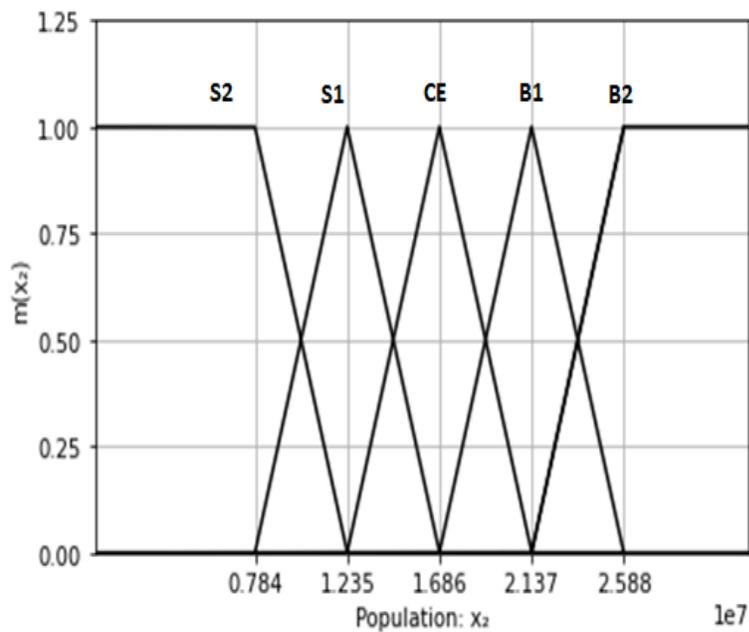


FIGURE 3.10 – Fonction d'appartenance triangulaire pour la variable population

- population "Très petit" (S_2),
- population "Petit" (S_1),
- population "Moyen" (CE),
- population "Grand" (B_1),
- population "Très grand" (B_2).

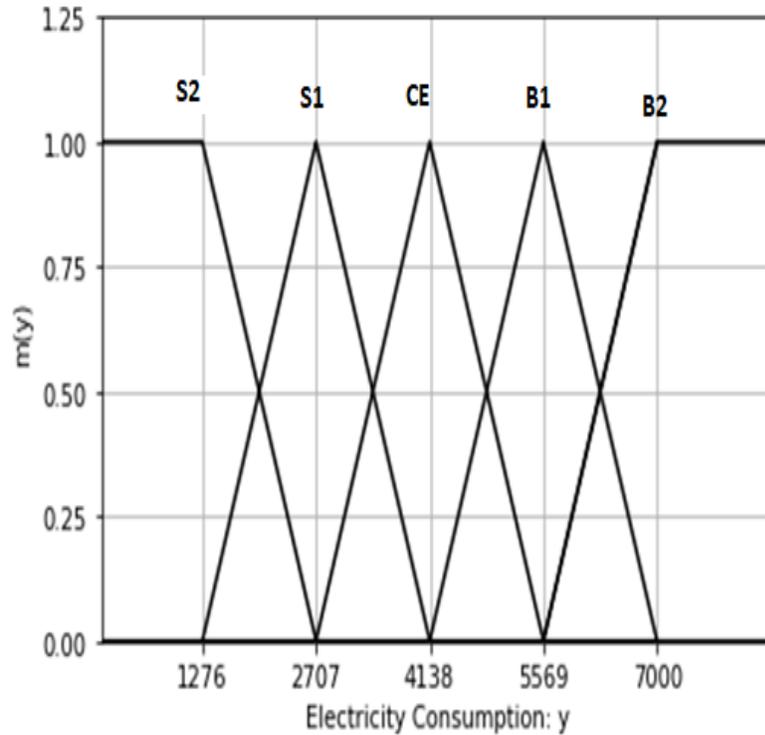


FIGURE 3.11 – Fonction d'appartenance triangulaire pour la charge électrique prévue

- Consommation électrique "Très petit" (S_2),
- Consommation électrique "Petit" (S_1),
- Consommation électrique "Moyen" (CE),
- Consommation électrique "Grand" (B_1),
- Consommation électrique "Très grand" (B_2).

3.1.1.5.2 Construction d'une base de règle

L'une des principales étapes de la résolution d'un problème par la logique floue est la construction d'une base des Règles floues. Dans cette section, le développement des règles qui relient les entrées floues et la sortie requise sont présentées. Dans le souci de simplicité, nous présentons dans la figure 3.12 ci-dessous une base des règles correspondant au cas où chaque donnée de x_1 et x_2 sont partitionnées en cinq ensembles flous numérotés de 0 à 4 où 0 représente B2, 1 représente B1, 2 représente CE, 3 représente S1 et 4 représente S2. Le code python nous donne

la base de règle suivante : $[[0, "", "", ""], [1, 1, "", ""], [", 1, 2, "", ""], [", "", 2, 3, ""], [", "", "", 3, 4]]$.

✦ Le zéro de la première ligne ($[0, "", "", ""]$) signifie que si x_1 est B_2 et x_2 est B_2 alors Y est B_2 ce qui veut dire concrètement que si la population (x_2) est très petite et le PIB(x_1) est très petit, alors la consommation électrique sera très petite.

✦ Le chiffre 1 de la troisième ligne ($[", 1, 2, "", ""]$) signifie que si x_1 est B_2 et x_2 est B_1 alors Y est B_1 et le chiffre 2 signifie que si x_1 est CE et x_2 est CE alors Y est CE.

✦ Le chiffre 3 de la cinquième ligne ($[", "", "", 3, 4]$) signifie que si x_1 est S_1 et x_2 est S_2 alors Y est S_1 et le chiffre 4 signifie que si x_1 est S_2 et x_2 est S_2 alors Y est S_2 .

Les éléments vides de la matrice de la figure 3.12 signifient l'absence des règles. Dans ce cas, notre technique ne pourra prédire que les valeurs dont les règles correspondantes sont connues. Pour compléter cette base des règles, il faut faire appel aux connaissances de l'expert ou aux méthodes statistiques.

Un schéma graphique équivalent de cette base de règle générée par le bout de code python est la figure 3.12.

B2	B2				
B1	B1	B1			
CE		B1	CE		
S1				CE	S1
S2				S1	S2
	B2	B1	CE	S1	S2

x1

FIGURE 3.12 – Représentation de la base des règles floues(Matrice de décision)

La figure 3.12 ci-dessous nous présente la base de règles floues obtenu en fonction des entrées et de la sortie du modèle (Y). Les règles d'inférence relient l'entrée à la sortie et chaque règle représente une relation floue. En partitionnant x_1 en 402 ensembles flous et x_2 en 42 ensembles flous, on obtient à partir du bout de code python une base de règle bien améliorée que celle précédente. Cette matrice modélisant notre base des règles est une matrice de taille 42*402, et les pas associés aux variables x_1 , x_2 sont respectivement 20026 et 45096. Après l'établissement d'une base de règles bien améliorées, l'étape suivante est la défuzzification. À ce stade, les données traduites en règles floues sont ressaisies sous forme de données nettes. La méthode de défuzzification Mamdani utilisée est la méthode centroïde.

3.1.1.5.3 Prévision de la charge à base des règles floues établies

Dans cette étude, les cent vingt-cinq règles floues sont utilisées. Chaque règle se voit attribuer une réponse au travers d'une matrice de décision. Les prévisions

passées et futures générées par ces règles sont présentées dans le tableau ci-dessous, ainsi que l'erreur associée à chaque valeur prédite. Une fois les résultats de la prévision obtenus, le pourcentage d'erreur absolu moyen (MAPE) est calculé.

Tableau 3.14 – Prévisions passées et future générées par le modèle de logique floue développé

périodes	Années	Données réelles	Prévision du modèle FLS	Erreur
Prévisions passées	2000	3541	3541,649534	0,64953403
	2001	3382,512	3383,649853	1,137852578
	2002	3174,219	3175,454548	1,23554802
	2003	3206,757	3208,978653	2,221652592
	2004	3508,842	3510,413972	1,571971608
	2005	3693,198	3693,571714	0,373714055
	2006	3822,195	3822,922462	0,727461576
	2007	3788,112	3789,745743	1,633742614
	2008	4080,234	4081,600735	1,366735339
	2009	3901,509	3902,829233	1,320232761
	2010	4159,554	4160,120263	0,566262633
	2011	5336	5337,049475	1,049475262
	2012	5541	5541,451182	0,451182097
	2013	5757	5757,833768	0,833767587
	2014	5994,765598	5994,769508	0,003910111
	2015	4750,999076	4751,173168	0,17409257
	2016	6536,520852	6536,987142	0,466290075
	2017	6885,193115	6885,660685	0,467570255
	2018	6896,550372	6897,181853	0,631480518
2019	6928,384707	6929,360624	0,975917127	
Prévisions futures	2020	//	7243.803325	//
	2021	//	7339.823823	//
	2022	//	7435.844321	//
	2023	//	7531.86482	//
	2024	//	7627.885318	//
	2025	//	7723.905816	//
	2026	//	7819.926314	//
	2027	//	7915.946812	//
	2028	//	8011.96731	//
	2029	//	8107.987809	//
	2030	//	8204.008307	//

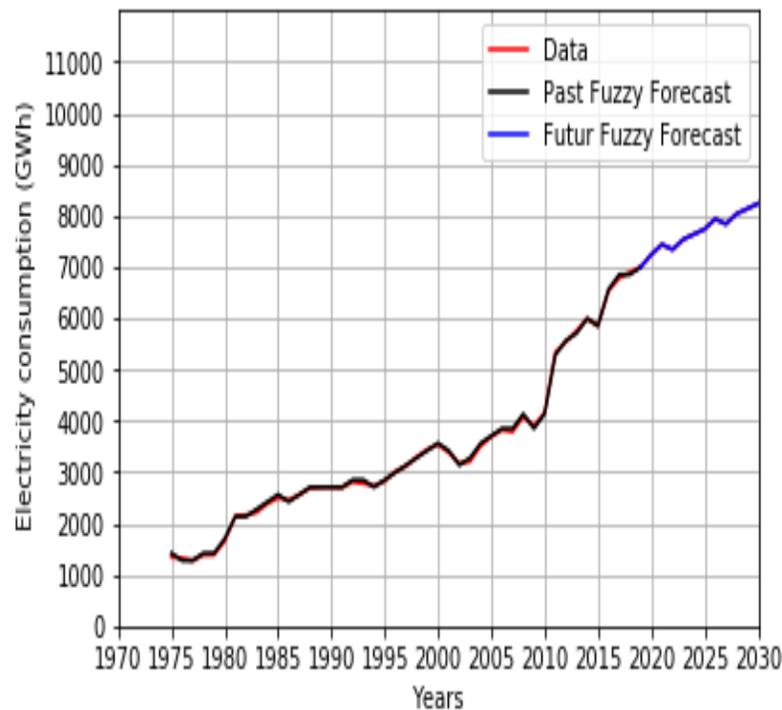


FIGURE 3.13 – Représentation graphique des prévisions de la consommation annuelle d'électricités par le modèle FLS

Les résultats obtenus à partir de la logique floue sont présentés dans le tableau 3.14 ci-dessus. On constate qu'il existe une erreur comprise entre 0,0039 et 1,633 pour les prévisions passées. La figure 3.13 montre la représentation graphique entre les consommations annuelles d'électricité réelle et les consommations prévisionnelles floues pour la période de 1975 à 2030. Ainsi qu'une comparaison entre les consommations réelles et les consommations prévisionnelles. Nous observons que les deux courbes sont parfaitement superposées. Ce qui signifie clairement que l'erreur de prévision du modèle FLS est très réduite.

Tableau 3.15 – Comparaison des résultats avec ceux des études similaires

MODELES	AUTEURS	ANNEES	FREQUENCE	MAPE	REFERENCE
Fuzzy Time Series (FTS)	Tay Kim Gaik et al.	2018	long terme	5.74%	[135]
Fuzzy Logic	G A Salihan, et al.	2021	long terme	3.80%	[136]
Fuzzy Logic	P.Lakshmi Priya et al.	2018	court terme	3.17%	[137]
FUZZY LOGIC APPROACH	ADE- IKUESAN OLANIKE OLUFISAYO et al.	2020	long-Term	8.34%	[138]
Deep Learning	Cheng-Hong Yang et al.	2022	long terme	0.613%	[139]
Artificial Neural Network (ANN)	R Adhiswara	2019	long terme	0.9%	[140]
Autoregressive Integrated Moving Average Approach	Mohammed Jamii et al.	2021	long-Term	4.856%	[141]
Econometric models (VECM-HES).	NZOKO TAYO et al.	2022	long terme	1.596%	[142]
Machine Learning	Terence K. Lukong et al.	2022	long terme	5.4962%	[143]
back propagation algorithm	Nooriya A. Mohammed et Ammar Al-Baz	2022	long terme	1.234%	[144]
Fuzzy logique systeme	NZOKO Tayo et al.	2022	long terme	0.011%	Writers

Le tableau 3.15 ci-dessus présente une étude comparative des résultats obtenus par le modèle de logique floue développé dans cette thèse avec ceux des études similaires existant dans la littérature. Nous constatons que la MAPE du modèle de logique floue développé est de 0.011%, ce qui est très faible comparativement à ceux des modèles similaires existant dans la littérature sur le sujet. Ce qui nous permet de conclure que la base des règles floues développée permet de fournir des très bons résultats.

3.1.2 Prévisions à court terme

Dans cette section, nous présentons les données utilisées, une étude détaillée des résultats obtenus par chacun des modèles pris séparément et dans l'ordre énoncé. Puis, nous présentons également les résultats du modèle hybride d'optimisation suivi d'une étude comparative aux modèles similaires parentés dans la littérature.

3.1.2.1 Présentation et analyse des données

Les données historiques utilisées dans cette étude ont été obtenues auprès d'eneo Cameroun. Elle nous a fourni les valeurs de la charge électrique horaire totale consommée par les utilisateurs de la ville de Yaoundé pour les périodes allant du 01 janvier 2017 au 29 Novembre 2019. Un aperçu de ces valeurs pour les périodes du 1er janvier 2019 au 26 janvier 2019 est résumé dans la figure 3.14 ci-dessous.

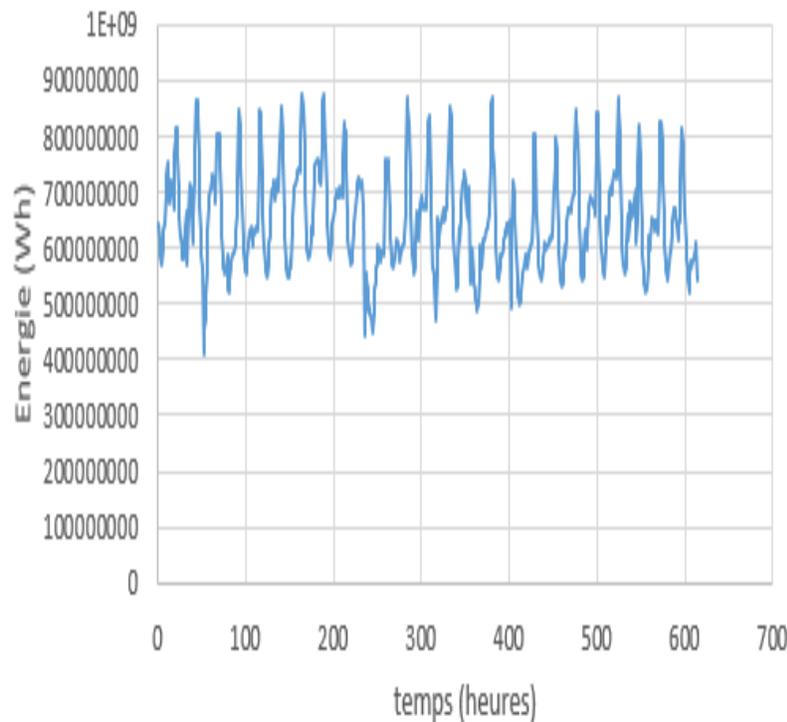


FIGURE 3.14 – La charge électrique consommée dans la ville de Yaoundé du 1er Janvier au 26 Janvier 2019

Sur la figure 3.14, nous remarquons que la représentation graphique est oscillante et a une variation cyclique journalière. Le changement influe directement sur le comportement des êtres humains et par conséquent sur les valeurs de la charge électrique horaire totale consommée par les utilisateurs de la ville de Yaoundé. Les décroissances brutales observées à la 52^{ième} heure et entre la 233^{ième} à 261^{ième} heures peuvent être dues à une panne d'équipement, un délestage ou une mauvaise planification.

Tableau 3.16 – Corrélations entre les consommations des jours de la semaine

	Lundi	Mardi	Mercredi	Jeudi	Vendredi	Samedi	Dimanche
Lundi	1	0.89	0.87	0.86	0.84	0.82	0.83
Mardi		1	0.89	0.88	0.87	0.85	0.86
Mercredi			1	0.92	0.90	0.88	0.87
Jeudi				1	0.92	0.89	0.87
Vendre					1	0.89	0.87
Samedi						1	0.90
Dimanche							1

Nous constatons à travers ce tableau 3.16 que toutes les corrélations sont comprises entre zéro et un ce qui signifie que les consommations horaires ont un lien de causalité entre elles et évoluent dans le même sens. De plus, ces corrélations sont toutes supérieures à 0.8. On peut donc conclure qu'il existe un lien fort entre ces consommations horaires. Par conséquent, on peut faire des estimations en fonction des valeurs passées.

