



N° d'ordre : 768

UNIVERSITE DE LOME

FACULTE DES SCIENCES

THESE

Présentée par :

GUENOUKPATI Agbassou

Pour obtenir le grade de :

Doctorat Unique en Sciences de l'Ingénieur

Option : Génie Électrique

**Élaboration d'un outil d'aide pour la
planification optimale à court terme des
réseaux électriques interconnectés**

Soutenue le 22 avril 2022 devant le Jury composé de :

Président : M. NAPO Kossi, Professeur Titulaire, Université de Lomé, Togo

Rapporteurs : M. MAÏGA SEIDOU HASSANE Amadou, Professeur Titulaire,
Université Gaston Berger de Saint-Louis, Sénégal
M. AJAVON Ayité Sénah Akoda, Professeur Titulaire, Université
de Lomé, Togo

Examineurs : M. KODJO Koffi Mawugno, Professeur Titulaire, Université de
Lomé, Togo
M. BOKOVI Yao, Maître de Conférences, Université de Lomé,
Togo
M. PALANGA Eyouléki Tcheyi Gnadi, Maître de Conférences,
Université de Lomé, Togo

Directeur : M. SALAMI Adekunlé Akim, Professeur Titulaire, Université de
Lomé, Togo

DEDICACES

au Dieu Tout Puissant, le plus Grand Omniscient et Omniprésent de tous les
temps, par Qui j'ai pu accomplir ce travail ;

à toi mon feu papa pour tes efforts, encouragements et conseils qui ne resteront pas vains ;

à toi ma maman pour ton soutien indéfectible ;

à mes sœurs et à mon frère ;

à mes tantes, oncles et leurs enfants, et à tous les membres de ma famille ;

à mes collègues de l'Ecole Nationale Supérieure d'Ingénieurs de l'Université de Lomé (ENSI-UL) ;

au Personnel Administratif Technique de l'Ecole Nationale Supérieure d'Ingénieurs de l'Université de Lomé (ENSI-UL) ;

à tous mes étudiants de l'Ecole Nationale Supérieure d'Ingénieurs de l'Université de Lomé (ENSI-UL) ;

à tous mes amis ;

à tous ceux qui de près ou de loin ont contribué d'une manière ou d'autre à l'élaboration de ce document, et tous ceux pour qui, il constitue une véritable source de fierté.

REMERCIEMENTS

Ce document présente les résultats des travaux de recherches durant mes trois années d'études en thèse de Doctorat Unique en Science de l'Ingénieur dans la spécialité Génie Electrique poursuivies à l'Ecole Nationale Supérieure d'Ingénieurs de l'Université de Lomé (ENSI-UL). Certaines parties des travaux réalisés sont effectuées au sein du Laboratoire Sur Energie Solaire (LES) du Département de Physique, Faculté des Sciences (FDS) de l'Université de Lomé (UL), et du Centre d'Excellence Régional pour la Maîtrise de l'Electricité (CERME) de l'UL.

Je tiens à exprimer ma profonde gratitude à :

Monsieur Kossi NAPO, Professeur Titulaire au Département de Physique à Faculté des Sciences (FDS) de l'Université (UL) de Lomé (TOGO), Ancien Directeur du Laboratoire Sur Energie Solaire (LES) pour avoir accepté évaluer cette thèse et de participer au jury ;

Monsieur Amadou MAÏGA SEIDOU HASSANE, Professeur Titulaire à l'Université Gaston Berger de Saint Louis (SENEGAL), Directeur Laboratoire d'Electronique, Informatique, Télécommunications et Energies Renouvelable (LEITER), pour avoir accepté évaluer cette thèse et de participer au jury ;

Monsieur Ayité Sénah Akoda AJAVON, Professeur Titulaire à l'ENSI-UL au Département du Génie Electrique, Directeur du Centre d'Excellence Régional pour la Maîtrise de l'Electricité (CERME) pour avoir accepté évaluer cette thèse et de participer au jury ;

Monsieur Adekunlé Akim SALAMI, Professeur Titulaire à l'ENSI-UL au Département du Génie Electrique, Directeur de l'ENSI-UL, Directeur de cette thèse, qui malgré ses multiples occupations n'a ménagé aucun effort pour la réussite de ce travail ;

Monsieur Koffi Mawugno KODJO, Professeur Titulaire à l'ENSI-UL au Département du Génie Electrique, Ancien Chef du Département du Génie Electrique, pour avoir accepté être examinateur de cette thèse et de participer au jury ;

Monsieur Yao BOKOVI, Maître de Conférences à l'ENSI-UL au Département du Génie Electrique, Ancien Chef du Département du Génie Electrique, pour avoir accepté être examinateur de cette thèse et de participer au jury ;

Monsieur Eyouléki Tcheyi Gnadi PALANGA, Maître de Conférences à l'ENSI-UL au Département du Génie Electrique, Ancien Chef du Département du Génie Electrique, pour avoir accepté être examinateur de cette thèse et de participer au jury ;

Monsieur le Professeur Koffi-Sa Eugène BEDJA, Professeur Titulaire à l'Ecole Nationale Supérieure d'Ingénieurs (ENSI-UL) de l'Université de Lomé (TOGO) ;

Aussi à :

la Présidence de l'Université de Lomé (UL).

Je tiens à remercier également : les collègues enseignants de l'ENSI-UL, des autres Ecoles et Facultés de l'Université de Lomé ;

les anciens Elèves Ingénieurs suivants : N'poh Yéloiti BABIKOU, Abiré Gisèle BELLEI, Messan Kossi Amos GOGRI, Kokou KPATOGBE, Mawumé Komla SENOU, Ezzo-Wazam Honoré TCHANDAO, Aloèssouri NOUTINOU ;

Monsieur Gnabouéva ANATO, sa Femme et ses enfants pour l'amour et l'éducation qu'ils m'ont donnés tout au long de mon cursus scolaire ;

la Jeunesse des Assemblées de Dieu, aux Responsables, du Temple de Résurrection de Bè-Gakpoto.

Même si mon nom est le seul à apparaître sur la couverture, ce document, ainsi que la personne que je suis est le fruit d'investissement et soutien de personnes dont je ne saurai citer les noms, mais qui ont été une source de bénédiction pour ma vie. Qu'ils trouvent ici, l'expression de ma profonde gratitude.

Merci infiniment ! Que Dieu vous bénisse et vous rende au centuple chacun de vos bienfaits.

«The day when we shall know exactly what “electricity” is, will chronicle an event probably greater, more important than any other recorded in the history of the human race. The time will come when the comfort, the very existence, perhaps, of man will depend upon that wonderful agent.»

Nikola Tesla, 1893

Nomenclatures

AC	: Courant alternatif
AIC	: Critère d'information d'Akaike
AIE	: Agence Internationale de l'Energie
ANNs	: Artificial Neural Networks
AR	: Modèle auto-régressif
ARIMA	: Moyenne Mobile Intégré Autorégressif
ARMA	: Modèles autorégressifs
ARMAX	: Modèle autorégressif exogène
BTA	: Basse Tension de classe A
BTB	: Basse Tension de classe B
CDF	: Fonction de densité de probabilité Cumulative
CEB	: Communauté Electrique du Bénin
CEI	: Commission Electrotechnique Internationale
CERME	: Centre d'Excellence Régional pour la Maîtrise de l'Electricité
CIE	: Compagnie Ivoirienne d'Electricité
CRPS	: Score de probabilité classée continue
Db3	: ondelette de Daubechies d'ordre 3
DC	: Courant continu
DNLP	: Programmation non linéaire différentiable
E-M	: Algorithme Espérance-Maximisation
ENSI	: Ecole Nationale Supérieure d'Ingénieurs
FDS	: Faculté des Sciences
GAMS	: General algebraic modeling system
GES	: Gaz à effet de serre
GM	: Modèle de Gray
GP	: Processus Gaussien
GPR	: Régression par processus gaussien
GRT	: Gestionnaire du Réseaux de Transport
HTA	: Réseaux haute tension classe A
HTB	: Haute Tension de classe B
IA	: Intelligence Artificielle
IC	: Intervalle de Confiance
IDE	: environnement de développement intégré
IEEE	: Institut des Ingénieurs en Électronique et Électricité
IRENA	: Agence Internationale pour les Energies Renouvelables
K-S	: Test d'ajustement de Kolmogorov-Smirnov
LES	: Laboratoire Sur Energie Solaire
Lin	: Noyau linéaire
M_{ν}	: Noyau Matérn
MA	: Modèle moyennes mobiles
MAPE	: Mean Absolute Percentage Error
MLP	: Perceptron multicouche
MPPT	: Maximum Power Point Tracking
NLP	: Programmation non linéaire
ODD	: Objectifs du Développement Durable

OGP	: Processus Gaussiens avec mise à jour
OMS	: Organisation Mondiale de la Santé
ONU DAES	: Division de la Statistique des Nations Unies
PDF	: Fonction de densité de probabilité
Per	: Noyau périodique
PICP	: Prediction Interval Coverage Probability
PICP	: Probabilité de Couverture d'Intervalle de Prédiction
PINAW	: Largeur Moyenne Normalisée de l'Intervalle de Prédiction
PQ	: Programmation quadratique
RBF	: Noyau fonction radial de base
RMSE	: Racine de l'erreur quadratique moyenne
RQ	: Noyau quadratique rationnel
SARMA	: Modèles autorégressifs saisonnier
SE	: Noyau exponentiel carré
STCED	: Statistic Tool for Characterizing Electricity Data
SVM	: Machines à Vecteur de Support
TBT	: Très Basse Tension
TCN	: Transmission Company of Nigeria
VRA	: Volta River Authority

Symboles

α	: Seuil de risque accepté
π_i	: Proportions du mélange
α	: Seuil de risque
\bar{P}	: Puissance de sortie moyenne
ϵ	: Seuil pour la convergence de l'algorithme
ϵ_t	: Bruit blanc
η	: Vitesse d'apprentissage
η_{pv}	: Rendement de la cellule photovoltaïque
η_t	: Rendement de la turbine hydraulique
η_{tr}	: Rendement du transformateur
Γ	: Ensemble des paramètres
γ	: Paramètre de la fonction de densité de probabilité conjointe
γ^s	: Paramètre du modèle à estimer à l'itération s
γ^{s+1}	: Paramètre du modèle à estimer à l'itération $1 + s$
$\hat{\theta}$: Vecteur des paramètres issus de l'apprentissage
$\mathcal{N}(\cdot)$: Loi normale
μ_i	: Moyenne des observation
Ω_{ren}^i	: Ensemble de la $i^{ème}$ source renouvelable
Ω_{hydro}	: Ensemble de générateurs hydroélectrique
Ω_{arbre}	: Vitesse de rotation de l'arbre
$\Omega_{éol}$: Ensemble de générateurs éolienne
ω_k	: Perturbation aléatoire de la charge
Ω_{NL}	: Nombre d'arcs de transport
Ω_{pv}	: Ensemble de générateurs solaire photovoltaïque
Ω_{th}	: Ensemble des centrales thermiques de production d'électricité
π_i	: Poids de la composante du $i^{ème}$ mélange Gaussien
Ψ	: Ondelette mère
Ψ^*	: Expression conjuguée de l'ondelette mère
ρ	: Masse volumique du fluide
σ^*	: Ecart type de l'échantillon
Σ_i	: Covariance
τ	: Facteur de translation
θ	: Vecteur de paramètres
$a(\cdot)$: Distance moyenne intra-cluster
a_0, \dots, a_n	: Coefficients de régression
$b(\cdot)$: Distance moyenne au cluster le plus proche
$C_{th}^i(P_{th}^i)$: Coût de production de la centrale thermique i
C_Ψ	: Constante d'admissibilité de l'ondelette mère
c_i	: Poids du modèle lissage exponentiel
C_k	: $k^{ième}$ cluster
C_{turb}	: Couple sur l'arbre de la turbine
c_k	: Coût t moyen par unité de capacité de la ligne k
CA_k	: Coefficient d'approximation
CD_k	: Coefficient de détails

$CT_{ren}^i(P_{ren})$: Coût de production des énergies renouvelables
$CT_{th}^i(P_{th}^i)$: Coût de production globale des centrales thermiques
D	: Ensemble de données d'entraînement
d	: Nombre de différences
$d(\cdot, \cdot)$: distance de Minkowski
$d_{th}^i, e_{th}^i, \text{ et } f_{th}^i$: Coefficients d'émission de la $i^{\text{ème}}$ centrale thermique
$E()$: Fonction partie entière
E_c	: Energie cinétique du flux d'eau
E_m	: Energie mécanique du flux d'eau
E_p	: Energie potentielle d'une chute d'eau
$Em_{th}^i(P_{th}^i)$: émission totale produite par l'unité thermique i
F	: Fonction de répartition théorique
f	: Fonction de distribution
F^*	: Répartition empirique
f_*	: Sortie d'un processus gaussien
g	: accélération de la pesanteur
h	: Fonction de Heaviside
H	: Hauteur nette de la chute
H_{gh}	: éclaircissement énergétique global
H_0	: Hypothèse nulle
I	: Matrice identité
K	: Matrice de covariance des paires de points d'entraînement
$k(\cdot, \cdot')$: Noyau de covariance
K_{**}	: Matrice de covariances évaluées à tous les pairs de points de test
K_*	: Matrice de covariance des paires de points d'entraînement et de test
L	: Maximum de la fonction de vraisemblance
L_f	: Fonction de vraisemblance
n	: Nombre de variable d'entrée ;
N_{hydro}	: Nombre de générateurs hydroélectrique
N_{pv}	: Nombre de générateurs solaire photovoltaïque
N_{th}	: Nombre de générateurs thermiques
p	: Nombre de termes auto-régressifs
P_{ren}^i	: Puissance en AC la $i^{\text{ème}}$ centrale renouvelable
P_{tr}^{max}	: Limite thermique en fonctionnement normal des lignes
P_{tr}^k	: Puissance à travers une ligne électrique k
P_{hyd}	: Puissance hydraulique
P_{mec}	: Puissance mécanique en sortie de la turbine hydraulique
P_n	: Puissance nominale d'une éolienne
P_r	: Probabilité d'occurrence d'un événement
P_r	: Pression du fluide
P_{rec}	: Potentiel énergétique récupérable au niveau de l'hélice
P_{th}	: Puissance transmise aux systèmes électro-énergétiques
P_g	: Puissance aux bornes de la génératrice
P_w	: Puissance des auxiliaires
q	: Nombre de moyennes mobiles
Q	: débit d'équipement

R	: Position de la valeur prédite
R^2	: Coefficient de détermination
s	: Facteur d'échelle
S	: surface exposée des modules photovoltaïques
T	: paires de vecteur
U_n	: Gamme de tension
v	: Vitesse du fluide
V_D	: Vitesse de démarrage pour laquelle l'éolienne fournit l'énergie
V_M	: Vitesse de freinage de l'éolienne
V_n	: Vitesse nominale de l'éolienne
w	: Vecteurs poids
$w(s, \tau)$: poids de la contribution de l'ondelette
w_{01}	: Biais
$x(t)$: Signal continu
x^*	: Point optimum
x_*	: Points de test à l'entrée d'un processus gaussien
x_i	: Variable explicative
x_{t+h}	: Point de test l'horizon h
$y(t)$: Valeur de la charge électrique t
y_i	: Variable expliquée
Y_p	: Valeur prédite de la charge électrique
Y_r	: Valeur réelle de la charge électrique
y_{MA}	: Sortie du modèle moyenne mobile
y_t	: Série temporelle
α	: Paramètre du modèle lissage exponentiel
CO_2	: Dioxyde de carbone
NO_2	: Dioxydes d'azote
NO_x	: Oxydes d'azote
SO_2	: Dioxyde de soufre
\mathbb{E}	: Espérance mathématique
\mathbb{R}	: Ensemble des nombres réels
P_{DC}	: Puissance générée par un module photovoltaïque
P_{hyd}	: Puissance hydraulique
$TE m_{th}^i(P_{th}^i)$: Emission globale pour un ensemble de centrales thermiques
y_{MA}	: Sortie du modèle moyenne mobile

Table des matières

Dédicaces	i
Remerciements	iii
Nomenclatures	vi
Symboles	viii
Liste des figures	xvi
Liste des tableaux	xix
Introduction générale	1
1 Généralités sur la planification à court terme des réseaux électriques interconnectés	6
1.1 Introduction	6
1.2 Sources de production d'énergie électrique	7
1.2.1 Energies fossiles	7
1.2.1.1 Modèle des centrales thermiques	8
1.2.1.2 Modèle de coût de production des centrales thermiques	8
1.2.1.3 Modèle de coût d'émission des centrales thermiques	9
1.2.2 Energies nucléaires	10
1.2.3 Energies renouvelables	10
1.2.3.1 Centrales hydroélectriques	11
1.2.3.2 Centrales solaires photovoltaïques	13
1.2.3.3 Centrales éoliennes	14
1.2.3.4 Modèle du coût de production des énergies renouvelables	17
1.3 Description des réseaux électriques	18
1.3.1 Réseaux électriques de transport	18
1.3.2 Réseaux électriques de répartition	19
1.3.3 Réseaux électriques de distribution	19
1.4 Topologie des réseaux électriques	20
1.4.1 Réseaux maillés	20
1.4.2 Réseaux bouclés	20
1.4.3 Réseaux radiaux	20

1.4.4	Réseaux en antenne	21
1.4.5	Postes électriques de transformation	21
1.5	Fonctionnement du marché de l'électricité	22
1.6	Revue littéraire sur la planification des réseaux électriques	23
1.7	Problématique la prévision à court terme de la charge électrique	25
1.8	Prévision de la charge électrique	29
1.8.1	Facteurs d'influence sur la demande en électricité	30
1.8.1.1	La météorologie et le climat	31
1.8.1.2	Les variations chronologiques	31
1.8.1.3	L'activité économique	31
1.8.1.4	Les facteurs exceptionnels	32
1.8.1.5	Les événements spéciaux	32
1.8.2	Processus général de modélisation de la prévision	32
1.8.3	Types de prévision de la charge électrique	33
1.8.3.1	Prévision à ultra-court terme de la charge électrique	33
1.8.3.2	Prévision à court terme de la charge électrique	33
1.8.3.3	Prévision à moyen terme de la charge électrique	34
1.8.3.4	Prévision à long terme de la charge électrique	34
1.8.4	Méthodes de prévision à court terme de la charge électrique	35
1.8.4.1	Méthodes de régression linéaire et multiple	35
1.8.4.2	Méthode des jours similaires	36
1.8.4.3	Filtre de Kalman	36
1.8.4.4	Modèle de Gray	36
1.8.4.5	Lissage exponentiel	36
1.8.4.6	Le modèle Persistance	37
1.8.4.7	Modèles de Box–Jenkins	38
1.8.5	Machines à vecteurs de support	41
1.8.6	Processus Gaussien	41
1.9	Conclusion	42
2	Approches de planification à court terme des réseaux électriques de transport interconnectés	43
2.1	Introduction	43
2.2	Approche probabiliste pour la caractérisation des sources de production d'électricité	44
2.2.1	Présentation des lois de probabilités sélectionnées	44
2.2.2	Test d'ajustement de Kolmogorov-Smirnov	47
2.2.3	Modélisation par mélange de distributions gaussiennes	47
2.2.4	Estimation des paramètres de mélange de distributions par algorithme d'Espérance-Maximisation	49
2.2.4.1	Approche d'estimation Bayésienne	49
2.2.4.1.1	Etape estimation de l'algorithme E-M	50
2.2.4.1.2	Etape maximisation de l'algorithme E-M	50
2.2.4.2	Estimation des paramètres de mélange gaussien	50
2.3	Prévision à court terme de la charge électrique	52
2.3.1	Approche k-means clustering / ANN	53

2.3.1.1	Réseaux de neurones artificiels de type perceptron monocouche	54
2.3.1.1.1	Algorithme d'apprentissage par gradient descendant	55
2.3.1.1.2	Limites du perceptron monocouche	56
2.3.1.2	Réseau de neurones artificiels de type perceptron multicouches	56
2.3.1.2.1	Algorithme d'apprentissage des ANN de type MLP	56
2.3.1.2.2	Apprentissage par rétropropagation du gradient d'erreur	57
2.3.1.3	Algorithme k-means clustering	58
2.3.1.3.1	Principe de l'algorithme de Lloyd	59
2.3.1.3.2	Choix du nombre de clusters	59
2.3.1.3.3	Méthode de la silhouette	60
2.3.1.4	Méthodologie de la méthode hybride proposée	61
2.3.2	Application de la transformée en ondelettes	61
2.3.3	Approche ondelettes / ARIMA	63
2.3.3.1	Ondelette mère	64
2.3.3.2	Transformée en ondelettes discrètes	65
2.3.3.3	Méthodologie de l'approche ondelettes / ARIMA	66
2.3.4	Approche ondelettes /Processus Gaussien	67
2.3.4.1	Propagation des erreurs dans la GPR	70
2.3.4.2	Composition des noyaux	72
2.3.4.3	Mise à jour du modèle	74
2.3.4.4	Méthodologie de l'approche ondelettes/Processus Gaussien	74
2.4	Formulations des problèmes d'optimisation des coûts de l'électricité et d'empreinte carbone	76
2.4.1	Optimisation des coûts de l'électricité	76
2.4.2	Optimisation des émissions CO ₂	77
2.4.3	Résolution par programmation quadratique	78
2.4.3.1	Définition mathématique	79
2.4.3.2	Conditions d'optimalité	79
2.5	Conclusion	80
3	Etude et réalisation d'un logiciel d'analyse, de caractérisation des sources d'énergie électrique, de prédiction de la demande et d'optimisation du coût et de CO₂	81
3.1	Introduction	81
3.2	Objectif du logiciel STCED	82
3.3	Aspects logiciel et matériel	83
3.3.1	Python : un langage de programmation polyvalent	84
3.3.2	Pourquoi choisir l'IDE PyCharm ?	84
3.3.3	Présentation de l'outil de création des interfaces graphiques Qt Designer	87

3.3.4	Logiciel de programmation GAMS	89
3.3.5	Aspects matériels	92
3.4	Développement du logiciel	92
3.4.1	Description sommaire du logiciel	92
3.4.2	Module de bases de données	94
3.4.3	Module d'analyse des données	94
3.4.3.1	Racine de l'erreur quadratique moyenne	96
3.4.3.2	Coefficient de détermination	96
3.4.3.3	Score de probabilité classée continue	97
3.4.4	Module de traitement du signal	97
3.4.5	Module de prédiction de charge électrique	98
3.4.5.1	Erreur absolue moyenne en pourcentage	99
3.4.5.2	Probabilité de Couverture d'Intervalle de Prédiction	99
3.4.5.3	Largeur Moyenne Normalisée de l'Intervalle de Prédiction	100
3.4.6	Module optimisation	100
3.5	Fonctionnement, validation et prototypage du logiciel	101
3.5.1	Importation et exportation	102
3.5.2	Validation et prototypage du logiciel : résultats de quelques modules	103
3.5.2.1	Module de bases de données : analyse des profils de la demande et de la production de l'électricité	106
3.5.2.2	Module statistique	106
3.5.2.3	Module optimisation	109
3.6	Conclusion	111
4	Mise en œuvre et contribution de l'application STCED pour la planification à court terme des réseaux électriques interconnectés	112
4.1	Introduction	112
4.2	Données de production d'électricité	112
4.3	Statistique descriptive des données de production d'électricité	114
4.4	Ajustements statistique des données de production d'électricité	116
4.4.1	Ajustement par des lois de distributions classiques	117
4.4.2	Ajustement par les mélanges gaussiens	119
4.5	Prévision de la charge électrique	122
4.5.1	Modèle ondelettes/ARIMA	122
4.5.1.1	Préparation des données d'étude	122
4.5.1.2	Choix des hyperparamètres optimaux	124
4.5.1.3	Résultats de prévision avec ondelettes/ARIMA	124
4.5.2	Modèle K-means/ANN	125
4.5.2.1	Application de l'algorithme de k-means clustering	125
4.5.2.2	Prévision avec les ANNs	128
4.6	Modèle ondelettes/GPR	131
4.6.1	Choix de la base de données d'étude	131
4.6.2	Choix du noyau de GPR	134
4.6.3	Présentation des variables d'entrées et de sorties	134

4.6.4	Résultats de prévisions avec différentes configurations	136
4.6.5	Processus gaussien avec mis à jour (OGP)	143
4.6.6	Améliorations de l'IC des prévisions	145
4.6.7	Prévision multihorizon	148
4.7	Optimisation du coût de l'électricité et d'emprunte carbone	149
4.7.1	Description du réseau IEEE à 24 nœuds	149
4.7.2	Présentation des données d'étude d'optimisation	154
4.7.3	Résultats d'optimisation du coût de l'électricité et de l'em- prunte carbone	154
4.8	Conclusion	158
	Conclusion générale	160
	Bibiographie	166
	ANNEXE	182

Liste des figures

1.1	Part des sources primaires dans la production mondiale de l'électricité	7
1.2	Principe de l'hydroélectricité	11
1.3	Les différentes étapes de transformations énergétiques d'une éolienne	15
1.4	Courbe de puissance d'une éolienne	16
1.5	Interface d'électronique de puissance d'une éolienne avec batterie connecté au réseau électrique	17
1.6	Poste de transformation électrique	21
1.7	Modèle de base du marché de l'électricité	22
1.8	Variations cycliques de la charge électrique	30
1.9	Classification des types de prévision de la charge	34
2.1	Méthodologie de modélisation statistique des sources électriques	45
2.2	Organigramme d'estimation des paramètre du mélange de distribution gaussienne par l'algorithme Espérance-Maximisation	51
2.3	Apprentissage supervisé	53
2.4	Architecture d'un perceptron	54
2.5	Architecture d'un perceptron multicouche	57
2.6	Algorithme de Lloyd	60
2.7	Méthodologie de de prévision par approche hybride k-means réseau de neurones artificiel	62
2.8	Cas de signaux basses et haute fréquences avec la même fenêtre	63
2.9	Transformée en ondelette	63
2.10	Quelques familles des ondelettes usuelles	64
2.11	Méthodologie de prévision par approche décomposition en ondelettes / ARIMA	67
2.12	Modèle graphique de la représentation fonction-espace du GP	68
2.13	Méthodologie de prévision par approche décomposition en ondelettes / Processus Gaussien	75
3.1	Interface utilisateur de l'éditeur PyCharm	85
3.2	Creation d'un projet avec l'éditeur PyCharm	86
3.3	Fenêtre principale de l'éditeur PyCharm après creation du projet	86
3.4	fenêtre principale de création d'un module en Python sous PyCharm	87
3.5	Fenêtre principale de Qt designer	88
3.6	Fenêtre d'affichage de Qt designer	89
3.7	Procédure de résolution de GAMS	90

3.8	Structure d'un modèle GAMS	91
3.9	Sortie d'un modèle GAMS	91
3.10	Organigramme général de fonctionnement du logiciel STCED	93
3.11	Schéma structural du logiciel STCED	93
3.12	Base de données sur l'électricité sous Excel	94
3.13	Organigramme de fonctionnement du module analyse statistique des données	95
3.14	Quelques Noyaux de la régression par GP avec 3 réalisations	99
3.15	Fenêtres de navigation des différents modules du logiciel STCED	101
3.16	Exemple de fenêtres d'information d'un module du logiciel STCED	102
3.17	Exemple de fenêtres de sortie d'un module du logiciel STCED	102
3.18	Importation d'un fichier Excel dans le logiciel STCED	103
3.19	Exportation d'un fichier Excel dans le logiciel STCED	103
3.20	Présentation d'un résultat graphique dans le logiciel STCED	104
3.21	Interface d'utilisateur du logiciel STCED	104
3.22	Profil de la charge électrique de la CEB présenté par le logiciel STCED	106
3.23	Profil de la production électrique de la CEB présenté par le logiciel STCED	107
3.24	Fenêtre d'analyse statistique de la production de CEB par la loi Normale	107
3.25	Fenêtre d'analyse statistique des importations de la CEB auprès de la TCN par la loi de Weibull	108
3.26	Fenêtre d'analyse statistique des importations de la CEB auprès de la VRA par la loi Skewnormal	108
3.27	Equilibre entre offre et demande électrique sans intégration des énergies renouvelables	111
4.1	Aperçu des données électriques de la CEB dans une feuille Excel	113
4.2	Comparaison des PDF et CDF de Skew-normale et de GMM à 1 composante : cas de Nangbéto	121
4.3	Comparaison du modèle de mélange gaussien à 4 composantes aux modèles de distribution Skew-normale et de Weibull : cas de TCN	121
4.4	Comparaison des PDF et CDF de Skew-normale et de GMM à 4 composantes : cas de VRA/CIE	121
4.5	Décomposition en ondelette de niveau 4 de la charge électrique de la CEB	123
4.6	Décomposition en ondelette de niveau 4 de la charge électrique de la CEB	123
4.7	Sorties générées par le modèle ARIMA et le modèle hybride CA4+CD	125
4.8	Variation de la silhouette en fonction du nombre de clusters	126
4.9	Représentation en 2D des différents profils de jours des données	127
4.10	Répartition suivant les différents profils de jour des données	127
4.11	Charges réelles et prédites avec le modèle généraliste	130
4.12	Charges réelles et prédites des jours ouvrables avec K-Mean et ANNs	130
4.13	Charges réelles et prédites des jours non ouvrables avec k-means et ANNs	131
4.14	Ajustement de l'histogramme par la loi normale sur l'ensemble des données de charge	132

4.15 Ajustement de l'histogramme par la loi normale sur la fenêtre de données	133
4.16 Méthodologie adoptée pour la modélisation de la charge électrique avec le GPR	134
4.17 Charge réelle et prédite sur une durée de 48 heures (01 au 02 Avril 2017)	143
4.18 Corrélacion entre les valeurs mesurées et prédites avec GP	143
4.19 Charge réelle et prédite sur les trois semaines de test avec OGP	144
4.20 intervalle de confiance à 95%	144
4.21 Vue dilatée des composantes CA3, CD3, CD2 et CD1	146
4.22 Nouvelle prédiction sur une durée de 48 heures (01 au 02 Avril 2017) avec un intervalle de confiance réduit.	146
4.23 Corrélacion entre les valeurs mesurées et prédites avec GP_MLP12_WAV	147
4.24 Charge réelle et prédite pour les différentes modèles (pour la semaine du 01 au 07 avril 2017) avec un intervalle de confiance réduit.	147
4.25 Topologie du réseau IEEE à 24 Bus	149
4.26 Profil journalier de la charge couvert en 24 heure	158

Liste des tableaux

2.1	Lois de probabilités sélectionnées	44
2.2	Différents noyaux courants utilisés dans le Processus Gaussien	73
3.1	Détails des éléments d'espace de travail du logiciel STCED	105
3.2	Valeurs optimales obtenues dans les 24 heures pour chaque centrale sans intégration des énergies renouvelables	109
3.3	Valeurs optimales obtenues dans les 24 heures pour chaque centrale avec intégration des énergies renouvelables	110
4.1	Indices statistiques des sources de production et d'importation de la CEB	115
4.2	Résultats des tests statistiques sur les fonctions de distributions sélectionnées	118
4.3	Choix du nombre de composantes pour les mélanges de distributions Gaussiennes	119
4.4	Paramètres du mélange Gaussien avec le nombre de composantes optimaux	120
4.5	Mesures de performances des modèles	120
4.6	Hyperparamètres optimaux des modèles ARIMA et ondelettes/ARIMA	124
4.7	Performance prédictive des modèles ARIMA et ondelette-ARIMA	124
4.8	Erreurs de prévision avec le modèle des jours ouvrables	128
4.9	Erreurs de prévision avec le modèle des jours non ouvrables	129
4.10	Erreurs de prévision pour le modèle généraliste	129
4.11	Comparaison des performances des modèles de prédiction	131
4.12	Statistique descriptive la fenêtre de données	132
4.13	Liste des variables explicatives, leur explication mathématique et leur codification	135
4.14	Liste des configurations	136
4.15	Performances de la configuration 1 - [G H I]	137
4.16	Performances de la configuration 2 - [A G H I]	137
4.17	Performances de la configuration 3 - [A B C G H I]	137
4.18	Performances de la configuration 4 - [A C G H I]	138
4.19	Performances de la configuration 5 - [A B C G I]	138
4.20	Performances de la configuration 6 - [A B C J]	138
4.21	Performances de la configuration 7 - [B C G H I J]	138
4.22	Performances de la configuration 8 - [B G H I J]	139

4.23	Performances de la configuration 9 - [A B C G]	139
4.24	Performances de la configuration 10 - [B C H J]	139
4.25	Performances de la configuration 11 - [D]	139
4.26	Performances de la configuration 12 - [E]	140
4.27	Performances de la configuration 13 - [A B C F J]	140
4.28	Performances de la configuration 14 - [A B C G J]	140
4.29	Performances de la configuration 15 - [A B C E J]	140
4.30	Bilan des meilleures performances de toutes les configurations	142
4.31	Bilan des erreurs pour le modèle avant et après décomposition	145
4.32	Erreurs de prévision suivant l'horizon	148
4.33	Données des lignes de transport du réseau IEEE à 24 nœuds	150
4.34	Données des lignes de transport du réseau IEEE à 24 nœuds (suite)	151
4.35	Données de coefficients de coûts des carburants et d'émissions pour un système IEEE 24 bus	151
4.36	Caractéristiques des générateurs du réseau IEEE 24 bus	152
4.37	Caractéristiques des générateurs du réseau IEEE 24 bus(suite)	153
4.38	Puissance moyenne extractible de la ferme éolienne aux différentes heures de la journée du 19 Novembre 2017	154
4.39	Puissance moyenne extractible de la centrale solaire aux différentes heures durant la journée de 19 Novembre 2017	155
4.40	Profil de la charge électrique de la CEB durant la journée de 19 Novembre 2017	155
4.41	Détail des différents scénarii avec les sources thermiques, solaires et éoliennes	156
4.42	Résultats des tests de cout et emission CO ₂ optimisés sur le réseau IEEE 24 nœuds	157

Introduction générale

Selon les rapports sur le progrès en énergie publié en 2019 conjointement par l'Agence Internationale de l'Energie (AIE), la Banque Mondiale, l'Organisation Mondiale de la Santé (OMS), l'Agence Internationale pour les Energies Renouvelables (IRENA) et la Division de la Statistique des Nations Unies (ONU DAES), près de 650 millions de personnes continueront d'être privées d'électricité dans le monde dont 573 millions de personnes en Afrique-subsaaharienne d'ici à 2030 [1]. Une situation beaucoup plus préoccupante dont il faudra faire face en redoublant d'efforts si nous voulons atteindre les Objectifs du Développement Durable (ODD) à l'horizon 2030 [2].

Le Togo, un pays d'Afrique sub-saharienne est confronté à la problématique d'accès à l'électricité. Près de 80 % de son énergie électrique est importé de l'extérieur grâce aux interconnexions du réseau électrique de la Communauté Electrique du Bénin (CEB) avec ceux de la Volta River Authority (VRA) du Ghana, de la Compagnie Ivoirienne d'Electricité (CIE) en Côte d'Ivoire et de la Transmission Company of Nigeria (TCN) au Nigeria [3]. Malgré cela, le pays voit continuellement croître sa demande en énergie électrique. Pour relever le défi énergétique afin de ne pas rentrer dans des fatalités [4] comme celles des années 2006 et 2007 où les populations du Togo et Bénin étaient privées d'énergie électrique pendant des heures (10 à 14 heures) tous les jours durant dix mois [5], plusieurs solutions sont envisagées par les compagnies d'énergie électrique. Il s'agit d'une diversification des sources d'approvisionnement en énergie électrique, l'extension des réseaux électriques, le développement des projets d'interconnexion, l'ouverture du marché de l'électricité, la construction de nouvelles centrales électriques, etc.

Par la suite, il est admis que notre siècle verra la fin du pétrole et du gaz. Or, ces combustibles fossiles utilisés par la plupart des centrales électriques contribuent à une augmentation exacerbée des gaz à effet de serre. Ainsi, l'intégration des énergies renouvelables comme le solaire, l'éolienne, etc. . . , dans le mix énergétique serait la meilleure alternative [6]. Dans le cas où l'évolution de la demande doit être assu-

rée par plusieurs sources d’approvisionnement d’énergie électrique des réseaux électriques interconnectés sous une configuration optimale et de stabilité de ces réseaux à moindre coût, sous les exigences environnementales, une étude de planification s’avère indispensable, ce qui constitue notre centre d’intérêt à travers ce travail dans le contexte de marché libéral.

La planification des réseaux électrique est un processus qui se situe dans le long, moyen et court-terme. Elle vise le développement des infrastructures (lignes, câbles, et postes) basées sur des investissements dont le principal objectif est d’anticiper les évolutions de système (consommation, mix énergétique, échanges transfrontaliers), et ce de manière optimale du point de vue technico-économique. Dans cette étude, nous nous limitons au court-terme. La recension des écrits montre que chaque thématique consacrée à la planification des réseaux électriques aborde un seul point des objectifs avec des spécificités particulières sous des hypothèses établies. Le gap est qu’aucun travail de recherche n’a encore été fait dans ce sens visant à fédérer tous les objectifs de la planification à court terme des réseaux électriques interconnectés. De plus selon une étude bibliographique faite par Philipp A Trotter et al [7] ressort que la plupart des pays d’Afrique sub-saharienne n’ont reçu que peu ou pas d’attention en matière de la planification des réseaux électriques.

Les principes de la planification à court terme des réseaux électriques sont axés autour de trois (03) objectifs principaux : assurer la sécurité d’approvisionnement en énergie électrique, promouvoir le développement durable et le respect de l’environnement, et prôner l’efficacité économique grâce à la libéralisation du marché de l’électricité. Cependant, l’électricité est un produit difficilement stockable en grande quantité, parfois intermittente. En plus de cela, les caractéristiques de la demande sont sa fluctuation et sa non linéarité. Il est question d’un véritable enjeu pour le Gestionnaire du Réseau de Transport (GRT), mais le défi est de grande envergure. De ce fait, les pays du Nord où l’expérience en matière de la maîtrise dans le domaine de la planification des réseaux électriques est très poussée, disposent des outils informatiques permettant d’analyser et de modéliser les sources de l’énergie électrique, de prédire la charge électrique, d’optimiser le coût et d’empreinte carbone [8–12].

Les outils informatiques utilisés pour l’analyse des données électriques emploient souvent des méthodes d’analyse statistiques [12]. Les ondelettes grâce à leurs performances dans le domaine de traitement du signal, ou encore en analyse mathématique interviennent comme de puissants outils d’analyse du signal ces dernières

années [13, 14].

Les outils informatiques emploient souvent, pour la caractérisation des sources de productions d'énergie électrique, de modèles probabilistes classiques. Cependant, comme les auteurs J. Munkhammar et al, R. Singh et al [15, 16] affirment, aucune conclusion ne peut être tirée sur l'existence d'une unique loi de distribution propre à la modélisation des données électriques à cause de leurs variabilités dans le temps et espace sans oublier la nature et la qualité de ces données collectées. Dans cette perspective, d'autres types de fonctions de distribution, les modèles hybrides, notamment les mélanges de distributions sont conseillés pour modéliser les données de production d'énergie électrique [17]. Dans cette optique, pour réduire des erreurs d'ajustement non négligeables, le mélange Gaussien est proposé dans le but de prévoir la disponibilité des sources de production.

Pour une exploitation et gestion optimale du réseau électrique, la production de l'énergie doit suivre la demande. Ainsi, l'élaboration des modèles robustes de prédiction de la charge électrique est d'une importance capitale pour les compagnies électriques. C'est dans cette logique que le marché de l'électricité dispose des outils informatiques, utilisant souvent plusieurs modèles de prédiction à court-terme de la charge électrique, etc. Il s'agit des méthodes statistiques et d'Intelligence Artificielle (IA) [18]. Durant ces dernières décennies, l'accessibilité accrue des données et l'essor de l'électrotechnique et de l'informatique, ont suscité de nouvelles recherches et engouements sur l'utilisation des techniques de l'IA, en particulier le Machine Learning dans la prévision, la modélisation et l'analyse des séries temporelles, principalement dans le secteur de l'électricité.

Les algorithmes du Machine Learning, les plus utilisés couramment par les outils informatiques pour la prévision de la charge sont les Réseaux de Neurones Artificiels (ANN, pour Artificial Neural Networks) et le Processus Gaussien (GP, pour Gaussian Process) [19] et le modèle ARIMA de Box & Jenkins [20–22], etc. Toutefois, les ANN souffrent du problème de fluctuation des données où il est difficile de trouver un algorithme ou une règle d'apprentissage générale, présentent les difficultés de trouver la structure ou la topologie du réseau avec les essais de minimisation d'erreur. De plus, l'architecture des ANN varie en fonction de la taille des données [23]. Dans ce cas, k-means offre notamment une alternative grâce à la possibilité de trouver des patterns dans les données. Des études ont prouvé que le GP est largement en avance sur les ANN. Un ANN avec une infinité de neurones est un GP. Avec

peu de données, le GP décrit mieux les motifs contenus dans les données. Le GP dispose aussi naturellement un intervalle de confiance (IC) qui capture directement l'incertitude du modèle : c'est-à-dire le GP donne directement une probabilité pour la valeur prédite, contrairement aux ANN. La seule difficulté serait d'obtenir un IC précis. La transformée en ondelettes pourra donc apporter sa contribution à ce problème grâce à sa capacité de comprendre toutes les informations contenues dans le signal. Outre, d'après les travaux de Blum et Riedmiller [24], le GP ne nécessiterait pas de variables liée au climat et au temps pour approximer la charge électrique. Par ailleurs, les outils informatiques utilisent aussi le modèle Moyenne Mobile Intégrée Autorégressive (ARIMA, pour Autoregressive Integrated Moving Average) de Box & Jenkins comme méthode classique de prévision de la charge électrique [20–22]. Cependant, La prise en compte des variables exogènes qui influencent la charge électrique limite l'application des modèles ARIMA dans le processus de prévision. La transformée en Ondelette peut être appliquée. Le modèle hybride constitué de la transformée en ondelettes et ARIMA [25, 26] fait des exploits au cours de ces derniers temps qui rivalisent avec les méthodes du Machine Learning dans le domaine de prévision.

L'état de l'art montre que dans la planification des réseaux électriques, les outils informatiques sur le marché de l'électricité utilisent les méthodes déterministes et stochastiques [27, 28]. Les méthodes stochastiques pourront conduire à des résultats différents par itération pour un même point initial. L'inconvénient majeur des méthodes stochastiques est que l'optimum global n'est pas garanti. Dans les méthodes déterministes, pour résoudre un problème, l'algorithme se comportera toujours de la même façon et donnera toujours la même réponse. Par la suite, les centrales thermiques représentent d'importantes sources d'émission des gaz à effet de serre (GES), en particulier le CO₂. Généralement, la fonction coût de production d'énergie électrique ou des émissions de CO₂ est modélisée et approximée par une courbe quadratique [29]. Pour la production d'électricité d'origine renouvelable, le coût de l'énergie produite est une fonction linéaire. De ce qui précède, nous allons utiliser l'approche déterministe basée sur la programmation quadratique pour l'optimisation du coût de l'énergie et des émissions de CO₂ dans la planification des réseaux électriques.

Comme notre centre d'intérêt est la planification optimale à court terme des réseaux électriques interconnectés pour une application dans un contexte de marché libéral, notre travail a pour but d'intégrer des méthodes de la planification des ré-

seaux électriques dans un environnement informatique. Cet outil informatique sera utilisé pour caractériser des sources interconnectées dans un réseau électrique, prédire à court-terme la charge électrique et optimiser le coût de l'électricité dans le respect des exigences environnementales avec une bonne robustesse. Dans le but de disposer d'un outil didactique et professionnel, cette application qui sera issue de l'intégration des méthodes, utilisera le mélange Gaussien pour l'analyse des données de puissances en MW produite par les sources électriques d'un réseau afin de prévoir leurs disponibilité, les modèles ondelettes/ARIMA, k-means/ANN et ondelettes/GP pour la prédiction à court terme de la charge électrique et la programmation quadratique pour l'optimisation du coût de l'électricité et d'empreinte carbone. Le présent travail est subdivisé en quatre (04) chapitres.

Après une introduction générale, le premier chapitre expose les généralités sur le système électrique et tous les éléments intervenant dans la planification des réseaux électriques. Il est suivi d'une section consacrée à la présentation du contexte actuel de la planification des réseaux électriques. La connaissance et la compréhension de ces éléments nous permet de poser la problématique de notre sujet au niveau de la demande. Il se termine par un état de l'art sur la prévision de la charge électrique.

Le second chapitre expose les modèles de Machine Learning hybrides (clustering k-means / ANN, ondelettes / ARIMA et ondelettes / processus gaussien), le modèle de mélange gaussien, la formulation et résolution du problème d'optimisation du coût de l'électricité et de l'empreinte carbone par programmation quadratique pour résoudre la problématique de la planification à court terme des réseaux électriques interconnectés.

Le troisième chapitre est consacré à l'étude, à la conception, à la réalisation et à la validation du logiciel STCED qui est un outil informatique d'analyse, de modélisation des sources électriques, d'optimisation de coût de l'électricité, de réduction de l'empreinte carbone et de prédiction de la charge électrique.

Le quatrième chapitre s'est préoccupée de la présentation des applications du logiciel STCED ainsi réalisé par une étude de cas sur les réseaux de la CEB et IEEE 24 bus et terminé par la conclusion générale et perspectives.

Chapitre 1

Généralités sur la planification à court terme des réseaux électriques interconnectés

1.1 Introduction

Chaque année, les réseaux électriques connaissent de mutations sans précédent. Cette évolution s'explique par des exigences techniques, économiques, sociales sans oublier les aspirations politiques [30–35]. On assiste donc au difficile pilotage du réseau électrique de nos villes soumis aux contraintes de forte consommation due aux activités économiques, sociales, et industrielles. D'une part, les impératifs environnementaux obligent les politiques à adopter des mesures de décarbonisation et s'engager dans le développement durable, notamment l'utilisation des énergies renouvelables et d'autre part la libéralisation du secteur de l'électricité a favorisé l'apparition de plusieurs acteurs sur le marché. Tout ceci entraîne de nouveaux défis de planification des réseaux électriques que le gestionnaire du réseau doit faire face afin de fournir l'électricité de façon fiable, sûre et durable aux consommateurs.

Ce chapitre présente les généralités sur les réseaux électriques en mettant un accent particulier sur les sources de production d'énergie électrique. Il est suivi d'une description de fonctionnement du marché de l'électricité ainsi que la problématique de la planification des réseaux électriques dans un contexte de marché libéral. La synthèse et l'objectif de la thèse sont présentés, puis terminé par un état de l'art sur la prévision de la charge électrique.

1.2 Sources de production d'énergie électrique

La figure 1.1 présente la majorité des principales sources primaires et leurs contributions dans la production mondiale de l'énergie électrique durant l'année 2018 [36]. Elle montre les sources de production classiques ou non renouvelables qui se classent en deux (02) grandes catégories : les sources d'énergies fossiles et fissiles ou nucléaires. Les sources production classiques occupent le premier rang dans la production mondiale de l'électricité suivies des énergies renouvelables.




FIGURE 1.1 – Part des sources primaires dans la production mondiale de l'électricité

1.2.1 Energies fossiles

Les énergies fossiles sont issues principalement du charbon, du pétrole, et du gaz naturel [37]. Elles proviennent du sous-sol et sont issues de la décomposition très lente de la matière organique des animaux ou végétaux, il y a de cela des millions d'années. Elles sont dites non renouvelables puisqu'après leur utilisation, elles ne peuvent pas être régénérées à l'échelle de temps humain (temps géologiques) comparativement aux ressources énergétiques renouvelables [38]. Riches en carbone, une importante quantité du dioxyde de carbone (CO_2) est émise lors de sa combustion pour produire de l'électricité. En plus du CO_2 , d'autres polluants sont émis conduisant au réchauffement de notre planète. En effet, les combustibles fossiles sont utilisés par des centrales thermiques (à flamme, cycle combiné et turbine à combustion). Le rendement de ces centrales thermiques est de 33% à 44% avec le charbon et de 60% pour celles à gaz à cycle combiné [39]. Malgré qu'il existe au-

aujourd'hui un paradoxe décrit par les associations de protection de l'environnement, la construction des centrales thermiques à sources fossiles continuent toujours par prendre de l'ampleur pour plusieurs raisons : la construction en un temps record de ces centrales, la grande flexibilité de leur technologie d'utilisation pour répondre efficacement à la demande de l'énergie électrique. Pour maîtriser les concepts clés des centrales thermiques, explorons leurs modèles.

1.2.1.1 Modèle des centrales thermiques

Elles sont largement utilisées partout, surtout dans les pays en voie de développement pour produire de l'électricité. Soient P_g et P_w , respectivement les puissances aux bornes de la génératrice et relative aux auxiliaires. En tenant compte des pertes dans les transformateurs de tension, la puissance nette P_{th} transmise aux systèmes électro-énergétiques est donnée par la relation (1.1).

$$P_{th} = (P_g - P_w) \cdot \eta_{tr} \quad (1.1)$$

où :

- P_g est la puissance aux bornes de la génératrice ;
- P_w est la puissance des auxiliaires ;
- η_{tr} est le rendement du transformateur.

La production de l'énergie électrique et les émissions des centrales thermiques nécessite un coût qui peut être modélisé.

1.2.1.2 Modèle de coût de production des centrales thermiques

La technologie des centrales thermiques transforme le combustible en électricité. Le coût de production d'une centrale thermique [29,40], est calculé par la relation (1.2).

$$C_{th}^i(P_{th}^i) = a_{th}^i \cdot (P_{th}^i)^2 + b_{th}^i \cdot (P_{th}^i) + c_{th}^i \quad i \in \Omega_{th} \quad (1.2)$$

Le coût de production de l'énergie pour un ensemble de centrales thermiques peut être déterminé par la relation (1.3).

$$CT_{th}^i(P_{th}^i) = \sum_{i \in \Omega_{th}} C_{th}^i(P_{th}^i) \quad (1.3)$$

où :

- $C_{th}^i(P_{th}^i)$ est le coût de production de la centrale thermique i ;

- Ω_{th} est l'ensemble des centrales thermiques de production d'électricité ;
- a_{th}^i , b_{th}^i , et c_{th}^i sont les coefficients du coût de production de la $i^{ème}$ centrale thermique.

1.2.1.3 Modèle de coût d'émission des centrales thermiques

Généralement les centrales thermiques, lors de la production de l'électricité émettent du dioxyde de carbone CO_2 , du dioxyde de soufre SO_2 , d'oxyde de nitrate NO_x qui à part leurs effets sur la couche d'ozone, présentent un degré de toxicité élevé [41, 42]. Dans ce contexte, l'amendement de Doha au protocole de Kyoto revu le 8 décembre 2012 pour les objectifs 2013-2020 sur la qualité de l'air [43], mandate les compagnies de production d'électricité à réduire les émissions de SO_2 à 10 million de tonnes par an et 2 millions par an pour NO_2 [41, 44], en les contraignant à rester dans ces proportions dans l'engagement de leurs unités de production avec une répartition optimale des sources si elles veulent atteindre les objectifs établis. Nous ne considérons que les émissions de CO_2 des centrales thermiques dans cette étude puisqu'elles constituent la principale source de réchauffement climatique. La quantité totale de CO_2 émise est donnée par la relation (1.4).

$$Em_{th}^i(P_{th}^i) = d_{th}^i \cdot (P_{th}^i)^2 + e_{th}^i \cdot (P_{th}^i) + f_{th}^i \quad i \in \Omega_{th} \quad (1.4)$$

Pour un ensemble de centrales thermiques, l'émission globale peut être déterminée par la relation (1.5).

$$TEm_{th}^i(P_{th}^i) = \sum_{i \in \Omega_{th}} Em_{th}^i(P_{th}^i) \quad (1.5)$$

où :

- $Em_{th}^i(P_{th}^i)$ est l'émission totale produite par l'unité thermique i ;
- Ω_{th} est l'ensemble des centrales thermiques de production d'électricité ;
- d_{th}^i , e_{th}^i , et f_{th}^i sont les coefficients d'émission de CO_2 de production de la $i^{ème}$ centrale thermique.

1.2.2 Energies nucléaires

Les énergies nucléaires proviennent de l'atome de l'uranium enrichi au plutonium dans les réacteurs nucléaires pour produire de l'électricité qui sera injectée dans les réseaux électriques très haute tension. L'énergie nucléaire peut être obtenue soit par fission ou fusion nucléaire [37, 45]. Les énergies nucléaires ne produisent ni du CO₂, ni des polluants aériens. Mais, leurs utilisations produisent des déchets radioactifs qui doivent être confinés du fait de la chaleur et des émissions radioactives générées, et dont la durée de vie peut atteindre des milliers d'années. De plus la sécurité des centrales nucléaires est problématique. Dans les décennies précédentes, les deux accidents majeurs survenus à Tchernobyl en 1986 et Fukushima en 2011 viennent donc confirmer cette problématique avec des bilans matériels, humains et environnementaux très lourds [46]. Bien que les sources fossiles soient les plus utilisées, la tendance nouvelle reste les énergies renouvelables.

1.2.3 Energies renouvelables

Les énergies renouvelables utilisent des forces ou des ressources dont les stocks sont illimités à l'échelle humaine : l'eau des rivières faisant tourner les turbines d'un barrage hydroélectrique, le vent brassant les pâles d'une éolienne, la lumière solaire excitant les photopiles ou cellules photovoltaïques, mais aussi l'eau chaude des profondeurs de la terre alimentant des réseaux de chauffage (géothermie). Sans oublier qu'avec les végétaux (biomasse), comme la canne à sucre ou le colza, grâce auxquels on peut produire des carburants automobiles ou des combustibles pour des chaudières très performantes. En plus de leur caractère illimité, ces sources d'énergie sont moins ou non polluantes. Le solaire, l'éolien, l'eau et la géothermie ne rejettent aucune pollution, lorsqu'elles produisent de l'énergie [47, 48]. La combustion de la biomasse génère certains gaz polluants, mais en bien moindre quantité que des carburants fossiles, tels que le charbon ou le fioul.

En dehors de l'hydroélectricité, la courbe de production mondiale (Figure 1.1) montre que deux (02) formes d'énergies renouvelables, à savoir les énergies solaires photovoltaïques et les énergies éoliennes connaissent durant ces dernières décennies une forte progression. Ceci, grâce aux subventions des états et du secteur privé, leurs facilités de mise en œuvre ainsi que les travaux de recherches existants qui montrent la maturité de ces formes d'énergies. Le vent et le soleil, on les trouve partout dans la nature de façon illimitée. L'Afrique, à l'instar le Togo, dispose d'un très grand potentiel solaire et éolien. Des études ont révélé qu'avec un parc solaire couvrant une

superficie de 10 000 km² dans le Sahara, on pourrait théoriquement couvrir toute la consommation énergétique mondiale [49, 50].

1.2.3.1 Centrales hydroélectriques

Ces centrales utilisent de l'énergie hydroélectrique issue de la force des chutes d'eau créées naturellement ou artificiellement grâce à des retenues de barrage pour produire de l'électricité, appelée l'hydroélectricité. Le processus de production de l'hydroélectricité est illustré sur la figure 1.2 [3]. On distingue plusieurs types de centrales hydrauliques. Cependant, du point de vue constitution, elles se ressemblent toutes.

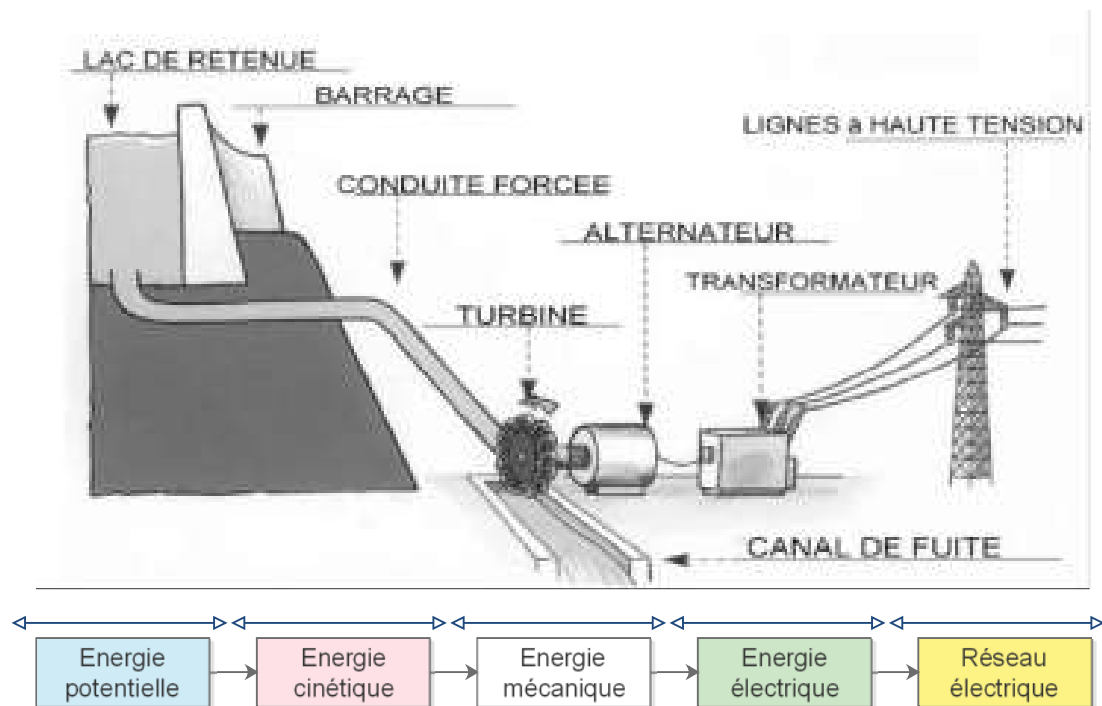


FIGURE 1.2 – Principe de l'hydroélectricité

plusieurs éléments rentrent dans la constitution d'une centrale hydraulique : l'unité de retenue ou de prise d'eau qui permet de créer une chute d'eau grâce à l'énergie potentielle exprimée par la relation (1.6). Généralement, le réservoir de stockage permet à la centrale de continuer par fonctionner durant les périodes de crue.

$$E_p = m \cdot g \cdot h \quad (1.6)$$

où :

- g est l'accélération de la pesanteur en m/s² ;

- m est la masse du fluide en kg ;
- h est la hauteur de chute du fluide en m.

Un canal de dérivation creusé peut permettre de dériver latéralement l'excédent d'eau arrivant vers un barrage. Un évacuateur de crues permet de faire passer les crues de la rivière sans danger pour les barrages. La conduite forcée permet d'utiliser la chute d'eau afin d'actionner les turbines qui ont pour rôle de transformer l'énergie cinétique de flux d'eau en une énergie mécanique (Relations (1.7) et (1.8)) entraînant un alternateur qui transforme cette énergie mécanique en énergie électrique qui sera injectée dans le réseau électrique.

$$E_c = \frac{1}{2} \cdot m \cdot v^2 \quad (1.7)$$

$$E_m = m \cdot \frac{P_r}{v} \quad (1.8)$$

où :

- v est la vitesse du fluide en m/s ;
- P_r est la pression du fluide en Pa ;
- ρ est la masse volumique du fluide en kg/m³.

En sommant les relations (1.7), (1.8) et (1.5), l'énergie totale par kg de fluide s'exprime donc par l'équation de Bernoulli, en introduisant une hauteur équivalente H utilisée par les hydrauliciens selon la relation (1.9).

$$\frac{E}{m} = \frac{v^2}{2} + g \cdot h + \frac{P_r}{\rho} = g \cdot H \quad (1.9)$$

La puissance d'une centrale hydraulique dépend de la hauteur de chute et du débit de l'eau et peut se calculer par la relation (1.10).

$$P_{hyd} = \rho \cdot g \cdot H \cdot Q \quad (1.10)$$

où :

- Q est le débit d'équipement en m^3/s ;
- H est la hauteur nette de la chute m.

Le type de turbine utilisé dépend de la hauteur de la chute d'eau [51]. On distingue les turbines à bulbe qui sont utilisées pour les très faibles hauteurs de chute allant de 1 à 30 m, Kaplan pour les faibles chutes (5 à 50 m) et débits importants, Francis pour les moyennes chutes (40 à 600 m) et moyen débit et Pelton adaptées aux hautes chutes allant de 200 à 1800 m et aux faibles débits. La puissance mécanique P_{mec} en sortie de la turbine hydraulique est obtenue à partir de la puissance hydraulique P_{hyd} et du rendement η_t de celle-ci. Elle est exprimée par la relation (1.11).

$$P_{mec} = \eta_t \cdot P_{hyd} = C_{turb} \cdot \Omega_{arbre} \quad (1.11)$$

où :

- η_t est le rendement de la turbine hydraulique ;
- P_{hyd} est la puissance hydraulique ;
- C_{turb} est le couple sur l'arbre de la turbine ;
- Ω_{arbre} est la vitesse de rotation de l'arbre.

1.2.3.2 Centrales solaires photovoltaïques

Les centrales solaires photovoltaïques, constituées de plusieurs champs solaires issus de la connexion en série ou en parallèle de plusieurs panneaux solaires photovoltaïques dont leur principe de fonctionnement se base sur l'absorption du rayonnement lumineux par les matériaux semi-conducteurs [3, 52, 53]. L'une des principales composantes à prendre en compte dans le dimensionnement d'un champ solaire photovoltaïque est le gisement solaire. Connaissant l'éclairement énergétique global H_{gh} (contribution des éclaircements directs, diffus et diffusés au sol), la puissance générée par un module photovoltaïque en kW pendant un temps Δt peut être exprimée par la relation (1.12).

$$P_{DC} = \frac{H_{gh}}{\Delta t} \cdot S \cdot \eta_{pv} \quad (1.12)$$

où :

- η_{pv} est le rendement de la cellule photovoltaïque (15% pour les monocristallins, 12% pour les polycristallins et 7% pour les amorphes) ;

- H_{gh} est l'éclairement énergétique global en W/m^2 ;
- S est la surface exposée des modules photovoltaïques en m^2 .

En fonction d'utilisation des panneaux photovoltaïques, nous distinguons trois (03) types de centrales solaires photovoltaïques : les centrales solaires photovoltaïques autonomes, hybrides et on-grid.

Plusieurs technologies existent de nos jours pour tirer le maximum de puissance produite par un champ solaire. Une d'entre elles la plus répandue est le Maximum Power Point Tracking (MPPT). Le régulateur MPPT permet d'ajuster la caractéristique électrique du module photovoltaïque en fonction de l'éclairement du soleil [3, 54]. La prise en compte de la conversion du courant continu (DC) en courant alternatif (AC) permet d'introduire η comme ratio de performance qui dépend de l'onduleur, la température, l'énergie perdue, etc. Il se calcule comme le rapport entre les rendements mesurés et théoriques. La puissance AC générée qui sera injectée dans le réseau électrique est exprimée par la relation (1.13).

$$P_{AC} = \eta \cdot P_{DC} \quad (1.13)$$

1.2.3.3 Centrales éoliennes

Une éolienne appelée aussi aérogénérateur convertit la force du vent en électricité. Comme le montre la figure 1.3, les éoliennes disposent d'une chaîne de transformation. L'énergie cinétique du vent est transformée en énergie mécanique ; ensuite le générateur transforme cette énergie mécanique en énergie électrique qui est finalement injectée dans le réseau en conformité aux normes électriques applicables [54].

Il existe différents types d'éoliennes. Les plus répandues sur le marché sont des éoliennes à axe horizontal constituées de pâles (3 en général), portées par un rotor et installées au sommet d'un mât vertical. Les éoliennes à axe vertical présentent un faible rendement aérodynamique, de fluctuations élevées de la puissance électrique, et sont plus utilisées dans les applications demandant un fort couple mécanique, ce qui les écarte du marché de production d'électricité. Dans cette thèse les éoliennes à axe horizontal sont considérées.

Pour chaque type d'éolienne, correspond une valeur optimale de la vitesse normalisée qui maximise le rendement aérodynamique. Ainsi un fonctionnement à vitesse de rotation variable, en fonction de la vitesse du vent, peut permettre de rester sur la valeur maximale de la courbe. Plus la caractéristique sera en cloche, plus il sera

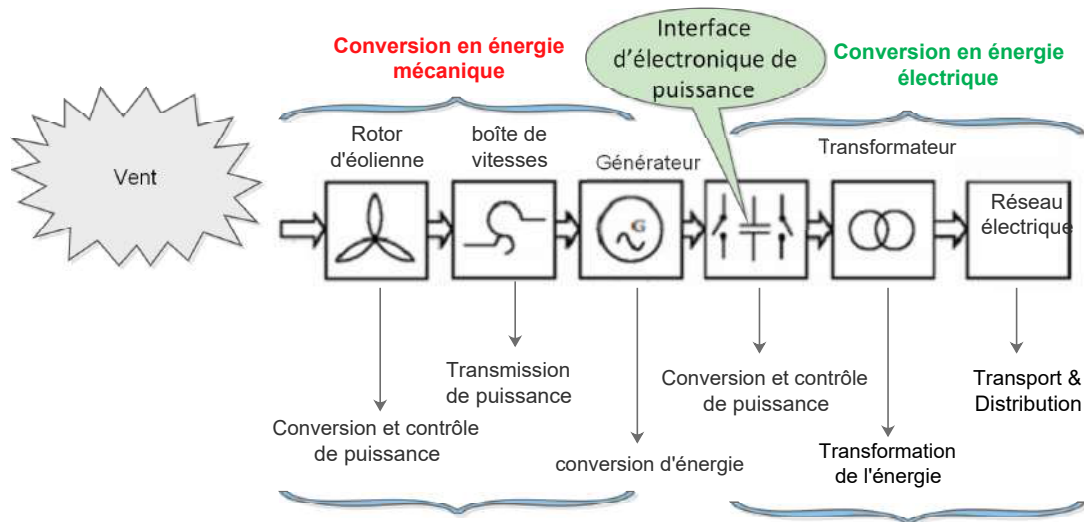


FIGURE 1.3 – Les différentes étapes de transformations énergétiques d'une éolienne

bénéfique d'adapter la vitesse de rotation à la vitesse du vent, afin de rester dans la zone optimale. Pour cette raison, une turbine éolienne est dimensionnée pour produire une puissance nominale P_n à partir d'une vitesse de vent nominale V_n . Dans le but d'éviter les surcharges mécaniques sur les turbines, le mât et la structure en général de la turbine éolienne doivent modifier ses paramètres aérodynamiques pour des vitesses de vent dont les valeurs sont supérieures à V_n de sorte que la puissance récupérée ne dépasse pas la valeur nominale pour laquelle l'éolienne a été dimensionnée. Il existe d'autres grandeurs importantes qui interviennent dans le dimensionnement d'une éolienne. Il s'agit de V_D , la vitesse du vent à partir de laquelle l'éolienne commence à fournir de l'énergie et V_M la vitesse maximale de vent au-delà de laquelle l'éolienne doit être stoppée pour des raisons de sûreté de fonctionnement. Le graphe, caractéristique de la puissance utile en fonction de la vitesse du vent, montré sur la figure 1.4 comporte quatre zones :

- dans la zone I, la vitesse du vent est inférieure à V_D . La turbine ne développe aucune puissance utile ;
- dans la zone II, la vitesse du vent est comprise entre V_D et V_n : la puissance fournie sur l'arbre dépend de la vitesse du vent ;
- dans la zone III, où généralement la vitesse de rotation est maintenue constante par un dispositif de régulation et où la puissance fournie reste sensiblement égale à P_n ;
- dans la zone IV, où la vitesse du vent est supérieure à V_M , le système arrête la rotation et le transfert de l'énergie.