3.1.2.2 Résultats du modèle de régression linéaire multiple

3.1.2.2.1 Résultats et interprétation de l'estimation des paramètres du modèle

Notre échantillon d'estimation des paramètres du modèle de régression linéaire multiple va du 28 Octobre 2019 au 10 novembre 2019. La prévision hors échantillon porte sur les 168 heures qui suivent la dernière heure du 28 Octobre 2019.

Tableau 3.17 – Statistiques de la régression

Variable explicatives	coefficients	t-statistic	Probabilité associée (P)
constant	0,00000314	0,21261306	0,54886270
Y_{t-1}	-0,442738	-16,45032	0,000000
Y_{t-2}	1,439607	6,98225	0,000000
Y_{t-3}	0,047532	3,1493275	0,0256393
Y_{t-4}	-0,038190	-2,247722074	0,03786263
Y_{t-5}	0,010297	4,33383570	0,007389
Y_{t-6}	-0,01363639	-5,46449536	0,005188
R-squared	0.981249	Mean dependent var	5.21E+08
Adjusted R-squared	0.980671	S.D. dependent var	71456448
S.E. of regression	9934608.	Akaike info criterion	35.09601
Sum squared resid	1.60E+16	Schwarz criterion	35.20758
Log likelihood	-2942.065	Hannan-Quinn criter.	35.14129
Durbin-Watson stat	0.941998		
F-statistique	4.35		

D'après le tableau 3.17, nous constatons après estimation des paramètres du modèle que :

En examinant les valeurs de t de Student et les probabilités correspondantes, les variables explicatives sont toutes significatives au seuil de 5% ($P \leq 0,05$) ;

la constante n'est pas significative car la probabilité associée est supérieure au seuil de 5% ;

Les coefficients des variables Y_{t-2} , Y_{t-3} , et Y_{t-5} sont tous positifs, ce qui

signifie qu'ils évoluent dans le même sens que la variable expliquée Y_t . Par contre les coefficients des variables Y_{t-1} , Y_{t-4} et Y_{t-6} sont négatifs ce qui signifie qu'ils n'évoluent pas dans le même sens que la variable expliquée Y_t . Ceci peut être dû au changement climatique qui influence directement le comportement des êtres humains et par conséquent sur les valeurs de la charge électrique horaire totale consommée par les utilisateurs ;

Au niveau global, le modèle est significatif avec un coefficient de détermination R^2 (0,981) élevé. Ce coefficient montre que la qualité d'ajustement du modèle est assez bonne.

Cependant, certains tests de validation des hypothèses sont nécessaires pour vérifier non seulement la bonne spécification des modèles mais aussi la stabilité des coefficients. Dans le premier cas, il s'agit du test d'autocorrélation des erreurs, du test de normalité des résidus, du test de spécification et du test d'hétéroscédasticité. Dans le deuxième cas, il s'agit du test de stabilité des paramètres du CUSUM et du carré du CUSUM.

3.1.2.2.2 Résultats et interprétations des tests

Il s'agit ici de mettre en exergue les tests de validation des hypothèses nécessaires pour la vérification non seulement de la bonne spécification du modèle mais aussi de la stabilité des coefficients.

1-tests de spécifications du modèle

Tableau 3.18 – Tests statistiques, source : auteur à partir d'Eviews 10

Intitulé	p-value
Test de Normalité de Jacque-béra	0.052834
Test d'autocorrélation de Breush GodfreyPagan	0,1186
Test d'hétéroscédasticité de Breusch-Pagan	0,7196

Test d'auto-corrélation des résidus :

La p-value associée à la statistique du test de Breusch-Godfrey est de 11,86% comme le montre le tableau 3.18. On accepte donc l'hypothèse nulle de l'absence d'auto-corrélation des erreurs. Car la probabilité critique de cette statistique est supérieure au seuil de significativité de 5%.

Test de normalité des résidus :

Cette normalité des résidus est conclue lorsque la probabilité critique est supérieure au seuil de 5%. Ainsi, la p-value associée à la statistique de J-B est de 5.28%. On conclut que les résidus sont normalement distribués.

Test d'hétéroscédasticité :

Nous constatons que la p-value 0,7196 est supérieure à 5%. Nous ne rejetons donc pas l'hypothèse nulle d'homoscédasticité.

2-Tests de stabilité des coefficients

Sur les figure 3.15 et figure 3.16, nous remarquons que les parcelles du CUSUM et CUSUM Squared restent dans les limites critiques du niveau de significativité de 5%, l'hypothèse nulle selon laquelle tous les coefficients sont stables ne peut être rejetée.

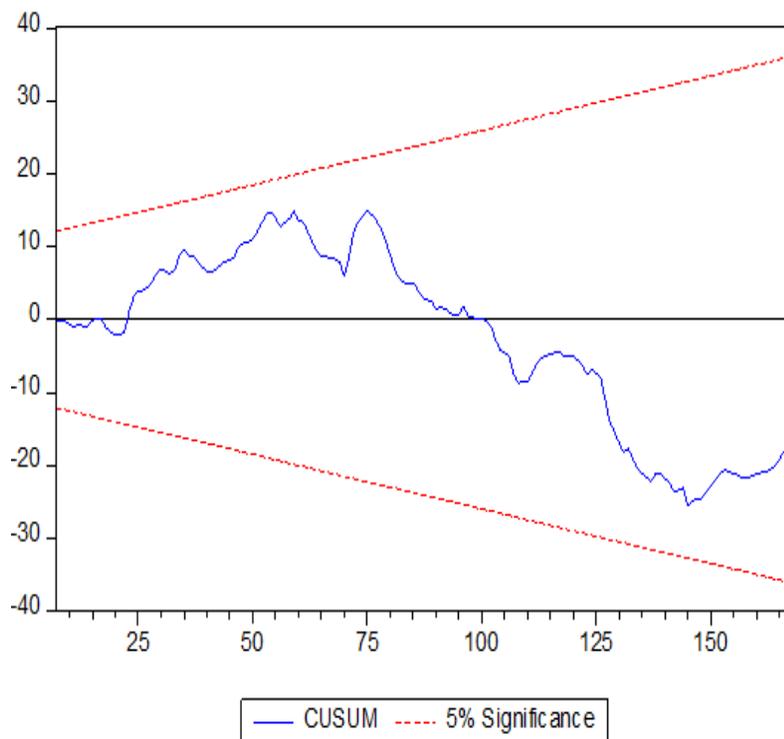


FIGURE 3.15 – Test de CUSUM

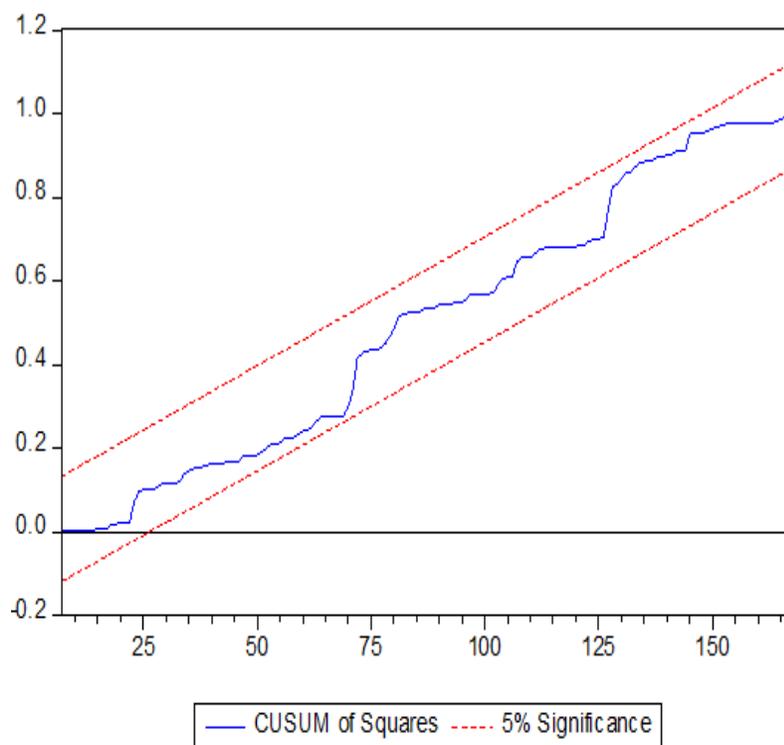


FIGURE 3.16 – Test du CUSUM Squares316

Après les tests de diagnostic et de stabilité effectués, nous pouvons passer aux

prévisions de consommation des 168 heures suivantes.

3.1.2.2.3 Prévisions du modèle de régression linéaire multiple

Les prévisions de consommation horaire d'énergie électrique sont effectuées sur les périodes allant du 11 novembre 2019 au 17 novembre 2019 soit 168 heures et les résultats sont comparés avec la consommation réelle sur la figure 3.17.

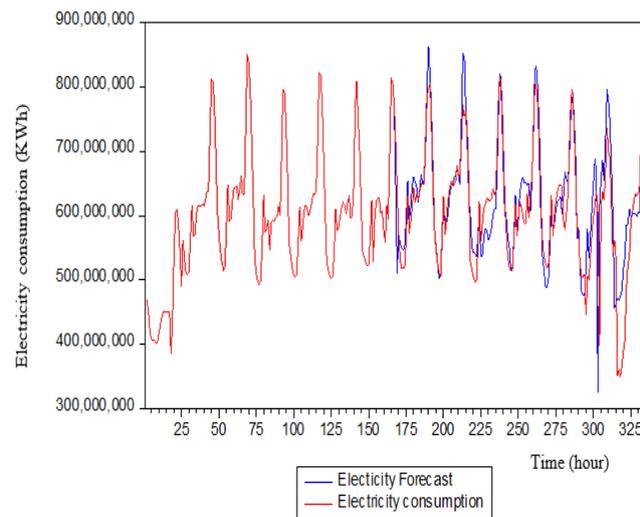


FIGURE 3.17 – Profil de prévision de la consommation d'électricité avec le modèle LRM pour 168h.

Au regard de la figure 3.17 on remarque une bonne superposition entre les valeurs prédites et les valeurs réelles. On peut donc conclure que le modèle de régression linéaire multiple est approprié pour les prévisions de consommation horaire d'électricité de la ville de Yaoundé-Cameroun au regard des indicateurs statistiques satisfaisants obtenus.

3.1.2.3 Résultats du modèle des réseaux de neurones artificiels

Les données utilisées sont divisées en quatre ensembles pour assurer une bonne estimation et vérification des méthodes de prédiction.

Ensemble d'apprentissage (du 1er janvier 2017 au 30 novembre 2018) : il sert à calculer les poids du réseau.

Ensemble de validations (1er décembre 2018 au 31 mai 2019) : il sert à éviter le sur-apprentissage.

Ensemble de tests (du 1er juin 2019 au 10 novembre 2019) : il sert à évaluer les performances du réseau obtenu.

Prévisions (du 11 novembre 2019 au 17 novembre 2019).

3.1.2.3.1 Prédiction à un pas en avant sur une semaine

Après plusieurs essais sur l'architecture en utilisant une seule couche cachée ensuite deux couches cachées, on a eu plusieurs architectures où l'erreur d'apprentissage et de validation convergent vers une valeur acceptable. Le tableau 3.19 présente les architectures jugées intéressantes avec leurs erreurs de validation.

Tableau 3.19 – Architectures du réseau et erreurs de prévision d'un pas en avant

Algorithme d'apprentissage	Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	nRMSE (%)	nMAPE (%)
quasineu	6-3-1	3	-	5.54	4.2386
	6-6-1	6	-	5.61	4.3170
	6-12-1	12	-	3.91	2.76
	6-6-3-1	6	3	8.10	8.07
conjgrad	6-3-1	3	-	5.85	4.3485
	6-6-1	6	-	5.67	4.1811
	6-12-1	12	-	5.69	4.2035
	6-6-3-1	6	3	7.11	6.02
scg	6-6-3-1	6	3	8.16	7.078
	6-3-1	3	-	5.66	4.2174
	6-6-1	6	-	6.29	4.7824
	6-12-1	12	-	5.46	4.0246
Levenberg Marquardt,	6-3-1	3	-	17.54	7.2586
	6-6-1	6	-	16.42	7.3489
	6-12-1	12	-	3.27	2.67
	6-6-3-1	6	3	14.11	9.27

L'observation des résultats sur le tableau 3.19 montre que l'architecture (6 12 1) utilisant l'algorithme de Levenberg Marquard présente la plus basse erreur vis-à-vis des autres architectures. Pour ce réseau, la variation de l'erreur d'apprentissage et de validation est schématisée dans la figure 3.18.

3.1.2.3.2 Analyse des erreurs d'entraînement, de validation et de test

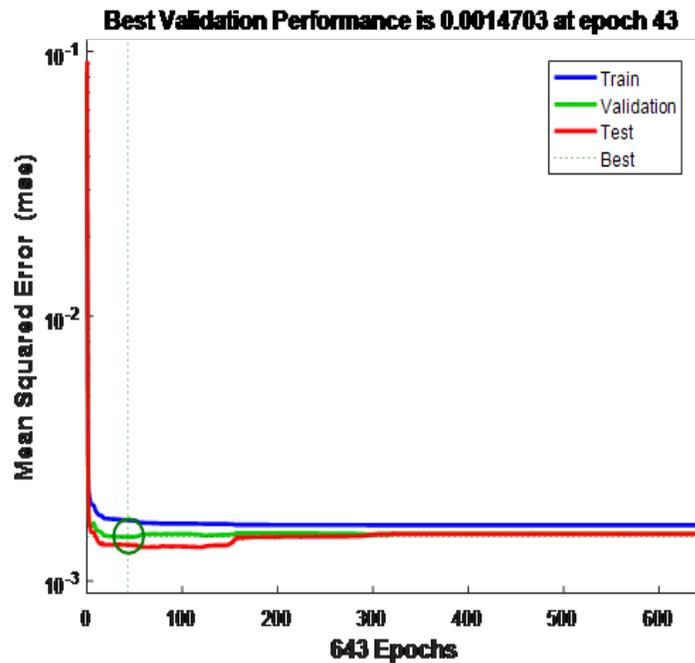


FIGURE 3.18 – Evolution des erreurs d’entraînement, de validation et de test

La figure 3.18 nous présente les courbes des erreurs d’entraînement, de validation et de test. Dans cette figure, nous pouvons constater que les résultats sont raisonnables en raison des considérations suivantes :

- L’erreur quadratique moyenne finale est faible.

- L’erreur de l’ensemble de test et l’erreur de l’ensemble de validation ont des caractéristiques similaires.

- Aucun sur-ajustement significatif n’est survenu à l’itération 43 (où les meilleures performances de validation se produisent).

3.1.2.3.3 Analyse de la réponse du réseau

Pour effectuer une analyse de la réponse du réseau. Nous avons effectué une régression linéaire entre la sortie du réseau et les cibles correspondantes.

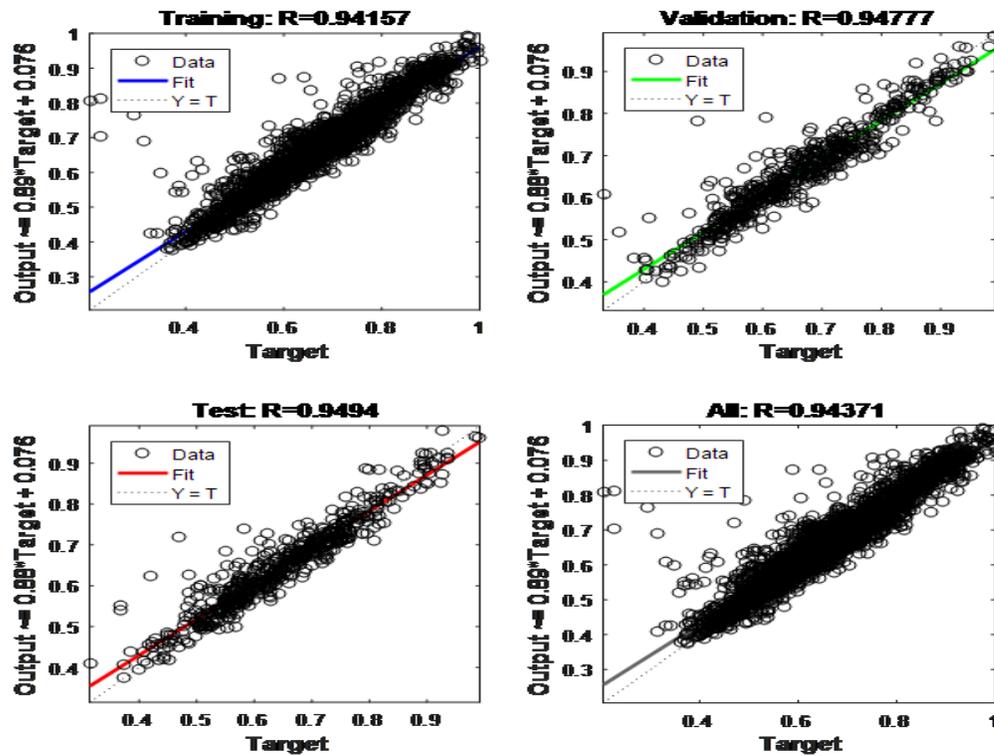


FIGURE 3.19 – Analyse de la réponse du réseau

D'après la figure 3.19, nous constatons que la sortie suit très bien les cibles pour la formation, les tests de la validation, et les valeurs de R sont tous supérieures à 0,94 pour les différentes réponses du réseau. Dans ce cas, la réponse du réseau est satisfaisante et nous pouvons maintenant mettre le réseau à profit sur de nouvelles entrées. Les variations de la charge électrique prédite et celle réelle sont représentées dans la figures 3.20. On voit que les valeurs des charges électriques horaires prédites par le modèle suivent la variation réelle, quel que soit le jour de la semaine.