La limite de Betz indique que la puissance théorique maximale produit par une éolienne par rapport à la puissance incidente du vent qui traverse l'éolienne [6]. La




FIGURE 1.4 – Courbe de puissance d'une éolienne

vitesse du vent en aval de la roue, n'étant jamais nulle, ceci implique que la puissance éolienne disponible n'est pas entièrement récupérée au niveau des pâles. Le potentiel énergétique récupérable au niveau de l'hélice est donné par la relation (1.14) [55].

$$P_{rec} = \frac{16}{27} \cdot \bar{P} \quad (1.14)$$

La production d'énergie électrique par aérogénérateurs peut se faire par diverses chaînes de productions différentes selon que l'on est en forte ou en petite puissance, en fonctionnement à vitesse fixe (ou faiblement variable) ou à vitesse variable. Ces solutions peuvent être classées par leur fonctionnement couplé ou non au réseau. En plus de la variabilité du vent qui présente de fortes incertitudes, la génératrice de l'éolienne produit de l'électricité à fréquence variable [56], qui doit être intégrée au réseau électrique. Une interface d'électronique de puissance est donc nécessaire pour connecter l'éolienne au réseau électrique (Figure 1.5). La partie électronique de puissance se compose d'un redresseur et d'un onduleur connectés par l'intermédiaire d'un étage à tension continue. L'onduleur est découplé de la machine à travers un bus continu et un lien direct entre la fréquence du réseau et celle délivrée par la machine. Cette interface doit être conçue de façon à limiter au minimum les perturbations qu'elle est susceptible de générer sur le réseau. En effet, la tension délivrée n'est pas sinusoïdale et peut contenir des harmoniques indésirables qui doivent être éliminées par des filtres [57]. Ajouté à ceci, les convertisseurs doivent être dimensionnés pour

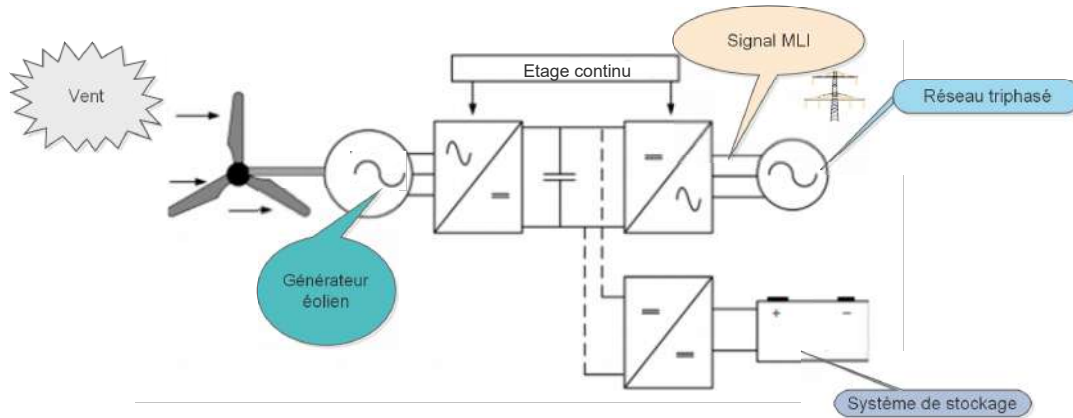


FIGURE 1.5 – Interface d'électronique de puissance d'une éolienne avec batterie connecté au réseau électrique

assurer le transit de la totalité d'énergie électrique générée par l'aérogénérateur au réseau électrique [6, 58].

Par ailleurs, le vent présente une forte intermittence dans le temps. Il faut un dispositif de stockage pour stocker l'énergie électrique produite qui sera restituée pendant les périodes de vent calme. Diverses technologies existent de nos jours et offrent des possibilités de stockage [59–61] : les stockages par batteries d'accumulateurs, hydraulique, thermique, supercondensateurs [62], etc. Toutefois, pour la production d'électricité, le stockage par batterie (plomb ou lithium-ion) est le plus utilisé. En dehors, de leurs volumes encombrants, les batteries s'adaptent mieux aux variations du vent.

1.2.3.4 Modèle du coût de production des énergies renouvelables

Pour des raisons de simplicité, dans ce document, une fonction de coût linéaire sera utilisée pour la production d'énergie électrique par un parc éolien, solaire photovoltaïque ou hydroélectrique [40]. Dans cette étude, les incertitudes des sources d'énergies renouvelables ne seront pas prises en compte. Puisque, l'approche que nous proposons est largement suffisante pour s'adapter à n'importe quel type de fonction de coût, et elle est exprimée par la relation (1.15).

$$CT_{ren}^i(P_{ren}) = \sum_{i \in \Omega_{ren}^i} C_{ren}^i \cdot P_{ren}^i \quad (1.15)$$

où :

- C_{ren}^i est le coefficient de coût direct de la $i^{\text{ème}}$ source renouvelable ;

- Ω_{ren}^i est l'ensemble de la $i^{ème}$ centrales de production d'électricité renouvelable ;
- P_{ren}^i est la puissance en AC produite par la $i^{ème}$ centrales de production d'électricité renouvelable.

L'électricité, après sa production est acheminée vers les consommateurs grâce aux réseaux électriques. La section suivante s'intéresse à la description des différents types de réseaux électriques, leurs topologies et classifications.

1.3 Description des réseaux électriques

Actuellement les réseaux électriques sont organisés en cinq classes suivant la gamme de tension U_n :

- le réseau de tension $U_n \geq 50\text{kV}$;
- le réseau haute tension classe A (HTA) dont $1\text{kV} \leq U_n < 50\text{kV}$;
- le réseau basse tension classe B (BTB) dont $500\text{V} \leq U_n < 1\text{kV}$;
- le réseau basse tension classe A (BTA) dont $50\text{V} \leq U_n < 500\text{V}$;
- le réseaux très basse tension (TBT) de tension $U_n < 50\text{V}$.

1.3.1 Réseaux électriques de transport

Les réseaux de transport n'acheminent pas que l'électricité depuis les centres de production vers les lieux de consommation (villes, usines, etc.), mais ils assurent également les interconnexions entre différentes régions au niveau national qu'international, ce qui les rend incontournables dans les systèmes électriques [3]. En effet, ce sont des lignes à très haute tension qui sont utilisées afin de minimiser les pertes Joules durant la transmission d'énergie électrique sur de longues distances. Du point de vue topologique, ils sont maillés pour des raisons de sécurité de fonctionnement. Les flux de puissance peuvent ainsi être répartis entre toutes les lignes du réseau. La gestion de ces réseaux est en revanche complexe. Les transferts de puissance entre zones de production et zones de consommation sont très importants et variables. De manière générale, comparativement aux réseaux de distribution, les réseaux de transport sont très supervisés afin de pouvoir effectuer des contrôles de la tension, fréquence, répartition des flux de puissance et coûts de production, etc.

Plusieurs coûts interviennent dans la réalisation d'un ouvrage du transport de l'énergie électrique. Le coût équivalent est composé des coûts de construction des lignes électriques, d'autres services, de génie civil, de la fourniture et pose des supports

électriques, etc. Les coûts de maintenance représentent 3% à 6%. Le coût de transit de l'énergie peut parfois atteindre 15% à 20% du coût global du projet avant sa durée de vie. Supposons un transit de puissance P_{tr}^k à travers une ligne électrique k tout en respectant les limites thermiques en fonctionnement normal des lignes P_{tr}^{max} d'un système électrique composé de N_L arcs de transport. Connaissant le coût moyen c_k par unité de capacité de la ligne k ainsi que les flux de puissance qui transitent chaque ligne électrique, le coût de transmission de l'énergie électrique à travers l'ensemble du système électrique est exprimé par la relation (1.16) [27, 63].

$$C_{tr} = \sum_{k \in \Omega_{N_L}} c_k \cdot P_{tr}^k \quad (1.16)$$

1.3.2 Réseaux électriques de répartition

Il s'agit des réseaux à haute tension dont la finalité est d'acheminer l'électricité du réseau de transport vers les grands centres de consommation qui sont soit, du domaine public avec l'accès au réseau de distribution HTA, soit du domaine privé avec l'accès aux abonnés à grande consommation (supérieure à 10 MVA) livrés directement en HTB. L'énergie dans les réseaux de répartition est injectée essentiellement par le réseau de transport via des transformateurs, mais également par des centrales électriques de moyennes puissances (inférieures à environ 100 MW). Ces réseaux de répartition sont distribués de manière assez homogène et ont une structure à la fois maillée et bouclée suivant les territoires des régions considérées.

1.3.3 Réseaux électriques de distribution

Les réseaux de distribution assurent la distribution de l'énergie électrique au niveau local. Ils sont constitués de deux types de réseaux : le réseau moyenne tension, et le réseau basse tension. Les consommateurs finaux de l'énergie électrique peuvent être très densément groupés comme dans les villes ou assez séparés les uns des autres par des distances relativement grandes comme dans les campagnes. L'énergie produite au niveau des centrales est ainsi acheminée par l'intermédiaire des réseaux de transport qui desservent les postes de répartition, ces derniers alimentent les réseaux de distribution, réseaux de distribution qui sont les derniers intermédiaires entre la source de production et le consommateur final. Des lignes de distribution à moyenne tension HTA sont issues du poste de répartition et alimentent les postes de transformation répartis en différents endroits de la zone à desservir. Ces postes de transformation abaissent la tension à une valeur convenable (400 V dans le cas des abonnés en basse tension) pour alimenter le réseau de distribution auquel les abonnés

sont raccordés. Les réseaux de distribution ont principalement une structure radiale c'est-à-dire une structure arborescente. Ainsi, le flux de puissance n'a qu'un trajet possible pour transiter du poste de transformation vers le point de consommation considéré [3].

1.4 Topologie des réseaux électriques

On entend par topologie d'un réseau électrique, l'ensemble des éléments qui le constituent (les composants) et les connexions entre eux.

1.4.1 Réseaux maillés

Dans les réseaux dits maillés, les connexions entre les composants du réseau forment des boucles réalisant une structure semblable aux mailles d'un filet. Dans ce type de réseau, l'énergie transportée vers un nœud y parvient par plusieurs parcours. Les réseaux maillés garantissent une très bonne sécurité d'alimentation, car la perte de n'importe quel élément (ligne électrique, transformateur ou groupe de production) n'entraîne pas automatiquement la coupure d'électricité. L'utilité du maillage est donc d'améliorer la fiabilité de l'ensemble du réseau en assurant une large continuité de service.

1.4.2 Réseaux bouclés

Ces réseaux sont considérés comme étant une simplification des réseaux maillés présentant un certain nombre de boucles fermées. Cette structure est adoptée pour les réseaux de répartition et de distribution. Dans ces réseaux, chaque ligne qui forme une boucle doit être alimentée à partir d'un même poste source HTB/HTA. Les postes têtes de pétales sont eux, connectés aux sources HTB/HTA par des conducteurs de section importante appelés câbles de structure [3, 64].

1.4.3 Réseaux radiaux


Le principe de fonctionnement des réseaux radiaux est à une seule voie d'alimentation. La représentation unifilaire d'un réseau radial est arborescente. En effet, il permet facilement et à moindre coût d'accéder à des points de consommation de faible densité de charge. Ce type de réseau peut présenter les boucles mais ces dernières sont normalement ouvertes. Le réseau radial est rencontré dans la distribution moyenne et basse tension [3].

1.4.4 Réseaux en antenne

Cette structure à une voie d'alimentation est simple et économique, mais elle n'offre pas de possibilité de reprise de service en cas d'incident. Pour obtenir une meilleure qualité de service, le réseau radial en antenne est parfois doublé à partir du jeu de barres du poste source. Chaque transformateur est raccordé aux deux câbles par un dispositif inverseur. En cas de défaut sur la première alimentation, il peut être basculé sur la deuxième, sans attendre que le tronçon en défaut ne soit identifié. La double dérivation est relativement coûteuse, aussi elle n'est utilisée que lorsqu'une grande continuité de service est nécessaire.

1.4.5 Postes électriques de transformation

Les postes électriques sont des éléments du réseau électrique intervenant aussi bien dans le transport que la distribution. Ils permettent d'élever la tension électrique afin de transporter l'énergie sur de longues distances depuis le lieu de production jusqu'au consommateur. Au niveau des consommateurs, ils interviennent encore pour faire redescendre la valeur de la tension en fonction du besoin. Les postes électriques se trouvent donc aux extrémités des lignes de transmission ou de distribution. Selon la définition de la Commission Electrotechnique Internationale (CEI), un poste électrique est la partie d'un réseau électrique, située en un même lieu, comprenant principalement les extrémités des lignes de transport ou de distribution, de l'appareillage électrique, des bâtiments et, éventuellement, des transformateurs. Les principaux éléments d'un poste électrique de transformation [65–67] sont présentés sur la figure 1.6. La libéralisation du secteur de l'électricité [68,69] dans le contexte actuel



Légende

- 1. Ligne électrique primaire ; 2. Câble de garde ; 3. Ligne électrique ; 4. Transformateur de tension ;
- 5. Sectionneur ; 6. Disjoncteur ; 7. Transformateur de courant ; 8. Parafoudre ; 9. Transformateur ;
- 10. Bâtiment secondaire ; 11. Clôture, 12. Ligne électrique secondaire

FIGURE 1.6 – Poste de transformation électrique

de la transition écologique fait apparaître de nouveaux producteurs sur le marché

qui se livrent à une compétition féroce à travers leurs offres. De ce fait, la mise en place d'un cadre réglementaire facilitera les transactions des flux de puissance entre grossistes et détaillants, puis entre détaillants et consommateurs à moindre coût suivant les négociations ou contrats entre les parties prenantes dans le but de fournir le produit de façon fiable, sûre et durable. Pour y arriver, il est important que le gestionnaire du réseau maîtrise le fonctionnement du marché de l'électricité.

1.5 Fonctionnement du marché de l'électricité

La figure 1.7 présente le principe de base du fonctionnement de marché de l'électricité, où *Poolco* définit un pool énergétique et GRT, le gestionnaire du réseau de transport [70].




FIGURE 1.7 – Modèle de base du marché de l'électricité

Une fois l'électricité injectée sur le réseau, il devient impossible de distinguer à qui elle appartient. Dans cette circonstance, le GRT met en place un système de traçabilité pour s'assurer du suivi et règlement des échanges entre les producteurs et fournisseurs. Toutes ces informations sont consignées dans un registre géré par GRT, qui comporte l'historique des transactions des puissances afin de les comparer avec les injections en temps réel sur le réseau électrique [71, 72]. Sur cette base, le régulateur doit définir clairement les modalités d'accès au réseau électrique suivant les coûts et aspects technologiques avant de laisser la place au GRT qui facilite les négociations entre les parties prenantes afin de satisfaire l'accroissement de la demande, tout en conservant une meilleure qualité du service rendu avec l'optimisation de dé-

penses et empreinte carbone. En effet, il existe deux principaux modèles de marché : le pool énergétique ou marché centralisé et le marché décentralisé [73].

Dans un pool énergétique, toutes les entreprises de production proposent des couples prix-quantité pour la fourniture d'électricité. Ces prix proposés peuvent être basés sur des coûts variables prédéterminés où les producteurs peuvent être libres de proposer le prix qu'ils souhaitent. Du côté de la demande, l'opérateur du marché peut prévoir la demande et allouer les unités de production en fonction de celle-ci. C'est ce qu'on appelle un pool unilatéral. Dans les pools bilatéraux, l'opérateur du marché peut allouer l'électricité en fonction d'une courbe de demande créée à partir des offres prix-quantités faites par les acheteurs du marché.

L'alternative au modèle pool est le marché basé sur des contrats bilatéraux. Cela signifie que les vendeurs et les acheteurs concluent librement des contrats bilatéraux pour la fourniture d'électricité. Les producteurs peuvent également devenir des acheteurs (en cas de pénurie de production). De même, les consommateurs peuvent devenir des vendeurs. Les courtiers peuvent servir d'intermédiaires entre les acheteurs et les vendeurs dans le cadre de contrats standards.

De façon argumentative, la principale raison de l'interconnexion de réseaux électriques est de minimiser les coûts de services liés à la fourniture d'électricité. Toutefois, elle met en mouvement des masses financières très importantes. Il est impératif que la tarification de l'électricité échangée doive faire l'objet d'un examen attentif et de négociations si l'on veut que toutes les parties en profitent. Une planification est nécessaire pour garantir la viabilité de l'interconnexion.

1.6 Revue littéraire sur la planification des réseaux électriques

Lors de la planification des réseaux électriques, il est très important de prendre en compte les aspects technico-économiques ainsi que les objectifs politiques afin d'aboutir à l'optimisation de l'ensemble du système électrique pour assurer un approvisionnement sûr et stable de l'électricité à moindre coût en conformité avec les exigences environnementales et technologiques.

C'est ainsi que certains travaux [74, 75], montrent l'actualité de la thématique qui mérite un regard particulier. Dans ce contexte, les auteurs présentent l'impact de

ces réformes sur trois (03) niveaux de l'ensemble du système électrique : au niveau des unités de production, côté réseau électrique, et au niveau de la demande. Ce qui a permis de proposer une approche mixte de planification des réseaux électriques propre au marché chinois. Toutefois, la demande n'est pas prise en compte. De plus, une étude de cas n'a pas été faite pour tester la validité de la méthode proposée.

Par ailleurs, les pays développés comme les Etats-Unis, l'Australie et la Grande Bretagne disposent des modèles de planification propre à leurs marchés [76] qui peuvent servir comme référence. Toutefois, ils affirment que la plupart des travaux de recherche entrepris se concentrent sur la compensation du marché.

Wang Wei et al [77], proposent l'application de l'algorithme des colonies de fourmis pour résoudre le problème de planification d'extension des réseaux électriques de transport. Les résultats obtenus montrent la performance de l'algorithme proposé. Cependant, l'horizon de la planification et le contexte d'applications réelles sont ambigus.

Ogunwolu et al [78], appliquent la programmation linéaire en nombres entiers mixte pour planifier les réseaux de distribution électrique afin de renforcer les capacités d'une sous-station électrique existante ou prévoir la construction d'une nouvelle dans la perspective de minimiser les frais des coupures de courant à travers une configuration optimale du réseau électrique. Des tests effectués sur les réseaux à 23 et 54 nœuds montrent l'efficacité de l'approche proposée. Toutefois, l'auteur affirme que ces modèles conviendraient mieux aussi aux réseaux de transport électrique.

Roger et al [79], proposent une approche déterministe d'optimisation du prix de l'électricité grâce aux informations collectées en temps réel sur le marché. Ce qui a permis d'élaborer une stratégie de planification et du dispatching des différentes unités de production pour desservir les consommateurs en fonction de leurs situations géographiques. Cependant, la formulation du problème d'optimisation utilise les contraintes associées au transport et à la demande pour trouver les solutions optimales grâce à la méthode de Lagrange sans clairement montrer l'applicabilité sur un type de réseau électrique donné.

Prakash Kerur et Chakrasal R.L. [68, 69], à travers leurs travaux ont montré que la restructuration du secteur de l'électricité a favorisé la dissociation des activités de production de celles du transport introduisant la concurrence sur le marché par

la création d'un pool énergétique. Par la suite, une analyse de la vulnérabilité du réseau électrique lors de la congestion a été faite sous Power World simulator afin de planifier les échanges de flux de puissances aux différents nœuds. La théorie des graphes [80] est aussi appliquée pour déterminer le plus court chemin permettant d'optimiser les coûts de transaction des flux de puissance de à travers les différentes lignes électriques sous le respect des contraintes technico physiques et thermiques de ces dernières. Cependant, l'aspect environnement n'est pas abordé.

Ngoffe et al [43] propose l'application de la méthode dite couloirs d'observation [81] pour résoudre le problème de Dispatching économique et environnemental. Il s'agit d'un problème d'optimisation avec des objectifs qui sont d'ordres économiques et environnementaux : la sélectivité et le dispatching des unités de production et la minimisation des gaz à effet de serre (NO_x et SO_2). Les résultats obtenus sont concluants avec une réduction de temps d'exécution par rapport à ceux de gamultiobj de Matlab. Toutefois, la minimisation de l'empreinte carbone n'est pas abordée alors qu'elle fait partie des principaux objectifs de « Act Air Amendement » [82].

Jian et al [83] présente l'état des lieux de la planification des réseaux de transport au cours de ces dernières années sous différents angles et discutent des problèmes d'incertitudes introduites par des réformes entreprises pour développement du marché de l'électricité. Par conséquent, de nombreuses méthodes de planification sont passées en revue [84–89]. Ce sont les méthodes d'optimisation mathématique, heuristique et de l'IA. Selon les auteurs, la planification du réseau de transport relève d'un problème d'optimisation multicritère qui se trouve au cœur de la recherche scientifique sur le marché de l'électricité.

1.7 Problématique la prévision à court terme de la charge électrique

Il est exigeant que l'électricité soit omniprésente 24 heures sur 24, 7 jours sur 7 pour satisfaire la demande qui fluctue aléatoirement au fil de la journée. Paradoxalement, trop d'électricité pour peu de demande entrainerait un risque de déconnexion des centrales du réseau. Réciproquement, trop de demande pour peu d'électricité pourrait se traduire par des dysfonctionnements ou pannes susceptibles d'influencer la stabilité et sécurité du réseau jusqu'à son effondrement complet, le blackout. Un autre défi technologique est qu'avec l'intégration des énergies renouvelables qui

peuvent varier fortement, les centrales classiques doivent compenser les fluctuations incessantes de la production renouvelable sur le réseau. D'autant qu'il est impossible de stocker l'électricité en grande quantité sur de longues périodes, dans le cas où l'évolution de la demande doit être assurée par plusieurs sources d'approvisionnement des différents réseaux électriques interconnectés, une étude de planification s'avère indispensable. L'état de l'art sur la planification des réseaux électriques qui présente l'état des lieux des travaux réalisés dans le domaine démontre que la libéralisation et les réformes du secteur de l'électricité ont permis la dissémination du processus de la planification. De ce fait, la synthèse des écrits recensés, nous a permis de relever les grands points ci-dessous :

- la planification des réseaux se fait à deux endroits du système électrique : côtés transport et distribution ;
- la planification est un processus évolutif qui utilise des approches multidisciplinaires pour répondre à des questions de plusieurs ordres au sein du système électrique qui se modernise perpétuellement ;
- la majorité des travaux de recherche effectués se concentrent sur les réalisés des pays développés et que peu d'études sont accordées aux pays sous-développés, particulièrement ceux d'Afrique Subsaharienne en matière de la planification des réseaux électriques ;
- une quasi-absence des pools énergétiques (marchés de l'électricité) par lesquels les pays interconnectés peuvent profiter de la complémentarité de leurs réseaux électriques pour échanger les flux d'énergie électrique ;
- le succès de la libéralisation et des réformes du secteur de l'électricité ont permis la restructuration du système (production, transport et fourniture d'électricité), ce qui permet aux spécialistes, chercheurs, de traiter les problèmes de façon spécifique ;
- les études ne spécifient pas ou clairement l'horizon de la planification ;
- aucun travail de recherche scientifique ne posent le problème d'une manière générale visant à rassembler en un, tous les objectifs de la planification des réseaux électriques.

Pour que les différentes parties prenantes puissent tirer profit des avantages du marché énergétique basé sur le modèle infra journalier, journalier, horaire, minute à l'avance, ou temps réel, cette étude tente de trouver un compromis entre ces composante pour une planification à court terme des réseaux électriques de transport interconnectés en résolvant la problématique à triple objectifs que cette étude s'est fixés : caractérisation des sources de production, prédiction de la demande, et optimisation du coût de transaction de l'électricité entre les réseaux de transport interconnectés

et de l’empreinte carbone.

On retrouve un éventail de modèles statistiques basés sur une forte connaissance de la théorie des probabilités (loi Gaussienne, log-normale log-logistique, Inverse-normale, Gamma, Weibull, Rayleigh, Gumbel, Beta, Erlang et Exponentielle) [17, 90–95] pour caractériser les sources de productions d’énergie électrique. D’autres méthodes comme les chaînes de Markov et la simulation de Monte-Carlo sont aussi utilisées pour prévoir la disponibilité des sources de production d’électricité. Toutefois, à cause de la variabilité des données électriques dans le temps et dans l’espace sans oublier leur qualité. Aucune conclusion ne peut être déduite en ce qui concerne l’existence d’une unique loi de distribution propre à la modélisation des données électriques [15, 16]. Par conséquent, ces fonctions de distribution présentent des erreurs d’ajustement non négligeables. Dans cette circonstance, il est conseillé (recommandé) d’utiliser d’autres types de fonctions de distribution, les modèles hybrides, notamment les mélanges de distributions pour modéliser les données de production d’énergie électrique [16, 17]. Dans le cas d’une modélisation par le modèle de mélange, les paramètres sont estimés par l’algorithme Espérance-Maximisation (E-M) [96, 97]. Cette alternative a accru les performances dans l’imagerie et la modélisation de la défaillance à plusieurs modes des matériaux industriels dans le cadre de l’ajustement des histogrammes de fréquences [98]. Dans le but de profiter des avantages de la méthode Espérance-Maximisation (E-M) et de la distribution Gaussienne, le mélange Gaussien est proposé pour les applications du marché de l’électricité dans le but de prévoir la disponibilité des sources de production d’énergie électrique des réseaux interconnectés.

Dans un processus où certaines des composantes qui compliquent l’utilisation du modèle sont à éliminer pour faciliter l’analyse des données par un modèle, la décomposition en ondelettes offre de meilleures perspectives.

De nos jours, les méthodes de Machine Learning sont largement utilisées pour prédire la demande en électricité. Ils s’agit des Réseaux de Neurones Artificiels (ANNs, pour Artificial Neural Networks), des Machines à Vecteur de Support (SVM, pour Support Vector Machine) et du Processus Gaussien (GP, pour Gaussian Process) peu connu [18, 19]. Les ANNs souffrent du problème de fluctuation des données où il est difficile de trouver un algorithme ou une règle d’apprentissage général. Ils présentent les difficultés de trouver la structure ou la topologie du réseau avec les essais de minimisation d’erreur. L’architecture des ANNs varie en fonction de la taille des données. Pour pallier à ce problème, l’utilisation de k-means serait une alternative. L’algorithme k-means est une méthode de clustering qui offre la possibi-

lité de trouver des patterns dans les données [18]. Pour les problèmes de régression, les méthodes SVM offrent peu de noyaux qui évaluent la similarité des données prédites et observées. Elles présentent une complexité de leur algorithme d'optimisation avec une consommation du temps de calcul, avec une charge plus élevée à cause des contraintes intervenant dans la résolution du problème. Avec peu de données, les modèles SVM sont moins performants [99–101]. Des études ont théoriquement prouvé que le GP est largement en avance sur les ANNs et SVM. Avec peu de données, le GP grâce à l'inférence bayésienne décrit mieux les motifs contenus dans les données. De plus, il est prouvé qu'un ANN avec une infinité de couche est un GP [19]. Le GP dispose aussi naturellement d'un intervalle de confiance (IC) qui capture directement l'incertitude du modèle pour les valeurs prédites contrairement aux ANNs. La seule difficulté serait d'obtenir un IC précis. La transformée en ondelettes pourra donc apporter sa contribution à ce problème grâce à sa capacité de comprendre toutes les informations contenues dans le signal.

la prise en compte des variables exogènes qui influencent la charge électrique limite l'application des modèles ARIMA dans le processus de prévision. Ce qui fait qu'il est délaissé par les chercheurs au détriment des modèles du Machine Learning à cause de ses mauvais résultats de prévision. Pour réduire considérablement les erreurs de prévision qui entraînent d'énormes pertes financières aux compagnies, la transformée en ondelettes peut être appliquée. Ainsi, le modèle hybride constitué de la transformée en ondelettes et ARIMA fait des exploits au cours de ces derniers temps qui se rivalise avec les méthodes du Machine Learning dans le domaine de prévision des séries temporelles.

A travers ce qui précède, nous constatons qu'un meilleur modèle de prédiction de la charge électrique contribuera à une meilleure planification optimisée des réseaux électriques. Ainsi pour y parvenir, la maîtrise des outils de prédiction de la charge électrique s'impose. Ces modèles sont utilisés par les agents de distributions pour la planification du dispatching et des ressources, l'achat et la production de l'énergie électrique, la commutation des charges, le développement des infrastructures, l'optimisation des coûts de fourniture de l'électricité, la planification de la maintenance du système électrique, etc.

1.8 Prédiction de la charge électrique

La prévision et la prédiction sont tous deux des termes plus ou moins liés et orientés vers l'avenir. Cependant, il existe une petite nuance entre ces deux termes. Par conséquent, il s'avère important de définir ces deux termes et mettre en évidence la différence entre eux.

Le terme prévision fait référence au processus d'analyse et d'élucidation d'un état futur concernant toute opération en cours. C'est un processus qui prend en compte le passé et les informations actuelles dans le but de prédire des faits pour les événements futurs.

La prédiction vient du latin "Pre" qui signifie avant et "dicer" signifiant dire. Bref, la prédiction est une déclaration qui explique un résultat possible ou un événement futur.

Prédire, c'est déclarer quelque chose avant la venue d'un événement, tandis que la prévision est faite sur la base d'une analyse des informations du passé. Dans la suite de cette étude, nous utiliserons la terminologie prévision de la charge pour définir l'extrapolation de la courbe de charge sur des instants futurs.

L'élaboration des modèles de prévision pour avoir une idée sur la quantité d'énergie électrique nécessaire est d'une importance capitale pour les compagnies électriques. Cela pose des défis majeurs dans l'acquisition et mise en œuvre d'outils de prévision fiables afin de permettre à tous les acteurs de maîtriser l'évolution future de la charge pour un bon équilibre du système électrique. Il faut donc trouver le modèle mathématique qui mime l'évolution de la charge électrique sur un horizon donné. Par ailleurs, la prise en compte des variables exogènes et endogènes est utile pour la construction du modèle. La prévision de la charge est un outil que les agents de distribution et les opérateurs utilisent dans la planification du dispatching et des ressources [102–104]. Elle aide à prendre des décisions importantes concernant l'achat et la production d'énergie électrique, la commutation de charge, et le développement des infrastructures. Également, elle joue un rôle crucial dans le fonctionnement des réseaux électriques à travers l'optimisation des coûts liés à la fourniture de l'électricité [105].

Par conséquent, un minimum de précision est requis dans l'évaluation des besoins futurs en électricité. Cette précision dépend généralement du jugement du prévi-

sionniste, mais il est difficile de se fier uniquement aux procédures analytiques pour tirer des conclusions. Puisque les erreurs de prévisions peuvent occasionner des coûts opérationnels importants [106]. D'après Hobbs et al [104], 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. Les recherches dans ce domaine sont nombreuses et couvrent plusieurs horizons de prévision : l'ultra court terme, le court terme, le moyen terme et le long terme sur le marché de l'électricité où les transactions se font en temps réel. D'où l'importance la prévision à court terme de la charge électrique.

1.8.1 Facteurs d'influence sur la demande en électricité

Difficile à stocker, l'électricité est produite en fonction des prévisions de consommation. Le marché de l'électricité repose donc sur une estimation des différents paramètres qui influencent la consommation d'électricité comme les variations météorologiques, les variations chronologiques, l'activité économique, les facteurs exceptionnels et les événements spéciaux présentés sur la figure 1.8. Selon l'analyse de ce profil, la charge présente une évolution cyclique au cours de l'année. Durant la journée, une pointe est atteinte le matin entre 8h-12h et une autre le soir entre 18h-21h.




FIGURE 1.8 – Variations cycliques de la charge électrique

1.8.1.1 La météorologie et le climat

Les variations météorologiques ou climatiques constituent un facteur clé de variation de la charge électrique. Elles sont pour une bonne part dues au climat tout au long de l'année. Les facteurs météorologiques comprennent la température, l'humidité, les précipitations, la vitesse du vent, la couverture nuageuse, le rayonnement solaire, etc. Le changement du temps influence le comportement du consommateur. L'usage de certains appareils comme le climatiseur, le chauffe-eau est directement conditionné par le temps qu'il fait. La température et les précipitations sont des facteurs météorologiques principaux qui sont souvent pris en compte dans la prévision de la charge électrique [107]. L'humidité relative est un autre facteur qui affecte l'évolution de la charge électrique. Dans le cas des zones chaudes ou humides, l'on constate qu'aux maxima de température, correspondent des maxima de consommation et des minima d'humidité et que les variations de température sont en opposition de phase avec l'humidité relative [108].

1.8.1.2 Les variations chronologiques

Le temps est un facteur qui influence fortement la variation de la charge. Le facteur temps concerne les périodes de l'année, les jours de la semaine et les heures de la journée. L'évolution de la charge électrique durant les jours ouvrables diffère les weekends. En plus, elle varie d'un jour à un autre. Par conséquent, on identifie trois cycles : journalier, hebdomadaire et annuel.

1.8.1.3 L'activité économique

L'activité économique impacte directement les statistiques sur la variation de la consommation énergétique. Au cours des vacances, la fermeture des entreprises occasionne une baisse significative de la demande en électricité. La production d'électricité est également ralentie dans les weekends, où la plupart des entreprises ferment. Le degré d'industrialisation et le prix de l'électricité ont aussi un impact significatif sur la variation de la charge électrique. Avec le développement des marchés de l'électricité moderne, la relation entre le prix de l'électricité et le profil de charge est encore plus forte [107]. L'environnement économique dans lequel fonctionne le fournisseur d'énergie aussi impacte les modes de consommation des clients. Les tendances économiques ont un impact significatif sur la tendance de la consommation. En règle générale, ces facteurs économiques fonctionnent avec des constantes de temps de plus d'une semaine. Ils ne doivent donc pas être pris en considération pour la prédiction à court terme. Ces effets sont directement observables sur les courbes

de consommation hebdomadaire.

1.8.1.4 Les facteurs exceptionnels

Les utilisateurs d'électricité sont de plus en plus diversifiés et le système électrique moderne se compose de nombreuses catégories d'utilisateurs. Bien qu'il ne soit pas possible de prédire comment chaque utilisateur consomme de l'énergie, la somme des charges totales de tous les petits utilisateurs offre de bonnes règles statistiques permettant de lisser les courbes de charge. Mais le démarrage et l'arrêt des charges importantes conduisent toujours à des impulsions évidentes sur la courbe de charge. Cela entraîne une perturbation aléatoire, puisque pour les opérateurs, l'heure de démarrage et d'arrêt des appareils par ces utilisateurs est tout à fait aléatoire du fait qu'il n'y a pas de règle évidente pour savoir quand et comment ils utilisent l'électricité du réseau. Lorsque les données d'une telle courbe de charge sont utilisées lors de la prévision de la charge, la composante d'impulsion de la charge rend complexe cette prévision. Du fait de leur caractère exceptionnel, aucune référence n'est disponible dans le passé. L'impact de tels événements est, de ce fait, impossible à prévoir.

1.8.1.5 Les événements spéciaux

Une autre source de perturbation de la charge électrique est formée des événements spéciaux. Ils sont connus à l'avance mais leurs effets sur la charge n'est pas connu. Pour un événement spécial typique comme la finale d'une coupe du monde de football, les opérateurs savent à coup sûr qu'il y aura une augmentation de l'utilisation de la télévision, mais ne peuvent pas estimer à priori la quantité d'énergie qu'il faudra pour satisfaire la demande. D'autres événements typiques comprennent les grèves, les fêtes et jours fériés influencent aussi la charge électrique.

1.8.2 Processus général de modélisation de la prévision

Supposons un ensemble de données d'entraînement D contenant T paires de vecteur x et de scalaire y selon la relation (1.17).

$$D = \{(x_t, y_t) | t = 1, \dots, T\} \quad (1.17)$$

où :

- y_t est une série temporelle ;
- x_t est un vecteur de dimension d : $x_t = [x_1, \dots, x_d]^{Tr}$

Tous les vecteurs d'entrée sont souvent combinés dans une matrice X , et les valeurs de sortie dans le vecteur de sortie Y . Le modèle général d'une série temporelle est donné par la relation (1.18).

$$y_t = f(x_t, \theta) + \epsilon_t \quad (1.18)$$

où :

- θ est le vecteur de paramètres ;
- x_t est l'observation au temps t ;
- ϵ_t est un bruit blanc.

La prévision à l'horizon h se fait en évaluant la fonction f au point de test x_{t+h} selon la relation (1.19).

$$y_{t+h} = f(x_{t+h}, \hat{\theta}) + \epsilon_t \quad (1.19)$$

où $\hat{\theta}$ est le vecteur des paramètres issus de l'apprentissage sur l'ensemble D des données d'entraînement [109].

1.8.3 Types de prévision de la charge électrique

On distingue globalement quatre (04) classes de prévision de la charge électrique par rapport à l'échelle de temps : les prévisions à long terme, moyen terme, à court terme et ultra-court terme [110]. Cependant, il existe des différences dans les définitions selon les types de scénario d'application et horizon de planification. La figure 1.9 montre la classification de la prévision de la charge électrique basée sur différentes échelles de temps.

1.8.3.1 Prévision à ultra-court terme de la charge électrique

La prévision à très court terme de la charge est principalement utilisée pour surveiller le fonctionnement du réseau électrique afin d'anticiper les fluctuations dans un intervalle de temps de quelques secondes sur une durée inférieure à l'heure [111]. Sur le marché de l'électricité, elle s'applique pour planifier les échanges de l'énergie électrique entre les différentes compagnies électriques.

1.8.3.2 Prévision à court terme de la charge électrique

La prévision de la charge à court terme fournit principalement des données pour une répartition optimale des centrales électriques [102, 112, 113]. La littérature montre

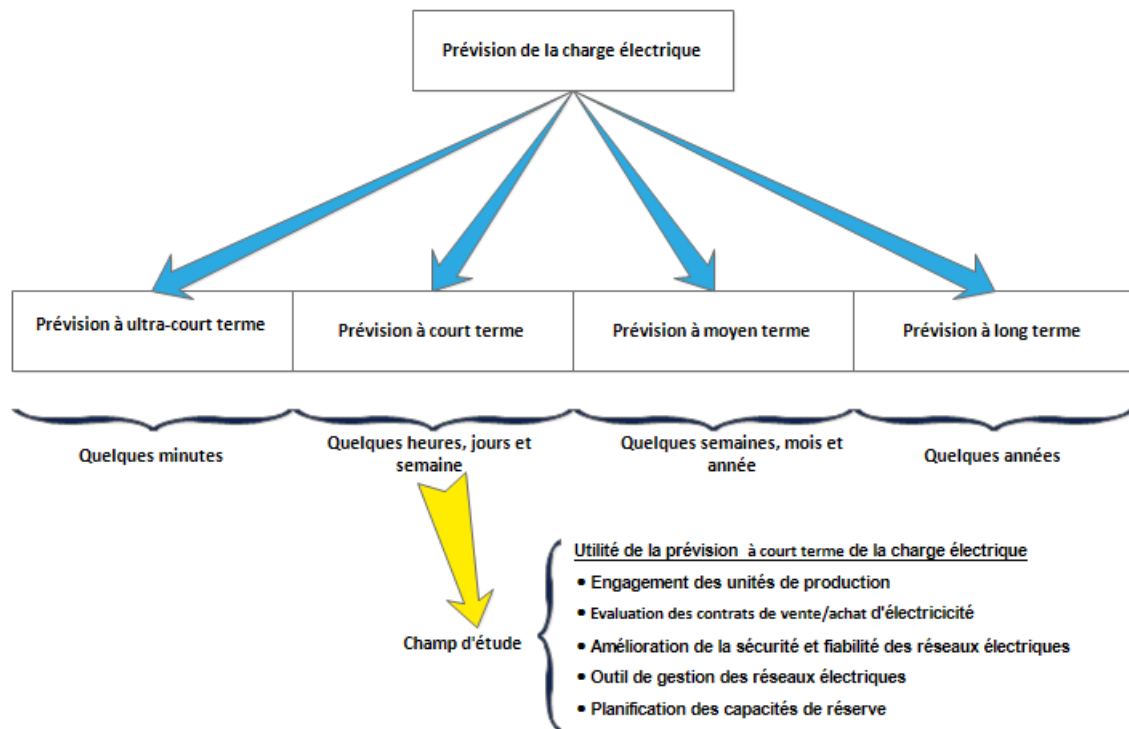


FIGURE 1.9 – Classification des types de prévision de la charge

que les recherches se sont principalement concentrées sur la prévision de la charge à court terme au cours de ces dernières décennies grâce à l'importance et au rôle vital qu'elle joue dans l'engagement optimal des unités de production, le contrôle de la réserve tournante, l'évaluation des contrats de vente/achat entre les différentes compagnies sur le marché de l'électricité [114]. Ce qui fait d'elle, le centre d'intérêt de notre étude.

1.8.3.3 Prévision à moyen terme de la charge électrique

La prévision de la charge à moyen terme consiste à prévoir la charge électrique dans les prochaines semaines, mois et saisons. Elle est utilisée pour élaborer des plans de maintenance du système électrique, [115,116] et la mise à la disposition du combustible nécessaire pour la production de l'énergie électrique.

1.8.3.4 Prévision à long terme de la charge électrique

Les prévisions de la charge à long terme sont utilisées pour le calcul et répartition de la demande future, la planification du système électrique et l'installation de nouvelles centrales électriques en fonction de la demande énergétique future, l'adoption du budget de l'entreprise, et la politique énergétique d'un état. De plus, elle est utilisée pour guider la transformation du réseau électrique.

1.8.4 Méthodes de prévision à court terme de la charge électrique

Différentes techniques ont été proposées dans la littérature pour la prévision de la charge électrique. Elles sont réparties en deux classes : les méthodes classiques [117, 118] et celles de l'IA [106, 119]. D'autres dites hybrides peuvent être rencontrées dans la bibliographie. Cette section présente les méthodes employées dans la prévision à court terme de la charge électrique sur le marché de l'électricité. De nos jours, les méthodes statistiques ont évolué et offrent des résultats innovants [119, 120] dans la prévision de la charge électrique. Les principales méthodes sont celles de régression, des jours similaires, de lissage exponentiel de Holt-Winters, de Gray, le filtre de Kalman et de Box & Jenkins.

1.8.4.1 Méthodes de régression linéaire et multiple

La régression est l'une des techniques statistiques les plus largement utilisées pour modéliser la relation entre la consommation d'énergie électrique et d'autres facteurs exogènes tels que le climat, le type de jour ou l'heure de la journée, etc. L'analyse par régression linéaire est aussi l'une des solutions qui existe pour montrer la corrélation qui existe entre une variable quantitative dépendante et plusieurs autres variables quantitatives indépendantes. On distingue la régression linéaire simple et la régression linéaire multiple [120–123] dont leurs expressions sont respectivement données par les relations (1.20) et (1.21).

$$y_i(t) = a_0 + a_1 \cdot x_i(t) + \epsilon(t) \quad (1.20)$$

$$y_i(t) = a_0 + a_1 \cdot x_i(t) + \dots + a_n \cdot x_n(t) + \epsilon(t) \quad (1.21)$$

où :

- y_i est la variable expliquée ;
- x_i est la variable explicative ;
- $\epsilon(t)$ est un bruit blanc ;
- a_0, \dots, a_n sont des coefficients de régression estimés par la méthode des moindres carrés.

1.8.4.2 Méthode des jours similaires

Cette approche consiste à rechercher des données historiques sur un, deux ou trois ans ayant des caractéristiques similaires avec le jour à prédire. Les caractéristiques similaires se basent sur la météo, le jour de la semaine et la date. La charge électrique d'une journée similaire est considérée comme la prévision. Au lieu d'utiliser la seule charge d'une journée similaire, la prévision peut être une combinaison ou une régression linéaire qui peut inclure plusieurs jours semblables. Les coefficients de régression obtenus peuvent être utilisés pour faire des prévisions au cours des années à venir [124].

1.8.4.3 Filtre de Kalman

Le filtre de Kalman [125] est un filtre à réponse impulsionnelle infinie qui estime les états d'un système dynamique à partir d'une série de mesures incomplètes ou bruitées. Il se limite aux systèmes linéaires. Cependant, la plupart des systèmes physiques sont non linéaires. Le filtre n'est donc optimal que sur une petite plage linéaire osculatrice des phénomènes réels. La non-linéarité peut être associée au modèle du processus, au modèle d'observation ou bien aux deux. Cette méthode de prédiction est de plus en plus délaissée.

1.8.4.4 Modèle de Gray

Le modèle de Gray (GM) utilise une petite quantité de données historiques pour construire des équations différentielles pour prédire les charges [126]. Premièrement, les données historiques sont accumulées pour générer de nouvelles séquences en vue de réduire le caractère aléatoire des données d'origine. Ensuite, les équations différentielles sont établies en utilisant la séquence générée. Par exemple, le modèle $GM(1,1)$ représente des équations différentielles d'ordre 1 avec une variable couramment utilisée dans la prévision de charge qui croît de manière exponentielle. De plus, Il est prouvé que la prévision nécessite moins de données et de calculs.

1.8.4.5 Lissage exponentiel

Le lissage exponentiel englobe une série de méthodes intuitives de lissage et de prévision apparues dans les années 1950. Au fil des années, ces méthodes ont laissé place à des spécifications rigoureuses. Ils permettent de mettre à jour les prédictions en $t + 1$ sur la base de moyennes pondérées des valeurs passées et s'exprime par la relation (1.22).

$$\mu_t = c_0 y_t + c_1 y_{t-1} + c_2 y_{t-2} + \dots \quad (1.22)$$

où $\mu_t \geq 0$ sont les poids définis suivant différentes manières. Si μ_t constitue la valeur prédite de la charge électrique y_t à $t + 1$, le modèle se base sous cette hypothèse pour attribuer des poids qui décroissent exponentiellement selon la relation (1.23).

$$c_i = \alpha (1 - \alpha)^i \quad (1.23)$$

Avec $i = 0, 1, 2, \dots$ et $\alpha \in [0, 1]$. C'est de là que vient l'appellation de lissage exponentiel. Plus le paramètre α est proche de 1, plus le passé immédiat influence la prévision. Ce schéma de pondération conduit à écrire la relation (1.24).

$$\mu_t = \alpha y_t + (1 - \alpha) \mu_{t-1} \quad (1.24)$$

1.8.4.6 Le modèle Persistance

Le modèle Persistance est souvent utilisé comme référence pour déterminer le facteur de compétence. Il est utile de savoir si un modèle de prévision donne de meilleurs résultats que n'importe quel modèle de référence trivial, qui est le modèle persistance [127]. Le modèle persistance considère que la charge électrique à l'instant $t + 1$ est égale à la charge électrique à l'instant t . Il suppose que les conditions atmosphériques sont stationnaires. Il est également appelé le prédicteur naïf.

$$y(t + 1) = y(t) \quad (1.25)$$

Sa précision diminue avec l'horizon de prédiction et n'est généralement pas adéquate pour plus de $1h$. Une version améliorée de ce modèle est le modèle persistance à l'échelle pour prendre en compte le fait que la prédiction à $t + 1$ n'est pas identique à t . La particularité des méthodes classiques est qu'elles n'arrivent pas à mieux modéliser les relations complexes et non linéaires entre les variables explicatives et la consommation d'électricité. Depuis de nombreuses années, les chercheurs tentent de développer des modèles précis de prévision de la charge électrique pour optimiser les revenus de la production et de la distribution de l'électricité. Ce qui conduit à l'élaboration des modèles robustes basés sur les techniques de Machine Learning.

1.8.4.7 Modèles de Box–Jenkins

Les modèles basés sur les séries temporelles utilisent des caractéristiques telles que l'autocorrélation, et la tendance de la variation saisonnière pour prédire la charge [128] et sont étudiés depuis des décennies jusqu'à nos jours. Les plus populaires sont ARIMA (Autoregressive Integrated Moving Average) et ARMA (Autoregressive Moving-Average) [129–131]. Généralement, on distingue deux catégories d'approches de prédiction des réalisations futures. L'une se concentre exclusivement sur les propriétés temporelles de la variable étudiée tandis que l'autre sur la relation entre la variable étudiée, son passé et d'autres variables explicatives exogènes.

La modélisation univariée d'une série temporelle se fait à l'aide d'une régression linéaire qui inclut deux composants : un terme autorégressif (AR) et une composante de moyenne mobile (MA). Le terme autorégressif (AR) est supposé être une combinaison linéaire des charges précédentes. La technique des moyennes mobiles (MA) peut s'exprimer comme une combinaison linéaire de bruits blancs à l'horizon t - q . Lorsqu'un processus $MA(q)$ est inversible, il peut être alors combiné avec un processus autorégressif $AR(p)$ pour construire un modèle à composants $AR(p)$ et $MA(q)$, appelé $ARMA(p, q)$. le modèle autorégressif peut être utilisé pour modéliser le profil de la charge comme indiqué par la relation (1.25) [132].

$$L_k = - \sum_{i=1}^m \alpha_{ik} L_{k-i} + \omega_k \quad (1.26)$$

où :

- L_k est la charge prédite à l'instant k ;
- ω_k est une perturbation aléatoire de la charge ;
- α_i sont des coefficients inconnus avec $i \in]1, m[$.

Les coefficients inconnus α_i peuvent être ajustés en utilisant l'algorithme des moindres carrés [133]. L'avantage du modèle autorégressif est sa simplicité. Cependant, la stationnarité des séries temporelles comme hypothèse limite leur application dans la prévision la consommation d'électricité [134]. Yves Aragon [135], propose la combinaison des modèles autorégressifs (AR) et moyenne mobile (MA) pour mieux capturer la dynamique sous-jacente, fruit de l'autocorrélation, des variations saisonnières et d'aspects aléatoires. Il s'agit du modèle $ARMA$. Les MA définissent la charge prédite en utilisant les données précédentes et actuelles des différentes perturbations (bruits) selon la relation (1.27). Pour un modèle ARMA

d'ordre (p, q) , l'équation prend la forme donnée par la relation (1.28).

$$y_{MA}(t) = a(t) - \theta_1 a(t-1) - \theta_2 a(t-2) - \dots - \theta_q a(t-q) \quad (1.27)$$

$$y(t) = \phi_1 y(t-1) - \phi_2 y(t-2) - \dots - \phi_p y(t-p) + y_{MA}(t) \quad (1.28)$$

L'identification des paramètres d'un modèle *ARMA* général peut être effectué par un système récursif, ou en utilisant la méthode de maximum de vraisemblance.

Lorsque le processus est non-stationnaire ou dynamique, la série doit être préalablement rendue à la forme stationnaire. Cette transformation peut être effectuée par une différenciation. Pour une série qui doit être d fois différenciées pour un processus *ARMA* (p, q) , le modèle *ARIMA* (p, d, q) [131, 136, 137] est exprimé par la relation (1.29).

$$\Phi(B) \nabla^d y(t) = \Theta(B) a(t) \quad (1.29)$$

La sélection des paramètres du modèle peut être effectuée sur la base des valeurs de critères spécifiques tels que les critères normalisés d'information d'Akaike (*AIC*) [18] suivant la relation(1.30).

$$AIC = 2k - 2\ln(L) \quad (1.30)$$

où :

- k est le nombre de paramètres à estimer du modèle ;
- L est le maximum de la fonction de vraisemblance (une fonction des paramètres d'un modèle statistique calculée à partir de données observées) du modèle.

La recherche de grille est utilisée pour explorer de manière itérative différentes combinaisons de paramètres. Une fois que nous aurons exploré l'ensemble des paramètres, notre ensemble optimal de paramètres sera celui qui donne les meilleures performances pour nos critères d'intérêt. Ce processus est appelé recherche par grille

(ou hyperoptimisation des paramètres) pour la sélection de modèles. La recherche sur grille consiste à générer les différentes combinaisons de paramètres qu'on veut évaluer. Lors de cette évaluation, une comparaison des modèles avec différents paramètres est effectuée selon la capacité de chaque modèle à prévoir avec précision les observations futures. Le modèle qui s'adapte aux données se verra attribuer un score plus élevé. En d'autres termes, le modèle qui aura la plus faible valeur de AIC .

Certaines séries temporelles comme la charge électrique, ont des comportements périodiques dus à des périodicités horaires, quotidiennes, hebdomadaires, mensuelles ou annuelles. Les modèles pour ces types de séries chronologiques sont connus sous le nom des processus saisonniers. Il existe une version saisonnière du modèle $ARMA(p, q)$, qui permet aux composants AR et MA de s'adapter aux cycles observés (semaine, mois, saison) [120]. On dénote ces modèles par $SARMA(p, q)$ ou encore qui peut s'écrire sous la forme $ARMA(p + sP, q + sQ)$, où s est la cyclicité du processus (ex : $s = 12$ pour un cycle mensuel), p et q sont les paramètres habituels de $ARMA$ non saisonnier et P , Q et s sont des paramètres spécifiques à la composante saisonnière. Il est alors indiqué de résoudre le problème en modélisant le résidu lui-même par un $ARMA$ ayant pour unité de temps la période de la saisonnalité. On obtient alors un modèle $ARMA$ saisonnier sous l'hypothèse de la stationnarité [135]. Des modèles dynamiques équivalant à ceux présentés ci-dessus existent pour les séries non stationnaires, pour lesquelles la non-stationnarité est d'origine stochastique. Il s'agit des modèles $ARIMA(p, d, q)$ et $SARIMA(p, d, q)$, qui sont des modèles adaptés aux séries qui deviennent stationnaires par différenciation d'ordre d pour la partie non saisonnière et d'ordre D pour la partie saisonnière. Lorsqu'un processus $ARMA(p, q)$ ou $ARIMA(p, d, q)$ est identifié pour modéliser une série chronologique, des variables explicatives exogènes dont l'influence directe est soupçonnée peuvent lui être ajoutées. Cela donne naissance à des modèles appelés $ARMAX$ ou $ARIMAX$ [24]. La composante X du modèle indique que le processus dépend de variables explicatives exogènes. Lorsque l'effet des variables explicatives sur la consommation de l'électricité est non linéaire, certains auteurs font appel à une fonction non-linéaire qui prend compte de certaines variables exogènes sur de consommation d'électricité. Une multitude de méthodes classiques qui permettent de modéliser la consommation d'électricité existent dans la littérature. Pourtant, le grand nombre des variables qui influencent la consommation d'électricité font qu'elles sont devenues obsolètes au détriment des méthodes de l'IA qui sont prometteuses de nos jours [138].

1.8.5 Machines à vecteurs de support

Les machines à vecteurs de support (ou de l'anglais SVM, Support Vector Machine) sont des techniques d'apprentissage supervisé dotées de nombreuses propriétés qui en font d'elles des algorithmes puissants et populaires [139]. Elles disposent d'une base théorique solide et offrent des résultats plus précis que la plupart des autres algorithmes du Machine Learning largement utilisés dans de nombreuses applications, particulièrement la prévision des séries temporelles dans le secteur de l'électricité [23, 140]. De plus, nombreux chercheurs ont montré que les méthodes SVM offrent de meilleures précisions pour la résolution des problèmes de classification et de régression [141]. Malgré les similitudes structurelles dans la fonction de sortie, les modèles SVM diffèrent de ceux des réseaux de neurones artificiels (ANN, Artificial Neural Networks) de la façon dont les solutions sont obtenues [99, 142] : par optimisation convexe pour trouver un minimum global et une solution unique pour les SVM, tandis que l'utilisation de la méthode de descente de gradient dans le cas des ANN, qui peuvent ne pas converger vers la solution optimale/globale [100, 142]. Contrairement aux modèles SVM, Les ANN peinent de trouver sur le plan architectural, la topologie optimale avec des essais de minimisation des erreurs [23]. Côté complexité, la résolution du problème d'optimisation quadratique, les modèles SVM exigent la consommation d'un temps de calcul et une mémoire assez importante à cause des contraintes intervenant dans la résolution du problème comparé aux ANNs [99–101].

1.8.6 Processus Gaussien

L'objet principal de notre étude peut ainsi être compris comme une fonction f définie sur un espace quelconque D et qui prend ses valeurs dans \mathbb{R} . Le problème dans la pratique est que l'on observe en général cette fonction que pour un ensemble fini des données observées présentant une incertitude. Dans de nombreux cas, l'utilisation d'un modèle paramétrique est efficace pour modéliser un phénomène grâce à des hypothèses qui sous-tendent le choix du modèle. Cependant, il arrive dans certains cas que le modèle choisi ne s'adapte pas aux données, ou bien qu'aucun argument ne pourrait confirmer le privilège d'un modèle au détriment d'un autre. Dans ces cas, l'approche paramétrique touche à ses limites. Il devient essentiel d'utiliser un modèle qui permet une plus grande souplesse. Un Processus Gaussien implémente un modèle capable de modéliser des comportements fortement non linéaires tout en étant capable de faire des prédictions avec des ensembles de données d'entraînement petits et rares [19]. De plus, il fournit une distribution prédictive définie par la valeur

moyenne et la variance. La principale difficulté des autres approches non paramétriques est bien entendue de pouvoir attribuer une probabilité à chaque élément d'un ensemble aussi grand que l'ensemble des \mathbb{R} . C'est sur ce point que les processus gaussiens interviennent comme des distributions sur des espaces de fonctions appelées kernel ou noyau. Il établit une distribution sur les données par inférence Bayésienne, de la même manière qu'une distribution gaussienne considère le cas de vecteurs d'une longueur finie. C'est une technique robuste de modélisation des données à fort pouvoir d'interpolation non gourmande en données d'une part, et d'autre part permet d'avoir naturellement une bonne idée sur l'intervalle de confiance pour les valeurs prédites comparées aux autres méthodes de prévision. Ce qui prouve que l'utilisation du Processus Gaussien permet d'atteindre des performances. Le fait d'utiliser le Processus Gaussien comme méthode d'apprentissage non-paramétrique permet une grande flexibilité lors de la modélisation des données d'entraînement. En effet, l'optimisation du réseau électrique présente beaucoup d'incertitudes. Naturellement l'application du processus gaussien nous permet non seulement de faire une prévision de la charge électrique mais aussi donne directement la probabilité associée aux incertitudes de prévision. L'application des ondelettes serait donc d'un atout inestimable pour une meilleure amélioration de l'intervalle de confiance. Outre, d'après les travaux de Blum et Riedmiller [24], le Processus Gaussien ne nécessiterait pas des variables liées au climat et au temps pour approximer la charge électrique.

1.9 Conclusion

Ce présent chapitre a eu pour objectif d'exposer le contexte et le positionnement de la problématique de la planification des réseaux électriques dans un contexte de marché libéralisé. Il est donc mentionné par la suite que la seule difficulté de la planification est de trouver un compromis entre la planification des unités de production, la gestion prévisionnelle de la demande et l'optimisation du coût des échanges des flux de puissance entre les réseaux interconnectés dans le respect des capacités des lignes électriques qui doivent assurer le transit de l'électricité dans le respect des politiques environnementales et réglementations en vigueur afin de gérer l'équilibre offre-demande tout en assurant une meilleure stabilité du réseau électrique. Ce qui passe par la résolution de la problématique à triple objectifs que cette étude s'est fixé : la caractérisation des sources de production, la prédiction de la demande en électricité, et l'optimisation du coût de transaction de l'électricité entre les réseaux de transport interconnectés ainsi que l'empreinte carbone.

Chapitre 2

Approches de planification à court terme des réseaux électriques de transport interconnectés

2.1 Introduction

Trouver une meilleure adéquation entre les capacités de production et les réseaux de transport et de distribution disponibles à court, moyen et long terme pour répondre à l'évolution future de la demande en électricité est d'une importance capitale pour les acteurs du marché de l'électricité. En plus de cela, le contexte actuel de la transition écologique exige des décisions rationnelles qui doivent être prises afin d'éviter les erreurs de planification conduisant à des pertes financières considérables et à l'effondrement du marché. Cela suscite le développement et la mise en œuvre de méthodes robustes et flexibles pour la planification des réseaux électriques.

Ce chapitre expose dans une première partie, les approches probabilistes pour caractériser les sources de production d'un système énergétique afin de prévoir les incertitudes et les disponibilités des unités de production afin de planifier des ressources nécessaires à allouer pour résorber la demande à un coût réduit. L'autre objectif est de formaliser le problème de prévision à court terme de la demande en électricité afin d'identifier et de proposer des approches de Machine Learning les plus appropriées. Enfin, la dernière partie du chapitre présente la formulation du problème d'optimisation des coûts de transactions de l'électricité entre les réseaux interconnectés et émissions des GES par programmation quadratique (PQ).

2.2 Approche probabiliste pour la caractérisation des sources de production d'électricité

L'élaboration d'un modèle probabiliste pour caractériser la distribution des sources de production d'électricité est d'une importance capitale dans le secteur de l'énergie [17]. De ce fait, considérons la production X comme variable aléatoire sur un univers Ω , prenant des valeurs x_i avec $i \in \{1, 2, \dots, n\}$. On définit sur Ω , une loi de X qui $\forall x_i$, on associe la fonction de distribution $f(x_i)$ [143]. La fonction de répartition F est définie par la relation (2.1) avec un seuil α donné. Selon la représentation graphique de la fonction de répartition ou de distribution (Figure 2.1), il existe une loi de distribution suivie par les données de charge ou de production. Ainsi, le GRT pourra aisément prédire la probabilité d'apparition d'une pointe au niveau de chaque source.

$$F(\alpha) = P_r(X \leq \alpha) = \int_{-\infty}^{\alpha} f(x) dx \quad (2.1)$$

2.2.1 Présentation des lois de probabilités sélectionnées

Les travaux de recherches présentés dans cette thèse se restreignent à l'appropriation des lois de Gauss, Weibull, Rayleigh, Exponentiel et loi Skewnormale ou Normale asymétrique pour modéliser les sources de productions d'énergie électrique. Le tableau 2.1 présente le détail sur les lois de probabilité utilisées [17].

TABLEAU 2.1 – Lois de probabilités sélectionnées

Loi de distribution	Fonction de de distribution	Fonction de répartition	Domaine
Normale	$\frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right]$	$\frac{1}{2}\left[1 + \operatorname{erf}\left(\frac{x-\mu}{\sigma\sqrt{2}}\right)\right]$	$x \in \mathbb{R}; \mu > 0; \sigma > 0$
Skewnormale	$\frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right)$	$\frac{1}{2}\left[1 + \operatorname{erf}\left(\frac{x}{\sqrt{2}}\right)\right]$	$x \in \mathbb{R}$
Exponentielle	$\lambda \exp(-\lambda x)$	$1 - \exp(-\lambda x)$	$x \geq 0; \lambda > 0$
Weibull	$\frac{k}{\lambda} \left(\frac{x}{\lambda}\right)^{k-1} \exp\left[-\left(\frac{x}{\lambda}\right)^k\right]$	$1 - \exp\left[-\left(\frac{x}{\lambda}\right)^k\right]$	$x \geq 0; k > 0; \lambda > 0$
Rayleigh	$\frac{2x}{\lambda} \exp\left[-\left(\frac{x}{\lambda}\right)^2\right]$	$1 - \exp\left[-\left(\frac{x}{\lambda}\right)^2\right]$	$x \geq 0; \lambda > 0$

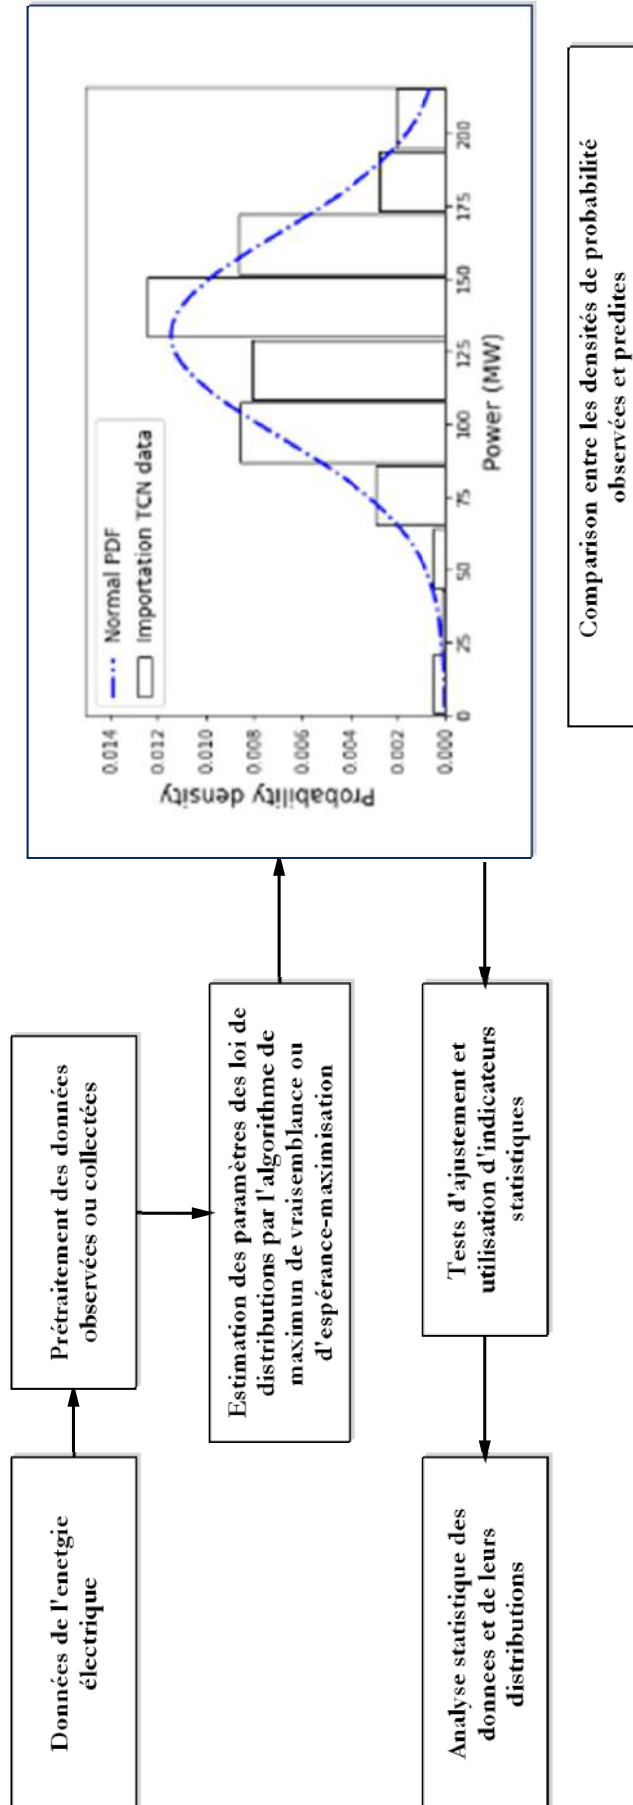


FIGURE 2.1 – Méthodologie de modélisation statistique des sources électriques

Les paramètres définissant chaque fonction de distribution sont estimés par la méthode du maximum de vraisemblance. Dans une telle estimation, étant donné les valeurs de l'ensemble de données $X = \{x_1, x_2, \dots, x_n\}$ et une fonction de distribution f supposée avec un paramètre θ inconnu, la fonction de vraisemblance L_f est donnée par la relation (2.2). Le paramètre θ est alors déterminé en maximisant L_f .

$$L_f(x_i|\theta) = \prod_{i=1}^n f(x_i|\theta) \quad (2.2)$$

Grâce au théorème de central limite, l'estimation par intervalle de confiance IC de la moyenne avec un seuil de risque accepté α est donné par l'expression de la relation (2.3). Cet intervalle est choisi de telle façon que la probabilité pour qu'il contienne la valeur inconnue du paramètre soit connue à l'avance, aussi grand que l'on veut. Ceci permettra aux différents acteurs du secteur d'électricité, d'estimer avec précision leur propre gestion, planifier l'intégration d'autres sources ainsi que la surveillance des situations qui s'écartent de la normale.

$$P_r \left(\mu - h \frac{\sigma^*}{\sqrt{n-1}} < \mu < \mu + h \frac{\sigma^*}{\sqrt{n-1}} \right) = 1 - \alpha \quad (2.3)$$

où :

- μ est la moyenne arithmétique de l'échantillon ;
- σ^* est l'écart type de l'échantillon ;
- h est le fractile lu sur la table de Student de degré de liberté $n - 1$;
- α est le seuil de risque.