3.1.2.4 Résultats du modèle de lissage exponentiel de Holt

Dans cette étude, la série chronologique qui illustre le lissage de Holt est celle de la consommation horaire d'électricité de la ville de Yaoundé. Le lissage est mis en oeuvre sur les observations du 1er janvier 2017 au 30 août 2019 dans

le but de déterminer les deux paramètres du modèle qui minimisent l'erreur de prévision. Ensuite ces deux paramètres sont utilisés pour effectuer les prévisions sur les périodes allant du 11 novembre 2019 au 17 novembre 2019 soit 168 heures et les résultats sont comparées avec la consommation réelle sur les figures 3.20. Les différentes mesures de l'erreur de prévision hors échantillon sont présentées dans le tableau 3.20. pour prévoir les valeurs comprises entre le 1er septembre 2019 au 29 Novembre 2019 et les comparer aux observations. En faisant varier les paramètres α et γ entre 0 et 1 par pas de 0.1. Les paramètres qui donnent une erreur de prévision acceptable pour la phase entraînement et de validation sont présentés dans le tableau3.20.

3.1.2.4.1 paramètres du modèle de lissage exponentiel de Holt

Tableau 3.20 – Paramètres du modèle, erreur d'apprentissage et validation du lissage

Paramètres($\alpha ; \gamma$)	Train MAPE	MAPE
$\alpha=0.3 \gamma=0.4$	4.39	4.44
$\alpha=0.4 \gamma=0.2$	4.47	4.51
$\alpha=0.8 \gamma=0.5$	6.85	6.32
$\alpha=0.4 \gamma=0.9$	5.02	5.31

Nous constatons à travers ce tableau que les paramètres qui donnent une MAPE minimale sont : $\alpha=0.3$, $\gamma=0.4$. Pour ces paramètres, les prévisions sur une période de 168 heures (du 11 novembre 2019 au 17 novembre 2019) (une semaine) sont représentées dans la figure 3.20 ci-dessous.

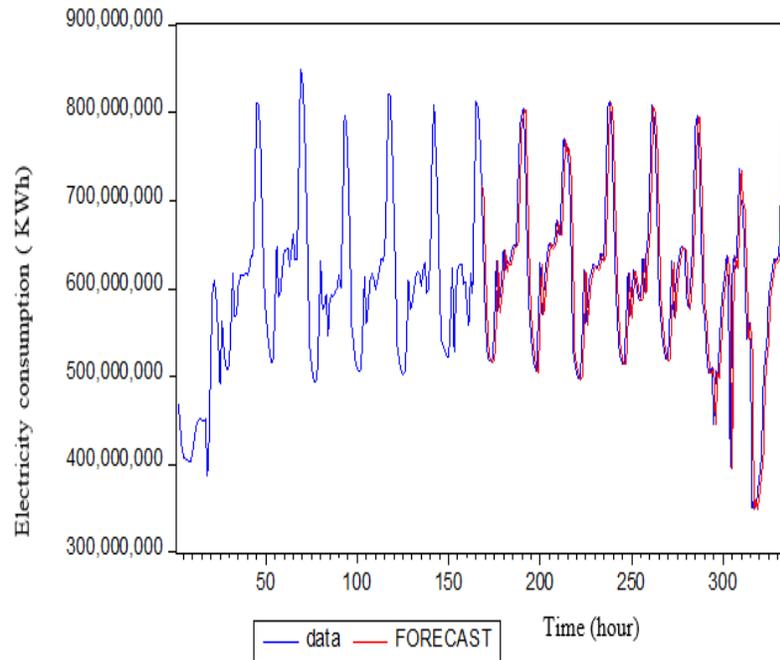


FIGURE 3.20 – Profil de prévision de la consommation d’électricité avec le modèle HES pour 168 h

Nous pouvons également remarquer à travers la figure 3.20 que les valeurs des charges électriques horaires prédites par le modèle suivent la variation réelle, quel que soit le jour de la semaine.

3.1.2.4.2 Comparaison entre les modèles de prédiction MLR, ANN et HES

Après avoir appliqué les méthodes de régression linéaire multiple, des Réseaux de Neurones Artificiels et le lissage exponentiel de Holt sur la charge électrique horaire de la ville de Yaoundé, les résultats obtenus sont jugés acceptables au vu des erreurs obtenues (tableau 3.21). Pour la comparaison nous avons retenu de chaque méthode la configuration qui donne une nMAPE plus faible. Ces modèles retenus sont consignés dans le tableau ci-dessous.

Tableau 3.21 – Paramètres des modèles retenus, erreur associée

Modèle	Algorithme d'apprentissage	Paramètres /architecture	nRMSE (%)	nMAPE (%)
MLR	/	/	5.30	3.98
ANN	Levenberg Marquardt	[6 – 12 – 1]	3.27	2.67
HES	/	$\alpha=0.3$ $\gamma=0.4$	6.39	3.91

En examinant les résultats des erreurs moyennes absolues associées à chaque modèle, on voit clairement que la méthode ANN utilisant la topologie (6-12-1) et l'algorithme de Levenberg Marquardt présente des résultats meilleurs que ceux obtenus par les modèles MLR et HES.

3.1.2.5 Résultats du modèle hybride d'optimisation

3.1.2.5.1 Influence du pas d'apprentissage (θ) dans l'algorithme du gradient descendant

Dans cette section, nous imposons la précision de l'erreur d'apprentissage souhaitée et l'algorithme d'apprentissage établi nous permet d'obtenir le Learning rate pas d'apprentissage (θ) optimal ainsi que les meilleurs coefficients C_1 , C_2 et C_3 du modèle hybride construit.

Tableau 3.22 – Influence du pas d'apprentissage et la précision sur les coefficients du modèle hybride

Précisions	Pas d'appren- tissage (θ)	C_1	C_2	C_3	MAPE (%)	RMSE
10^{-1}	267.18	0.3373	0.3311	0.3314	1.765	0.0688
10^{-2}	267.18	0.3373	0.3312	0.3314	1.669	0.0686
10^{-3}	267.18	0.3374	0.3312	0.3314	1.636	0.0671
10^{-4}	267.18	0.3375	0.3313	0.3313	1.596	0.0676

Nous remarquons à travers le tableau 3.22 que plus la précision souhaitée est faible plus l'erreur de prévision est réduite mais θ reste constant. Il est donc important de déterminer les valeurs optimales des coefficients qui réduisent au plus l'erreur de prévision. Nous remarquons également que les coefficients C_1 , C_2 et C_3 sont tous proches de 0.33, mais nous ne pouvons pas faire cette approximation car celle-ci induira des erreurs de prévisions qui peuvent, en effet, occasionner des coûts opérationnels importants. D'après Hobbs et al.[130], une réduction de l'erreur moyenne de prévision de 1% peut épargner des milliers, voire même des millions de dollars dans une unité de production d'électricité. Soares et al.[131] citent l'estimation effectuée en 1984 dans une installation électrique au Royaume-Uni, où un accroissement de 1% de l'erreur de prévision avait causé un accroissement annuel des coûts opérationnels de 10 millions de livres sterling.

En tenant compte des critères évoqués ci-dessus, les coefficients optimaux retenus pour ce modèle sont ceux ayant la précision de 10^{-4} et $\theta=267.18$ car au-delà de cette précision, le pas et les coefficients varient très peu. Le tableau 3.23 nous présente les indicateurs de performance retenus pour chaque modèle étudié.

Tableau 3.23 – Influence du Pas d'apprentissage et la précision sur les coefficients du modèle hybride

MODELS	MAPE (%)	RMSE	p-value
MLR	3.91	5.30	0.02
ANN	2.67	3.27	0.01
HES	3.93	6.39	0.04
MLR-ANN-HES	2.596	3.374	0.01

Dans le tableau 3.23, les résultats MAPE(%), RMSE et la p-value sont indiqués pour tous les modèles mis en œuvre dans cette étude. Nous observons que dans la phase de validation, la MAPE obtenue par l'approche hybride MLR-ANN-HES est de 2.596%, ce qui est inférieur à celle des modèles MLR, ANN et HES pris séparément. On peut donc conclure que, l'approche hybride MLR-ANN-HES surpasse les autres modèles pris séparément dans la prévision de la consommation nette d'électricité et a une valeur MAPE faible par rapport aux MAPE de 3.91%, 2.67% et 3.93% respectivement pour les modèles MLR, ANN et HES qui sont relativement bons. On peut dire que ces niveaux d'erreur sont considérés comme de haute précision, selon Yadav et Chandel[68]. De plus, la p-value du modèle hybride (0.01) est inférieure au seuil de 5% ce qui nous permet de conclure que ce modèle est globalement excellent.

3.1.2.5.2 Résultats du modèle hybride et comparaison

La figure 3.21 ci-dessous représente les prévisions horaires obtenues sur une période d'une semaine (168 heures) pour chacun des modèles étudiés.

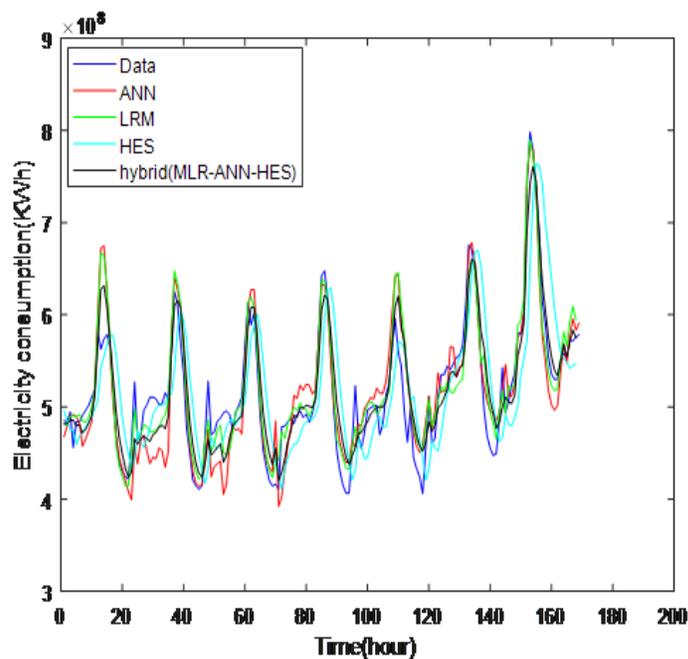


FIGURE 3.21 – Courbe comparative des prévisions de la consommation horaire d'énergie électrique dans la ville de Yaoundé sur une période d'une semaine (168 heures)

3.1.2.5.3 Comparaison des résultats avec ceux des modèles hybrides similaires

Indicateurs de performance de chaque modèle

Tableau 3.24 – Comparaison de la précision avec ceux des modèles hybrides similaires

MODELS	AUTHORS	YEARS	MAPE (%)	RMSE (kWh)
GM(1,1)- ARMA(2,1)	Xu Weijun et al.	2015	4.39	—
GM(1,1)- ARIMA(2,1,1)	Yuan C et al.	2016	2.30	—
ARIMA- LSSVM	Kazil k et al.	2020	10.02	—
VDM-EELM	Niu et al.	2020	2.960	471.781
VDM-SVM- PSO	Feny et al.	2020	—	3640,830
VDM-SR- SVRCBS	Zhang et al.	2020	0.9	85.5
SARIMA- MetaFA- LSSVR	Diogo M. F. Izidio et al	2021	15.66	0.164
SARIMA- PSO-LSSVR	Diogo M. F. Izidio et al	2021	16.19	0.182
EvoHyS	Diogo M. F. Izidio et al	2021	12.74	0.046
EMD- Fbprophet	Guorong Zhu	2021	0.49	0.05
EMD- Fbprophet- LSTM	Guorong Zhu	2021	0.28	0.03
MLR-ANN- HES	Nzoko T et al.	2022	2.596	3.374

Dans le tableau 3.24, nous présentons les indicateurs de performance des mo-

dèles hybrides(MLR-ANN-HES) et ceux des modèles hybrides similaires en termes d'erreur absolue moyenne en pourcentage (MAPE) et d'erreur quadratique moyenne (RMSE). Au regard des indicateurs de performances des modèles de prévision présentés dans le tableau ci-dessus, nous constatons que l'erreur obtenue par le modèle hybride proposé (MLR-ANN-HES) est très faible comparativement à ceux des modèles SARIMA-MetaFA-LSSVR, SARIMA-PSO-LSSVR, ARIMA-LSSVM, GM(1,1)-ARMA(2,1), VDM-EELM et EvoHyS. Ceci nous permet de conclure que le modèle hybride proposé (MLR-ANN-HES) peut être classé parmi les meilleurs modèles hybrides qui existent dans la littérature sur le sujet. Ces résultats intéressants sont dus à l'efficacité de l'algorithme d'optimisation utilisé pour la conception de ce nouveau modèle hybride d'une part et, d'autre part, au fait que les variables explicatives utilisées sont toutes caractérisées par une tendance de croissance exponentielle. Cette tendance améliore la qualité des prévisions du modèle[134]. Compte tenu du fait que les modèles statistiques traditionnels, tels que SARIMA, MLR et HES présentent des performances limitées en présence des modèles non linéaires et que les modèles non linéaires peuvent ne pas traiter aussi bien les modèles linéaires et non linéaires, les résultats de l'évaluation montrent que les systèmes hybrides en général sont plus performants que les modèles uniques.

Conclusion

En somme, ce chapitre présente les résultats obtenus après modélisation de la consommation d'énergie électrique au Cameroun à partir des outils classiques de l'économétrie des séries temporelles et les méthodes de l'intelligence artificielle. Il ressort des résultats obtenus que tous les modèles utilisés ont produit des résultats acceptables au vu des erreurs de prévisions associées obtenues et des comparaisons

faites avec des modèles similaires dans la littérature sur le sujet. Dans le souci de parfaire les résultats, des modèles dits hybrides ou multi-modèles ont aussi été conçus et appliqués avec pour objectif principal de combiner les modèles économétriques et les modèles issus de l'intelligence artificielle pour avoir de meilleurs résultats en comparaison avec les modèles simples. Les résultats obtenus nous permettent de conclure que le modèle hybride VECM-HES est satisfaisant pour les prévisions à long terme car la précision des prévisions de ce modèle est estimée à MAPE=1.596%. Par contre pour les prévisions à court terme on peut conclure que le modèle hybride MLR-ANN-HES avec une MAPE de 2.596% est plus performant et satisfaisant que les autres modèles utilisés séparément. La comparaison de L'erreur moyenne absolue (MAPE) obtenue des modèles développés est très faible comparativement à celle des modèles similaires existant dans la littérature. Ce qui nous permet de conclure que ces deux modèles hybrides peuvent surpasser certains modèles d'intelligence artificielle récents.

CONCLUSION GÉNÉRALE ET PERSPECTIVES

La prévision à moyen long terme de la charge électrique a un rôle vital dans la production, la transmission et la planification du réseau. Pour cette raison, de nombreuses recherches ont été menées dans le but de trouver des solutions. Les premières méthodes utilisées sont des méthodes statistiques telles que les modèles de régression, qui ne pouvaient pas fournir une représentation fidèle du comportement de la charge électrique dans un marché de l'électricité volatil.

Au cours des dernières années, les méthodes issues de l'intelligence artificielle ont été beaucoup appliquées pour la prévision de la charge : les réseaux neurones artificiels, les systèmes neuro-flous, SVM, etc. qui, contrairement aux méthodes statistiques, fournissent des solutions prometteuses malgré les divers facteurs qui doivent être pris en compte lors de la prévision de charge, ce qui rend cette dernière complexe. La meilleure méthode de prévision serait donc celle qui pourrait trouver des relations non linéaires entre la charge et divers facteurs économiques et autres, et est adaptable aux changements.

À notre connaissance, dans le domaine des prévisions de la demande en énergie au Cameroun, très peu de travaux ont été publiés à ce sujet. Ces travaux, pour la plupart, parlaient beaucoup de la modélisation de la production d'énergie électrique à partir des scénarios et très peu d'auteurs se sont focalisés sur la modélisation à partir des modèles hybrides d'intelligence artificielle et des modèles économétriques. Contrairement aux pays développés, qui disposent d'une multi-

tude des résultats de modélisations et prévisions des charges électriques à différent horizon où il est facile d'aller puiser les informations dont on a besoin pour les mettre en pratique.

Cette thèse a pour but d'examiner et de proposer des solutions appropriées liées aux problèmes de planification et de gestion efficace d'énergie électrique disponible, en développant un modèle numérique optimal basé sur les méthodes hybrides d'intelligences artificielles et des modèles économétriques. Ainsi, pour y parvenir, nous avons au premier chapitre, présenter un état de l'art sur les modèles de prévisions de la charge électrique ainsi que la situation d'énergie électrique du Cameroun. Dans la première partie de cette présentation, il ressort qu'il existe deux grandes familles des méthodes de prévision : les méthodes issues de la statistique et celle de l'intelligence artificielle. De ces méthodes, nous avons présenté les modèles de prévisions les plus importantes et surtout celles sollicitées dans les études que nous avons proposées dans cette thèse. Dans la deuxième partie de ce chapitre, nous avons présenté l'historique et la situation actuelle du secteur électrique au Cameroun. De cette présentation, il ressort que malgré le fait que le Cameroun possède le deuxième plus grand potentiel hydroélectrique d'Afrique subsaharienne (19,7 Gw) après la république démocratique du Congo, seulement 5% environ de cette ressource naturelle est exploitée en raison de plusieurs obstacles naturels et du faible taux de développement des infrastructures de production. Concernant l'analyse entre l'offre et la demande d'énergie électrique au Cameroun, on a conclu qu'elle est caractérisée par un déséquilibre remarquable qui se traduit par un nombre croissant des délestages observés au quotidien. On a conclu le chapitre par un état de l'art des travaux qui traitent de la prévision de la charge électrique dans le moyen et le long terme.

Dans le chapitre 2, il était question de présenter les étapes de modélisation des

modèles retenus pour la modélisation de la charge électrique à court et long terme. Concernant les prévisions à long terme, les modèles vectoriels à correction d'erreur (VECM), le lissage exponentiel de Holt (HES) et le modèle hybride d'optimisation VECM-HES sont utilisés. Pour les prévisions à court terme, les modèles de régression linéaire multiple (MLR) le lissage exponentiel de Holt (HES), les réseaux de neurone artificiel (ANN) et le modèle hybride MLR-ANN-HES sont utilisés. Enfin, les indicateurs de performances des modèles ainsi que les tests statistiques associés permettant d'approuver la validité des modèles ont été présentés. Dans le chapitre 3, il était question d'appliquer les données historiques de consommation d'énergie électrique à court et à long terme aux modèles de prévisions développés et de présenter les résultats obtenus ainsi que des recommandations. Pour les prévisions à long terme, les indicateurs de performance présentés nous ont permis de conclure que les séries étudiées ne sont pas stationnaires à niveau mais sont intégrées de même ordre $I(1)$ comme indiqué dans le tableau 3.2. De plus, le tableau 3.4 nous a permis de conclure qu'il existe au plus une relation de co-intégration entre la consommation annuelle d'électricité et les variables explicatives donc la méthode d'estimation VECM est appropriée pour cette étude. La figure 3.5 montre également que le modèle VECM estimé est stable. Cette stabilité nous a conduit aux résultats de prévisions relativement bons d'après les critères de performances obtenu pour ce modèle ($MAPE = 12.65\%$ et $RMSE = 3,9544\%$). Pour ce qui est du modèle HES, la jarque-Bera obtenue ($JB = 5.188$) est inférieure à la valeur de référence (5.92). Donc, nous pouvons conclure que les résidus suivent une loi normale. De plus, RMSE est estimé à 2.29%. Donc, d'après les critères de performance, on peut également conclure que le modèle est très bon pour les prévisions de la charge électrique à long terme. Enfin, l'application de l'approche hybride VECM-HES nous a conduit aux résultats plus intéressants que

les précédents au vu des indicateurs de performances obtenus ($MAPE = 1.59\%$ et $RMSE = 0,067\%$). Ces niveaux d'erreur dans la formation et le processus de validation sont considérées comme de haute précision, de plus la p-value du modèle hybride (0.01) est inférieure au seuil de 5%. Ce qui permet de conclure que les résultats obtenus sont excellents et peuvent être à la hauteur de certains modèles d'intelligence artificielle récents. L'interprétation des résultats de la dynamique de long terme des variables explicatives ($X_{pI}(t)$, $X_{po(t)}(t)$ et $X_{Dm}(t)$) nous a permis de conclure qu'une augmentation de la consommation annuelle d'électricité au-dessus de la valeur prévue, entrainera automatiquement une hausse du PIB et des dépenses de consommation finale des ménages. Mais, malheureusement, un déficit d'alimentation en énergie électrique pour les populations qui se manifestera généralement par les délestages réguliers. Pour éviter ce type de déséquilibre entre l'offre et la demande, nous conseillons aux populations de s'intéresser davantage aux énergies renouvelables telles que l'énergie solaire, éolienne et thermique. Car les tentatives de l'État camerounais pour répondre à la demande d'électricité au regard de ces investissements sont multiples mais insuffisantes. Les résultats présentés dans le tableau 3.11 et la figure 3.7 nous permettent de conclure qu'au même titre que l'évolution de la population, les prévisions de la consommation d'énergie électrique ont une tendance croissante. Elles vont de 7169.031 GWh en 2020 à 8134.772 GWh en 2024 soit une augmentation de 965.741 GWh en cinq ans. Cette augmentation considérable est due à la forte croissance économique et démographique du Cameroun depuis plus de dix ans qui s'accompagne d'une demande également croissante de la consommation électrique. Ces résultats intéressants permettront aux pouvoirs publics ainsi qu'aux opérateurs du secteur électrique d'avoir une vision plus claire et importante dans la planification, la construction et la maintenance du réseau électrique.

Pour les prévisions à court terme, l'utilisation des données horaires de la consommation total d'énergie électrique dans la ville de Yaoundé nous a permis d'avoir plusieurs résultats.

Pour le modèle MLR, il ressort de notre étude que ce modèle est significatif avec un coefficient de détermination $R^2(0,905)$ élevé. Ce coefficient montre que la qualité d'ajustement du modèle est assez bonne. De plus, les tests de validation des hypothèses effectuées ainsi que la moyenne des erreurs en pourcentage (MAPE=3.91) confirment non seulement la bonne spécification du modèle mais aussi la stabilité des coefficients.

Pour les NNA, l'architecture (6-12-1) utilisant l'algorithme Levenberg Marquardt présente la plus basse erreur vis-à-vis des autres architectures. Pour ce réseau, la variation de l'erreur d'apprentissage et de validation est raisonnable pour des considérations suivantes : la moyenne des erreurs absolues en pourcentage (MAPE=2.67) est très faible, les erreurs de l'ensemble de test et de validation ont des caractéristiques similaires, aucun sur-ajustement significatif n'est survenu à l'itération 43 (où les meilleures performances de validation se produisent) et l'analyse de la réponse du réseau est satisfaisante.

Pour le modèle HES, les paramètres $\alpha = 0.3$, $\gamma = 0.4$ ont été retenus comme étant celles qui minimisent le plus l'erreur d'apprentissage et de validation (MAPE=3.93).

Pour le modèle hybride MLR-ANN-HES, nous observons que dans la phase de validation, la $MAPE(2.596\%)$ obtenue est inférieure à celle des modèles MLR, ANN et HES pris séparément, ou ces erreurs de prévisions sont respectivement 3.91%, 2.67% et 3.93%. On peut dire que ces niveaux d'erreur sont considérés comme étant de haute précision selon Yadav et Chandel 2014. De plus, la p-value du modèle hybride (0.01) est inférieure au seuil de 5%, ce qui nous permet de conclure que ce modèle est globalement excellent. L'étude comparative

effectuée à partir du tableau 3.24 nous permet d'affirmer que l'erreur obtenue par le modèle hybride proposé (MLR-ANN-HES) est très faible comparativement à ceux des modèles SARIMA-MetaFA-LSSVR, SARIMA-PSO-LSSVR, ARIMA-LSSVM, GM(1,1)-ARMA(2,1), VDM-EELM et EvoHyS présentés dans la littérature. Ceci nous permet de conclure que le modèle hybride proposé (MLR-ANN-HES) peut être classé parmi les meilleurs modèles hybrides qui existent dans la littérature sur le sujet. Ces résultats intéressants sont dus à l'efficacité de l'algorithme d'optimisation utilisé pour la conception de ce nouveau modèle hybride qui a amélioré la qualité des prévisions du modèle. Les résultats de cette étude permettront aux pouvoirs publics ainsi qu'aux opérateurs du secteur énergétique d'une part de garantir à la fois l'équilibre offre/demande à court terme et une exploitation rationnelle de celle-ci, d'autre part de disposer d'une vision prospective sur la qualité et la quantité d'énergie à distribuer, la budgétisation des investissements nécessaires à la construction des infrastructures additionnels ainsi que la planification des interventions sur le terrain.

♠ Perspectives et travaux futurs

Nous proposons comme première perspective dans cette thèse de concevoir une boîte noire contenant des modèles hybrides de prévisions statistiques et d'intelligence artificielle pour faciliter l'application et réduire le temps de recherche du modèle optimal pour une série statistique donnée.

La deuxième perspective que nous proposons serait la modélisation et l'optimisation du transport de l'électricité. En effet, le transport de l'énergie électrique entraîne des pertes par effet joule : les câbles s'échauffent et de l'énergie thermique est dissipée dans l'environnement. Ces pertes représentent un peu plus de 2% de l'énergie électrique transportée, elles sont d'autant plus grandes que les câbles sont longs et que l'intensité du courant est élevée.

Une perspective supplémentaire serait d'analyser la corrélation qui existe entre la consommation d'eau et la consommation d'électricité. Cette démarche est à nuancer parce qu'il n'y a pas nécessairement de lien direct entre les deux grandeurs. Il serait donc judicieux de détecter les périodes ou les phases pendant lesquelles les deux grandeurs sont liées. Ainsi les données relatives à la consommation de la première grandeur permettraient de renforcer la prédiction de la deuxième.

Bibliographie

- [1] Rapport annuel Eneo-Cameroun 2018 web : eneo.ethicspoint.com
- [2] FUSS. Cameroon and renewable energy. Country at a glance. Fed Univ Appl Sci 2013 :1-2. <https://www.laurea.fi/en/document/Documents/Cameroon,FactSheet.pdf>
- [3] Xu W T, Wang Y L, Li T, Tang Q, Zhang J F, Shen L and Zhu M 2017 Long term intelligent load forecasting method considering the expectation of power market transaction Proceedings of the 29th Chinese Control and Decision Conference, CCDC 2017 2310-2315
- [4] Sun W and Zhao W 2010 Mid-long term power load forecasting based on MG-CACO and SVM method Proceedings of the 2010 2nd International Conference on Future Computer and Communication, ICFCC 2010 1 118-121
- [5] Haida, T. and S. Muto (1994). Regression based peak load forecasting using a transformation technique. Power Systems, IEEE Transactions on 9(4) : 1788-1794.
- [6] Hobbs, B. F., Jitprapaikulsarn, S., Konda, S., Chankong, V., Loparo, K. A., and Maratukulam, D. J. (1999). Analysis of the value for unit commitment of improved load forecasts. Power Systems, IEEE Transactions on, 14(4), 1342-1348.

- [7] Soares, L. J. and M. C. Medeiros (2008). Modeling and forecasting short-term electricity load : A comparison of methods with an application to Brazilian data. *International Journal of Forecasting* (4) : 630-644.
- [8] Weron, R. and A. Misiorek (2008). Forecasting spot electricity prices : A comparison of parametric and semiparametric time series models. *International Journal of Forecasting* (4) : 744-763.
- [9] ENEO 2018. Rapport annuel 2018, Vers une modernisation de la distribution électrique. Douala : Tome 2, 2018. p. 52.
- [10] Badar Ul Islam. Comparison of conventional and modern load forecasting techniques based on artificial intelligence and expert systems. *IJCSI International Journal of Computer Science Issues*, 8(5) :504-513, 2011.
- [11] G. Nalcaci, A. Özmen, and G. W. Weber, "Long-term Load Forecasting : Models Based on MARS, ANN and LR methods," *Central European Journal of Operations Research (CEJOR)*, Springer-Verlag GmbH Germany, vol. 27, no. 2019, pp. 1033-1049, 2018.
- [12] H Lee Willis and JED Northcote-Green. Comparison tests of fourteen distribution load forecasting methods. *IEEE Transactions on Power Apparatus and Systems*, PAS-103(6) :1190-1197, June 1984.
- [13] MODESTE, Nematchoua Kameni, Mempoou Blaise, Rene Tchinda, et al. Resource potential and energy efficiency in the buildings of Cameroon : a review. *Renew Sustain Energy Rev* 2015 ;50 :835e46.
- [14] MINEPDED. Cameroon-climate investment fund. Minist Environ Prot Nat Sustain Dev n.d. :1-10. [https ://www-cif.climateinvestmentfunds.org/sites/default/files/meeting-documents/cameroon.pdf](https://www-cif.climateinvestmentfunds.org/sites/default/files/meeting-documents/cameroon.pdf) [Accessed 12 August 2016].

- [15] Asan Vernyuy Wirba, Mas' UD, Abubakar Abdullahi, MuhammadSukki Firdaus, et al. Renewable energy potentials in Cameroon : prospects and challenges. *Renew Energy* 2015 ;76 :560e5.
- [16] Patricia Pareira Da Silva. Determinants of renewable energy growth in sub-saharan Africa : Evidence from panel ARDL. *Energy* 2018 ;156. <https://doi.org/10.1016/j.energy.2018.05.068>.
- [17] USAID. Cameroon power Africa fact sheet. 2016.
- [18] Thomas Tamo Tatietse, Alexis Kemajou, Salomon et, Benjamin Diboma. Electricity self-generation costs for industrial companies in Cameroon. *Energies* 2010 ;3(7) :1353e68.
- [19] Rapport d'activité.
- [20] Mahmoud M, HAMMAD,BORUT JEREB " Methods and Models for Electric Load Forecasting : A Comprehensive Review" *Logistics and Sustainable Transport* Vol. 11, No. 1, February 2020, 51-76 doi : 10.2478/jlst-2020-0004
- [21] D. delignières, Séries temporelles-Modèles ARIMA, Séminaire EA "Sport-PerformanceSanté", pp 1-19, Mars 2000.
- [22] J. Contreras, R. Espinola, F.J. Nogale et A.J. Conejo, ARIMA models to predict next day electricity prices, *IEEE Transactions on Power Systems* Vol 18, N° 3, Août 2003.
- [23] S. A.h. Soliman and A. M. Al-Kandari, *Electrical Load Forecasting : Modeling and Model Construction*, 1st ed. Butterworth-Heineman, 2010.
- [24] G. Welch and G. Bishop, "An Introduction to the Kalman Filter," University of North Carolina, Chapel Hill2004, vol. TR 95-041.
- [25] M. Gaur and A. Majumdar, "One-Day-Ahead Load Forecasting using nonlinear Kalman filtering algorithms," 2016.

- [26] E. Kayacan, B. Ulutas, and O. Kaynak, "Grey system theory-based models in time series prediction," *Expert Systems with Applications*, vol. 37, no. 2, pp. 1784-1789, 2010.
- [27] Y. Feng, "Study on Medium and Long Term Power Load Forecasting Based on Combination Forecasting Model," *Chemical Engineering Transactions*, vol. 51, no. 2015, pp. 859-864, 2015.
- [28] J. Zhang, "Research on Power Load Forecasting Based on the Improved Elman Neural Network," *The Italian Association of Chemical Engineering (AI-DIC)*, vol. 51, no. 2016, pp. 589-594, 2016.
- [29] X. Zhanga, J. Wanga, and K. Zhang, "Short-Term Electric Load Forecasting Based on Singular Spectrum Analysis and Support Vector Machine Optimized by Cuckoo Search Algorithm," *Electric Power Systems Research*, vol. 146, no. 2017, pp. 270-285, 2017.
- [30] R. J. Hyndman, *Forecasting with exponential smoothing*. Berlin ; London : Springer, 2008.
- [31] R. Weron, *Modeling and Forecasting Electricity Loads and Prices : A Statistical Approach*. England : John Wiley, Sons Ltd, 2006.
- [32] E. Ostertagová and O. Ostertag, "The Simple Exponential Smoothing Model," presented at the *Modelling of Mechanical and Mechatronic Systems 2011 : The 4th International conference*, Faculty of Mechanical engineering, Technical university of Kosice, 2011.
- [33] X. Wang, K. Smith-Miles, and R. Hyndman, "Rule Induction for Forecasting Method Selection : Meta-Learning the Characteristics of Univariate Time Series," *Neurocomputing*, vol. 72, no. 10-12, pp. 2581-2594, 2009.