Dans de nombreuses applications quotidiennes, les statistiques sont la disposition des tests que les analystes utilisent pour faire des inférences à partir des données. Ces tests permettent de valider des hypothèses et prendre des décisions sur la base de modèles à partir de données observées. Il existe un large éventail de tests statistiques : les tests t, Z, chi carré, anova, binomial, Kolmogorov–Smirnov, etc. Le choix du test statistique à utiliser dépend de la structure des données, de la distribution des données et du type de variable. Nous avons utilisé le test de Kolmogorov–Smirnov (K-S) pour comparer un échantillon avec une distribution de probabilité de référence. Le test (K-S) peut intervenir dans la comparaison deux échantillons, car il ne fait aucune hypothèse sur la distribution des données.

2.2.2 Test d'ajustement de Kolmogorov-Smirnov

Le principe du test K-S consiste à mesurer l'écart maximum qui existe soit entre une fonction de répartition empirique et une fonction de répartition théorique, ou entre deux fonctions de répartitions empiriques. Dans le premier cas, soit une fonction de répartition empirique F^* , et F la fonction de répartition théorique. On définit une variable de décision par la relation (2.4).

$$d = \sup_x |F^*(x) - F(x)| \quad (2.4)$$

Soit D une statistique qui prend aléatoirement la valeur de d . Sous l'hypothèse H_0 définie par la relation (2.5). Il est évident que la statistique d tend vers 0. Au cas contraire, on définit H_1 , une hypothèse alternative.

$$\begin{cases} H_0 \longrightarrow F^*(x) = F(x) \\ H_1 \longrightarrow F^*(x) \neq F(x) \end{cases} \quad (2.5)$$

La distribution de D fait l'objet des tables de K-S ou des logiciels informatiques qui prennent en compte l'effectif de chaque échantillon avec un seuil de risque α accepté. L'hypothèse H_0 est acceptée lorsque d est inférieur à D . De plus, une probabilité p appelée p-valeur (p-value en anglais) est utilisée dans les tests d'hypothèses pour rejeter, ou non, l'hypothèse nulle. Plus p-valeur a une valeur petite, plus la probabilité de faire une erreur en rejetant l'hypothèse nulle est faible. Une valeur limite de $\alpha = 0,05$ est souvent utilisée. Autrement dit, l'hypothèse nulle peut être rejetée si la valeur de p-valeur est inférieure à 0,05.

Dans la réalité, la distribution de données électriques est multimodale. Dans ce cas, les mélanges de lois de distributions conviennent le mieux pour décrire ces données. Dans cette étude, nous utiliserons le modèle de mélange gaussien dans la suite, pour améliorer la prévision des incertitudes auxquelles sont soumises les sources de production d'énergie électrique.

2.2.3 Modélisation par mélange de distributions gaussiennes

La densité de probabilité d'un modèle de mélange gaussien est constituée d'une combinaison linéaire de deux ou plusieurs lois de distributions gaussiennes [144]. Le modèle de mélange gaussien est particulièrement utilisé dans le cas où les données d'études ne peuvent pas être modélisées par une simple loi de distribution. Le modèle

de mélange gaussien est exprimé selon une densité de mélange et se caractérise par le nombre de composantes dont chacune affectée par son poids, sa moyenne et sa variance. La somme de tous les poids doit être égale à l'unité. la fonction de densité de probabilité d'un modèle de mélange de distribution s'exprime par la relation (2.6).

$$f(x|\theta) = \sum_{i=1}^m \pi_i f(x|\mu_i, \Sigma_i) \quad (2.6)$$

où :

- m est le nombre de composantes du mélange ;
- π_i est le poids de la composante du $i^{\text{ème}}$ mélange, sous la contrainte $\pi_i \geq 0$ et $\sum_{i=1}^m \pi_i = 1$;
- θ est choisi dans l'ensemble des paramètres $\Gamma = \{\mu_i, \pi_i, \Sigma_i\}_{i=1}^m$ dont un membre définit un mélange de distribution.

Soit une variable aléatoire X définie dans un espace de dimension d , avec une moyenne μ_i et une covariance Σ_i . La fonction densité de probabilité de chaque composante du mélange $f(x|\mu_i, \Sigma_i)$ d'une distribution normale s'écrit sous la forme exprimée par la relation (2.7).

$$f(x|\mu_i, \Sigma_i) = \frac{1}{(2\pi)^{\frac{d}{2}} \det(\Sigma_i)^{\frac{d}{2}}} \exp\left(-\frac{1}{2}(x_i - \mu_i)^T \Sigma_i^{-1} (x_i - \mu_i)^T\right) \quad (2.7)$$

Pour le cas particulier où une fonction de distribution est représentée par une somme pondérée de deux fonctions de densité normalement distribuées de paramètres $\pi_1, \pi_2, \mu_1, \mu_2, \sigma_1^2$ et σ_2^2 , la fonction densité de probabilité résultante est exprimée par la relation (2.8).

$$f(x|\mu_1, \mu_2, \sigma_1^2, \sigma_2^2) = \pi_1 \cdot \mathcal{N}(\mu_1, \sigma_1) + \pi_2 \cdot \mathcal{N}(\mu_2, \sigma_2) \quad (2.8)$$

avec :

$$\pi_1 + \pi_2 = 1 \quad (2.9)$$

où $\mathcal{N}(\cdot)$ définit la loi normale présentée dans le tableau 2.1. L'équation (2.10) montre

que la fonction de répartition du modèle de mélange probabiliste est une combinaison convexe des deux densités de lois de distribution gaussienne.

$$F(x|\mu_1, \mu_2, \sigma_1^2, \sigma_2^2) = \pi_1 \cdot F(\mu_1, \sigma_1) + \pi_2 \cdot F(\mu_2, \sigma_2) \quad (2.10)$$

L'estimation des paramètres se fait donc par l'algorithme Espérance-Maximisation (E-M). Les détails d'E-M pour obtenir les paramètres d'un modèle de mélange probabiliste adaptés à une distribution sont décrits dans la section suivante.

2.2.4 Estimation des paramètres de mélange de distributions par algorithme d'Espérance-Maximisation

L'Algorithme espérance-maximisation en anglais "Expectation-Maximisation algorithm", souvent abrégé "E-M", proposé par Dempster et al. en 1977, utilise l'approche de Bayes pour estimer les paramètres de modèles de mélange de lois probabilistes. C'est une méthode générale utilisée pour estimer par maximum de vraisemblance les paramètres d'une loi de distribution d'un ensemble de données lorsque celles-ci sont incomplètes, présentent des valeurs manquantes ou encore des informations cachées [96]. C'est un algorithme itératif, qui consiste à estimer en alternance, les probabilités à posteriori des variables latentes (étape E) et les paramètres du modèle (étape M). On utilise ensuite les paramètres trouvés en M comme initialisation d'une nouvelle phase d'évaluation de l'étape E jusqu'à la convergence finale. Il s'utilise dans divers domaines d'application tels que la reconnaissance de formes, la classification de données, l'apprentissage machine, la vision artificielle par ordinateur, etc.

2.2.4.1 Approche d'estimation Bayésienne

Soit X un ensemble de n échantillons de données de distributions incomplètes tel que $X = \{x_1, x_2, \dots, x_n\}$ et $Y = \{y_1, y_2, \dots, y_n\}$ un vecteur inconnu, tel que $y \in \Gamma$. Chaque y_i se réfère à une composante du mélange à travers laquelle une observation x_i est évaluée. Supposons qu'il existe des données complètes $D = (X, Y)$, et posons une fonction de densité de probabilité conjointe de paramètre γ issue d'une dépendance conditionnelle définie par la relation (2.11) grâce au théorème de Bayes.

$$f(X, Y|\gamma) = f(Y|X, \gamma) \cdot f(X|\gamma) \quad (2.11)$$

Notre but consiste à rechercher le paramètre γ qui maximisera la log-vraisemblance

définie par la relation (2.12). L'estimation des paramètres par l'E-M se fera donc par les étapes d'Estimation et de Maximisation jusqu'à l'obtention des paramètres optimaux.

$$L(\gamma|X, Y) = \sum_{i=1}^n (\log f(y_i|x_i, \gamma) + \log f(x_i|\gamma)) \quad (2.12)$$

2.2.4.1.1 Etape estimation de l'algorithme E-M

L'algorithme E-M trouve premièrement les valeurs espérées de la log-vraisemblance complétée $\log f(x_i|\gamma)$; Y étant les données inconnues ou la variable latente, X l'observation donnée et γ^s les paramètres actuels estimés. on calcule l'espérance de la fonction de vraisemblance complétée par la relation (2.13).

$$Q(\gamma, \gamma^s) = \mathbb{E}[L(\gamma|X, Y), \gamma^s] \quad (2.13)$$

Nous pouvons donc représenter dans cette section les étapes de l'algorithme E-M suivant l'organigramme présenté à la figure 2.2.

2.2.4.1.2 Etape maximisation de l'algorithme E-M

C'est la seconde étape d'estimation des paramètres par l'algorithme E-M. Les valeurs espérées compilées dans la première étape sont maximisées suivant la relation (2.14) qui définit un ensemble de valeurs γ qui maximise $Q(\gamma, \gamma^s)$ sur Ψ .

$$\gamma^{s+1} = \arg \max_{\gamma \in \Psi} Q(\gamma, \gamma^s) \quad (2.14)$$

Ces deux étapes sont itérées jusqu'à l'obtention d'une convergence. Dans la pratique, pour que le maximum local soit atteint, on fait tourner l'algorithme E-M un grand nombre de fois à partir de valeurs initiales différentes de manière à avoir de plus grandes chances d'atteindre le maximum global de vraisemblance [97, 98, 144–146].

2.2.4.2 Estimation des paramètres de mélange gaussien

Considérons le modèle de mélange défini en (2.6). Supposons une variable latente $Y = \{y_1, y_2, \dots, y_n\}$. On a la fonction log-vraisemblance de données complètes $X = \{x_1, x_2, \dots, x_n\}$, en terme de mélange gaussien qui s'écrit suivant les relation (2.15) et (2.16).

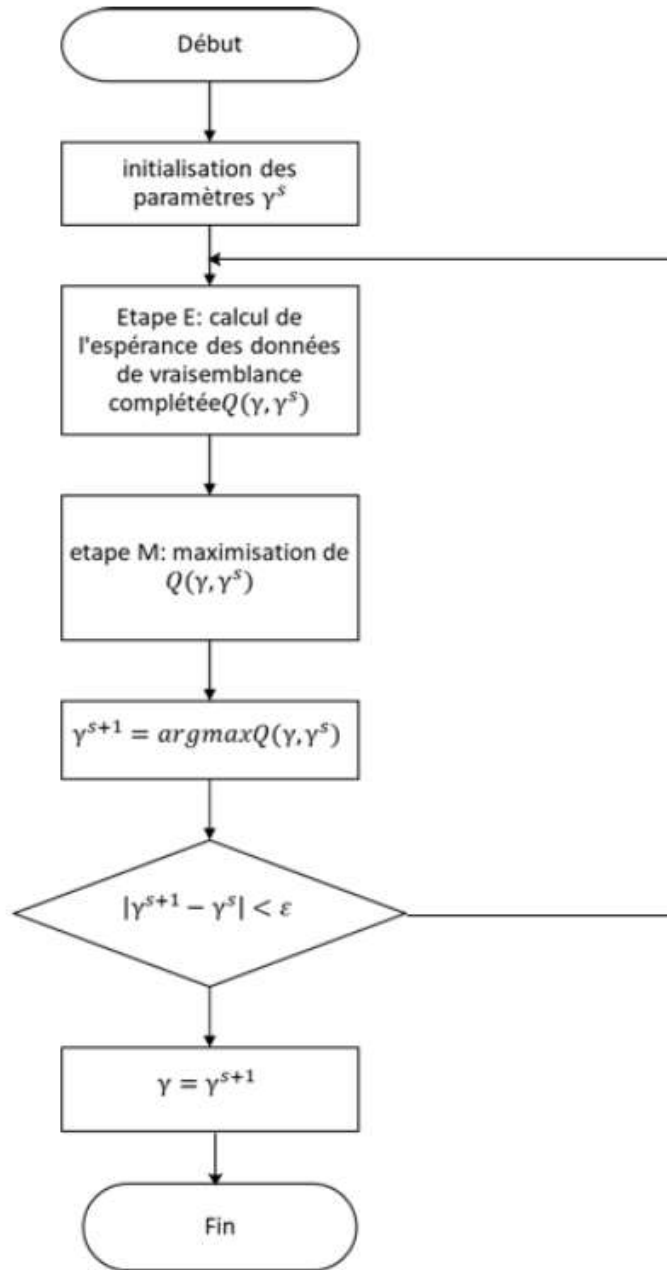


FIGURE 2.2 – Organigramme d’estimation des paramètre du mélange de distribution gaussienne par l’algorithme Espérance-Maximisation

$$\log (f (X, Y|\gamma)) = \sum_{i=1}^n \log (\pi_i \cdot f (x_i|\mu_i, \Sigma_i)) \quad (2.15)$$

$$f (y|X, \gamma^s) = \prod_{i=1}^n (f (y_i|x_i\gamma^s)) \quad (2.16)$$

Dans cette étape d’estimation, les paramètres courants sont utilisés pour calculer l’espérance grâce au théorème de Bayes dont l’expression est montrée à la relation

(2.17).

$$f(y_i|x_i, \gamma^s) = \frac{f(x_i|y_i, \gamma^s)}{f(x_i|\gamma^s)} = \frac{\pi_i^s \cdot f(x_i|\mu_i^s, \Sigma_i^s)}{\sum_{m=1}^j \pi_j^s \cdot f(x_j|\mu_j^s, \Sigma_j^s)} \quad (2.17)$$

La quantité Q doit être maximisée par rapport aux différents paramètres du modèle à l'étape M qui consiste à faire la mise à jour des paramètres du modèle selon la relation (2.13) développée en (2.18).

$$Q(\gamma, \gamma^s) = \sum_{y \in \Gamma} \sum_{i=1}^n \ln(f(x_i|\mu_i, \Sigma_i^s)) \prod_{i=1}^n f(y_i|x_i, \gamma^s) \quad (2.18)$$

Les paramètres du mélange peuvent être obtenus en maximisant l'expression de l'équation précédente. Par utilisation des coefficients de multiplication de Lagrange, les nouveaux paramètres estimés sont exprimés par les relations (2.19) pour les proportions, (2.20) pour les moyennes et (2.21) pour les matrices de covariances.

$$\pi_j = \frac{1}{n} \sum_{i=1}^n f(y_j|x_i, \gamma^s) \quad (2.19)$$

$$\mu_j = \frac{\sum_{i=1}^n x_i f(y_j|x_i, \gamma^s)}{\sum_{i=1}^n f(y_j|x_i, \gamma^s)} \quad (2.20)$$

$$\Sigma_j = \frac{\sum_{i=1}^n f(y_j|x_i, \gamma^s) \cdot (x_i - \mu_j) \cdot (x_i - \mu_j)^T}{\sum_{i=1}^n f(y_j|x_i, \gamma^s)} \quad (2.21)$$

2.3 Prédiction à court terme de la charge électrique

Les modèles du Machine Learning que nous avons proposés dans cette thèse pour prédire la consommation de l'électricité relèvent des problèmes d'apprentissage supervisé dont le principal objectif est d'apprendre à faire des prédictions, à partir d'une liste d'exemples étiquetés, c'est-à-dire accompagnés de la valeur à prédire (Figure 2.3) [139].

Le formalisme du processus d'apprentissage se décrit de la façon suivante : soit un ensemble de n observations $\{x_i\}_{i=1}^n$ décrites dans un espace X , et $\{y_i\}_{i=1}^n$ leurs étiquettes dans un espace Y . On suppose que les étiquettes peuvent être obtenues à par-

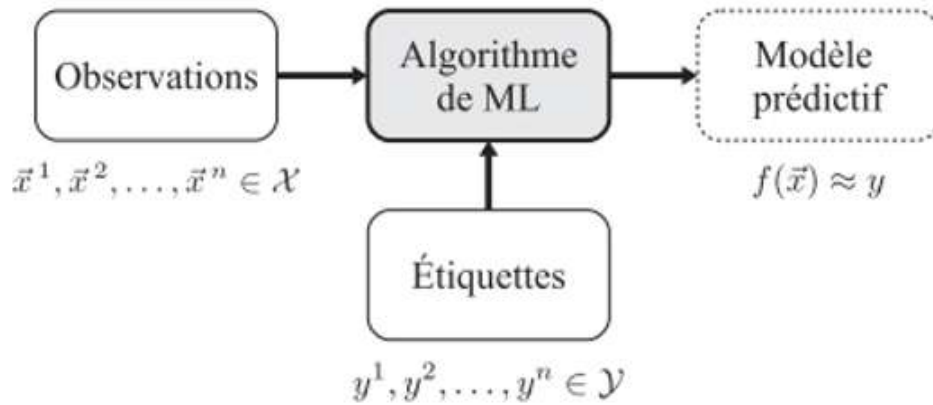


FIGURE 2.3 – Apprentissage supervisé

tir des observations grâce à une fonction $\Phi : X \rightarrow Y$ fixe et inconnue : $y_i = \Phi(x_i) + \epsilon_i$, où ϵ_i est un bruit aléatoire. Il s'agit alors d'utiliser les données pour déterminer une fonction $f : X \rightarrow Y$ telle que, pour tout couple $(x, \Phi(x)) \in X \times Y$, $\Phi(x) \approx f(x)$.

Un examen systématique des modèles d'apprentissage automatique utilisés dans la prévision de la charge électrique a été présenté à travers un état de l'art [138], montre que les algorithmes de Machine Learning sont fréquemment utilisés et sont en plein essor dans le secteur de l'électricité. Bien que les modèles de Machine Learning offrent de meilleures perspectives dans la prévision de la charge électrique, la tendance actuelle est d'intégrer ces outils dans des architectures hybrides. Pour cette raison, nous avons développé dans cette thèse trois types de modèles hybrides : k-means clustering / réseaux de neurones artificiels, ondelettes / Processus Gaussien et ondelettes / ARIMA pour améliorer la performance dans la prévision à court terme de la charge électrique.

2.3.1 Approche k-means clustering / ANN

Le choix d'une méthode de prévision de la charge électrique n'est pas une tâche facile. Toutes les méthodes de prévision décrites ci-dessus ont des particularités distinctives. Certaines d'entre elles offrent de meilleures performances que d'autres. Cependant, ils ne sont pas habituellement favorables aux changements brutaux de l'utilisation d'énergie due aux événements inattendus. Dans ce contexte, les ANN sont largement utilisés puisqu'ils offrent généralement un meilleur résultat de prévision de la charge électrique qui présente d'énormes incertitudes avec un profil non linéaire. Une fois que l'entrée et la sortie sont choisies et introduites dans un ANN, le rapport entre l'entrée et la sortie est identifié par un processus d'autoapprentissage. La précision

de la prévision peut être améliorée en ajustant l'architecture des ANN. En raison de ce dispositif unique, le temps et l'effort qui sont normalement exigés pour établir un modèle mathématique approprié dans une méthodologie conventionnelle de prévision peut être réduit et limité.

2.3.1.1 Réseaux de neurones artificiels de type perceptron monocouche

L'histoire des réseaux de neurones artificiels remonte aux années 1950 et aux travaux de plusieurs chercheurs, en particulier ceux du psychologue Frank Rosenblatt pour comprendre le cerveau humain [147]. L'objectif principal était d'élaborer un modèle mathématique de traitement des informations reçues par les neurones biologiques qui se trouve dans le cortex des mammifères. De nos jours, avec l'évolution de l'Informatique et la disponibilité des données massives, les ANN se dissocient du concept biologique par leurs exploits dans la résolution des problèmes de régression et de classification grâce à leur flexibilité de modélisation des motifs complexes et non linéaires que présentent les observations. La figure 2.4 présente la structure du perceptron monocouche [147] constitué de n neurones associés à chaque variable d'entrée affectée par son poids, puis rajouté à un biais introduit dans le noyau auquel une fonction d'activation est appliquée pour avoir une sortie suivant la relation (2.22).

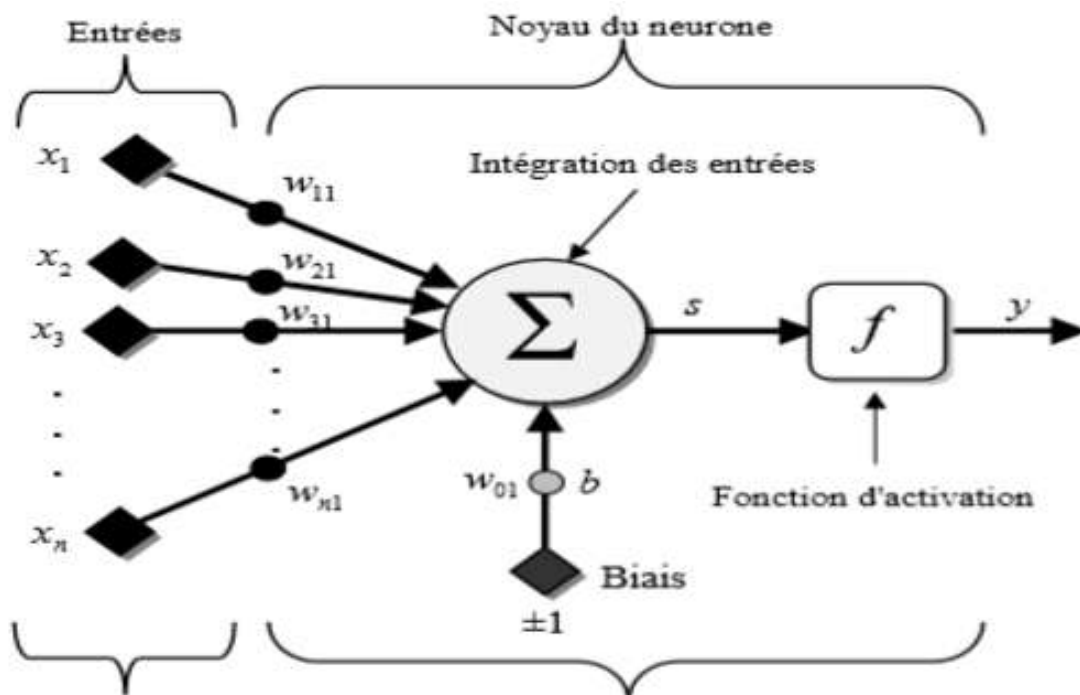


FIGURE 2.4 – Architecture d'un perceptron

$$y_k = f \left(w_{01} + \sum_{j=1}^n w_{jk} \cdot x_j \right) = f (\langle \mathbf{w}, \mathbf{x} \rangle) \quad (2.22)$$

où :

- f est une fonction d'activation ;
- w_{01} est le biais ;
- $\{x_j\}_{j=1}^n$ sont les variables d'entrées du modèle ;
- k est le nombre de neurones ;
- n est le nombre de variable d'entrée ;
- $\langle \mathbf{w}, \mathbf{x} \rangle$ définit le produit scalaire entre les vecteurs poids w et entrée x

La fonction d'activation f joue un rôle très important dans le comportement du neurone. Elle renvoie une valeur représentative de l'activation du neurone et a comme paramètre la somme pondérée des entrées et le seuil d'activation. La nature de cette fonction diffère selon le réseau de neurones. Il existe différentes fonctions d'activation présentées dans la littérature [148]. La fonction Unité de rectification linéaire (ReLU, Rectified Linear Unit) est l'une des fonctions d'activation modernes disposant d'une forte capacité de généralisation qui résout le problème de saturation que rencontrent les fonctions sigmoïde et tangente hyperbolique. C'est la fonction la plus utilisée dans l'apprentissage des réseaux profonds et son expression est donnée par la relation (2.23). Elle est choisie dans notre étude pour faire la prévision de la charge électrique. Le cadre de l'apprentissage profond ne sera pas couvert dans cette étude.

$$\phi(x) = \max(0, x) \quad (2.23)$$

2.3.1.1.1 Algorithme d'apprentissage par gradient descendant

Pour l'entraînement du modèle, supposons un ensemble d'observations (x_i, y_i) qui sont disponibles simultanément. Le but principal recherché est de minimiser le risque empirique L pour permettre au modèle d'avoir un fort pouvoir de généralisation [149]. Le processus de mise à jour des poids des ANN de type perceptron se base sur l'apprentissage incrémental qui consiste à la minimisation du risque empirique de manière itérative en utilisant l'algorithme du gradient descendant [150] qui consiste à une initialisation des poids de connexion $w^{(0)} = (w_{1k}^{(0)}, w_{2k}^{(0)}, \dots, w_{nk}^{(0)})$. A chaque observation, le poids est ajusté suivant la direction opposée au gradient du risque empirique. Ceci indique la direction de la plus forte risque empirique ; le redescendre permet de se rapprocher au point optimum où le risque est minimal. L'itération

de l'algorithme se poursuit pour de nouvelles observations pour une mise à jour des poids suivant la relation (2.24) où η est un hyperparamètre appelé la vitesse d'apprentissage (learning rate). Pour des données massives, il est recommandé de faire plusieurs itération jusqu'à la convergence de l'algorithme à ε près.

$$w_{jk} \leftarrow w_{jk} - \eta \cdot \frac{\partial L(f(x_i), y_i)}{\partial w_{jk}} \quad (2.24)$$

2.3.1.1.2 Limites du perceptron monocouche

Loin d'être profond, le perceptron monocouche présente des limites dans sa capacité à pouvoir modéliser non linéarité des données. Ce qui fait de lui, un modèle controversé par de nombreux chercheurs. Ces derniers reprochent à son algorithme d'apprentissage d'être intrigant et simpliste. Très vite, la mise en œuvre du perceptron multicouche (MLP, Multilayer Perceptron) vient élaguer toutes ces critiques et a permis aux ANN d'être l'une des méthodes de l'Intelligence Artificielle la plus utilisée de nos jours dans la prévision de la charge électrique [151].

2.3.1.2 Réseau de neurones artificiels de type perceptron multicouches

Le perceptron multicouche (MLP, Multilayer perceptron en anglais) est un réseau de neurone construit en introduisant les couches cachées entre les couches d'entrée et de sortie d'un perceptron. Chaque couche cachée reçoit en entrée les sorties des neurones de la couche précédente. Il n'y a pas de retour d'une couche vers une autre qui la précède. On parle des ANN à propagation avant (ou feed forward propagation ANN en anglais). La figure 2.5 présente l'architecture d'un ANN de type MLP utilisé dans cette étude.

2.3.1.2.1 Algorithme d'apprentissage des ANN de type MLP

Le modèle ANN de type MLP proposé dans cette étude utilise la rétropropagation du gradient de l'erreur (ou backpropagation error) comme algorithme d'optimisation pour la mise à jour de ses poids afin de mettre en correspondance des entrées et sorties référencées sur une base d'apprentissage. Dans ce contexte, considérons w_{jk}^h le poids de la connexion du neurone j de la couche $h - 1$ vers le neurone k de la couche h . De façon la plus simple, la mise à jour du poids $w_{jk}^h(t)$ à un moment $t + 1$ est exprimée par la relation (2.25).

$$w_{jk}^h(t + 1) = w_{jk}^h(t) + \Delta w_{jk}^h(t) \quad (2.25)$$

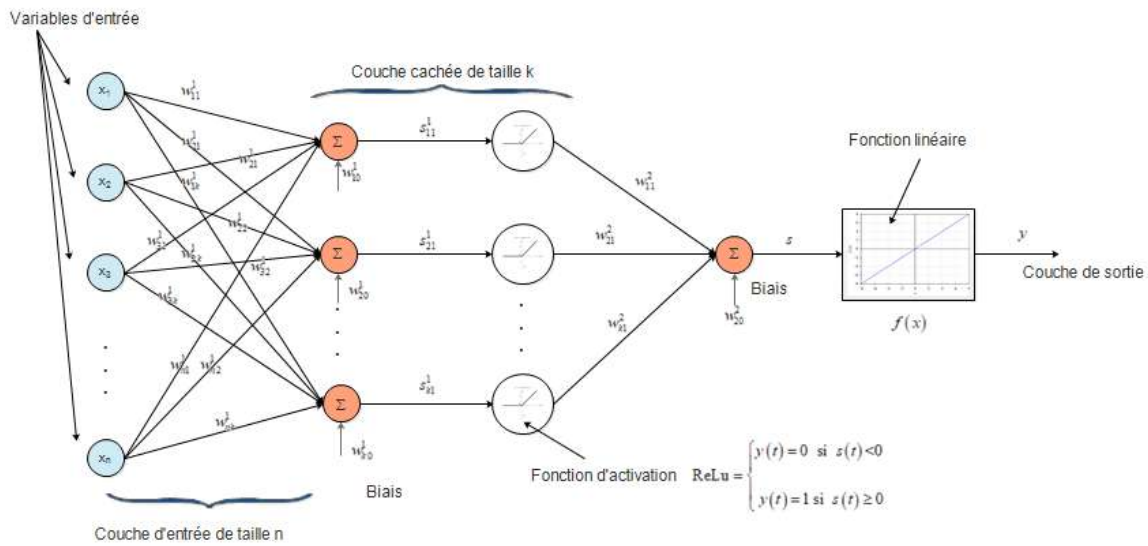


FIGURE 2.5 – Architecture d'un perceptron multicouche

Il faut retenir que la littérature regorge toute une panoplie d'algorithmes d'apprentissage pour les ANN de type MLP [152]. La rétropropagation du gradient de l'erreur que nous utilisons dans cette thèse est le plus ancien et le plus répandu. Cet algorithme utilise la méthode de descente de gradient pour minimiser le risque empirique $L(f(x_i), y_i)$ de manière itérative. A chaque itération, le signal d'entrée se propage dans le réseau suivant le sens entrée – sortie (phase de propagation avant) qui permet de calculer les sorties de chaque neurone. Une sortie est obtenue et l'erreur entre cette sortie et celle désirée est calculée, puis par rétropropagation des erreurs intermédiaires de la dernière couche cachée vers l'unité de sortie et en remontant le réseau vers les poids w_{jk}^h allant de l'entrée vers la première couche cachée.

2.3.1.2.2 Apprentissage par rétropropagation du gradient d'erreur

Le formalisme mathématique permet dans un premier temps à calculer $\frac{\partial L(f(x_i), y_i)}{\partial w_{jk}}$ et appliquer le théorème de dérivation des fonctions composées (chaine rule) à la descente de gradient par la relation (2.26). Soit s_k^h la combinaison linéaire du $k^{i\text{ème}}$ neurone de la couche cachée h telle que $y_k^h = f_k(s_k^h)$. Nous supposons par la suite que $y_k^0 = x_k$. Par la technique de mémorisation, la mise à jour des poids de la couche cachée h se calcule en fonction des gradients $\frac{\partial L(f(x_i), y_i)}{\partial s_r^{h+1}}$ nécessaires pour la mise à jour de la couche $h + 1$.

$$\begin{aligned}
 \frac{\partial L(f(x_i), y_i)}{\partial w_{jk}^h} &= \frac{\partial L(f(x_i), y_i)}{\partial y_k^h} \cdot \frac{y_k^h}{s_k^h} \cdot \frac{s_k^h}{w_{jk}^h} \\
 &= \left(\sum_{r=1}^{nh+1} \frac{\partial L(f(x_i), y_i)}{\partial s_r^{h+1}} \cdot \frac{s_r^{h+1}}{y_k^h} \right) \cdot \frac{y_k^h}{s_k^h} \cdot \frac{s_k^h}{w_{jk}^h} \\
 &= \left(\sum_{r=1}^{nh+1} \frac{\partial L(f(x_i), y_i)}{\partial s_r^{h+1}} \cdot w_{rk}^{h+1} \right) \cdot f'(s_k^h) \cdot \partial y_k^{h-1}
 \end{aligned} \tag{2.26}$$

Cependant, à part les difficultés liées au choix optimal du nombre des couches cachées, au temps de calcul très coûteux pour l'optimisation des hyperparamètres, et à l'exigence des données de taille importante, un des problèmes que rencontrent généralement les réseaux de neurones est la fluctuation des données. Ce qui est le cas avec la consommation électrique qui fluctue d'une heure à une autre au fil de la journée. Pour pallier à ce problème, la méthode de k-means clustering peut être utilisée pour répartir la charge électrique suivant les profils de jours ouvrables et de weekend avant de la mettre à l'entrée de l'ANN.