- [34] P. Ji, D. Xiong, P. Wang, and J. Chen, "A Study on Exponential Smoothing Model for Load Forecasting," presented at the Asia-Pacific Power and Energy Engineering Conference (APPEEC), 2012.27-29 March 2012, Shanghai, China; proceedings, Piscataway, NJ, 2012. Available : <http://ieeexplore.ieee.org/document/6307555/>
- [35] A. Chusyairi, R. N. S. Pelsri, and Bagio, "The Use of Exponential Smoothing Method to Predict Missing Service E-Report," presented at the Information Systems and Electrical Engineering (ICITISEE) : 2nd International Conferences on Information Technology, 2017.
- [36] D. Dragan, A. Keshavarzsaleh, T. Kramberger, B. Jereb, and M. Rosi, "Forecasting US Tourists' inflow to Slovenia by modified Holt-Winters Damped model : A case in the Tourism industry logistics and supply chains," *Logistics and Sustainable Transport*, vol. 10, no. 1, pp. 11-30, 2019.
- [37] R. J. Hyndman, *Forecasting with exponential smoothing*. Berlin ; London : Springer, 2008.
- [38] Bourbonnais, R. (2015) *Econométrie, manuel et exercice corrigés*. Dunod, 9ème édition. <https://www.dunod.com>
- [39] C. Kuster, Y. Rezgui, and M. Mourshed, "Electrical Load Forecasting Models : A Critical Systematic Review," in *Sustainable Cities and Society*, ed, 2017.
- [40] R. Adhikari and R. K. Agrawal, *An Introductory Study on Time Series Modeling and Forecasting*. LAP Lambert Academic Publishing, 2013.
- [41] Bernard Widrow and Marcian E Hoff. *Adaptive switching circuits*. In *Neurocomputing : foundations of research*, pages 123-134. MIT Press, 1988.

- [42] Hans-Dieter Block. The perceptron : A model for brain functioning. i. Reviews of Modern Physics, 34(1) :123, 1962.
- [43] G.E. Hinton, D.E. Rumelhart, and R.J. Williams. Learning internal representations by back-propagating errors. Parallel Distributed Processing : Explorations in the Microstructure of Cognition, 1, 1985.
- [44] J. Zhang, "Research on Power Load Forecasting Based on the Improved Elman Neural Network," The Italian Association of Chemical Engineering (AI-DIC), vol. 51, no. 2016, pp. 589-594, 2016.
- [45] M. Y. Khamaira, A. S. Krzma, and A. M. Alnass, "Long Term Peak Load Forecasting for the Libyan Network," in Conference for Engineering Sciences and Technology (CEST), 2018, vol. 1, pp. 185-193 : AIJR Publisher.
- [46] S. A.h. Soliman and A. M. Al-Kandari, Electrical Load Forecasting : Modeling and Model Construction, 1st ed. Butterworth-Heineman, 2010.
- [47] R. Weron, Modeling and Forecasting Electricity Loads and Prices : A Statistical Approach. Wiley, 2007.
- [48] S. Kalogirou, Artificial Intelligence in Energy and Renewable Energy Systems. Nova Science Publishers, 2007.
- [49] S. A. Soliman and A. M. Al-Kandari, Electrical Load Forecasting : Modeling and Model Construction. Elsevier Science, 2010.
- [50] M. Mitchell, An introduction to genetic algorithms, 7. print ed. (A Bradford book). Cambridge, Mass., 2001, p. 209.
- [51] R. L. Haupt and S. E. Haupt, Practical genetic algorithms, 2nd ed. Hoboken, N.J. ; Chichester : Wiley-Interscience,2004.
- [52] J. Carr, "An Introduction to Genetic Algorithms," 2014.

- [53] C. C. Hsu, C. H. Wu, S. C. Chen, and K. L. Peng, "Dynamically Optimizing Parameters in Support Vector Regression : An Application of Electricity Load Forecasting," presented at the System Sciences, the 39th Annual Hawaii International Conference, 2006.
- [54] D. Beasley, D. R. Bull, and R. R. Martin, "An Overview of Genetic Algorithms : Part 1, Fundamentals," *University Computing*, vol. 15, no. 2, pp. 56-69, 1993.
- [55] Y. K. AlDouri, H. Al-Chalabi, and J. Lundberg, "Time Series Forecasting using Genetic Algorithm," in *The Twelfth International Conference on Advanced Engineering Computing and Applications in Sciences*, 2018.
- [56] R. R. B. de Aquino, O. N. Neto, M. M. S. Lira, A. A. Ferreira, and K. F. Santos, "Using Genetic Algorithm to Develop a NeuralNetwork-Based Load Forecasting," in *Artificial Neural Networks - ICANN 2007, Berlin, Heidelberg, 2007*, pp. 738-747 : Springer Berlin Heidelberg.
- [57] A. Gupta and P. K. Sarangi, "Electrical load forecasting using genetic algorithm based back-propagation method," *ARPN Journal of Engineering and Applied Sciences*, vol. 7, no. 8, pp. 1017-1020, 2012.
- [58] G. M. Khan, F. Zafari, and S. A. Mahmud, "Very Short Term Load Forecasting Using Cartesian Genetic Programming Evolved Recurrent Neural Networks (CGPRNN)," in *2013 12th International Conference on Machine Learning and Applications*, 2013, vol. 2, pp. 152-155.
- [59] F. Li and X. Zhao, "The application of genetic algorithm in power short-term load forecasting," in *2012 International Conference on Image, Vision and Computing (ICIVC 2012)*, 2012.

- [60] J. I. Silva-Ortega, B. Cervantes-Bolivar, I. A. Isaac-Millan, Y. Cardenas-Escorciab, and G. Valencia-Ochoa, "Demand energy forecasting using genetic algorithm to guarantee safety on electrical transportation system," *CHEMICAL ENGINEERING*, vol. 67, 2018.
- [61] R. Weron, *Modeling and Forecasting Electricity Loads and Prices : A Statistical Approach*. England : John Wiley, Sons Ltd, 2006.
- [62] Y. Lin, H. Luo, D. Wang, H. Guo, and K. Zhu, "An Ensemble Model Based on Machine Learning Methods and Data Preprocessing for Short-Term Electric Load Forecasting," *Energies*, vol. 10, no. 1186, 2017.
- [63] X. Zhanga, J. Wang, and K. Zhang, "Short-Term Electric Load Forecasting Based on Singular Spectrum Analysis and Support Vector Machine Optimized by Cuckoo Search Algorithm," *Electric Power Systems Research*, vol. 146, no. 2017, pp. 270-285, 2017.
- [64] R. Wang, J. Wang, and Y. Xu, "A Novel Combined Model Based on Hybrid Optimization Algorithm for Electrical Load Forecasting," *Applied Soft Computing Journal*, vol. 82, no. 2019, p. 105548, 2019.
- [65] H. Verdejo, A. Awerkin, C. Becker, and G. Olguin, "Statistic Linear Parametric Techniques for Residential Electric Energy Demand Forecasting : A Review and An Implementation to Chile," *Renewable and Sustainable Energy Reviews*, vol. 74, no. 2017, pp. 512-521, 2017.
- [66] Badar Ul Islam. Comparison of conventional and modern load forecasting techniques based on artificial intelligence and expert systems. *IJCSI International Journal of Computer Science Issues*, 8(5) :504-513, 2011.
- [67] Zolfaghari, M. ; Golabi, M.R. Modeling and predicting the electricity production in hydropower using conjunction of wavelet transform, long short-term

- memory and random forest models. *Renew. Energy* 2021, 170, 1367-1381.
- [68] Yadav, A. K., and S. Chandel. 2014. "Solar Radiation Prediction Using Artificial Neural Network Techniques : A Review." *Renewable and Sustainable Energy Reviews* 33 : 772-781. doi :10.1016/j.rser.2013.08.055.
- [69] Samsher Kadir Shiekh and Unde M. G. 2012. Short Term Load Forecasting Using ANN Technique. *International Journal of Engineering Sciences and Emerging Technologies* Vol 1.Issue 2, Pp : 99-107.
- [70] Park, D. C., El-Sharkawi, M. A., Marks, R. A. II, Atlas, L. E. and Danborg, M. J. 1991. Electric Load Forecasting Using an Artificial Neural Network. *IEEE Transactions of Power Engineering* Vol. 6 Pg. 442-449.
- [71] Kuo P 2018 A High Precision Artificial Neural Networks Model for Short-Term Energy Load Forecasting 1-13
- [72] Forderer K et al (2018) Towards the modeling of flexibility using artificial neural networks in energy management and smart grids.
- [73] Anvari Moghaddam A, Seifi AR (2011) Study of forecasting renewable energies in smart grids using linear predictive filters and neural networks. *IET Renew Power Gener* 5(6) :470-480
- [74] Liew A. C. and Chen S. P. 1991. A Novel Approach to Electric Load Forecasting Based on Neural Networks *IEEE International Joint Conference of Neural Networks*, Singapore.
- [75] Chen, C. S, Tzeng, T. M and Hwang, J. C. 1996. Application of Artificial Neural Networks to Substation Load Forecasting. *Electric Power Systems Research*, 38,153-160.
- [76] Amara Ismail Melhum, Lamy Abdullateef Omar and Sozan Addulla Mahmood 2013. Short Term Load Forecasting Using Artificial Neural Network

- International Journal of Soft Computing and Engineering (IJSCE), Vol. 3, Pg. 56-58.
- [77] Adepoju, G. A, Ogunjuyigbe, S. O. A and Alawode, K. O. 2007. Application of Neural network to Load Forecasting in Nigerian Electrical Power System. The Pacific Journal of Science and Technology. Vol. 8 Number 1. Pg 68-72.
- [78] Mohammed Buhari and Sanusi Sani Adamu 2012. Short-Term Load Forecasting Using ANN. Proceedings of the International Multi-conference of Engineers and Computer Scientist IMECS 2012, Hong Kong Vol. 1 Pg. 978-988.
- [79] Slobodan Ilic, Aleksandar Selakov, Srđan Vukmirovic, Aleksandar Erdeljan and Filip Kulic 2013. Short Term Load Forecasting in Large Scale Electrical Utility Using Artificial Neural Network, Journal of Scientific and Industrial Research Vol. 72, Pg 739-745.
- [80] Nima Amjady and Farshid Keynia 2011. A New Neural Network Approach to Short Term Load Forecasting of Electrical Power Systems. Energies ISSN 1996-1073.
- [81] Zohreh Souzanchi k, hadi Fanace T, Mahdi Yagbobi 2010. A Multi Adaptive Neuro Fuzzy Inference System For STLf by Using Previous Day Features. International Conference on Electronics and Information Engineering.
- [82] Din GMU, Marnerides AK (2017) Short term power load forecasting using deep neural networks. In : 2017 International conference on computing networks communications, pp 594-598
- [83] Ryu S, Noh J, Kim H (2017) Deep neural network based demand side short term load forecasting. Energies 10(1) :1-20 Smart Electric Power Alliance (2018) Utilities and electric vehicles : evolving to unlock grid value. March,

2018 Publisher's Note Springer Nature remains neutral with regard to jurisdictional claims in published maps and institutional affiliations.

- [84] Ford V, Siraj A, Eberle W (2015) Smart grid energy fraud detection using artificial neural network. In : IEEE symposium on computational intelligence applications in smart grid, CIASG, 2015-January. <https://doi.org/10.1109/ciasg.2014.7011557> In : e-Energy 2018-Proceedings of the 9th ACM international conference on future energy systems, pp 85-90
- [85] Chen K, Chen K, Wang Q, He Z, Hu J, He J (2018) Short-term load forecasting with deep residual networks. IEEE Trans Smart Grid. <https://doi.org/10.1109/tsg.2018.2844307>
- [86] Mohammed A, Hamodi S. J., Alkilani, F. M. H., Effect of adding different levels of Annatto seed powder *Bixa orellana* in laying chicken diets on oxidation indicators. Biochem. Cell. Arch., 18(2),(2018)1621.
- [87] P.Lakshmi Priya and V.S.Felix Enigo, "Fuzzy Logic based Short-Term Electricity Demand Forecast", International Journal of Engineering and Technology (IJET), DOI : 10.21817/ijet/2018/v10i2/181002064 Vol 10 No 2 Apr-May 2018
- [88] Danladi Ali, Michel Yohanna, M.I. Puwu, B.M. Garkida" Long-term load forecast modelling using a fuzzy logic approach" journal homepage : www.journals.elsevier.com/pacific-sciencereview-a-natural-science-and-engineering <http://dx.doi.org/10.1016/j.psra.2016.09.011>
- [89] Sun-Youn Shin , and Han-Gyun Woo "Energy Consumption Forecasting in Korea Using Machine Learning Algorithms" Energies 2022, 15, 4880. <https://doi.org/10.3390/en15134880>.

- [90] T. M. Ghazal, S. Noreen, R. Said, M. Khan, S. Siddiqui, S. Abbas, S. Aftab and M. Ahmad, "Energy demand forecasting using fused machine learning approaches," *Intelligent Automation and Soft Computing*, vol. 31, no. 1, pp. 539-553, 2022.
- [91] Shi Zhang and Dingwei Wang. Medium and long-term load forecasting based on pca and bp neural network method. In *Energy and Environment Technology*, 2009. ICEET'09. International Conference on, volume 3, pages 389-391. IEEE, 2009.
- [92] Qian Zhang and Tongna Liu. Research on mid-long term load forecasting base on wavelet neural network. In *Computer Engineering and Applications (ICCEA)*, 2010 Second International Conference on, volume 2, pages 217-220. IEEE, 2010.
- [93] Shao Z, Gao F, Zhang Q, Yang S, L, Multivariate statistical and similarity measure based semiparametric modeling of the probability distribution : a novel approach to the case study of mid-log term electricity consumption forecasting in China. *Applied Energy* (156),(2015)502.
- [94] Shuai Wang, Lean Yu, Ling Tang, and Shouyang Wang. A novel seasonal decomposition based least squares support vector regression ensemble learning approach for hydropower consumption forecasting in china. *Energy*, 36(11) :6542-6554, 2011.
- [95] Qia Ding. Long-term load forecast using decision tree method. In *Power Systems Conference and Exposition*, 2006. PSCE'06. 2006 IEEE PES, pages 1541-1543. IEEE, 2006.
- [96] Mohammad Moradi Dalvand, Seyed Bahram Zahir Azami, and Hadi Tarimoradi. Long-term load forecasting of iranian power grid using fuzzy and arti-

- facial neural networks. In Universities Power Engineering Conference, 2008. UPEC 2008. 43rd International, pages 1-4. IEEE, 2008.
- [97] Otavio AS Carpinteiro, Rafael C Leme, Antonio C Zambroni de Souza, Carlos AM Pinheiro, and Edmilson M Moreira. Long-term load forecasting via a hierarchical neural model with time integrators. *Electric Power Systems Research*, 77(3) :371- 378, 2007.
- [98] Tian, M.W, Alattas, K. and al., A New Short Term Electrical Load Forecasting by Type-2 Fuzzy Neural Networks. *Energies* 2022, 15, 3034. <https://doi.org/10.3390/en15093034>
- [99] Mohammed Jamii, and Mohamed Maaroufi 2021 "The Forecasting of Electrical Energy Consumption in Morocco with an Autoregressive Integrated Moving Average Approach" *Hindawi Mathematical Problems in Engineering* Article ID 6623570, 9 pages <https://doi.org/10.1155/2021/6623570>
- [100] Feng Gao, and Hong Chi, Forecasting residential electricity consumption using a hybrid machine learning model with online search data, *Applied Energy* 300 (2021) 117393 journal homepage : www.elsevier.com/locate/apenergy <https://doi.org/10.1016/j.apenergy.2021.117393>
- [101] Joel Sotamenou et Cyrille Nanko Nguemdjo, Consommation d'énergie, croissance économique et émissions de Co2 au Cameroun : une analyse de causalité. *African Integration and Development Review* Volume 11, March 2019.
- [102] Pesaran, M.H., Shin, Y., Smith, R.J.(2001). 'Bounds testing approaches to the analysis of level relationships', *Journal of Applied Econometrics* 16, 289-326

- [103] Kwiatkowski, D., Phillips, P. C. B., Schmidt, P. and Shin, Y., Testing the null hypothesis of stationarity against the alternative of unit root : How sure are we that economic time series have a unit root ? Journal of Econometrics, (54),(1992)159.
- [104] Bourbonnais, R. (2015) Econométrie, manuel et exercice corrigés. Dunod, 9ème édition. <https://www.dunod.com>
- [105] Yuan Chaoqing, Liu Sifeng, et FANG, Zhigeng. Comparison of China's primary energy consumption forecasting by using ARIMA (the autoregressive integrated moving average) model and GM (1,1) model. Energy 2016;100 : 384e90.
- [106] Bourbonnais, R. (2009) Econométrie, manuel et exercice corrigés. Dunod, 7ème édition. <https://www.dunod.com>
- [107] Bernard Widrow and Marcian E Hoff. Adaptive switching circuits. In Neurocomputing : foundations of research, pages 123-134. MIT Press, 1988.
- [108] Jain, D., and M. Lalwani. 2018. "Multi-Objective Optimization of Solar Irradiance and Variance at Pertinent Inclination Angles." Journal of The Institution of Engineers (India) : Series C 100 (5) : 811-831. doi :10.1007/s40032-018-0464-4.
- [109] GE Hinton, DE Rumelhart, and RJ Williams. Learning internal representations by back-propagating errors. Parallel Distributed Processing : Explorations in the Microstructure of Cognition, 1, 1985.
- [110] Jamil, B., A. T. Siddiqui, and D. C. Denkenberger. 2018. "Solar Radiation on South-Facing Inclined Surfaces Under Different Climatic Zones in India." Environmental Progress and Sustainable Energy 38 (3) : 1-13. doi :10.1002/ep.13050.

- [111] Yadav, A. K., and S. Chandel. 2014. "Solar Radiation Prediction Using Artificial Neural Network Techniques : A Review." *Renewable and Sustainable Energy Reviews* 33 : 772-781. doi :10.1016/j.rser.2013.08.055.
- [112] Anvari Moghaddam A, Seifi AR (2011) Study of forecasting renewable energies in smart grids using linear predictive filters and neural networks. *IET Renew Power Gener* 5(6) :470-480
- [113] M. Despotovic, V. Nedic, D. Despotovic, S. Cvetanovic, Review and statistical analysis of different global solar radiation sunshine models, *Renew. Sustain. Energy Rev.* 52 (2015) 1869-1880, <https://doi.org/10.1016/j.rser.2015.08.035>
- [114] A.K. Yadav, S. Chandel, Solar radiation prediction using artificial neural network techniques : a review, *Renew. Sustain. Energy Rev.* 33 (2014) 772-781, <https://doi.org/10.1016/j.rser.2013.08.055>.
- [115] Despotovic, M., V. Nedic, D. Despotovic, and S. Cvetanovic. 2015. "Review and Statistical Analysis of Different Global Solar Radiation Sunshine Models." *Renewable and Sustainable Energy Reviews* 52 : 1869-1880. doi :10.1016/j.rser.2015.08.035
- [116] IMF.(2021). Report for Selected Countries and Subjects : October 2021., disponible à l'adresse suivante : Rapport du FMI octobre 2021
- [117] BUCREP, 2010. Population du Cameroun en 2010, Troisième Recensement Général de la population et de l'habitat (RGPH), pp 10.
- [118] IMF. (2021). Cameroon, disponible à l'adresse suivante : <https://www.imf.org/en/Countries/CMR/countrydata>
- [119] IMF. (2021). Report for Selected Countries and Subjects : October 2021, disponible à l'adresse suivante : Rapport du FMI octobre 2021

- [120] Banque Mondiale. Cameroon (2021), disponible à l'adresse suivante : <https://www.banquemondiale.org/fr/country/cameroon/overview> 1
- [121] IMF. (2022). IMF staff country reports. P.9-15., disponible à l'adresse suivante/<https://www.imf.org/en/Publications/CR/Issues/2022/03/11/Cameroon-2021-Article-IV-Consultation-and-First-Reviews-Under-the-Extended-Credit-Facility-514974>
- [122] IMF. (2022). Cameroon, disponible à l'adresse suivante : <https://www.imf.org/en/Countries/CMR> countrydata
- [123] IMF. (2021). Cameroon, disponible à l'adresse suivante : <https://www.imf.org/en/Countries/CMR>
- [124] Lloyds Bank. (2022). Cameroon : Economic and Political Overview, disponible à l'adresse suivante : <https://www.lloydsbanktrade.com/en/market-potential/cameroon/economical>.
- [125] MB. The Socio-Political Crisis in the Northwest and Southwest Regions of Cameroon Assessing the Economic and Social Impacts, disponible à l'adresse suivante : [https://openknowledge.worldbank.org/bitstream/handle/10986/35933/The-Socio-PoliticalCrisis-in-the-Northwest-and-Southwest-Regions-of-Cameroon-Assessing-the-Economic-and-SocialImpacts.pdf?sequence=1,mscl-kid=d9af3a2ebbce11ec837c3d2079047d4a](https://openknowledge.worldbank.org/bitstream/handle/10986/35933/The-Socio-PoliticalCrisis-in-the-Northwest-and-Southwest-Regions-of-Cameroon-Assessing-the-Economic-and-SocialImpacts.pdf?sequence=1&mscl-kid=d9af3a2ebbce11ec837c3d2079047d4a).
- [126] SIE-Cameroun, 2011. Situation Energétique au Cameroun : Rapport 2011, Ministère de l'énergie et de l'eau.
- [127] Eviews, 2004. Eviews10 Command and Programming Reference. Quantitative Micro Software, LLC, pp638.

- [128] Erasmus Muh, Sofiane Amara, and Fouzi Tabet 2020 "Sustainable energy policies in Cameroon : A holistic overview" *Renewable and Sustainable Energy Reviews*, November 2017 doi :10.1016/j.rser.2017.10.049.
- [129] Haida, T., and Muto S., "Regression based peak load forecasting using a transformation technique". *Power Systems, IEEE Transactions on* (1994),9(4), 1788-1794.
- [130] Hobbs, B. F., Jitprapaikulsarn, S., Konda, S., Chankong, V., Loparo, K. A., and Maratukulam, D. J. "Analysis of the value for unit commitment of improved load forecasts". *Power Systems, IEEE Transactions on* (1999),14(4), 1342-1348.
- [131] Soares, L. J., and Medeiros M. C., "Modeling and forecasting short-term electricity load : A comparison of methods with an application to Brazilian data". *International Journal of Forecasting* (2008), (4), 630-644.
- [132] Yadav, A. K., and S. Chandel. 2014. "Solar Radiation Prediction Using Artificial Neural Network Techniques : A Review." *Renewable and Sustainable Energy Reviews* 33 : 772-781. doi :10.1016/j.rser.2013.08.055.
- [133] FUSS. Cameroon and renewable energy. Country at a glance. Fed Univ Appl Sci 2013 :1-2. <https://www.laurea.fi/en/document/Documents/Cameroon?FactSheet.pdf> [Accessed 15 August 2016].
- [134] Serge G, Jean Gaston T and al. 2020. "Forecast of electricity consumption in the Cameroonian residential sector by Grey and vector autoregressive models" *Energy* 214 (2021) 118791. <https://doi.org/10.1016/j.energy.2020.118791>.
- [135] Tay Kim Gaik and al " Forecasting Electricity Consumption Using Fuzzy Time Series" *International Journal of Engineering and Technology(UAE)*

(2018) 342-346 DOI 10.14419/ijet.v7i4.30.22305

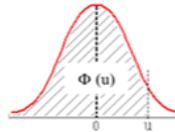
- [136] G A Salihan, and A G Abdullah and D L Hakim ” Long-term forecasting of electricity in East Kalimantan Province using the fuzzy logic approach” Materials Science and Engineering 1098 (2021) 042012 doi :10.1088/1757-899X/1098/4/042012.
- [137] P.Lakshmi Priya and V.S.Felix Enigo, "Fuzzy Logic based Short-Term Electricity Demand Forecast", International Journal of Engineering and Technology (IJET), DOI : 10.21817/ijet/2018/v10i2/181002064 Vol 10 No 2 Apr-May 2018
- [138] ADE-IKUESAN OLANIKE OLUFISAYO , ATILOLA MORUFDEEN OLATUNBOSUN and al,. ” FUZZY LOGIC APPROACH TO ENERGY PLANNING IN NIGERIA” Journal of Engineering Studies and Research - Volume 26 (2020) No. 4
- [139] Cheng-Hong Yang., Bo-Hong Chen and al., ” Deep Learning for Forecasting Electricity Demand in Taiwan” Mathematics 2022, 10, 2547. <https://doi.org/10.3390/math10142547> Web Pages The World Bank Database, GDP of Cameroon. Retrieved from <https://data.worldbank.org/indicator/NY.GDP.MKTP.KD.ZG?locations=CM> The world Bank Database, Population of Cameroon. Retrieved from <https://data.worldbank.org/indicator/SP.POP.TOTL?locations=CM>
- [140] R Adhiswara, A G Abdullah and Y Mulyadi ” Long-term electrical consumption forecasting using Artificial Neural Network (ANN)” Journal of Physics : Conference Series 1402 (2019) 033081 doi :10.1088/1742-6596/1402/3/033081
- [141] Mohammed Jamii and al,. ” Forecasting of Electrical Energy Consumption in Morocco with an Autoregressive Integrated Moving Ave-

- rage Approach ” Mathematical Problems in Engineering Volume 2021,
<https://doi.org/10.1155/2021/6623570>
- [142] Nzoko tayo , Talla Konchou, ” Prediction of electrical energy consumption in Cameroon through econometric models” Electric Power Systems Research 210, <https://doi.org/10.1016/j.epsr.2022.108102>
- [143] Terence K. Lukong, Derick N. Tanyu and al., ” Long Term Electricity Load Forecast Based on Machine Learning for Cameroon’s Power System” Energy and Environment Research; Vol. 12, No. 1; (2022) : <https://doi.org/10.5539/eer.v12n1p45>
- [144] Nooriya A. Mohammed1 , Ammar Al-Bazi ” An adaptive backpropagation algorithm for long-term electricity load forecasting” Neural Computing and Applications (2022) 34 :477-491 <https://doi.org/10.1007/s00521-021-06384-x>

ANNEXES

Table de Loi Normale

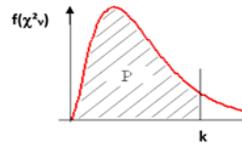
Fonction de répartition Φ de la loi normale
centrée réduite : $U \rightarrow N(0, 1)$.
Probabilité de trouver une valeur inférieure à u .
 $\Phi(u) = P(U \leq u)$; $\Phi(-u) = P(U \leq -u) = 1 - \Phi(u)$



u	0.00	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09
0.0	0.50000	0.50399	0.50798	0.51197	0.51595	0.51994	0.52392	0.52790	0.53188	0.53586
0.1	0.53983	0.54380	0.54776	0.55172	0.55567	0.55962	0.56356	0.56749	0.57142	0.57535
0.2	0.57926	0.58317	0.58706	0.59095	0.59483	0.59871	0.60257	0.60642	0.61026	0.61409
0.3	0.61791	0.62172	0.62552	0.62930	0.63307	0.63683	0.64058	0.64431	0.64803	0.65173
0.4	0.65542	0.65910	0.66276	0.66640	0.67003	0.67364	0.67724	0.68082	0.68439	0.68793
0.5	0.69146	0.69497	0.69847	0.70194	0.70540	0.70884	0.71226	0.71566	0.71904	0.72240
0.6	0.72575	0.72907	0.73237	0.73565	0.73891	0.74215	0.74537	0.74857	0.75175	0.75490
0.7	0.75804	0.76115	0.76424	0.76730	0.77035	0.77337	0.77637	0.77935	0.78230	0.78524
0.8	0.78814	0.79103	0.79389	0.79673	0.79955	0.80234	0.80511	0.80785	0.81057	0.81327
0.9	0.81594	0.81859	0.82121	0.82381	0.82639	0.82894	0.83147	0.83398	0.83646	0.83891
1.0	0.84134	0.84375	0.84614	0.84849	0.85083	0.85314	0.85543	0.85769	0.85993	0.86214
1.1	0.86433	0.86650	0.86864	0.87076	0.87286	0.87493	0.87698	0.87900	0.88100	0.88298
1.2	0.88493	0.88686	0.88877	0.89065	0.89251	0.89435	0.89617	0.89796	0.89973	0.90147
1.3	0.90320	0.90490	0.90658	0.90824	0.90988	0.91149	0.91309	0.91466	0.91621	0.91774
1.4	0.91924	0.92073	0.92220	0.92364	0.92507	0.92647	0.92785	0.92922	0.93056	0.93189
1.5	0.93319	0.93448	0.93574	0.93699	0.93822	0.93943	0.94062	0.94179	0.94295	0.94408
1.6	0.94520	0.94630	0.94738	0.94845	0.94950	0.95053	0.95154	0.95254	0.95352	0.95449
1.7	0.95543	0.95637	0.95728	0.95818	0.95907	0.95994	0.96080	0.96164	0.96246	0.96327
1.8	0.96407	0.96485	0.96562	0.96638	0.96712	0.96784	0.96856	0.96926	0.96995	0.97062
1.9	0.97128	0.97193	0.97257	0.97320	0.97381	0.97441	0.97500	0.97558	0.97615	0.97670
2.0	0.97725	0.97778	0.97831	0.97882	0.97932	0.97982	0.98030	0.98077	0.98124	0.98169
2.1	0.98214	0.98257	0.98300	0.98341	0.98382	0.98422	0.98461	0.98500	0.98537	0.98574
2.2	0.98610	0.98645	0.98679	0.98713	0.98745	0.98778	0.98809	0.98840	0.98870	0.98899
2.3	0.98928	0.98956	0.98983	0.99010	0.99036	0.99061	0.99086	0.99111	0.99134	0.99158
2.4	0.99180	0.99202	0.99224	0.99245	0.99266	0.99286	0.99305	0.99324	0.99343	0.99361
2.5	0.99379	0.99396	0.99413	0.99430	0.99446	0.99461	0.99477	0.99492	0.99506	0.99520
2.6	0.99534	0.99547	0.99560	0.99573	0.99585	0.99598	0.99609	0.99621	0.99632	0.99643
2.7	0.99653	0.99664	0.99674	0.99683	0.99693	0.99702	0.99711	0.99720	0.99728	0.99736
2.8	0.99744	0.99752	0.99760	0.99767	0.99774	0.99781	0.99788	0.99795	0.99801	0.99807
2.9	0.99813	0.99819	0.99825	0.99831	0.99836	0.99841	0.99846	0.99851	0.99856	0.99861
3.0	0.99865	0.99869	0.99874	0.99878	0.99882	0.99886	0.99889	0.99893	0.99896	0.99900

Exemple : $\Phi(1.26) = P(U \leq 1.26) = 0.89617 = 89.62\%$

Table de la loi du χ^2_v
 Fractiles F_p de la loi de khi-deux à v degrés de liberté
 $P = F(k) = P(\chi^2_v \leq k)$

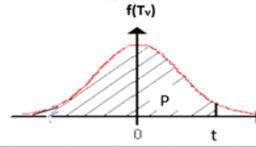


v	P	0.010	0.020	0.025	0.050	0.100	0.150	0.200	0.800	0.900	0.950	0.975	0.980	0.990
1		0.000	0.001	0.001	0.004	0.016	0.036	0.064	1.642	2.706	3.841	5.024	5.412	6.64
2		0.020	0.040	0.051	0.103	0.211	0.325	0.446	3.219	4.605	5.991	7.378	7.824	9.21
3		0.115	0.185	0.216	0.352	0.584	0.798	1.005	4.642	6.251	7.815	9.348	9.837	11.35
4		0.297	0.429	0.484	0.711	1.064	1.366	1.649	5.989	7.779	9.488	11.143	11.668	13.28
5		0.554	0.752	0.831	1.145	1.610	1.994	2.343	7.289	9.236	11.070	12.833	13.388	15.09
6		0.872	1.134	1.237	1.635	2.204	2.661	3.070	8.558	10.645	12.592	14.449	15.033	16.81
7		1.239	1.564	1.690	2.167	2.833	3.358	3.822	9.803	12.017	14.067	16.013	16.622	18.48
8		1.646	2.032	2.180	2.733	3.490	4.078	4.594	11.030	13.362	15.507	17.535	18.168	20.09
9		2.088	2.532	2.700	3.325	4.168	4.817	5.380	12.242	14.684	16.919	19.023	19.679	21.67
10		2.558	3.059	3.247	3.940	4.865	5.570	6.179	13.442	15.987	18.307	20.483	21.161	23.21
11		3.053	3.609	3.816	4.575	5.378	6.336	6.989	14.631	17.275	19.675	21.920	22.618	24.73
12		3.571	4.178	4.404	5.226	6.304	7.114	7.807	15.812	18.549	21.026	23.337	24.054	26.22
13		4.107	4.765	5.009	5.892	7.042	7.901	8.634	16.985	19.812	22.362	24.736	25.472	27.69
14		4.660	5.368	5.629	6.571	7.790	8.696	9.467	18.151	21.064	23.685	26.119	26.873	29.14
15		5.229	5.985	6.262	7.261	8.547	9.499	10.307	19.311	22.307	24.996	27.488	28.259	30.58
16		5.812	6.614	6.908	7.962	9.312	10.309	11.152	20.465	23.542	26.296	28.845	29.633	32.00
17		6.408	7.255	7.564	8.672	10.085	11.125	12.002	21.615	24.769	27.587	30.191	30.995	33.41
18		7.015	7.906	8.231	9.390	10.865	11.946	12.857	22.760	25.989	28.869	31.526	32.346	34.81
19		7.633	8.567	8.907	10.117	11.651	12.773	13.716	23.900	27.204	30.144	32.852	33.687	36.19
20		8.260	9.237	9.591	10.851	12.443	13.604	14.578	25.038	28.412	31.410	34.170	35.020	37.57
21		8.897	9.915	10.283	11.591	13.240	14.439	15.445	26.171	29.615	32.671	35.479	36.343	38.93
22		9.542	10.600	10.982	12.338	14.041	15.279	16.314	27.301	30.813	33.924	36.781	37.659	40.29
23		10.196	11.293	11.689	13.091	14.848	16.122	17.187	28.429	32.007	35.172	38.076	38.968	41.64
24		10.856	11.992	12.401	13.848	15.659	16.969	18.062	29.553	33.196	36.415	39.364	40.270	42.98
25		11.524	12.697	13.120	14.611	16.473	17.818	18.940	30.675	34.382	37.652	40.646	41.566	44.31
26		12.198	13.409	13.844	15.379	17.292	18.671	19.820	31.795	35.563	38.885	41.923	42.856	45.64
27		12.879	14.125	14.573	16.151	18.114	19.527	20.703	32.912	36.741	40.113	43.195	44.140	46.96
28		13.565	14.847	15.308	16.928	18.939	20.386	21.588	34.027	37.916	41.337	44.461	45.419	48.28
29		14.256	15.574	16.047	17.708	19.768	21.247	22.475	35.139	39.087	42.557	45.722	46.693	49.59
30		14.953	16.306	16.791	18.493	20.599	22.110	23.364	36.250	40.256	43.773	46.979	47.962	50.89
40		22.164	23.838	24.433	26.509	29.051	30.856	32.345	47.269	51.805	55.758	59.342	60.436	63.69
50		29.707	31.664	32.357	34.764	37.689	39.754	41.449	58.164	63.167	67.505	71.420	72.613	76.15
60		37.485	39.699	40.482	43.188	46.459	48.759	50.641	68.972	74.397	79.082	83.298	84.580	88.38
80		53.540	56.213	57.153	60.391	64.278	66.994	69.207	90.405	96.578	101.88	106.63	108.07	112.33