2.3.1.3 Algorithme k-means clustering

L'algorithme k-means clustering doit sa popularité à sa simplicité et sa capacité de traiter de larges ensembles de données. Il est mis au point par McQueen en 1967 [153, 154], est l'un des plus simples algorithmes d'apprentissage non supervisé, appelé algorithme des centres mobiles [155] utilisés pour le clustering qui divise les données en plusieurs groupes. Cet algorithme est l'une des méthodes de clustering de données non hiérarchiques qui regroupe les données en plusieurs clusters en fonction de leurs similarités [156, 157]. Chaque cluster est représenté par son centre de gravité. Ce mécanisme regroupe les données qui ont les mêmes caractéristiques dans un cluster et les données qui ont des caractéristiques différentes dans un autre cluster. Ces éléments peuvent être tous et n'importe quoi, du moment qu'ils sont encodés dans une matrice de données. Pour déterminer l'étiquette de cluster de toutes les données, la distance entre les données avec chaque centre de cluster doit être calculée. Par conséquent, l'affectation des observations x à k clusters C_1, C_2, \dots, C_k doit être trouvée afin de minimiser la variance globale intra-cluster définie par la relation (2.27), avec μ_k le centre de gravité du cluster C_k . Cependant, résoudre ce problème de manière exacte n'est pas possible. On utilise donc une heuristique, proposée par Stuart Lloyd en 1982 [158].

$$\arg \min_{C_1, C_2, \dots, C_k} \sum_{k=1}^K \sum_{x \in C_k} \|x - \mu_k\|^2 \tag{2.27}$$

2.3.1.3.1 Principe de l'algorithme de Lloyd

L'algorithme de Lloyd (Figure (2.6)) implémente une stratégie gloutonne pour résoudre le problème posé en (2.27). S'il converge en général très rapidement, il peut tomber dans un minimum local. Il peut donc être pertinent de le faire tourner plusieurs fois, et de garder la solution qui a la plus faible variance intra-cluster. Pour un ensemble de n observations dans \mathbb{R}^n et un k nombre de clusters, l'algorithme de Lloyd se procède de manière suivante :

1. définir les k centroïdes arbitraires $\mu_1, \mu_2, \dots, \mu_k$ pour servir de centroïdes initiaux. Ces centroïdes doivent être placés dans des emplacements différents. Le meilleur choix est de les placer le plus possible éloignés les uns des autres.
2. La prochaine étape est de prendre chaque point x_i appartenant à l'ensemble de données \mathbb{R}^n et l'associer au centroïde dont il est le plus proche selon la relation (2.28).

$$k(x_i) = \arg \min_{k=1,2,\dots,K} \|x_i - \mu_k\|_2 \quad (2.28)$$

3. chaque classe C_i sera représentée par un ensemble d'individus les plus proches de son centroïde μ_i . Lorsqu'aucun point n'est en attente, la première étape est terminée et un groupage précoce est fait. A cet effet, nous avons besoin de recalculer les k nouveaux centroïdes μ_k des groupes issus de l'étape précédente qui vont remplacer les C_i .

$$\mu_k = \frac{1}{|C_i|} \sum_{x_i \in C_k} x_i \quad (2.29)$$

4. Après, on réitère les processus des étapes 2-3 jusqu'à la convergence. En d'autres termes jusqu'à ce que les affectations ne changent plus [159].

2.3.1.3.2 Choix du nombre de clusters

Pour pouvoir regrouper un jeu de données en k clusters distincts, l'algorithme K-Means a besoin d'un moyen pour comparer le degré de similarité entre les différentes observations. Ainsi, deux points qui se ressemblent, auront une distance de dissimilarité réduite, alors que deux points différents auront une distance de séparation plus grande. Les littératures mathématiques et statistiques [160] regorgent un ensemble de définitions de distance. Les plus connues pour les cas de clustering sont la distance Euclidienne et de Manhattan (taxi-distance). En effet, pour un même jeu de données, il n'existe pas un unique clustering possible. La difficulté résidera

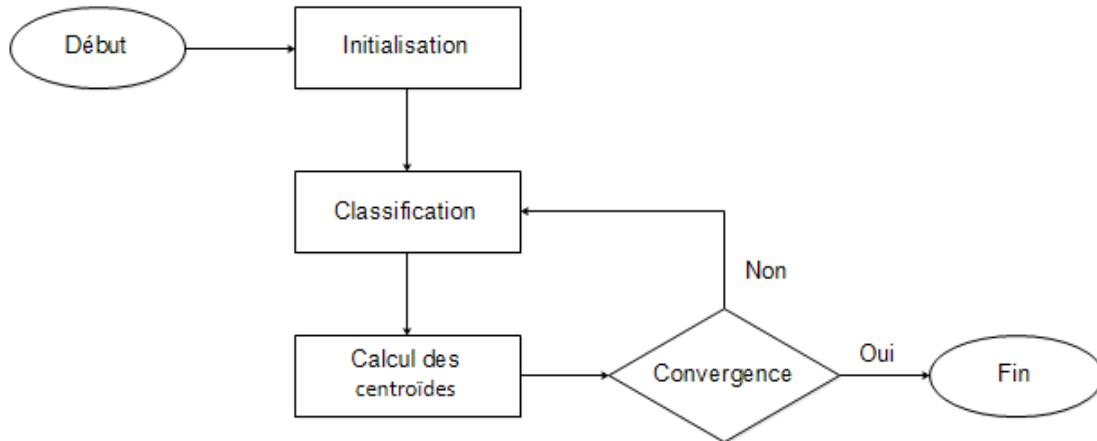


FIGURE 2.6 – Algorithme de Lloyd

donc à choisir un nombre de cluster qui permettra de mettre en lumière des motifs intéressants entre les données. Malheureusement il n'existe pas de procédé automatisé pour trouver le bon nombre de clusters. Toutefois, quelques méthodes usuelles pour choisir le nombre de clusters sont : méthode Elbow ou de la variance, du dendrogramme et de la silhouette. Nous avons utilisé la méthode de la silhouette dans cette étude pour déterminer le nombre de clusters.

2.3.1.3.3 Méthode de la silhouette

La silhouette est une mesure de la similitude d'un point avec son propre cluster (cohésion) par rapport à d'autres clusters (séparation). La silhouette varie de -1 à $+1$, où une valeur élevée indique que le point est bien adapté à son propre cluster et mal adapté aux clusters voisins. Si la plupart des points ont une valeur élevée, la configuration de clustering est appropriée. La silhouette peut être calculée avec n'importe quelle distance métrique. Le coefficient de silhouette de l'observation x a la valeur définie suivant la relation (2.30).

$$s(x) = \frac{b(x) - a(x)}{\min(a(x), b(x))} \quad (2.30)$$

où $a(x)$ est la distance moyenne de x à tous les autres éléments du cluster auquel il appartient (voir relation (2.31)), et $b(x)$ est la plus petite valeur que pourrait prendre $a(x)$ si $a(x)$ appartenait à un autre cluster (voir relation (2.32)).

$$a(x) = \frac{1}{|C_k - 1|} \sum_{u \in C_k, u \neq x} d(u, x) \quad (2.31)$$

$$b(x) = \min_{l \neq k} \frac{1}{|C_l|} \sum_{u \in C_l} d(u, x) \quad (2.32)$$

Le coefficient de silhouette global du clustering est son coefficient de silhouette moyen. Ainsi, le coefficient de silhouette de x est d'autant plus proche de 1 que son assignation au cluster C_k est satisfaisante suivant la relation (2.33).

$$s = \frac{1}{n} \sum_{i=1}^n s(x_i) \quad (2.33)$$

2.3.1.4 Méthodologie de la méthode hybride proposée

L'approche que nous proposons dans cette étude est présentée par l'organigramme de la figure 2.7. Après une étape de prétraitement des données (extraction des données manquantes et aberrantes, et traitement des caractéristiques), le jeu de données est prêt à être partitionné en clusters par la méthode des k-means. Les paramètres sont définis dans une classe d'estimateurs adaptés à l'ensemble de données. Une fois le nombre approprié de clusters choisi, les données sont introduites dans un modèle de réseau de neurones MLP qui utilise l'apprentissage par rétropropagation de gradient comme algorithme d'apprentissage. Des tests d'ajustement sont effectués sur la topologie du réseau en fonction du nombre d'entrées, de couches cachées, sorties, vitesse et algorithme d'apprentissage, et fonction d'activation pour avoir un modèle de configuration optimale. Le modèle développé présente finalement un certain nombre de couches d'entrée et de couches cachées qui utilisent ReLU comme fonction d'activation.

2.3.2 Application de la transformée en ondelettes

Considérons la figure 2.8, dans les deux cas (de signaux basses et haute fréquences) en utilisant la même fenêtre. Pour le signal qui est de haute fréquence dans la figure à gauche plusieurs périodes sont capturées par la fenêtre. Mais dans le cas d'un signal basse-fréquence, le support temporel de la fenêtre n'est pas suffisant. Donc pour les basses fréquences, la fenêtre utilisée est de large support temporel, alors que pour les hautes fréquences, la fenêtre est de grande largeur de bande en fréquence. Pour corriger cette défaillance une autre technique de transformation dont la fenêtre qui s'adapte mieux aux variations de fréquence dans le signal à

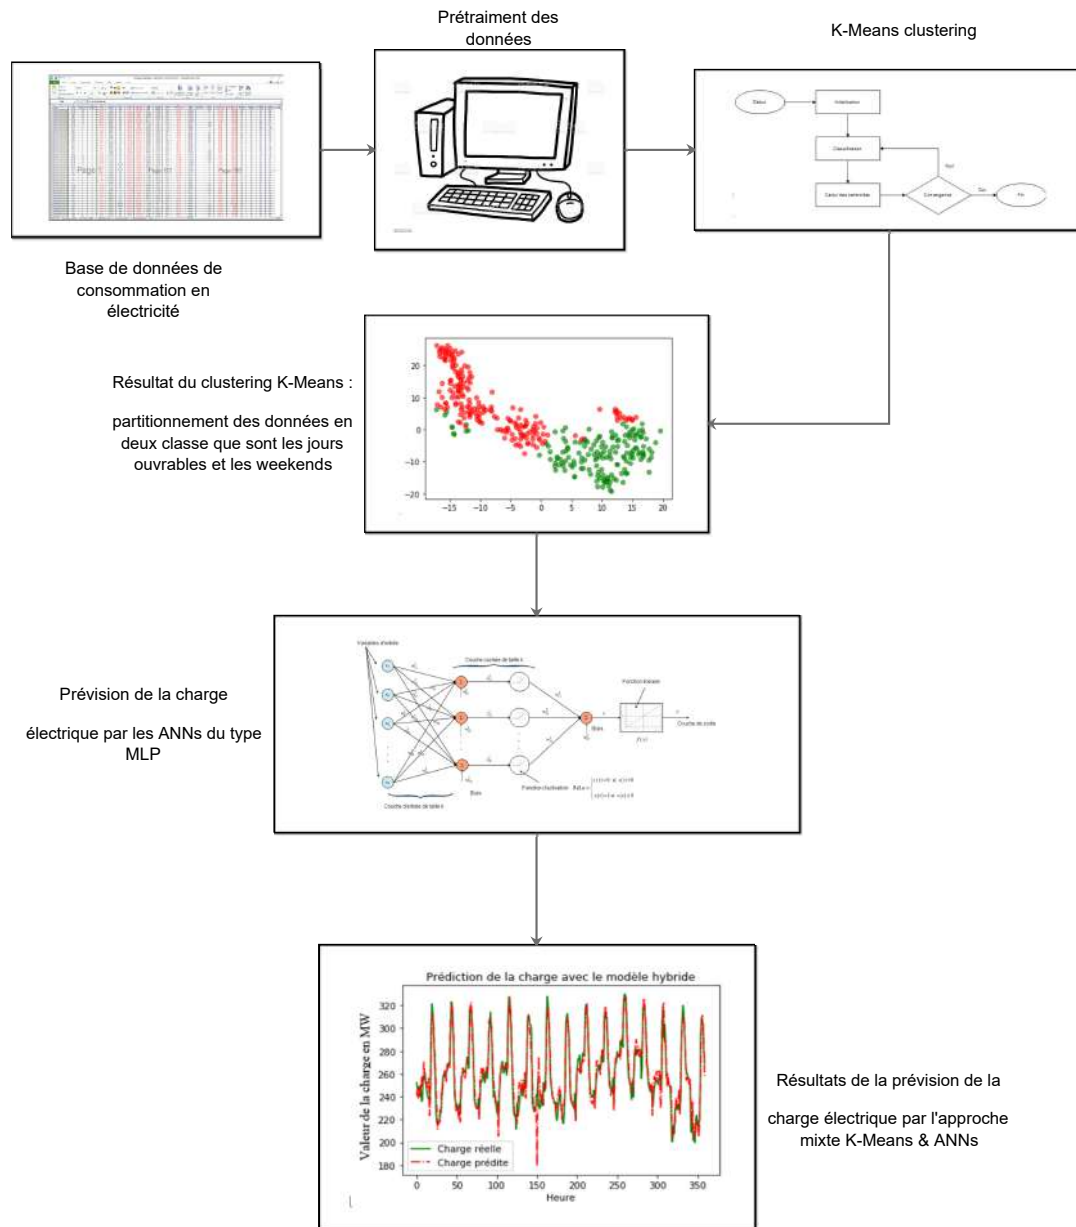


FIGURE 2.7 – Méthodologie de de prévision par approche hybride k-means réseau de neurones artificiel

analyser est utilisée. Cette technique existe et est appelée transformée en ondelettes. Une ondelette est une forme d'onde dont la valeur moyenne est nulle et une durée limitée. La transformée en ondelette est un outil mathématique, elle permet de réaliser une décomposition d'un signal en fréquences. Elle influence comme un « zoom mathématique » qui agit sur le signal à analyser en faisant varier l'échelle d'analyse du signal afin d'extraire les détails présents à différentes résolutions.

Suivant la figure 2.9 à droite pour les basses fréquences (haute échelle), les ondelettes sont étendues et se trouvent bien localisées en fréquence mais pas en temps (espace),




FIGURE 2.8 – Cas de signaux basses et haute fréquences avec la même fenêtre

cependant, pour les hautes fréquences (petite échelle), les ondelettes sont étroites et bien localisés temporellement (spatialement), mais la localisation en fréquence est mauvaise. Cela traduit que par la caractéristique d’adaptabilité de la transformée en ondelette au signal étudié contrairement à la transformée de Fourier fenêtrée qui conserve une résolution d’analyse fixe.

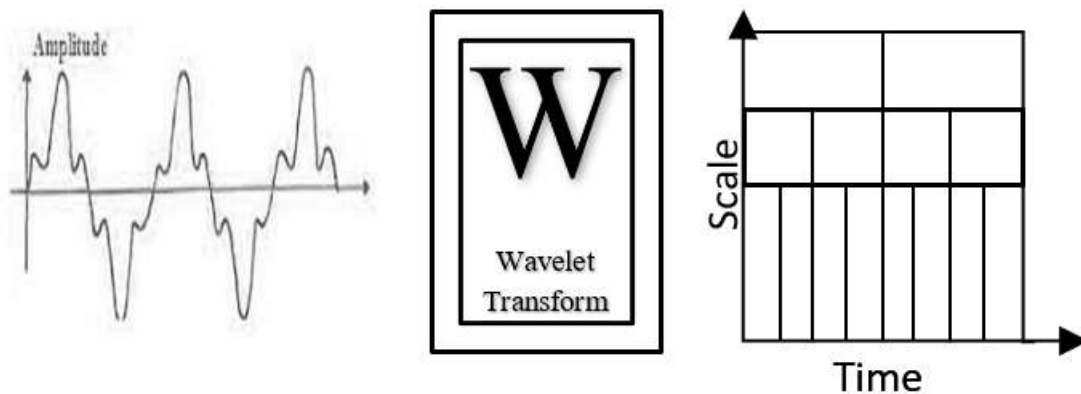


FIGURE 2.9 – Transformée en ondelette

Il existe différentes familles des ondelettes. La figure 2.10 donne quelques formes d’ondelettes usuelles.

2.3.3 Approche ondelettes / ARIMA

Les ondelettes représentent un outil de traitement récent, ils ont l’avantage de s’adapter avec la forme des signaux grâce aux caractéristiques de dilatation et de contraction, ainsi que la translation afin d’assurer un bon traitement du signal. Cet outil est rencontré dans différents domaines (le débruitage d’image, compression d’images,




FIGURE 2.10 – Quelques familles des ondelettes usuelles

traitement de signal, etc.). Notre travail exploite les ondelettes discrètes comme un outil de prétraitement sans perte d’informations. Les ondelettes discrètes se composent de deux types de filtres complémentaires : filtres passe-haut et des filtres passe-bas. A travers ces filtres les ondelettes discrètes permettent de choisir les données utiles qui peuvent représenter le signal et qui permettra par la suite après un autre traitement de régénérer le signal original. Ces données à garder sont appelées coefficients d’ondelette d’approximations du niveau de décomposition choisie qui sont associés au filtre passe-bas et autres données sont appelées coefficients d’ondelette de détails associés au filtre passe-haut. La méthodologie hybride que nous proposons dans cette étude implique l’application de la décomposition en ondelettes discrètes à l’ensemble de données de charge électrique, qui divise ces données d’entrée en séries de composantes d’approximations et de détails grâce à l’algorithme de Mallat. Puis, ils sont appliqués au modèle ARIMA pour faire des prévisions à court terme.

2.3.3.1 Ondelette mère

L’analyse par ondelettes est à la base d’une fonction dite ondelette mère. Il est possible de représenter n’importe quel signal par une base d’ondelette qui peut être dérivée d’une fonction mère par des opérations de dilatation et contraction avec translation. La représentation d’un signal continu $x(t)$ par une base d’ondelettes est donnée par la relation (2.34).

$$x(t) = \sum w(s, \tau) \cdot \Psi_{s,\tau}(t) \quad (2.34)$$

où : $w(s, \tau)$ est le poids de la contribution de l'ondelette $\Psi_{s,\tau}(t)$ définie à partir de translations et dilatations/contractions de l'ondelette mère Ψ par la relation (2.35).

$$\Psi_{s,\tau}(t) = \frac{1}{\sqrt{s}} \Psi\left(\frac{t-\tau}{s}\right) \quad (2.35)$$

où

- τ est facteur de translation ;
- s est le facteur d'échelle, il joue le rôle de l'inverse de la fréquence ;
- Ψ est l'ondelette mère ;
- $\frac{1}{\sqrt{s}}$ est le facteur de normalisation de l'énergie afin que le signal transformé ait la même énergie à toutes les échelles.

2.3.3.2 Transformée en ondelettes discrètes

Il est impossible d'analyser des signaux discrets avec la transformée en ondelettes continues. La transformée en ondelettes discrètes est une technique qui peut être exploitée dans le domaine du Machine Learning comme étape de prétraitement pour une entrée d'un modèle de prévision. La transformée en ondelettes discrètes est issue de la version continue, sauf qu'elle utilise un facteur d'échelle et une translation discrétisée [161]. Elle est plus pratique en implémentation sur tout système numérique. De plus, elle intervient pour résoudre le problème de redondance de la transformée en ondelettes continue. Dans le cas de la transformée en ondelettes discrètes, les fonctions d'ondelette doivent être discrétisées ; les paramètres de dilatation et de translation s et τ de l'ondelette prennent des valeurs discrètes telles que : $s = s_0^j$ et $\tau = \tau_0 k s_0^j$ avec $s > 0$ et $j \in \{0, 1, \dots, n\}$ des constantes. En introduisant ces constantes, l'ondelette mère dilatée et translatée s'écrira suivant la relation (2.36).

$$\Psi_{j,k}(t) = \frac{1}{\sqrt{s_0^j}} \Psi\left(\frac{t - \tau_0 k s_0^j}{s_0^j}\right) \quad (2.36)$$

La transformée discrète en ondelettes du signal $x(t)$ est exprimée par la relation (2.37) [162], où Ψ^* désigne l'expression conjuguée de la fonction Ψ .

$$A_{j,k}(t) = \frac{1}{\sqrt{s_0^j}} \int_{-\infty}^{+\infty} x(t) \Psi_{j,k}^*(t) dt \quad (2.37)$$

Pour qu'une ondelette existe, les critères mathématiques suivants doivent être vérifiés : elle doit avoir une l'énergie finie (voir, la relation (2.38)). Elle doit être

admissibles (voir, la relation (2.39)), et de moyenne ou composante continue de la fonction d'ondelette $\Psi(t)$ nulle (voir, la relation (2.41)) [21].

$$\int_{-\infty}^{+\infty} |\Psi(t)|^2 dt < \infty \quad (2.38)$$

$$C_{\Psi} = \int_{-\infty}^{+\infty} \frac{|\hat{\Psi}(w)|^2}{w} dw \quad (2.39)$$

avec $\hat{\Psi}(w)$ la transformée de Fourier de $\Psi(t)$ exprimée par la relation (2.40), $w = 2\pi f$ la vitesse angulaire, et C_{Ψ} la constante d'admissibilité.

$$\hat{\Psi}(w) = \int_{-\infty}^{+\infty} \Psi(t) e^{-j\omega t} dt \quad (2.40)$$

$$\int_{-\infty}^{+\infty} \Psi(t) dt = \Psi(f=0) = 0 \quad (2.41)$$

La reconstruction du signal original $x(t)$ à partir des coefficients d'ondelettes est donnée par la relation (2.42).

$$x'(t) = \sum_{j=-\infty}^{+\infty} \sum_{k=-\infty}^{+\infty} A_{j,k}(t) \Psi_{j,k}(t) \quad (2.42)$$

Pour sélectionner le nombre de niveaux de décomposition, la relation (2.43) est utilisée [163], où L et n sont respectivement le nombre de niveaux de décomposition et la taille de la série chronologique.

$$L = E(\log(n)) \quad (2.43)$$

2.3.3.3 Méthodologie de l'approche ondelettes / ARIMA

La procédure du modèle d'ondelettes-ARIMA présentée sur la figure 2.11 se base sur la méthodologie proposée par Niya Chen et al [164]. Elle est décrite comme suit : la transformation en ondelettes, de type Daubechies-3 et de niveau de décomposition 4 dans notre cas, est appliquée à la série $Y(t = 1, 2, \dots, T)$ conduit à 5 sous-séries, qui sont désignées C_{A4} , C_{D4} , C_{D3} , C_{D2} et C_{D1} . Les ondelettes de Daubechies présentent un bon compromis entre parcimonie et richesse d'information et les événements identiques dans les séries temporelles observées [165]. La série est

reconstruite en éliminant la composante haute fréquence, en utilisant la méthode de débruitage par ondelettes. Le modèle ARIMA approprié est appliqué à chaque sous-série reconstruite pour prédire la série de tests. Le choix de l'ondelette mère dépend des données à analyser. Grâce à la décomposition en ondelettes inverses, des résultats de prévision finaux pour la charge électrique sont obtenus en agrégeant la valeur prévisionnelle de la sous-série et terminés par un calcul des indicateurs statistique pour évaluer la performance des résultats de prévision.

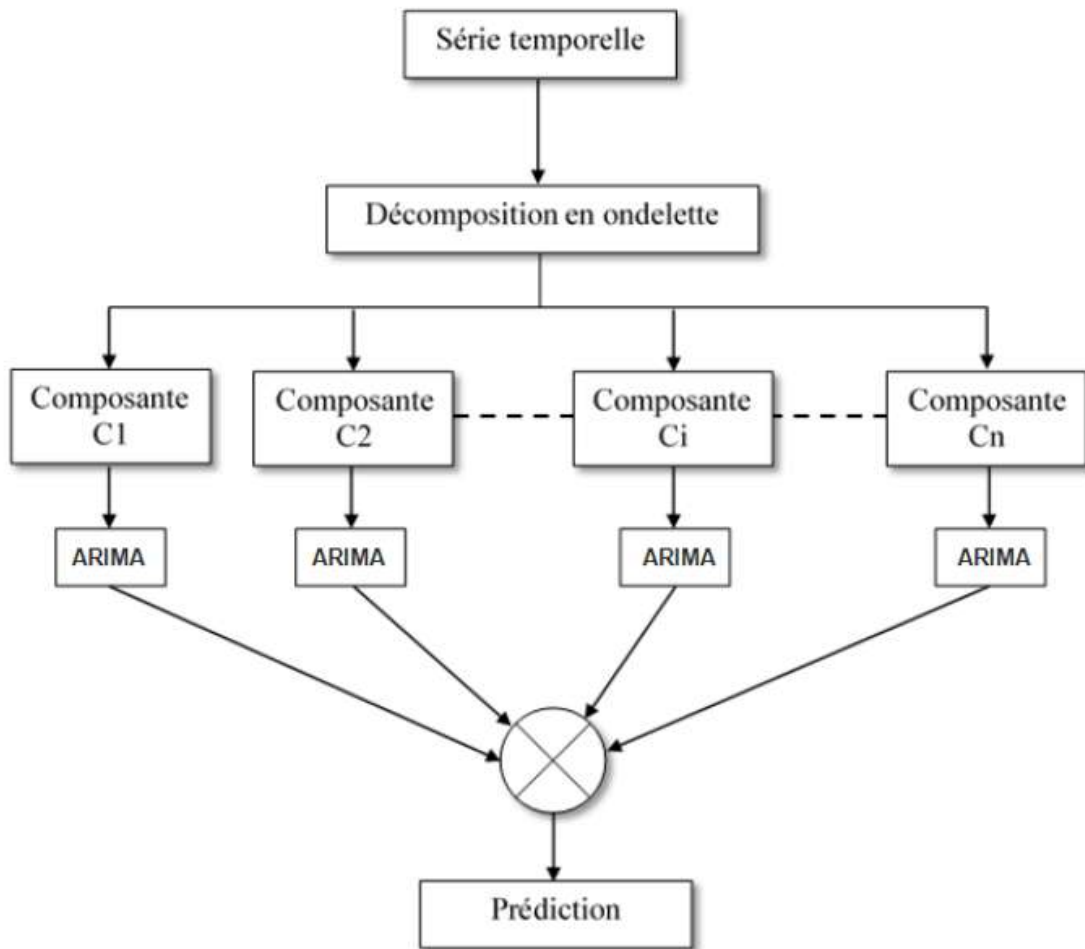


FIGURE 2.11 – Méthodologie de prévision par approche décomposition en ondelettes / ARIMA

2.3.4 Approche ondelettes /Processus Gaussien

Un Processus Gaussien (ou GP, pour Gaussien process) est un ensemble de variables aléatoires dont tout nombre fini a une distribution gaussienne commune [19]. Un GP définit une distribution gaussienne à priori sur les fonctions qui peut être convertie en une distribution à posteriori par l'observation de données.

Pour indiquer qu'une fonction $f(x)$ suit un processus gaussien, elle s'écrit $f(x) \sim \mathcal{GP}(\mu(x), k(x, x'))$, où x et x' sont des variables d'entrée arbitraires $\mu(x) = \mathbb{E}[f(x)]$ est la fonction moyenne et $k(x, x') = \mathbb{E}[(f(x) - \mu(x))(f(x') - \mu(x'))^T)]$ est la fonction covariance ou noyau. Un noyau quantifie la similarité entre deux points et formule les hypothèses sur la fonction à apprendre. Ces hypothèses décrivent à quel point la fonction est lisse ou périodique. Toute fonction peut être utilisée comme noyau tant que la matrice de covariance résultante est semi-définie positive.

Une liste détaillée de noyaux est présentée dans [19]. Bref, le processus gaussien est une généralisation de la distribution de probabilité gaussienne. La régression par Processus Gaussien (GPR, pour Gaussian Process Regression) est un processus stochastique qui régit les propriétés des fonctions. Imaginez qu'une fonction $f(x)$ soit un vecteur infiniment long, chaque élément du vecteur est une évaluation de la fonction $f(x)$ en un point x . En considérant les instances du vecteur ayant des propriétés d'un processus stochastique, les propriétés de la fonction $f(x)$ peuvent être déduites par le Processus Gaussien en se basant seulement sur un nombre fini de point [19].

Dans l'apprentissage supervisé, on suppose qu'un ensemble de données d'entraînement contient des entrées x_i et des sorties y_i qui sont liées par une fonction inconnue $f(x_i)$, de sorte que $y_i = f(x_i)$. On peut déduire une distribution sur les fonctions, $p(f|x, y)$ pour faire des prédictions $f_* = y_*$ étant donné de nouvelles entrées : $p(f_*|x_*, x, y)$ [166]. La figure 2.12 montre le modèle graphique de la représentation fonction-espace du processus gaussien. Les carrés représentent les variables observées et les cercles représentent les inconnues. Le champ gaussien est une distribution sur les fonctions [19].




FIGURE 2.12 – Modèle graphique de la représentation fonction-espace du GP

A partir de ces deux fonctions $\mu(x)$ et $k(x, x')$, le processus de régression est contrôlé et paramétré pour bien apprendre la grandeur physique en question. Dans le cas de

cette thèse, il s'agit de la charge électrique. La fonction noyau décrit la structure et détermine les interrelations entre les points dans la base de données où x et x' étant deux variables d'entrée différentes (variables indépendantes). Elle est utilisée pour construire la matrice de covariance. L'optimisation du noyau se fait par l'ajustement itératif de ses hyperparamètres.

Supposons que l'on dispose d'un ensemble de données d'entraînement $D = \{(x_i, y_i)\}_{i=1}^N$ provenant des observations sur le terrain. Nous posons $f_i = f(x_i)$ est l'observation de la fonction évaluée à x_i [166]. Supposons maintenant qu'un ensemble de données de test x_* de dimension $N_* \times D$ ait été fourni. L'objectif est de prédire les sorties f_* de la fonction connaissant l'ensemble d'entraînement D et les points de test x_* . Ce qui revient à trouver la distribution $p(f_*|x_*, x, f)$. D'après la définition de la distribution gaussienne jointe, la distribution jointe sur les fonctions exprimées par la relation (2.44).

$$\begin{bmatrix} f \\ f_* \end{bmatrix} \sim \mathcal{N} \left(\begin{bmatrix} \mu \\ \mu_* \end{bmatrix}, \begin{bmatrix} K & K_* \\ K_*^T & K_{**} \end{bmatrix} \right) \quad (2.44)$$

où :

- $K = k(x, x')$ est la sous-matrice de dimension $N \times N$ des covariances évaluées à toutes les paires de points d'entraînement ;
- $K_* = k(x, x_*)$ est la sous-matrice de dimension $N \times N_*$ des covariances évaluées à toutes les paires de point d'entraînement et de test ;
- $K_{**} = k(x_*, x_*)$ est la sous-matrice de dimension $N_* \times N_*$ des covariances évaluées à toutes les paires de points de test [19].

Afin de prédire les sorties f_* de la fonction, il faut conditionner la distribution jointe en utilisant les règles de conditionnement d'une gaussienne suivant les relations (2.45), (2.46) et (2.47).

$$p(f_*|x_*, x, f) = \mathcal{N}(f_*|\mu_*, \Sigma_*) \quad (2.45)$$

$$\mu_* = \mu_*(x_*) + K_*^T K^{-1} (f - \mu(x)) \quad (2.46)$$

$$\Sigma_* = K_{**} - K_*^T K^{-1} K_* \quad (2.47)$$

Pour simplifier, supposons que $\mu = \begin{bmatrix} 0 & 0 \end{bmatrix}^T$. Ce qui donne les expressions (2.48) et

(2.49).

$$\mu_* = K_*^T K^{-1} f \quad (2.48)$$

$$f | \mu_*, \Sigma_* \sim \mathcal{N} \left(K_*^T K^{-1} f, K_{**} - K_*^T K^{-1} K_* \right) \quad (2.49)$$

Dans des situations plus réalistes, nous n'avons pas accès à de vraies valeurs de fonction mais à des versions bruitées de celles-ci $y = f(x) + \epsilon$. En supposant qu'il existe un bruit gaussien additif indépendant et identiquement distribué avec variance σ^2 , nous avons les observations bruitées à priori qui deviennent $\text{cov}(y) = K + \sigma^2 I$. La distribution conjointe des valeurs observées et des valeurs de fonction aux nouveaux points de test est exprimée par la relation (2.50).

$$\begin{bmatrix} y \\ f_* \end{bmatrix} \sim \mathcal{N} \left(0, \begin{bmatrix} K + \sigma^2 I & K_* \\ K_*^T & K_{**} \end{bmatrix} \right) \quad (2.50)$$

En dérivant la distribution conditionnelle, nous obtenons les équations prédictives de la GPR sous la forme donnée par la relation (2.54)

$$\bar{f}_* | X_*, X, y = \mathcal{N} \left(\bar{f}_*, \text{cov}(\bar{f}_*) \right) \quad (2.51)$$

avec :

$$\bar{f}_* = K_*^T \left[K + \sigma^2 I \right]^{-1} y \quad (2.52)$$

$$\text{cov}(\bar{f}_*) = K_{**} - K_*^T \left[K + \sigma^2 I \right]^{-1} K_* \quad (2.53)$$

Dans la fonction de variance, on peut noter que la variance $\text{cov}(\bar{f}_*)$ ne dépend pas de la sortie observée y mais seulement des entrées x et x_{**} . C'est l'une des propriétés de la distribution gaussienne [19].

2.3.4.1 Propagation des erreurs dans la GPR

L'ensemble de données d'entraînement peut contenir des erreurs dues aux incertitudes et aux erreurs de mesures [167]. Ces erreurs se retrouvent dans la matrice de covariance du processus gaussien via les hyperparamètres du noyau. Si les erreurs

sont liées à la mesure, elles sont prises en compte par la nature probabiliste de la régression. L'incertitude sera définie par des intervalles de confiances sur les valeurs modélisées [168]. Les erreurs pourraient également être liées à la modélisation. Une matrice mal conditionnée pourrait entraîner des erreurs dans les calculs matriciels, où une petite erreur à l'entrée sur les valeurs des hyperparamètres du noyau entraîne une grande erreur à la sortie. Le coefficient de conditionnement est le rapport entre la valeur propre la plus grande et la plus petite de la matrice.

En effet, le problème d'une matrice mal conditionnée peut être résolu en ajoutant des termes de gigue à la diagonale de la matrice de covariance, ou en résolvant une matrice équivalente bien conditionnée [169]. Les fonctions `GaussianProcessRegressor` et `GPRRegressor` respectivement des bibliothèques python `Sklearn` et `GPY` garantissent une matrice de covariance définie positive en ajoutant une valeur à chaque entrée de la diagonale de la matrice. Cette valeur peut être spécifiée par l'utilisateur [170]. Pour ne pas courir ce risque nous utiliserons dans cette étude les bibliothèques ci-dessus mentionnées qui garantissent le bon conditionnement des matrices. La mauvaise précision due aux matrices mal conditionnées est largement évitable dans la plupart des cas. Les Processus Gaussiens offrent une manière efficace d'apprendre les hyperparamètres à partir de l'observation. La probabilité de y étant donnés μ , k et θ , aussi appelée vraisemblance des observations, est donnée par la relation (2.54).

$$p(y|\mu, k, \theta) = \mathcal{N}(y|\mu, K_\theta) \quad (2.54)$$

où K_θ est la matrice de covariance de dimension $N \times N$. L'optimisation consiste à maximiser la vraisemblance. Le principe de l'estimation au maximum de vraisemblance est de choisir θ qui maximise la vraisemblance des observations. La relation (2.55) correspond aux hyperparamètres optimaux.

$$\theta^* = \arg \max_{\theta} p(y|\mu, k, \theta) \quad (2.55)$$

La maximisation de la vraisemblance est équivalente à minimiser l'opposé de son logarithme népérien selon la relation suivant la relation (2.56).

$$\theta^* = \arg \min_{\theta} [-\ln(p(y|\mu, k, \theta))] \quad (2.56)$$

Dans le cas gaussien et pour des processus à valeurs dans \mathbb{R} , la relation (2.54) prend une forme particulière, obtenue par la simple application du logarithme à l'expression

de la probabilité des observations. Cette expression correspond à la relation (2.55) développée en (2.60).

$$\theta^* = \arg \min_{\theta} [\ln(p(y|\mu, k, \theta))] \quad (2.57)$$

$$\theta^* = \arg \min_{\theta} \frac{1}{2} (y - \mu)^T K_{\theta} + \frac{1}{2} \ln |K_{\theta}| + \frac{N}{2} \ln(2\pi) \quad (2.58)$$

ou bien

$$\theta^* = \arg \min_{\theta} \frac{1}{2} \left(y^T (K + \sigma^2 I)^{-1} y + \ln(\det(K + \sigma^2 I)) + N \ln(2\pi) \right) \quad (2.59)$$

Le problème d'estimation des hyperparamètres devient alors un problème standard d'optimisation, où l'objectif est d'estimer θ^* qui minimise la fonction de coût. En fonction de la covariance et de l'hyperparamètre considéré, ce problème peut avoir une solution analytique ou pas. Il est fréquent d'utiliser pour la résolution de tels problèmes un algorithme de descente de gradient.

2.3.4.2 Composition des noyaux

La fonction de covariance également connue sous le nom de noyau représente nos hypothèses sur la fonction que nous souhaitons approximer. Dans cette croyance initiale, l'on peut dire si la fonction est périodique ou pas et si elle est lisse ou pas. Toute fonction peut être une fonction de covariance tant que la matrice de covariance résultante est semi-définie positive. Les noyaux peuvent être unidimensionnels ou multidimensionnels. Une multitude de noyaux sont définis dans la littérature [19]. Les plus utilisés sont : le noyau linéaire (Lin), le noyau exponentiel carré (SE) qui est la fonction radial de base (RBF), le noyau quadratique rationnel (RQ), le noyau perceptron multicouche (MLP), le noyau périodique (Per) et les noyaux Matérn (M_{ν}) présentés dans le tableau 2.2. Il est possible de combiner plusieurs noyaux par les opérations de base pour obtenir des noyaux plus complexes et plus adaptés aux données. La seule condition est que le noyau résultant soit semi-défini positif. L'addition et la multiplication sont deux opérations de combinaison qui ne modifient pas la propriété définie positive des noyaux. En additionnant ou en multipliant deux noyaux k_1 et k_2 semi-définis positifs, on obtient un noyau k semi-défini positif.

TABLEAU 2.2 – Différents noyaux courants utilisés dans le Processus Gaussien

Noyau	Expression mathématique de $k(x, x')$	Paramètre
Le noyau linéaire (Lin)	$k(X, X') = (X - c)(X' - c)$	c permet de localiser le noyau
La fonction radiale de base (RBF)	$k(X, X') = \sigma_f^2 \exp\left(-\frac{(X-X')^2}{l^2}\right)$	$\sigma > 0$ est l'amplitude, $l > 0$ est le paramètre de corrélation ou l'échelle de longueur caractéristique des données
Le noyau quadratique rationnel (RQ) [29]	$k(X, X') = \sigma_f^2 \exp\left(1 + \frac{(X-X')^2}{2\alpha l^2}\right)^{-\alpha}$	$\alpha > 0$ est l'amplitude, $l > 0$
Le noyau perceptron multicouche (MLP)	$\sigma^2 \frac{2}{\pi} \arcsin\left(\frac{\sigma_w^2 x^T x' + \sigma_b^2}{\sqrt{\sigma_w^2 x^T x + \sigma_b^2 + 1} \sqrt{\sigma_w^2 x'^T x' + \sigma_b^2 + 1}}\right)$	σ^2 est la variance, σ_w^2 est le vecteur des variances sur les poids à priori, σ_b^2 le vecteur des variances sur les biais à priori
Les noyaux de la class Matérn (M ν)	$\sigma^2 \cdot \frac{2^{1-\nu}}{\Gamma(\nu)} \left(\frac{\sqrt{2\nu} x-x' }{l}\right)^\nu B_\nu\left(\frac{\sqrt{2\nu} x-x' }{l}\right)$	σ_b^2 est l'amplitude; l est le paramètre de l'échelle de corrélation, Γ est la fonction standard Gamma; B_ν est la fonction de Bessel modifiée de second type d'ordre ν . Le paramètre ν contrôle le degré de régularité de la résultante du processus gaussien. Les noyaux de la class Matérn les plus utilisés sont Matérn 32 (M32) et Matérn 52 (M52)
Le noyau périodique (Per)	$\sigma_f^2 \exp\left(-\frac{2 \sin^2\left(\frac{\pi x-x' }{l^2}\right)}{l^2}\right)$	p est la période, $\sigma > 0$ est l'amplitude, $l > 0$ est le paramètre de corrélation ou l'échelle de longueur caractéristique des données

2.3.4.3 Mise à jour du modèle

Dans la pratique, lorsque le modèle fait des prévisions, de nouvelles valeurs sont observées. Des mises à jour s'imposent donc à chaque fréquence choisie (heures, minutes ou et même seconde). Malheureusement, lors de l'implémentation du processus gaussien standard comme définie ci-dessus, il est difficile de faire la mise à jour du modèle. Car cela engendre des calculs prohibitifs puisque la matrice $K + \sigma^2 I$ qui doit être inversée avec sa complexité $\mathcal{O}(N^3)$. La solution est d'utiliser l'approche dénommée régression par processus gaussien en ligne (Online Gaussian Process Regression OGPR) [171]. Supposons que nous connaissons la distribution du processus gaussien sachant les n premiers points de l'ensemble d'entraînement (X, y) et $\mu = 0$. Si l'on a n_+ nouvelles observations concaténées dans le vecteur X_+ , on pourra écrire la relation (2.60).

$$\left(\begin{bmatrix} K \\ K_+ \end{bmatrix} + \sigma^2 I_{n+n_+} \right)^{-1} = \begin{bmatrix} K(X, X) + \sigma^2 I_n & K(X, X_+) \\ K(X_+, X) + \sigma^2 I_n & K(X_+, X_+) + \sigma^2 I_{n_+} \end{bmatrix}^{-1} \quad (2.60)$$

En posant $A = K(X, X) + \sigma^2 I_n$, $B = K(X, X_+)$, $D = K(X_+, X_+) + \sigma^2 I_{n_+}$, les propriétés d'inversion des matrices en blocs permettent d'écrire la relation (2.58).

avec :

$$\Delta = D - B^T A^{-1} B \in \mathbb{R}^{n_+ \times n_+} \quad (2.61)$$

L'inversion de la matrice d'ordre $(n + n_+) \times (n + n_+)$ requiert maintenant seulement l'inversion de la matrice A que l'on connaît déjà et dont l'inversion d'une matrice de dimension $n_+ + n_+$. La complexité est donc réduite de $\mathcal{O}((n + n_+)^3)$ à $\mathcal{O}(n_+^3 n^2)$.

2.3.4.4 Méthodologie de l'approche ondelettes/Processus Gaussien

La méthode des ondelettes qui sera utilisée dans ce travail consiste en la décomposition de la charge électrique en plusieurs composantes. La décomposition en ondelette appliquée dans cette étude peut être des ondelettes continues ou discrètes dont l'ondelette mère respecte les conditions (2.38) à (2.41). En effet, l'une des propriétés de la transformée en ondelettes continues est la redondance, ce qui signifie que la même information est rencontrée plusieurs fois. La plupart des recherches utilisent des fonctions symétriques telles que Symlet ou Morlet pour la décomposition en ondelette. Cependant, ces types d'ondelette ne sont pas adaptés aux problèmes de prévision.

Car dans les ondelettes symétriques, des informations futures sont également nécessaires ainsi que des informations antérieures [164]. Pour éviter la redondance, des bases orthogonales doivent être utilisées. C'est le but de l'analyse par ondelettes discrètes. Dans cette étude, une fonction d'ondelettes de type Daubechies d'ordre 3 (en abrégé Db3), qui est une ondelette asymétrique, est utilisée pour résoudre ce problème. Les ondelettes de Daubechies présentent un bon compromis entre parcimonie et richesse d'information et les événements identiques dans les séries temporelles observées [165]. Le modèle GP approprié est appliqué à chaque sous-série reconstruite pour prédire la série de tests. Grâce à la décomposition en ondelettes inverses, des résultats de prévision finaux pour la charge électrique sont obtenus en agrégeant la valeur prévisionnelle de la sous-série comme le montre sur la figure 2.13 [164].

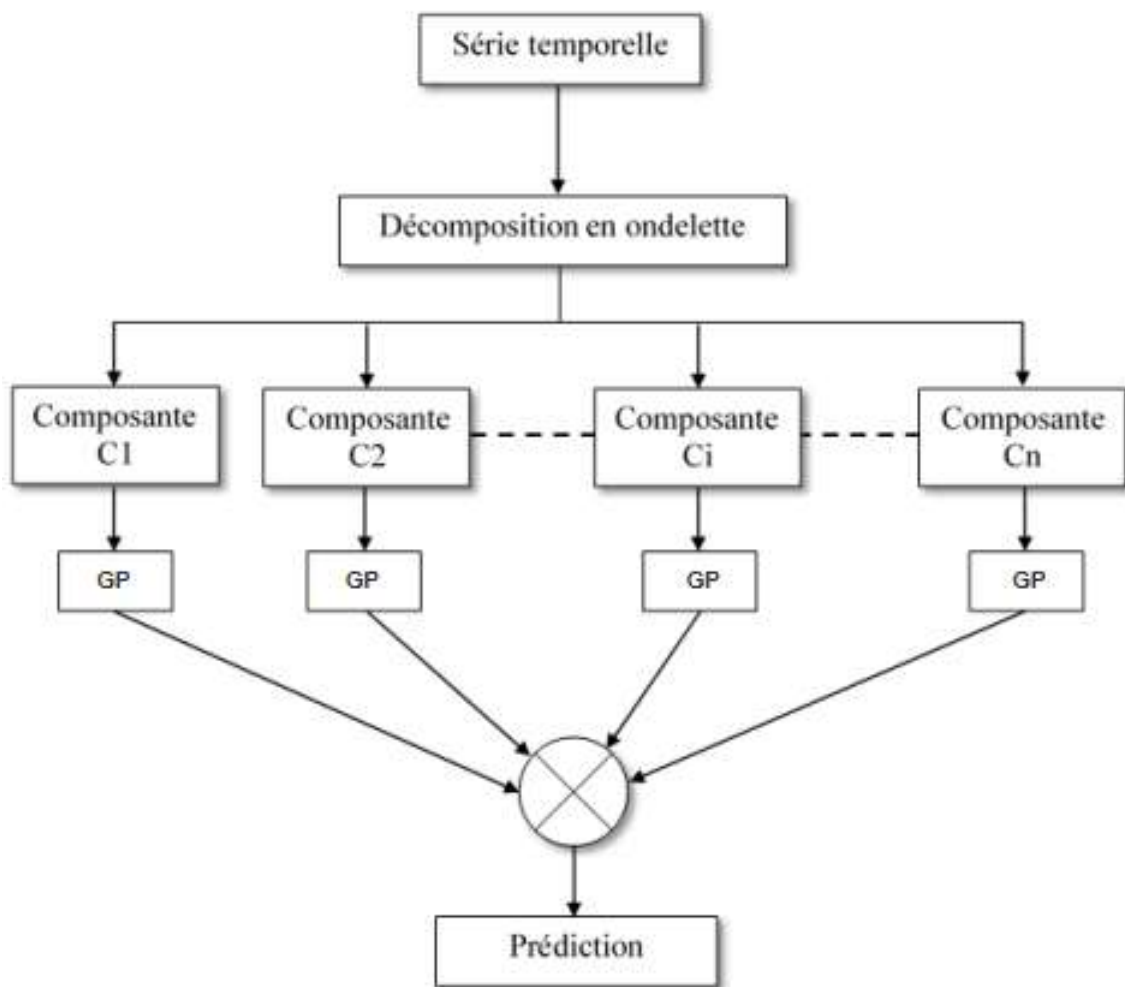


FIGURE 2.13 – Méthodologie de prévision par approche décomposition en ondelettes / Processus Gaussien

2.4 Formulations des problèmes d'optimisation des coûts de l'électricité et d'empreinte carbone

La construction des prix sur le marché de l'électricité se fait par empilement des coûts d'amont en aval le long du réseau électrique : les coûts de production, du transport de l'énergie, et ceux liés à d'autres services. Dans la littérature, les deux derniers coûts sont souvent négligés compte tenu du manque des informations les concernant et aussi de leurs complexités dans la formulation du problème d'optimisation du coût de l'énergie électrique [40, 61, 172]. Par conséquent, Les deux premiers seront donc utilisés dans cette thèse pour permettre aux planificateurs de prendre séparément des décisions relatives aux choix du producteur le moins disant. Dans la suite de l'étude, nous considérons que le réseau électrique est stable dans toute globalité et que le problème lié à capacité de transfert disponible sous contrainte de stabilité pour une évaluation rapide de l'impact des transactions dans un système électrique est résolu. La formulation mathématique du problème d'optimisation que nous présentons dans cette thèse, consiste à minimiser les fonctions coûts des échanges de l'énergie électrique et d'émission de CO₂ sous des contraintes d'égalités et d'inégalités.

2.4.1 Optimisation des coûts de l'électricité

Généralement, cette fonction pour les centrales thermiques est modélisée et approximée par une courbe quadratique [173], dont l'expression totale du coût en pour une période t donnée pour un ensemble Ω_{th} de générateurs thermiques est donnée par la relation (2.62). Nous désignons par N_{th} le cardinal de Ω_{th} , le nombre de générateurs thermiques. Pour le parc de production des énergies renouvelable : le solaire, l'éolien et l'hydroélectrique nous nous reportons aux coûts de l'électricité produite par ces centrales. Soient $\Omega_{éol}$, Ω_{pv} , Ω_{hydro} , les ensembles respectifs des sources de production d'électricité d'origine éolienne, solaire photovoltaïque et hydroélectrique de tailles $N_{éol}$, N_{pv} , N_{hydro} .

$$\min_{P_{th,t}^i, P_{hyd,t}^i, P_{éol,t}^i, P_{pv,t}^i} CT = CT_{th,t}^i (P_{th,t}^i) + CT_{hyd,t}^i (P_{hyd,t}^i) + CT_{éol,t}^i (P_{éol,t}^i) + CT_{pv,t}^i (P_{pv,t}^i) \quad (2.62)$$

avec :

$$CT_{th,t}^i (P_{th,t}^i) = \sum_{t=1}^T \sum_{i=1}^{N_{th}} C_{th,t}^i (P_{th,t}^i) \quad (2.63)$$

$$CT_{hyd,t}^i(P_{hyd,t}^i) = \sum_{t=1}^T \sum_{i=1}^{N_{hyd}} C_{hyd,t}^i(P_{hyd,t}^i) \quad (2.64)$$

$$CT_{éol,t}^i(P_{éol,t}^i) = \sum_{t=1}^T \sum_{i=1}^{N_{éol}} C_{éol,t}^i(P_{éol,t}^i) \quad (2.65)$$

$$CT_{pv,t}^i(P_{pv,t}^i) = \sum_{t=1}^T \sum_{i=1}^{N_{pv}} C_{pv,t}^i(P_{pv,t}^i) \quad (2.66)$$

sous les contraintes :

1. liées aux limites de production de chaque unité de génération.

$$\alpha_{th} P_{th,min}^i \leq P_{th,t}^i \leq \alpha_{th} P_{th,max}^i \quad (2.67)$$

$$\alpha_{hyd} P_{hyd,min}^i \leq P_{hyd,t}^i \leq \alpha_{hyd} P_{hyd,max}^i \quad (2.68)$$

$$\alpha_{éol} P_{éol,min}^i \leq P_{éol,t}^i \leq \alpha_{éol} P_{éol,max}^i \quad (2.69)$$

$$\alpha_{pv} P_{pv,min}^i \leq P_{pv,t}^i \leq \alpha_{pv} P_{pv,max}^i \quad (2.70)$$

2. d'équilibre des puissances.

$$\sum_{i=1}^{N_{th}} P_{th,t}^i + \sum_{i=1}^{N_{hyd}} P_{hyd,t}^i + \sum_{i=1}^{N_{éol}} P_{éol,t}^i + \sum_{i=1}^{N_{pv}} P_{pv,t}^i \geq P_{D,t} \quad (2.71)$$

3. liées à la disponibilité α_s de chaque unité de production d'énergie électrique quelconque s .

$$\alpha_s = \begin{cases} 0 & \text{si non} \\ 1 & \text{si oui} \end{cases} \quad (2.72)$$

2.4.2 Optimisation des émissions CO₂

Différentes stratégies ont été proposées pour prendre en compte les questions environnementales dans la répartition puissance entre les centrales électriques [29]. Certaines d'entre elles sont énumérées ci-dessous :

- minimiser la pollution totale de l’environnement comme fonction objective principale ;
- ajout de la pollution environnementale comme une pénalité à la fonction de coût (pénalité) au coût global de production ;
- ajout de la pollution environnementale comme contrainte au problème initial de répartition économique.

Nous allons utiliser la première stratégie pour formuler les problèmes de minimisation du CO₂. Les émissions de CO₂ par les centrales de type renouvelables étant négligeables à l’échelle humaine, nous ne considérons que les émissions des centrales thermiques. En se basant sur l’expression globale des émissions produite par les centrales thermiques, nous pouvons écrire la relation (2.73).

$$\min_{P_{th,t}^i} TEm_{th,t}^i \quad (2.73)$$

Sous les contraintes :

1. coûts de production de l’énergie (voir relation (2.62)) ;
2. liées aux limites de production de chaque unité de génération (voir relation (2.67) à (2.70)) ;
3. d’équilibre des puissances (voir relation (2.71)) ;
4. liées à la disponibilité de chaque unité de production d’énergie électrique quelconque (voir relation (2.72)).

2.4.3 Résolution par programmation quadratique

La programmation quadratique (PQ) est une méthode d’optimisation efficace pour trouver la solution globale si la fonction objectif est quadratique et les contraintes sont linéaires. Elle peut être appliquée à des problèmes d’optimisation ayant un objectif non quadratique sous des contraintes non linéaires approximées en contraintes linéaires. En effet, l’obtention des optima intérieurs sont possibles. Cela conduit à des conditions d’optimalité, qui sont une extension des principes de base de l’optimisation [29].

2.4.3.1 Définition mathématique

Un PQ est un problème d'optimisation d'une fonction objectif quadratique soumise à des contraintes linéaires formulée par la relation (2.74).

$$\min \frac{1}{2}x^T Qx + R^T x + S \quad (2.74)$$

sous les contraintes :

$$Ax \leq b \quad (2.75)$$

$$A_{eq}x = b_{eq} \quad (2.76)$$

où $x \in \mathbb{R}^n$ est le vecteur des variables de conception. Les matrices ou vecteurs restants $Q \in \mathbb{R}^{n \times n}$, $R \in \mathbb{R}^n$, $S \in \mathbb{R}$, $A \in \mathbb{R}^{n \times m}$, $b \in \mathbb{R}^m$, $A_{eq} \in \mathbb{R}^{l \times n}$, $b_{eq} \in \mathbb{R}^l$, où n est le nombre de variables de conception, m est le nombre de contraintes d'inégalité, et l est le nombre de contraintes d'égalité. Pour résoudre le problème d'optimisation des coûts de l'énergie électrique produite et de l'empreinte carbone, la PQ peut être mise en œuvre efficacement en définissant les matrices Q , R , A , A_{eq} et b .

2.4.3.2 Conditions d'optimalité

En calcul, une condition nécessaire pour les minimiseurs des PQ est que la pente de la fonction soit nulle à l'optimum. Nous étendons cette notion aux fonctions multi variables. Autrement dit, si x^* est un optimum, alors le gradient est nul à l'optimum (voir relation (2.77)).

$$\frac{d}{dx} f(x^*) = 0 \implies Qx^* = -R \quad (2.77)$$

Nous appelons cette condition, la condition nécessaire de premier ordre pour l'optimalité. Cette condition est nécessaire pour un optimum, mais pas suffisante pour caractériser complètement un minimiseur ou un maximiseur. Par conséquent, nous appelons solution un point stationnaire x^\dagger . En calcul, le terme "extremum" est souvent utilisé. Rappelons que la dérivée seconde peut révéler si un point stationnaire est un minimiseur, maximiseur ou aucun des deux. Pour les fonctions à une variable $f(x)$, le point stationnaire x^\dagger a une nature caractérisée par la relation (2.78).

$$\begin{cases} x^\dagger \text{ est minimum si } f''(x^\dagger) > 0 \\ x^\dagger \text{ est maximum si } f''(x^\dagger) < 0 \\ x^\dagger \text{ est un point d'inflexion si } f''(x^\dagger) = 0 \end{cases} \quad (2.78)$$

Cette notion s'étend aux problèmes d'optimisation multivariables. Considérons la dérivée seconde d'une fonction multivariable, que l'on appelle le Hessien défini par la relation (2.79) où Q est le hessien.

$$\frac{d}{dx} f(x^\dagger) = Q \quad (2.79)$$

La nature du point stationnaire est donnée par la définition de la matrice Q . À savoir, si Q est définie positivement alors x^\dagger est un minimiseur local. Si Q est définie négativement alors x^\dagger est un maximiseur local. Il est également possible d'avoir des solutions infinies qui peuvent être caractérisées par le hessien Q . Si Q est semi-défini positif (négatif), alors x^\dagger est une vallée (crête). Dans le cas où Q est indéfini, alors x^\dagger est un point de selle.

2.5 Conclusion

Pour faire face aux mutations du paysage énergétique, il est nécessaire d'actualiser l'évolution du système exigeant la mise en place des outils capables planifier en permanence l'équilibre entre l'offre et la demande sur le réseau électrique. Ceci passe par la mise en place des outils de planification permettant de caractériser les sources disponibles dans le réseau électrique, l'optimisation du coût de l'électricité et de prévision de la charge électrique. Dans ce chapitre, nous avons proposé le modèle de mélange gaussien de manière générale et la méthode utilisée pour estimer ses paramètres (l'algorithme de l'Espérance-Maximisation(E-M)). Le modèle de mélange sera comparé aux modèles classiques dont les paramètres sont estimés par la méthode de maximum de vraisemblance à partir des critères de performance statistiques. Pour une prévision à court terme de la demande d'électricité, trois (03) modèles k-means clustering / ANN, ondelettes / ARIMA et ondelettes / Processus Gaussien qui sont des approches hybrides robustes sont proposées. Du point de vue de la démarche d'optimisation, une programmation quadratique est abordée afin de trouver des solutions permettant des transactions des flux de puissances à moindre coût avec un taux CO₂ optimisé. La maîtrise de ces outils nous conduit à la mise en œuvre d'un logiciel pour la planification à court terme des réseaux électriques.

Chapitre 3

Etude et réalisation d'un logiciel d'analyse, de caractérisation des sources d'énergie électrique, de prédiction de la demande et d'optimisation du coût et de CO₂

3.1 Introduction

Dans ce chapitre, les méthodes de caractérisation des sources de production d'énergie électrique, les techniques de prévision de la charge électrique, ainsi que le problème d'optimisation que nous avons proposés dans le chapitre précédent, seront intégrés dans une application dénommée STCED (Statistic Tool for Characterizing Electricity Data). La terminologie STCED prête son nom de la langue anglaise, et constitue un outil d'aide pour le gestionnaire du réseau électrique capable de planifier dans un temps record, des échanges des flux d'énergie entre les réseaux électriques interconnectés sur le marché de l'électricité. L'outil STCED sera un atout inestimable pour les compagnies électriques des pays en voie de développement dans le but d'organiser une approche structurée et intégrée de leurs réseaux électriques, de prendre en compte des besoins, d'identifier les solutions optimales pour réduire le déficit énergétique. De plus, le logiciel STCED aidera les techniciens et les ingénieurs à une meilleure prise de décision dans l'étude et l'élaboration des projets de développement et de la planification des réseaux électriques. Enfin, sur le plan éducatif,

ce logiciel constitue un matériel didactique pour nos écoles d'ingénieurs pour réaliser les Travaux Pratiques dans les cours de planification des réseaux électriques et d'introduction au marché de l'électricité.

3.2 Objectif du logiciel STCED

La planification des réseaux électriques constitue une problématique d'actualité sur le marché de l'électricité. Elle est une tâche très capitale dans la mise en œuvre, le fonctionnement, la sécurité et la stabilité de l'ensemble du système électrique. Les contributions apportées par cette thèse se situent au niveau du côté de transport des réseaux électriques. De ce fait, il est très important de prendre en compte tous ces aspects dans l'élaboration du processus de planification des réseaux électriques pour assurer un approvisionnement sûr et stable de l'électricité à moindre coût, en conformité avec les exigences environnementales et technologiques.

Dans ce contexte, plusieurs outils ont été développés sur le marché de l'électricité pour faciliter l'analyse, la modélisation, la prévision, la planification, l'optimisation et la visualisation des comportements des réseaux électriques de transport. Ce sont les logiciels NEPLAN [8], PowerWorld [68, 69], ETAP [10], CYME [11], Aiolos Forecasting Studio [174], GMDH [175, 176], ESCOWare [177, 178], SAS [177], Statgraphics [179–181] et ceux de l'Innovation Energie et Développement (IED) [12]. Tous ces logiciels sont spécifiquement développés pour les pays du nord et difficilement ou parfois non adaptés au contexte des pays en voie de développement. En plus d'être payants, certains d'entre eux sont des boîtes noires configurables par l'utilisateur sans accéder aux algorithmes et techniques de modélisation utilisés lors de simulation avec les données réelles. Ce qui remet parfois en cause les méthodes et techniques utilisées par ces outils de planification des réseaux électriques dans l'environnement actuel du marché auquel s'engagent différents acteurs. Cependant, le gestionnaire du réseau, les propriétaires et les exploitants de réseaux de transport doivent non seulement planifier la croissance future de la demande et des portefeuilles de production de plus en plus incertains, mais aussi fournir des services de transport pour des scénarios comportant une grande quantité de ressources distribuées.

Plusieurs axes de recherches importants pourront aider les planificateurs à relever ces défis à venir. Nous pouvons citer entre autres : la validation périodique des modèles génériques pour les études de planification, la gestion des contingences pour les problèmes de stabilité, l'application accrue d'équipements de transmission à interface électronique de puissance, ainsi que des technologies d'amélioration du réseau de

transport, l'intégration du stockage et des ressources diversifiées, la prise en compte de l'impact du changement climatique, l'utilisation de l'intelligence artificielle (AI), etc.

Dans le cadre de cette thèse, nous utilisons le Machine Learning qui est d'actualité pour développer un nouvel outil de planification des réseaux électriques. Le logiciel, STCED, que nous proposons est un outil de caractérisation des sources de production d'énergie électrique, de prédiction de la demande d'énergie électrique, d'optimisation du coût d'achat de l'énergie électrique et de perspective d'intégration des énergies renouvelables afin de minimiser l'empreinte carbone. Une fois élaboré, les compagnies électriques et les planificateurs des réseaux électriques se serviront de cet outil pour :

- planifier les sources de production d'énergie électrique ;
- prédire la consommation future d'énergie électrique ;
- identifier la meilleure stratégie de planification appliquée à un réseau électrique (interconnecté) afin d'optimiser le coût de l'énergie achetée ;
- minimiser l'empreinte carbone.

Le logiciel STCED, que nous avons développé dans cette thèse, est à sa première version et utilise Python 3.8 comme langage de programmation. Il fonctionne sous l'environnement Windows et autres plateformes. Il offre en toutes circonstances au gestionnaire du réseau, la possibilité de pouvoir réaliser une vérification et une analyse rapide des résultats à partir des données d'entrée avec une bonne précision afin de prendre des décisions les plus appropriées.

3.3 Aspects logiciel et matériel

Dans cette partie, nous passons à la description des langages de programmation Python 3.8 et GAMS (General Algebraic Modeling System) pour la résolution du problème d'optimisation, de l'environnement de développement intégré dédié à la programmation (IDE) en Python PyCharm, de l'outil Qt Designer qui permet de concevoir des interfaces graphiques avec sans avoir à écrire une seule ligne de code. Ensuite, la description du matériel informatique puissant, ergonomique et durable impliqué dans la réalisation du logiciel fera l'objet d'une présentation dans cette section.

3.3.1 Python : un langage de programmation polyvalent

Python est un langage puissant, à la fois facile à apprendre et riche en possibilité d'écrire des scripts ou de programmes complets ayant une mission très précise [182, 183]. Une fois installé sur ordinateur, nombreuses fonctionnalités sont intégrées au langage offrant la facilité de créer ou d'étendre les fonctionnalités existantes grâce à des bibliothèques propres à des projets particuliers. Ce qui fait de lui le premier langage de programmation utilisé dans le scripting, développement Web, calcul scientifique, Big Data et le Machine Learning ainsi que la programmation en Systèmes Embarqués. De plus, Python permet le développement de nombreux autres types d'applications graphiques. Tous ces avantages en fait de Python notre choix pour le développement mise œuvre du logiciel STCED.

3.3.2 Pourquoi choisir l'IDE PyCharm ?

Il existe actuellement une pléthore d'EDI (Environnement de Développement Intégré) permettant le développement d'une application sous Python : IDLE, eric, Wing IDE, PyCharm, PyDev, Ninja-IDE, Spyder, etc. Cependant, il est difficile d'élire un meilleur EDI, car il y a plusieurs critères de sélection dont l'importance varie d'un type d'utilisation à l'autre. Il s'agit de question des licences, du prix et de la version. Il nous a semblé plus intéressant de choisir PyCharm particulier comme IDE de développements complets d'application Python.

Le choix de PyCharm comme EDI est justifié essentiellement par le fait qu'il est gratuit et offre une bonne intégration avec PyQt [184]. Ceci nous a paru être des critères importants pour son choix dans le contexte de cette étude. De plus, PyCharm a des caractéristiques intéressantes qu'on ne trouve pas forcément dans tous les EDI :

- il est l'IDE le plus populaire et le plus utilisé pour la programmation Python ;
- il est relativement riche au niveau de ses fonctionnalités ;
- il supporte les versions 2 et 3 du langage Python ;
- il est un outil puissant qui permet de développer des applications complexes ;
- il dispose deux versions : la version Communautaire (et gratuite) non limitée dans le temps et la version Professionnelle (qui est payante et soumise à licence commerciale) qui propose de nombreux autres outils orientés développement Web, calculs scientifiques et Machine Learning ;

Une fois lancé après l'installation, l'interface utilisateur de l'éditeur PyCharm est

présentée sur la figure 3.1. Nous voyons que l'éditeur comprend diverses fonctionnalités pour créer un nouveau projet ou importer à partir d'un projet existant.