Exemple : $v = 10$ d.l. $P = P(\chi^2_{10} \leq F_p) = 0.95 \Rightarrow F_p = 18.307$

Approximation : Pour $v > 100$ d.l. $\chi^2(v) \cong N(v; \sqrt{2v})$ ou $\sqrt{2}\chi^2 - \sqrt{2v-1} \cong N(0,1)$

Table de la Loi de Student
 Fractiles de la loi de Student à v degrés de liberté. Probabilité P de trouver une valeur inférieure ou égale à t
 $P = F(t) = P(T_v \leq t)$

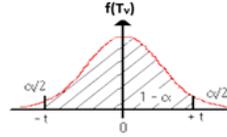


v \ P	0,9250	0,9300	0,9350	0,9400	0,9450	0,9500	0,9550	0,9600	0,9650	0,9700	0,9750	0,9900	0,9950
1	4,1653	4,4737	4,8288	5,2422	5,7297	6,3138	7,0264	7,9158	9,0579	10,5789	12,7062	31,8205	63,6567
2	2,2819	2,3834	2,4954	2,6202	2,7604	2,9200	3,1040	3,3198	3,5782	3,8964	4,3027	6,9646	9,9248
3	1,9243	1,9950	2,0719	2,1562	2,2494	2,3534	2,4708	2,6054	2,7626	2,9505	3,1824	4,5407	5,8409
4	1,7782	1,8375	1,9016	1,9712	2,0475	2,1318	2,2261	2,3329	2,4559	2,6008	2,7764	3,7469	4,6041
5	1,6994	1,7529	1,8104	1,8727	1,9405	2,0150	2,0978	2,1910	2,2974	2,4216	2,5706	3,3649	4,0321
6	1,6502	1,7002	1,7538	1,8117	1,8744	1,9432	2,0192	2,1043	2,2011	2,3133	2,4469	3,1427	3,7074
7	1,6166	1,6643	1,7153	1,7702	1,8297	1,8946	1,9662	2,0460	2,1365	2,2409	2,3646	2,9980	3,4995
8	1,5922	1,6383	1,6874	1,7402	1,7973	1,8595	1,9280	2,0042	2,0902	2,1892	2,3060	2,8965	3,3554
9	1,5737	1,6185	1,6663	1,7176	1,7729	1,8331	1,8992	1,9727	2,0554	2,1504	2,2622	2,8214	3,2498
10	1,5592	1,6031	1,6498	1,6998	1,7538	1,8125	1,8768	1,9481	2,0283	2,1202	2,2281	2,7638	3,1693
11	1,5476	1,5906	1,6365	1,6856	1,7385	1,7959	1,8588	1,9284	2,0067	2,0961	2,2010	2,7181	3,1058
12	1,5380	1,5804	1,6256	1,6739	1,7259	1,7823	1,8440	1,9123	1,9889	2,0764	2,1788	2,6810	3,0545
13	1,5299	1,5718	1,6164	1,6641	1,7154	1,7709	1,8317	1,8989	1,9742	2,0600	2,1604	2,6503	3,0123
14	1,5231	1,5646	1,6087	1,6558	1,7064	1,7613	1,8213	1,8875	1,9617	2,0462	2,1448	2,6245	2,9768
15	1,5172	1,5583	1,6020	1,6487	1,6988	1,7531	1,8123	1,8777	1,9509	2,0343	2,1314	2,6025	2,9467
16	1,5121	1,5529	1,5962	1,6425	1,6921	1,7459	1,8046	1,8693	1,9417	2,0240	2,1199	2,5835	2,9208
17	1,5077	1,5482	1,5911	1,6370	1,6863	1,7396	1,7978	1,8619	1,9335	2,0150	2,1098	2,5669	2,8982
18	1,5037	1,5439	1,5867	1,6322	1,6812	1,7341	1,7918	1,8553	1,9264	2,0071	2,1009	2,5524	2,8784
19	1,5002	1,5402	1,5827	1,6280	1,6766	1,7291	1,7864	1,8495	1,9200	2,0000	2,0930	2,5395	2,8609
20	1,4970	1,5369	1,5791	1,6242	1,6725	1,7247	1,7816	1,8443	1,9143	1,9937	2,0860	2,5280	2,8453
21	1,4942	1,5338	1,5759	1,6207	1,6688	1,7207	1,7773	1,8397	1,9092	1,9880	2,0796	2,5176	2,8314
22	1,4916	1,5311	1,5730	1,6176	1,6655	1,7171	1,7734	1,8354	1,9045	1,9829	2,0739	2,5083	2,8188
23	1,4893	1,5286	1,5703	1,6148	1,6624	1,7139	1,7699	1,8316	1,9003	1,9782	2,0687	2,4999	2,8073
24	1,4871	1,5263	1,5679	1,6122	1,6596	1,7109	1,7667	1,8281	1,8965	1,9740	2,0639	2,4922	2,7969
25	1,4852	1,5242	1,5657	1,6098	1,6571	1,7081	1,7637	1,8248	1,8929	1,9701	2,0595	2,4851	2,7874
26	1,4834	1,5223	1,5636	1,6076	1,6547	1,7056	1,7610	1,8219	1,8897	1,9665	2,0555	2,4786	2,7787
27	1,4817	1,5205	1,5617	1,6056	1,6526	1,7033	1,7585	1,8191	1,8867	1,9632	2,0518	2,4727	2,7707
28	1,4801	1,5189	1,5600	1,6037	1,6506	1,7011	1,7561	1,8166	1,8839	1,9601	2,0484	2,4671	2,7633
29	1,4787	1,5174	1,5583	1,6020	1,6487	1,6991	1,7540	1,8142	1,8813	1,9573	2,0452	2,4620	2,7564
30	1,4774	1,5159	1,5568	1,6004	1,6470	1,6973	1,7520	1,8120	1,8789	1,9546	2,0423	2,4573	2,7500
50	1,4620	1,4996	1,5394	1,5818	1,6271	1,6759	1,7289	1,7870	1,8516	1,9244	2,0086	2,4033	2,6778
60	1,4582	1,4956	1,5352	1,5772	1,6222	1,6706	1,7232	1,7808	1,8448	1,9170	2,0003	2,3901	2,6603
70	1,4555	1,4927	1,5321	1,5740	1,6187	1,6669	1,7192	1,7765	1,8401	1,9118	1,9944	2,3808	2,6479
100	1,4507	1,4876	1,5267	1,5682	1,6125	1,6602	1,7120	1,7687	1,8315	1,9024	1,9840	2,3642	2,6259
5000	1,4398	1,4760	1,5144	1,5550	1,5985	1,6452	1,6957	1,7510	1,8123	1,8812	1,9604	2,3271	2,5768

Exemples : $v = 10$ d.l.l. $P(T_{10} \leq t) = 0,975 \Rightarrow t = +2,2281$ et $P(T_{10} \leq -t) = 0,025 \Rightarrow t = -2,2281$
 Approximation par une loi normale : pour $n = v = 5000$ d.l.l. on a $P(T_{5000} \leq t) = 0,975 \Rightarrow t = +1,9604$

Table de la Loi de Student

Fractiles de la loi de Student à v degrés de liberté : valeur du fractile t ayant la probabilité α d'être dépassée en valeur absolue :
 $P(|T_v| > t) = 1 - P(|T_v| \leq t) = \alpha$
 $P(|T_v| \leq t) = P(-t \leq T_v \leq t) = 1 - \alpha$



v	α	0.90	0.80	0.70	0.60	0.50	0.40	0.30	0.20	0.10	0.05	0.02	0.01	0.005	0.001
1		0.1584	0.3249	0.5095	0.7265	1	1.3764	1.9626	3.0777	6.3137	12.706	31.821	63.656	127.32	636.58
2		0.1421	0.2887	0.4447	0.6172	0.8165	1.0607	1.3862	1.8856	2.92	4.3027	6.9645	9.925	14.089	31.6
3		0.1366	0.2767	0.4242	0.5844	0.7649	0.9785	1.2498	1.6377	2.3534	3.1824	4.5407	5.8408	7.4532	12.924
4		0.1338	0.2707	0.4142	0.5686	0.7407	0.941	1.1896	1.5332	2.1318	2.7765	3.7469	4.6041	5.5975	8.6101
5		0.1322	0.2672	0.4082	0.5594	0.7267	0.9195	1.1558	1.4759	2.015	2.5706	3.3649	4.0321	4.7733	6.8685
6		0.1311	0.2648	0.4043	0.5534	0.7176	0.9057	1.1342	1.4398	1.9432	2.4469	3.1427	3.7074	4.3168	5.9587
7		0.1303	0.2632	0.4015	0.5491	0.7111	0.896	1.1192	1.4149	1.8946	2.3646	2.9979	3.4995	4.0294	5.4081
8		0.1297	0.2619	0.3995	0.5459	0.7064	0.8889	1.1081	1.3968	1.8595	2.306	2.8965	3.3554	3.8325	5.0414
9		0.1293	0.261	0.3979	0.5435	0.7027	0.8834	1.0997	1.383	1.8331	2.2622	2.8214	3.2498	3.6896	4.7809
10		0.1289	0.2602	0.3966	0.5415	0.6998	0.8791	1.0931	1.3722	1.8125	2.2281	2.7638	3.1693	3.5814	4.5868
11		0.1286	0.2596	0.3956	0.5399	0.6974	0.8755	1.0877	1.3634	1.7959	2.201	2.7181	3.1058	3.4966	4.4369
12		0.1283	0.259	0.3947	0.5386	0.6955	0.8726	1.0832	1.3562	1.7823	2.1788	2.681	3.0545	3.4284	4.3178
13		0.1281	0.2586	0.394	0.5375	0.6938	0.8702	1.0795	1.3502	1.7709	2.1604	2.6503	3.0123	3.3725	4.2209
14		0.128	0.2582	0.3933	0.5366	0.6924	0.8681	1.0763	1.345	1.7613	2.1448	2.6245	2.9768	3.3257	4.1403
15		0.1278	0.2579	0.3928	0.5357	0.6912	0.8662	1.0735	1.3406	1.7531	2.1315	2.6025	2.9467	3.286	4.0728
16		0.1277	0.2576	0.3923	0.535	0.6901	0.8647	1.0711	1.3368	1.7459	2.1199	2.5835	2.9208	3.252	4.0149
17		0.1276	0.2573	0.3919	0.5344	0.6892	0.8633	1.069	1.3334	1.7396	2.1098	2.5669	2.8982	3.2224	3.9651
18		0.1274	0.2571	0.3915	0.5338	0.6884	0.862	1.0672	1.3304	1.7341	2.1009	2.5524	2.8784	3.1966	3.9217
19		0.1274	0.2569	0.3912	0.5333	0.6876	0.861	1.0655	1.3277	1.7291	2.093	2.5395	2.8609	3.1737	3.8833
20		0.1273	0.2567	0.3909	0.5329	0.687	0.86	1.064	1.3253	1.7247	2.086	2.528	2.8453	3.1534	3.8496
21		0.1272	0.2566	0.3906	0.5325	0.6864	0.8591	1.0627	1.3232	1.7207	2.0796	2.5176	2.8314	3.1352	3.8193
22		0.1271	0.2564	0.3904	0.5321	0.6858	0.8583	1.0614	1.3212	1.7171	2.0739	2.5083	2.8188	3.1188	3.7922
23		0.1271	0.2563	0.3902	0.5317	0.6853	0.8575	1.0603	1.3195	1.7139	2.0687	2.4999	2.8073	3.104	3.7676
24		0.127	0.2562	0.39	0.5314	0.6848	0.8569	1.0593	1.3178	1.7109	2.0639	2.4922	2.797	3.0905	3.7454
25		0.1269	0.2561	0.3898	0.5312	0.6844	0.8562	1.0584	1.3163	1.7081	2.0595	2.4851	2.7874	3.0782	3.7251
26		0.1269	0.256	0.3896	0.5309	0.684	0.8557	1.0575	1.315	1.7056	2.0555	2.4786	2.7787	3.0669	3.7067
27		0.1268	0.2559	0.3894	0.5306	0.6837	0.8551	1.0567	1.3137	1.7033	2.0518	2.4727	2.7707	3.0565	3.6895
28		0.1268	0.2558	0.3893	0.5304	0.6834	0.8546	1.056	1.3125	1.7011	2.0484	2.4671	2.7633	3.047	3.6739
29		0.1268	0.2557	0.3892	0.5302	0.683	0.8542	1.0553	1.3114	1.6991	2.0452	2.462	2.7564	3.038	3.6595
30		0.1267	0.2556	0.389	0.53	0.6828	0.8538	1.0547	1.3104	1.6973	2.0423	2.4573	2.75	3.0298	3.646
50		0.1263	0.2547	0.3875	0.5278	0.6794	0.8489	1.0473	1.2987	1.6759	2.0086	2.4033	2.6778	2.937	3.496
60		0.1262	0.2545	0.3872	0.5272	0.6786	0.8477	1.0455	1.2958	1.6706	2.0003	2.3901	2.6603	2.9146	3.4602
70		0.1261	0.2543	0.3869	0.5268	0.678	0.8468	1.0442	1.2938	1.6669	1.9944	2.3808	2.6479	2.8987	3.435
80		0.1261	0.2542	0.3867	0.5265	0.6776	0.8461	1.0432	1.2922	1.6641	1.9901	2.3739	2.6387	2.887	3.4164
infini (loi normale)		0.1257	0.2533	0.3853	0.5244	0.6744	0.8416	1.0364	1.2816	1.6449	1.96	2.3264	2.5759	2.8072	3.2908

Exemples : $v = 10$ d.d.l. $P(|T_{10}| \leq t) = P(-t \leq T_{10} \leq t) = 0.95 \Rightarrow t = \pm 2.2281$
 $P(T_{10} \leq t) = 0.95 \Rightarrow t = +1.8125$

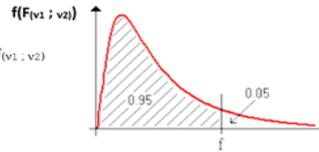
Table : Loi de Fisher-Snedecor

Valeur f de la variable de Fisher-Snedecor $F_{(v_1 ; v_2)}$ ayant la probabilité 0.05 d'être dépassée.

v_1 : degrés de liberté du numérateur

v_2 : degrés de liberté du dénominateur

$$F(f) = P (F_{(v_1 ; v_2)} \leq f) = 95\%$$

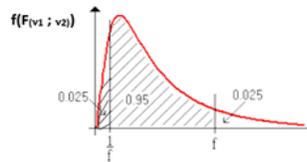


$v_2 \setminus v_1$	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	161.45	199.50	215.71	224.58	230.16	233.99	236.77	238.88	240.54	241.88	242.98	243.90	244.69	245.36	245.95	246.47
2	18.51	19.00	19.16	19.25	19.30	19.33	19.35	19.37	19.38	19.40	19.40	19.41	19.42	19.42	19.43	19.43
3	10.13	9.55	9.28	9.12	9.01	8.94	8.89	8.85	8.81	8.79	8.76	8.74	8.73	8.71	8.70	8.69
4	7.71	6.94	6.59	6.39	6.26	6.16	6.09	6.04	6.00	5.96	5.94	5.91	5.89	5.87	5.86	5.84
5	6.61	5.79	5.41	5.19	5.05	4.95	4.88	4.82	4.77	4.74	4.70	4.68	4.66	4.64	4.62	4.60
6	5.99	5.14	4.76	4.53	4.39	4.28	4.21	4.15	4.10	4.06	4.03	4.00	3.98	3.96	3.94	3.92
7	5.59	4.74	4.35	4.12	3.97	3.87	3.79	3.73	3.68	3.64	3.60	3.57	3.55	3.53	3.51	3.49
8	5.32	4.46	4.07	3.84	3.69	3.58	3.50	3.44	3.39	3.35	3.31	3.28	3.26	3.24	3.22	3.20
9	5.12	4.26	3.86	3.63	3.48	3.37	3.29	3.23	3.18	3.14	3.10	3.07	3.05	3.03	3.01	2.99
10	4.96	4.10	3.71	3.48	3.33	3.22	3.14	3.07	3.02	2.98	2.94	2.91	2.89	2.86	2.85	2.83
11	4.84	3.98	3.59	3.36	3.20	3.09	3.01	2.95	2.90	2.85	2.82	2.79	2.76	2.74	2.72	2.70
12	4.75	3.89	3.49	3.26	3.11	3.00	2.91	2.85	2.80	2.75	2.72	2.69	2.66	2.64	2.62	2.60
13	4.67	3.81	3.41	3.18	3.03	2.92	2.83	2.77	2.71	2.67	2.63	2.60	2.58	2.55	2.53	2.51
14	4.60	3.74	3.34	3.11	2.96	2.85	2.76	2.70	2.65	2.60	2.57	2.53	2.51	2.48	2.46	2.44
15	4.54	3.68	3.29	3.06	2.90	2.79	2.71	2.64	2.59	2.54	2.51	2.48	2.45	2.42	2.40	2.38
16	4.49	3.63	3.24	3.01	2.85	2.74	2.66	2.59	2.54	2.49	2.46	2.42	2.40	2.37	2.35	2.33
17	4.45	3.59	3.20	2.96	2.81	2.70	2.61	2.55	2.49	2.45	2.41	2.38	2.35	2.33	2.31	2.29
18	4.41	3.55	3.16	2.93	2.77	2.66	2.58	2.51	2.46	2.41	2.37	2.34	2.31	2.29	2.27	2.25
19	4.38	3.52	3.13	2.90	2.74	2.63	2.54	2.48	2.42	2.38	2.34	2.31	2.28	2.26	2.23	2.21
20	4.35	3.49	3.10	2.87	2.71	2.60	2.51	2.45	2.39	2.35	2.31	2.28	2.25	2.22	2.20	2.18
21	4.32	3.47	3.07	2.84	2.68	2.57	2.49	2.42	2.37	2.32	2.28	2.25	2.22	2.20	2.18	2.16
22	4.30	3.44	3.05	2.82	2.66	2.55	2.46	2.40	2.34	2.30	2.26	2.23	2.20	2.17	2.15	2.13
23	4.28	3.42	3.03	2.80	2.64	2.53	2.44	2.37	2.32	2.27	2.24	2.20	2.18	2.15	2.13	2.11
24	4.26	3.40	3.01	2.78	2.62	2.51	2.42	2.36	2.30	2.25	2.22	2.18	2.15	2.13	2.11	2.09
25	4.24	3.39	2.99	2.76	2.60	2.49	2.40	2.34	2.28	2.24	2.20	2.16	2.14	2.11	2.09	2.07
26	4.23	3.37	2.98	2.74	2.59	2.47	2.39	2.32	2.27	2.22	2.18	2.15	2.12	2.09	2.07	2.05
27	4.21	3.35	2.96	2.73	2.57	2.46	2.37	2.31	2.25	2.20	2.17	2.13	2.10	2.08	2.06	2.04
28	4.20	3.34	2.95	2.71	2.56	2.45	2.36	2.29	2.24	2.19	2.15	2.12	2.09	2.06	2.04	2.02
29	4.18	3.33	2.93	2.70	2.55	2.43	2.35	2.28	2.22	2.18	2.14	2.10	2.08	2.05	2.03	2.01
30	4.17	3.32	2.92	2.69	2.53	2.42	2.33	2.27	2.21	2.16	2.13	2.09	2.06	2.04	2.01	1.99
32	4.15	3.29	2.90	2.67	2.51	2.40	2.31	2.24	2.19	2.14	2.10	2.07	2.04	2.01	1.99	1.97
34	4.13	3.28	2.88	2.65	2.49	2.38	2.29	2.23	2.17	2.12	2.08	2.05	2.02	1.99	1.97	1.95
36	4.11	3.26	2.87	2.63	2.48	2.36	2.28	2.21	2.15	2.11	2.07	2.03	2.00	1.98	1.95	1.93
38	4.10	3.24	2.85	2.62	2.46	2.35	2.26	2.19	2.14	2.09	2.05	2.02	1.99	1.96	1.94	1.92
40	4.08	3.23	2.84	2.61	2.45	2.34	2.25	2.18	2.12	2.08	2.04	2.00	1.97	1.95	1.92	1.90

Exemple : $v_1 = 5$ d.d.l. et $v_2 = 10$ d.d.l. $P (F_{5, 10} \leq f) = 0.95 \Rightarrow f = 3.33$

Table : Loi de Fisher-Snedecor

Valeur f de la variable de Fisher-Snedecor $F(v_1; v_2)$ ayant la probabilité 0.025 d'être dépassée.
 v_1 : degrés de liberté du numérateur
 v_2 : degrés de liberté du dénominateur



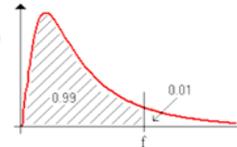
$v_2 \setminus v_1$	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	647.8	799.5	864.2	899.6	921.8	937.1	948.2	956.6	963.3	968.6	973.0	976.7	979.8	982.5	984.9	986.9
2	38.51	39.00	39.17	39.25	39.30	39.33	39.36	39.37	39.39	39.40	39.41	39.41	39.42	39.43	39.43	39.44
3	17.44	16.04	15.44	15.10	14.88	14.73	14.62	14.54	14.47	14.42	14.37	14.34	14.30	14.28	14.25	14.23
4	12.22	10.65	9.98	9.60	9.36	9.20	9.07	8.98	8.90	8.84	8.79	8.75	8.72	8.68	8.66	8.63
5	10.01	8.43	7.76	7.39	7.15	6.98	6.85	6.76	6.68	6.62	6.57	6.52	6.49	6.46	6.43	6.40
6	8.81	7.26	6.60	6.23	5.99	5.82	5.70	5.60	5.52	5.46	5.41	5.37	5.33	5.30	5.27	5.24
7	8.07	6.54	5.89	5.52	5.29	5.12	4.99	4.90	4.82	4.76	4.71	4.67	4.63	4.60	4.57	4.54
8	7.57	6.06	5.42	5.05	4.82	4.65	4.53	4.43	4.36	4.30	4.24	4.20	4.16	4.13	4.10	4.08
9	7.21	5.71	5.08	4.72	4.48	4.32	4.20	4.10	4.03	3.96	3.91	3.87	3.83	3.80	3.77	3.74
10	6.94	5.46	4.83	4.47	4.24	4.07	3.95	3.85	3.78	3.72	3.66	3.62	3.58	3.55	3.52	3.50
11	6.72	5.26	4.63	4.28	4.04	3.88	3.76	3.66	3.59	3.53	3.47	3.43	3.39	3.36	3.33	3.30
12	6.55	5.10	4.47	4.12	3.89	3.73	3.61	3.51	3.44	3.37	3.32	3.28	3.24	3.21	3.18	3.15
13	6.41	4.97	4.35	4.00	3.77	3.60	3.48	3.39	3.31	3.25	3.20	3.15	3.12	3.08	3.05	3.03
14	6.30	4.86	4.24	3.89	3.66	3.50	3.38	3.29	3.21	3.15	3.09	3.05	3.01	2.98	2.95	2.92
15	6.20	4.77	4.15	3.80	3.58	3.41	3.29	3.20	3.12	3.06	3.01	2.96	2.92	2.89	2.86	2.84
16	6.12	4.69	4.08	3.73	3.50	3.34	3.22	3.12	3.05	2.99	2.93	2.89	2.85	2.82	2.79	2.76
17	6.04	4.62	4.01	3.66	3.44	3.28	3.16	3.06	2.98	2.92	2.87	2.82	2.79	2.75	2.72	2.70
18	5.98	4.56	3.95	3.61	3.38	3.22	3.10	3.01	2.93	2.87	2.81	2.77	2.73	2.70	2.67	2.64
19	5.92	4.51	3.90	3.56	3.33	3.17	3.05	2.96	2.88	2.82	2.76	2.72	2.68	2.65	2.62	2.59
20	5.87	4.46	3.86	3.51	3.29	3.13	3.01	2.91	2.84	2.77	2.72	2.68	2.64	2.60	2.57	2.55
21	5.83	4.42	3.82	3.48	3.25	3.09	2.97	2.87	2.80	2.73	2.68	2.64	2.60	2.56	2.53	2.51
22	5.79	4.38	3.78	3.44	3.22	3.05	2.93	2.84	2.76	2.70	2.65	2.60	2.56	2.53	2.50	2.47
23	5.75	4.35	3.75	3.41	3.18	3.02	2.90	2.81	2.73	2.67	2.62	2.57	2.53	2.50	2.47	2.44
24	5.72	4.32	3.72	3.38	3.15	2.99	2.87	2.78	2.70	2.64	2.59	2.54	2.50	2.47	2.44	2.41
25	5.69	4.29	3.69	3.35	3.13	2.97	2.85	2.75	2.68	2.61	2.56	2.51	2.48	2.44	2.41	2.38
26	5.66	4.27	3.67	3.33	3.10	2.94	2.82	2.73	2.65	2.59	2.54	2.49	2.45	2.42	2.39	2.36
27	5.63	4.24	3.65	3.31	3.08	2.92	2.80	2.71	2.63	2.57	2.51	2.47	2.43	2.39	2.36	2.34
28	5.61	4.22	3.63	3.29	3.06	2.90	2.78	2.69	2.61	2.55	2.49	2.45	2.41	2.37	2.34	2.32

Exemples : $v_1 = 5$ d.d.l. et $v_2 = 10$ d.d.l. $P(F_{0.5\%}; 5, 10 \leq f) = 0.975 \Rightarrow f = 4.24$
 $P(F_{2.5\%}; 5, 10 \leq f) = 0.025$
 $P(F_{0.5\%}; 10, 5 \leq f) = 0.975 \Rightarrow f = 6.62 \Rightarrow f' = 1/f = 1/6.62 = 0.151$

Table : Loi de Fisher-Snedecor

Valeur f de la variable de Fisher-Snedecor $F (v_1 ; v_2)$ ayant la probabilité 0.01 d'être dépassée.

v_1 : degrés de liberté du numérateur
 v_2 : degrés de liberté du dénominateur



$v_2 \setminus v_1$	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	4052	4999	5403	5624	5763	5858	5928	5980	6022	6055	6083	6106	6125	6143	6156
2	98.50	99.00	99.16	99.25	99.30	99.33	99.36	99.38	99.39	99.40	99.41	99.42	99.42	99.43	99.43
3	34.12	30.82	29.46	28.71	28.24	27.91	27.67	27.49	27.34	27.23	27.13	27.05	26.98	26.92	26.87
4	21.20	18.00	16.69	15.98	15.52	15.21	14.98	14.80	14.66	14.55	14.45	14.37	14.31	14.25	14.20
5	16.26	13.27	12.06	11.39	10.97	10.67	10.46	10.29	10.16	10.05	9.96	9.89	9.82	9.77	9.72
6	13.75	10.92	9.78	9.15	8.75	8.47	8.26	8.10	7.98	7.87	7.79	7.72	7.66	7.60	7.56
7	12.25	9.55	8.45	7.85	7.46	7.19	6.99	6.84	6.72	6.62	6.54	6.47	6.41	6.36	6.31
8	11.26	8.65	7.59	7.01	6.63	6.37	6.18	6.03	5.91	5.81	5.73	5.67	5.61	5.56	5.52
9	10.56	8.02	6.99	6.42	6.06	5.80	5.61	5.47	5.35	5.26	5.18	5.11	5.05	5.01	4.96
10	10.04	7.56	6.55	5.99	5.64	5.39	5.20	5.06	4.94	4.85	4.77	4.71	4.65	4.60	4.56
11	9.65	7.21	6.22	5.67	5.32	5.07	4.89	4.74	4.63	4.54	4.46	4.40	4.34	4.29	4.25
12	9.33	6.93	5.95	5.41	5.06	4.82	4.64	4.50	4.39	4.30	4.22	4.16	4.10	4.05	4.01
13	9.07	6.70	5.74	5.21	4.86	4.62	4.44	4.30	4.19	4.10	4.02	3.96	3.91	3.86	3.82
14	8.86	6.51	5.56	5.04	4.69	4.46	4.28	4.14	4.03	3.94	3.86	3.80	3.75	3.70	3.66
15	8.68	6.36	5.42	4.89	4.56	4.32	4.14	4.00	3.89	3.80	3.73	3.67	3.61	3.56	3.52
16	8.53	6.23	5.29	4.77	4.44	4.20	4.03	3.89	3.78	3.69	3.62	3.55	3.50	3.45	3.41
17	8.40	6.11	5.19	4.67	4.34	4.10	3.93	3.79	3.68	3.59	3.52	3.46	3.40	3.35	3.31
18	8.29	6.01	5.09	4.58	4.25	4.01	3.84	3.71	3.60	3.51	3.43	3.37	3.32	3.27	3.23
19	8.18	5.93	5.01	4.50	4.17	3.94	3.77	3.63	3.52	3.43	3.36	3.30	3.24	3.19	3.15
20	8.10	5.85	4.94	4.43	4.10	3.87	3.70	3.56	3.46	3.37	3.29	3.23	3.18	3.13	3.09
21	8.02	5.78	4.87	4.37	4.04	3.81	3.64	3.51	3.40	3.31	3.24	3.17	3.12	3.07	3.03
22	7.95	5.72	4.82	4.31	3.99	3.76	3.59	3.45	3.35	3.26	3.18	3.12	3.07	3.02	2.98
23	7.88	5.66	4.76	4.26	3.94	3.71	3.54	3.41	3.30	3.21	3.14	3.07	3.02	2.97	2.93
24	7.82	5.61	4.72	4.22	3.90	3.67	3.50	3.36	3.26	3.17	3.09	3.03	2.98	2.93	2.89
25	7.77	5.57	4.68	4.18	3.85	3.63	3.46	3.32	3.22	3.13	3.06	2.99	2.94	2.89	2.85
26	7.72	5.53	4.64	4.14	3.82	3.59	3.42	3.29	3.18	3.09	3.02	2.96	2.90	2.86	2.81
27	7.68	5.49	4.60	4.11	3.78	3.56	3.39	3.26	3.15	3.06	2.99	2.93	2.87	2.82	2.78
28	7.64	5.45	4.57	4.07	3.75	3.53	3.36	3.23	3.12	3.03	2.96	2.90	2.84	2.79	2.75
29	7.60	5.42	4.54	4.04	3.73	3.50	3.33	3.20	3.09	3.00	2.93	2.87	2.81	2.77	2.73
30	7.56	5.39	4.51	4.02	3.70	3.47	3.30	3.17	3.07	2.98	2.91	2.84	2.79	2.74	2.70
40	7.31	5.18	4.31	3.83	3.51	3.29	3.12	2.99	2.89	2.80	2.73	2.66	2.61	2.56	2.52

Exemple : $v_1 = 5$ d.l. et $v_2 = 10$ d.l. $P(F_{5, 10} \leq f) = 0.99 \Rightarrow f = 5.64$

LISTE DES PUBLICATIONS ISSUES DE LA THÈSE

1. **Nzoko Tayo Dieudonné**, Talla Konchou Armel, Aloyem Kaze Claude Vidal and Tchinda René, *Prediction of electrical energy consumption in Cameroon through econometric models*, Electric Power Systems Research **210**, (2022) 108102.
2. **Nzoko Tayo Dieudonné**, Talla Konchou Armel, Djeudjo Temene Hermann, Aloyem Kaze Claude Vidal and Tchinda René, *Optimization of Short-Term Forecast of Electric Power Demand in the city of Yaoundé-Cameroon by a hybrid model based on the combination of neural networks and econometric methods from a designed energy optimization algorithm*, Technological Forecasting and Social Change **187**, (2023) 122212.
3. **Nzoko Tayo Dieudonné**, Talla Konchou Armel, Aloyem Kaze Claude Vidal, Djeudjo Temene Hermann and Tchinda René, *Modeling and forecasting of the annual consumption of electrical energy in Cameroon by fuzzy logic*, under review into Technological Forecasting and Social Change.