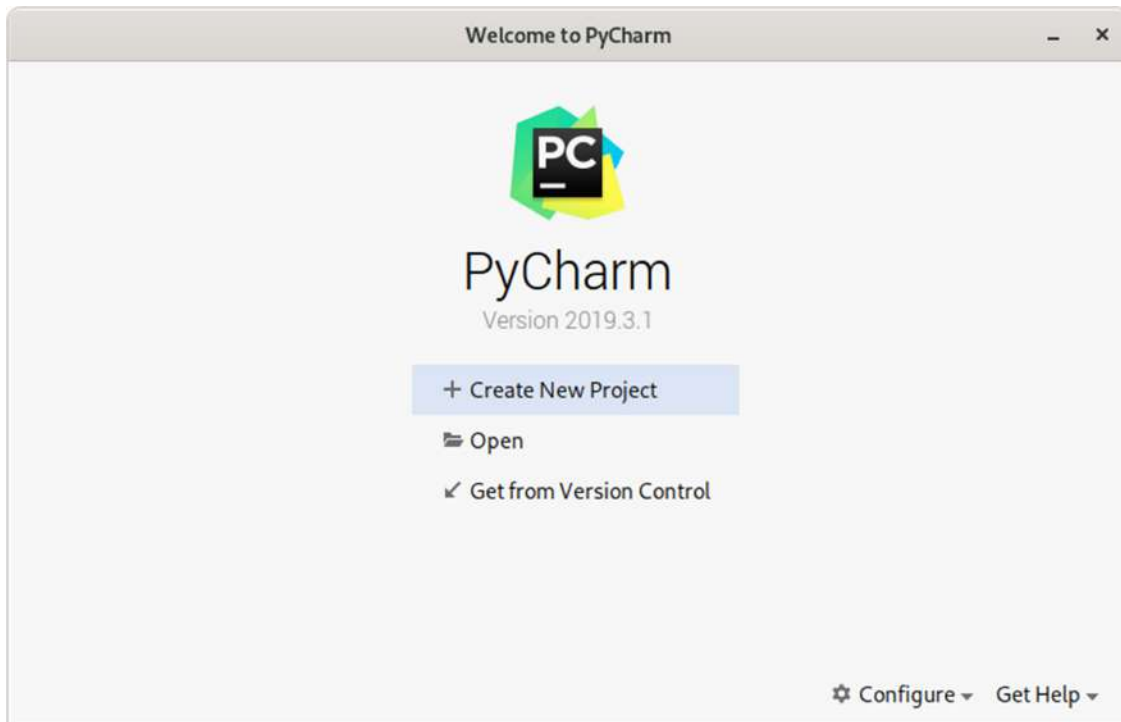


FIGURE 3.1 – Interface utilisateur de l'éditeur PyCharm

Pour créer un nouveau projet, il suffit de cliquer sur le bouton « Create New Project ». Un nouvel écran est alors proposé. Ensuite, il faut dérouler l'entrée « Project Interpreter » pour accéder à l'ensemble des configurations proposées. Souvent, il est conseillé de rester avec une configuration de type « New environment using VirtualEnv » avec une version de Python 3 suivant la figure 3.2.

Ensuite, il faut renseigner un nom de projet dans la zone d'édition proposée en haut de la fenêtre, et sa localisation. Après cela, il faut cliquer sur « Create » pour procéder à sa génération. Au bout de quelques secondes, cette fenêtre (Figure 3.3) apparaîtra.

En Python, un fichier de code est communément appelé « un module ». Pour créer un nouveau Fichier/Module de code Python, il faut cliquer avec le bouton droit de la souris puis sélectionner « New / Python File ». Un popup doit apparaître dans lequel il faut y saisir en haut le nom du fichier à produire (Figure 3.4). En appuyant sur la touche « Entrée », le fichier `Essai.py` par exemple doit être produit. Une fois le code édité, il ne reste plus qu'à l'exécuter. Pour ce faire, il faut cliquer avec le bouton droit de la souris dans le fichier en cours d'édition, puis sélectionner « Run

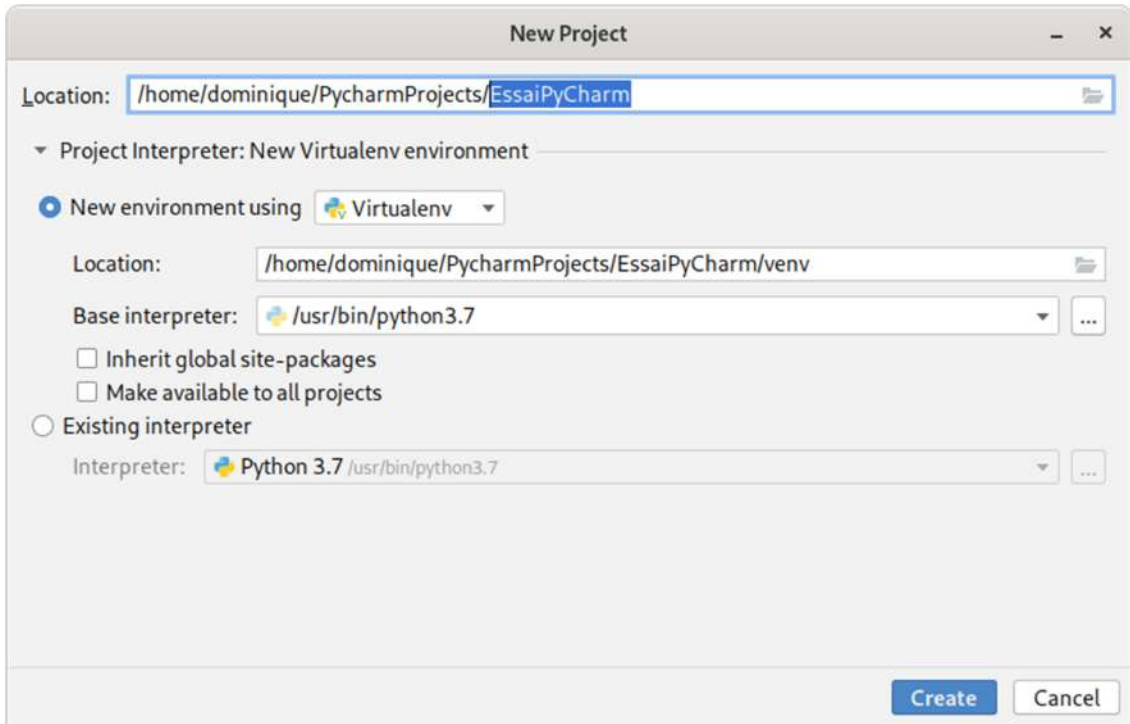


FIGURE 3.2 – Creation d'un projet avec l'éditeur PyCharm

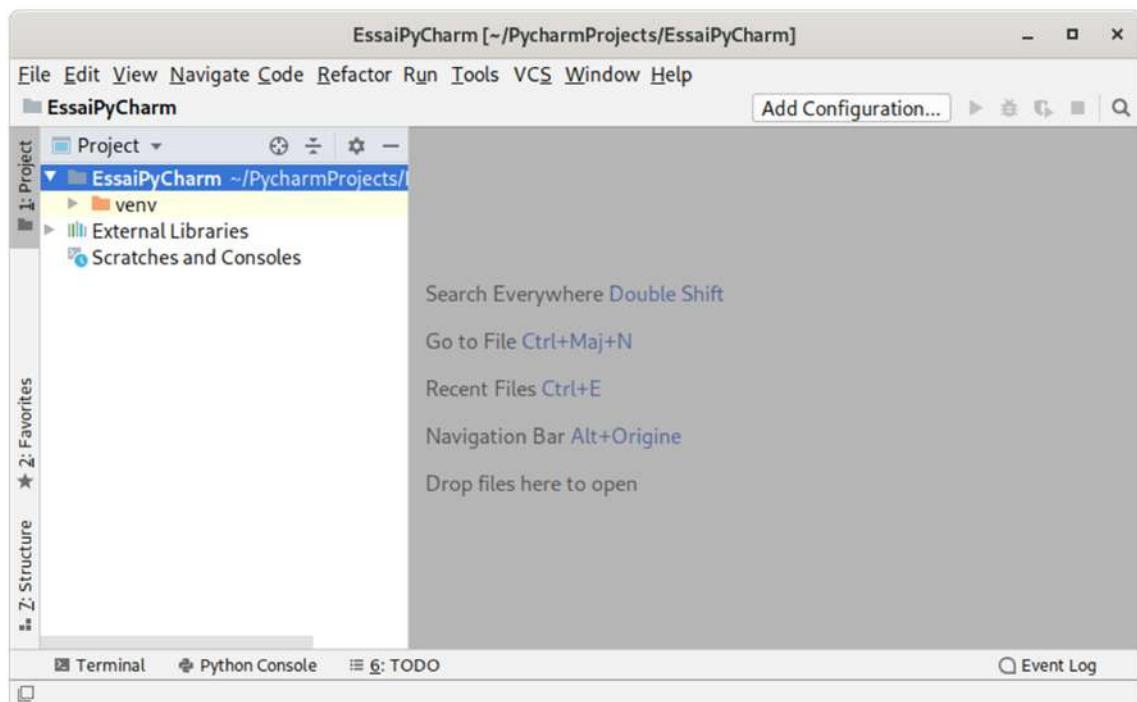


FIGURE 3.3 – Fenêtre principale de l'éditeur PyCharm après creation du projet

Essai ». L'affiche du programme est réalisé dans la vue « Run » affichée en bas de

la fenêtre de PyCharm. Cela permet de créer un nouveau projet Python dans lequel nous pouvons travailler à partir de zéro. Il faut noter que contrairement à d'autres IDE, PyCharm se concentre uniquement sur le travail avec des projets de script Python langage.

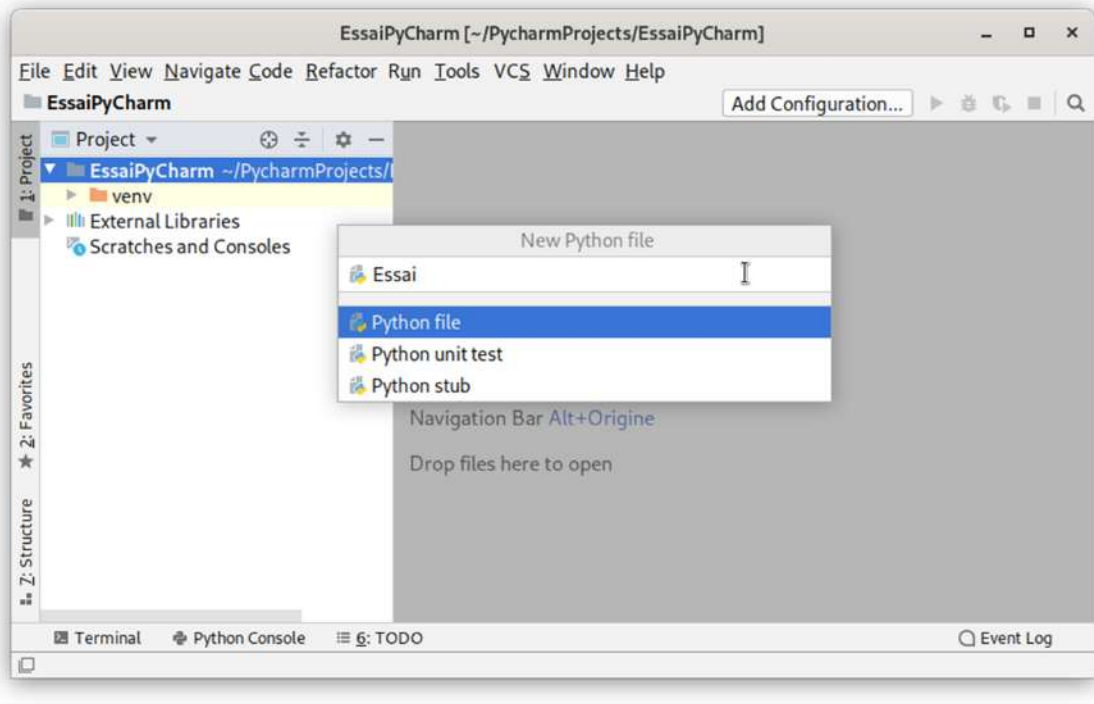


FIGURE 3.4 – fenêtre principale de création d'un module en Python sous PyCharm

3.3.3 Présentation de l'outil de création des interfaces graphiques Qt Designer

Pour le développement de notre application, nous avons besoin du framework PyQt qui est un module permettant la liaison entre la bibliothèque Qt à l'environnement Python [182]. Etymologiquement, PyQt est constitué de deux mots que sont Python et Qt. Qt est un cadriciel écrit en C++ et qui aide principalement pour la création des interfaces graphiques. Pour le développement d'interfaces utilisateur, Qt propose un outil puissant et bien pensé : Qt Designer. C'est une application très bénéfique aux concepteurs de GUI pour la réalisation des maquettes des applications sans toutefois rentrer dans la programmation. Une fois que la maquette est stable, on peut définir via Qt Designer, les noms qui serviront à identifier les éléments de l'interface graphique, puis générer des slots afin de les connecter aux signaux. Lors de son lancement, Qt Designer propose la création d'un nouveau projet grâce à la fenêtre présentée sur la figure 3.5.

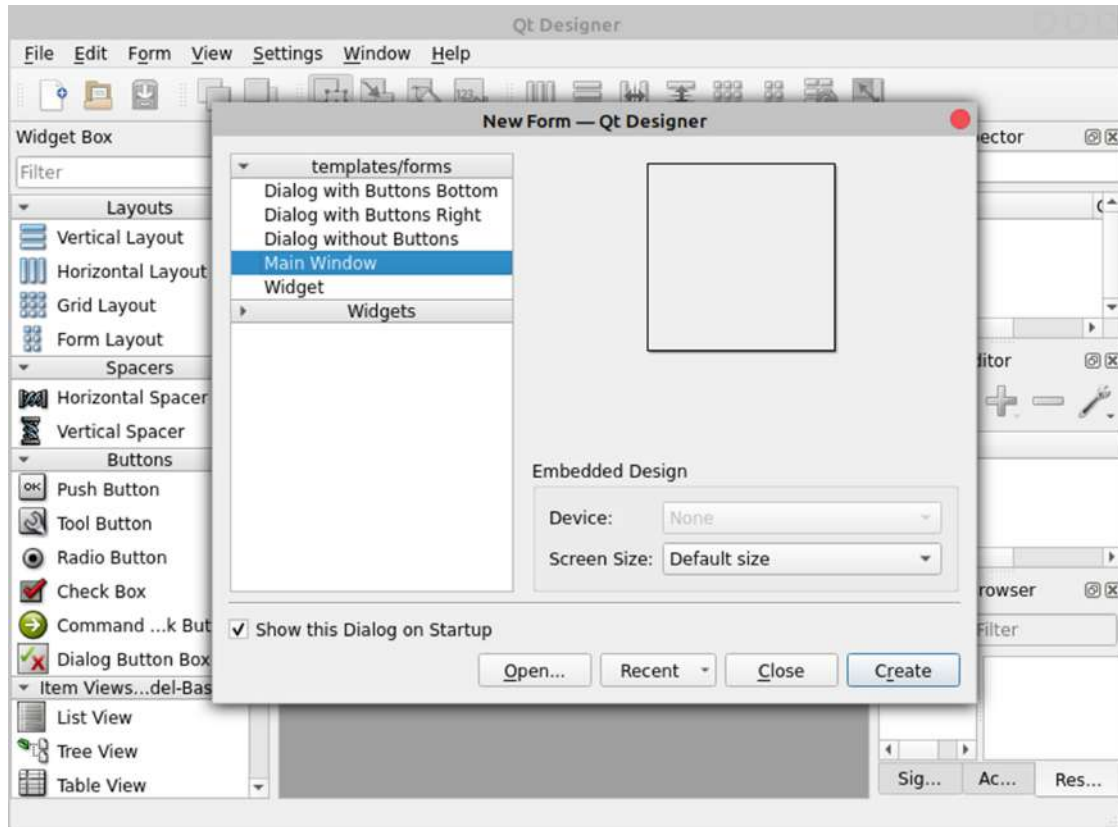


FIGURE 3.5 – Fenêtre principale de Qt designer

Au démarrage, Qt Designer affiche par défaut les éléments les plus importants :

- l'espace de travail présenté au milieu disponible pour contenir tous les composants nécessaires au projet ;
- la boîte de widgets, qui est la grande boîte à outils de widgets fournis par Qt, qu'on va pouvoir placer sur notre fenêtre ;
- l'inspecteur d'objet, qui répertorie tous les objets (widgets et layouts) placés sur la fenêtre en cours de conception, en détaillant leur structure arborescente utile au début et qui peut rapidement devenir pratique pour sélectionner les objets difficilement atteignables sur la vue graphique ;
- l'éditeur de propriétés, qui montre toutes les propriétés du widget sélectionné et permet de les éditer. La liste précise dépendra du widget sélectionné. Les propriétés sont rangées par classe héritée, en commençant par la classe racine QWidget.

Lorsque un nouveau projet créé, l'interface de Qt Designer commence à s'animer. Elle est présentée sur la figure 3.6.

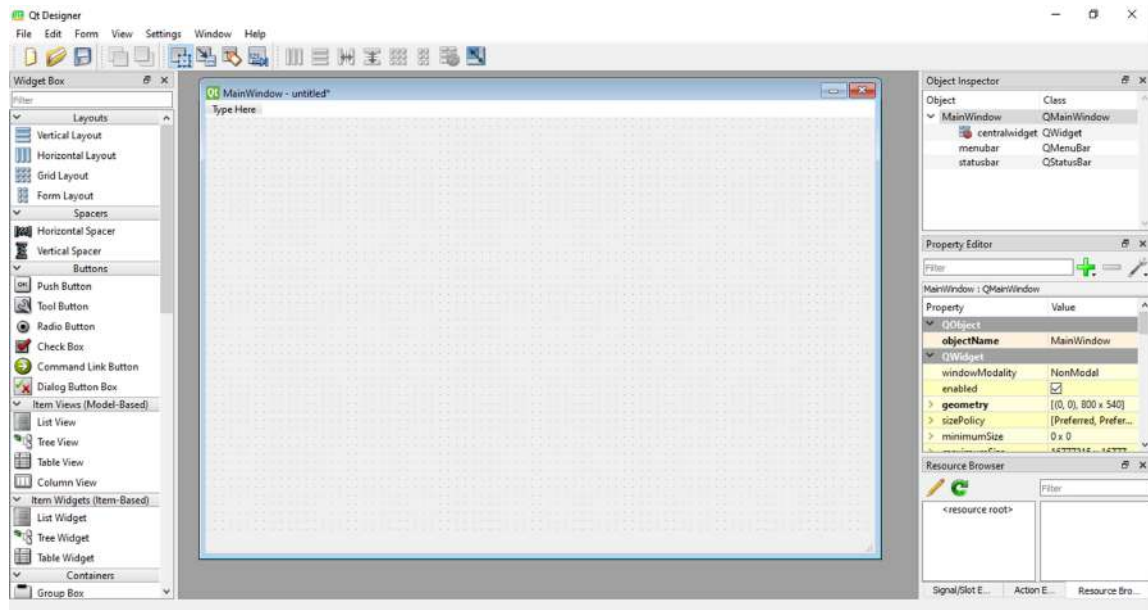


FIGURE 3.6 – Fenêtre d'affichage de Qt designer

3.3.4 Logiciel de programmation GAMS

L'outil GAMS est un modèleur mathématique pour l'optimisation dans le domaine de l'industrie et des recherches scientifiques. Il permet de décrire le problème d'optimisation dans un langage de modélisation mathématique dédié. Il assure ensuite la résolution et le prétraitement du problème afin de le mettre sous une forme compatible avec l'utilisation des algorithmes d'optimisation [29]. Ce prétraitement consiste notamment à effectuer un certain nombre de simplifications et à calculer les gradients du modèle. Enfin, ils font appel à un algorithme d'optimisation pour la résolution du problème, puis permettent l'affichage du résultat. GAMS est compatible avec un nombre important d'algorithmes d'optimisation libres ou commerciaux, adressant de nombreux types de problèmes d'optimisation. Ces outils d'optimisation ont pour objectif de simplifier la tâche de l'utilisateur en constituant l'interface entre la formulation du problème et les algorithmes d'optimisation. Les résultats obtenus sont enregistrés dans un tableur Excel puis envoyé à STCED pour une étude plus approfondie.

La caractéristique la plus frappante de l'application GAMS pour résoudre certains problèmes d'optimisation mathématique est la capacité d'élaborer des modèles linéaires et non linéaires et de prendre en compte des variables continues, discrètes ou binaires. La structure de base du modèle mathématique codé dans GAMS contient les éléments suivants : « sets » (affectations des membres), « data » (paramètres,

tableaux et scalaires), «variable» (limites et/ou valeurs initiales), «equation» (composants qui contiennent la définition de la fonction objectif), «model» (composant qui sélectionne les contraintes à être utilisées par GAMS dans l'optimisation de la fonction objective) et «output» qui constitue la sortie par défaut d'une exécution GAMS est étendue et informative. La procédure de résolution d'un problème par GAMS est décrite sur la figure 3.7.

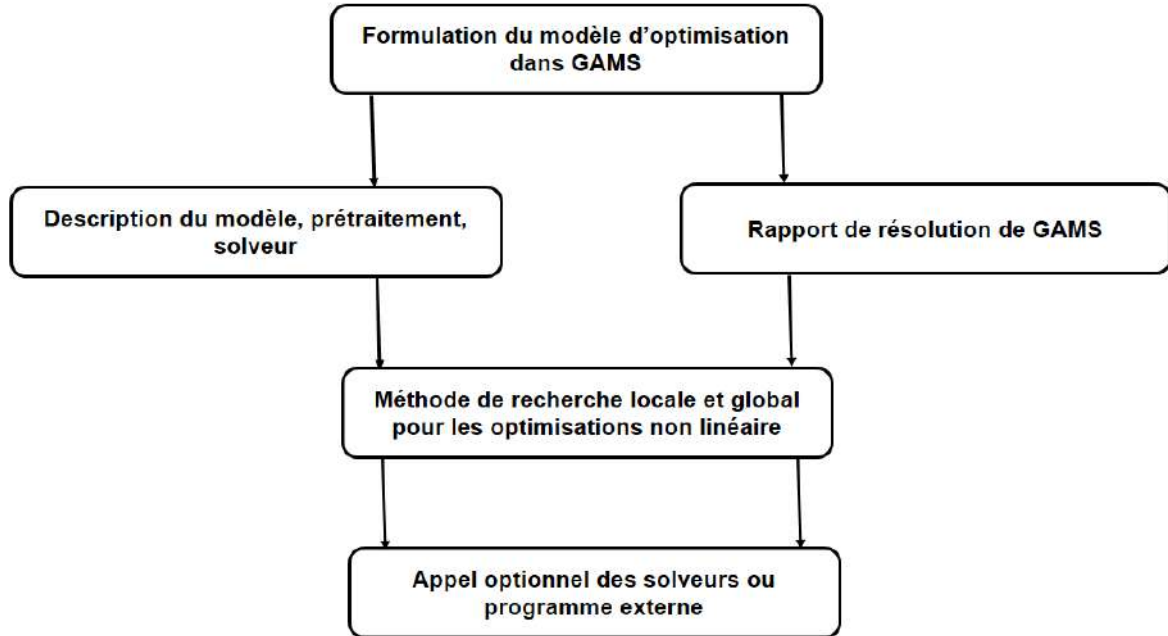


FIGURE 3.7 – Procédure de résolution de GAMS

L'implémentation d'un problème dans GAMS ainsi que les résultats obtenus à la sortie, sont respectivement présentés sur les figures 3.8 et 3.9. Un grand nombre de solveurs pour les modèles de programmation mathématique (optimisation globale déterministe, solveur de programmation stochastique, programmation linéaire, solveur de régression linéaire, etc.) est intégré dans GAMS. GAMS a deux classes de modèles non linéaires : la programmation non linéaire (NLP) et la programmation non linéaire différentiable (DNLP). Les modèles DNLP peuvent en outre utiliser des fonctions lisses mais ayant des dérivées discontinues. Pour cette raison, dans ce travail, nous avons utilisé des modèles NLP. Actuellement, il existe un grand nombre de solveurs différents disponibles pour résoudre la NLP dans GAMS. Nous avons décidé d'utiliser le solveur CONOPT pour les raisons suivantes :

- GAMS / CONOPT convient bien aux modèles avec des contraintes non linéaires ;
- GAMS / CONOPT peut utiliser des dérivées secondaires ;

```

We do request that publications derived from the use of the developed GAMS code
explicitly acknowledge that fact by citing
Geroudi, Alireza. Power System Optimization Modeling in GAMS. Springer, 2017.
DOI: doi.org/10.1007/978-3-315-62350-4
$offText
|

Set Gen / g1*g5 /;

Scalar load / 400 /;

Table data (Gen,*)
      a      b      c      Pmin  Pmax
G1  3      20     100     28    206
G2  4.05   18.07  98.87   90    284
G3  4.05   15.55  104.26   68    189
G4  3.95   19.21  107.21   76    266
G5  3.98   26.18  95.31    19    53;

Variable P (gen), OF;
Equation eq1, eq2;

eq1.. OF =e= sum (gen, data (gen,'a')*P (gen)+ data (gen,'b')*P (gen)+ data (gen,'c'));
eq2.. sum (gen,P (gen)) =g= load;

P.lo (gen) = data (gen,'Pmin');
P.up (gen) = data (gen,'Pmax');

Model ED / eq1, eq2 /;
solve ED using qcp minimizing of;
    
```

FIGURE 3.8 – Structure d'un modèle GAMS

```

GENERATION TIME = 0.016 SECONDS 4 MB 35.2.0 r33388c4 WEX-WEI
GAMS 35.2.0 r33388c4 Released Jun 2, 2021 WEX-WEI x86 64bit/MS Windows - 10/20/21 10:37:11 Page 5
Economic Load Dispatch
Solution Report SOLVE ED Using QCP From line 42

      SOLVE SUMMARY

MODEL ED          OBJECTIVE OF
TYPE QCP          DIRECTION MINIMIZE
SOLVER CONOPT    FROM LINE 42

**** SOLVER STATUS 1 Normal Completion
**** MODEL STATUS  2 Locally Optimal
**** OBJECTIVE VALUE 131455.0003

RESOURCE USAGE, LIMIT 0.000 10000000000.000
ITERATION COUNT, LIMIT 15 2147483647
EVALUATION ERRORS 0 0
--- *** This solver runs with a demo license. No commercial use.

C O N O P T 3 version 3.17K
Copyright (C) ARKI Consulting and Development A/S
Bagevaerdvej 246 A
DK-2880 Bagevaerd, Denmark

The model has 6 variables and 2 constraints
with 11 Jacobian elements, 5 of which are nonlinear.
    
```

FIGURE 3.9 – Sortie d'un modèle GAMS

- GAMS / CONOPT a été conçu pour les grands modèles ;
- GAMS / CONOPT est conçu pour les modèles avec des fonctions fluides, mais il peut également être appliqué à des modèles qui n'ont pas de fonctions différentiables.

3.3.5 Aspects matériels

Le logiciel STCED 1.0 s'exécute dans l'environnement de l'IDE PyCharm Community Edition 2021.1.1 utilisant Python 3.8 comme langage de programmation. Python, vu ses caractéristiques, est un langage puissant utilisé dans l'apprentissage machine qui consiste à automatiser un système informatique pour étudier une grande quantité de données et prendre des décisions basées sur l'analyse, le tout sans aucune intervention humaine. Il s'agit donc d'un sous ensemble de l'IA, qui utilise de lourds algorithmes d'apprentissage automatique pour étudier de grandes quantités de données. Ceci exige une machine puissante qui a besoin de beaucoup d'espace mémoire et d'un processeur de fréquence élevée pour assurer la rapidité et la précision dans le traitement des données. Ainsi, après plusieurs exécutions du logiciel STCED 1.0 sur des ordinateurs portatifs de configurations matérielles différentes, sera donc requis un environnement minimum d'un micro-ordinateur type TensorBook de :

- Processeur : 2.3 GHz Intel Core i7-10875H ;
- RAM : 64 GO ;
- Stockage : 2TB SSD ;
- Affichage : 15,6 pouces FHD OLED (1920 x 1080) ;
- GPU : 8 Go NVIDIA GeForce RTX 2080 Super Max-Q ;
- Durée de vie de la batterie : Jusqu'à 2 heures.

3.4 Développement du logiciel

Après une présentation complète des éléments matériels et logiciels requis pour le développement de notre application, nous passons à la description du logiciel ainsi que toute les étapes nécessaires à son élaboration.

3.4.1 Description sommaire du logiciel

Le logiciel STCED développé, a son organigramme principal présenté sur la figure 3.10. Ce logiciel (tout en un), constitue pour le gestionnaire du réseau, un outil de planification du réseau électrique en se servant des données sur le marché de l'électricité. Grâce à son interface graphique bien conçue, il permettra à l'utilisateur d'économiser beaucoup d'effort dans la formulation et résolution des problèmes complexes dans le secteur d'électricité avec un temps de simulation rapide. Les résultats obtenus à la sortie du logiciel, sont présentés sous forme numérique, ou de tableau ou graphique. Une structure détaillée du logiciel STCED est présentée sur la figure 3.11. Cette structure décrit les caractéristiques de modélisation de ce logiciel

à travers cinq (05) modules qui sont :

- module de bases de données ;
- module d'analyse statistique des données ;
- module de traitement du signal ;
- module de prédiction de charge électrique ;
- module optimisation.

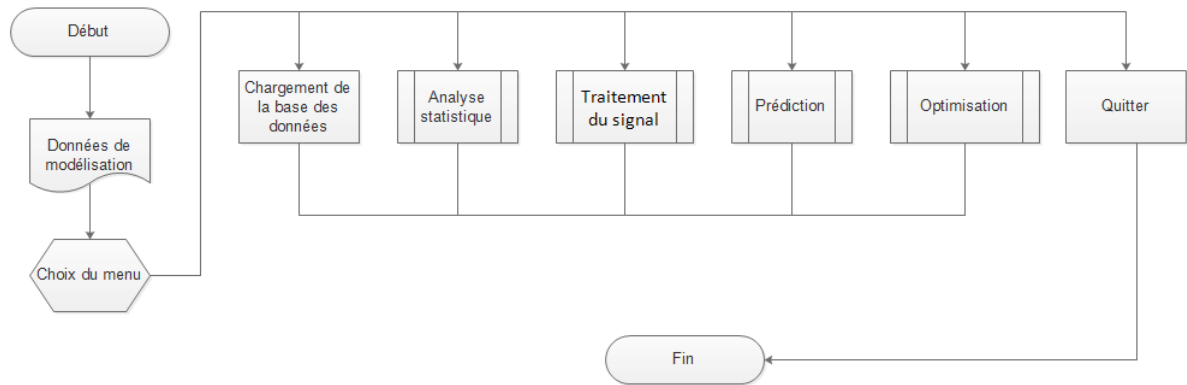


FIGURE 3.10 – Organigramme général de fonctionnement du logiciel STCED

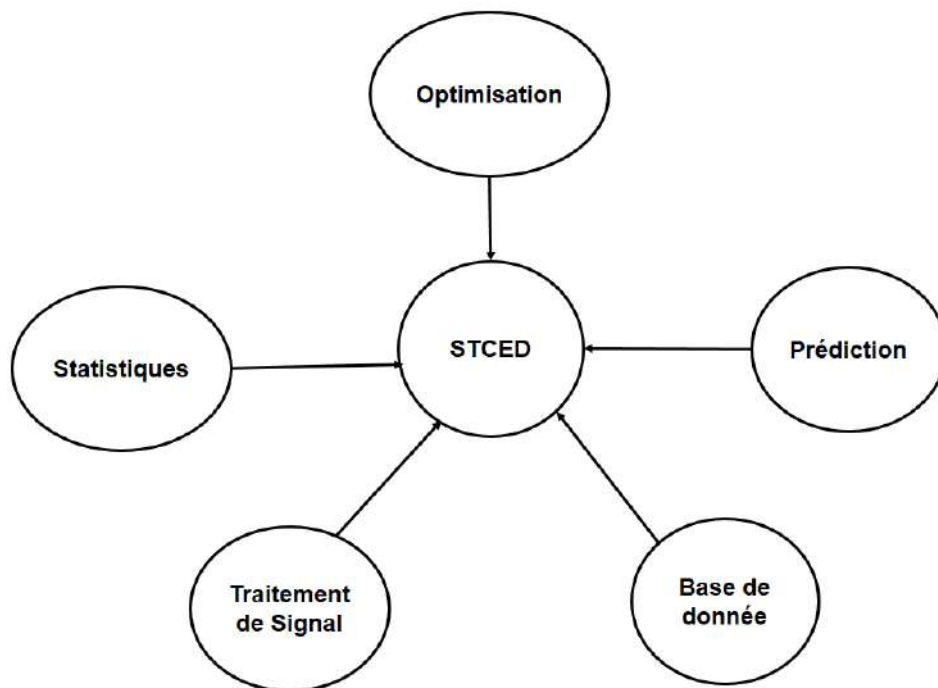


FIGURE 3.11 – Schéma structural du logiciel STCED

3.4.2 Module de bases de données

Le Logiciel STCED dispose d'excellentes méthodes pour lire des données à partir de fichiers Excel accessibles à depuis le menu « parcourir (Browse) ». L'utilisateur pourra exporter les résultats de STCED en fichier Excel (pour les tableaux) ou en image (pour les représentations graphiques) pour d'autres tâches d'analyse de données telles que : introduire ces données dans des outils d'apprentissage automatique pour construire des modèles.

STCED offre aussi la flexibilité à l'utilisateur d'ajouter à la base de données d'autres variables qui interviennent dans la modélisation de la demande électrique qui peuvent être complétés à partir du logiciel. Une autre mission assignée à ce module est l'utilisation des statistiques descriptives pour résumer la tendance centrale, la dispersion et la forme de la distribution d'un ensemble de données, à l'exclusion des valeurs NaN sur tout l'ensemble de colonnes de la feuille de calcul Excel. Les résultats varient en fonction de ce qui est fourni. Il faut noter qu'il est pratique de considérer les données tabulaires d'une feuille de calcul Excel comme une table de base de données bien préparée et prétraitée comme celle présentée sur la figure 3.12 avant de l'importer dans le logiciel.

FIGURE 3.12 – Base de données sur l'électricité sous Excel

3.4.3 Module d'analyse des données

L'étude et l'analyse du profil des données d'énergie électrique occupent une place importante dans le management et la planification quotidiens des compagnies élec-

triques. Cependant, l'évolution de la production de l'électricité est conditionnée par la nature saisonnière voire aléatoire de la demande. D'où la nécessité de développer des modèles mathématiques performants et fiables suivant les approches déterministes ou stochastiques. Il est donc important de choisir un modèle de distribution précis qui imite fidèlement la distribution de la production ou les importations à tout moment pour réduire les erreurs d'estimation liées aux coûts de planification des sources de production. Les travaux de recherches présentés dans cette thèse proposent des lois comme celles de Gauss, Weibull, Rayleigh, Exponentielle, Normale asymétrique et de mélange de distributions Gaussiennes pour caractériser ces sources. La figure 3.13 présente l'organigramme du module analyse statistique des données.

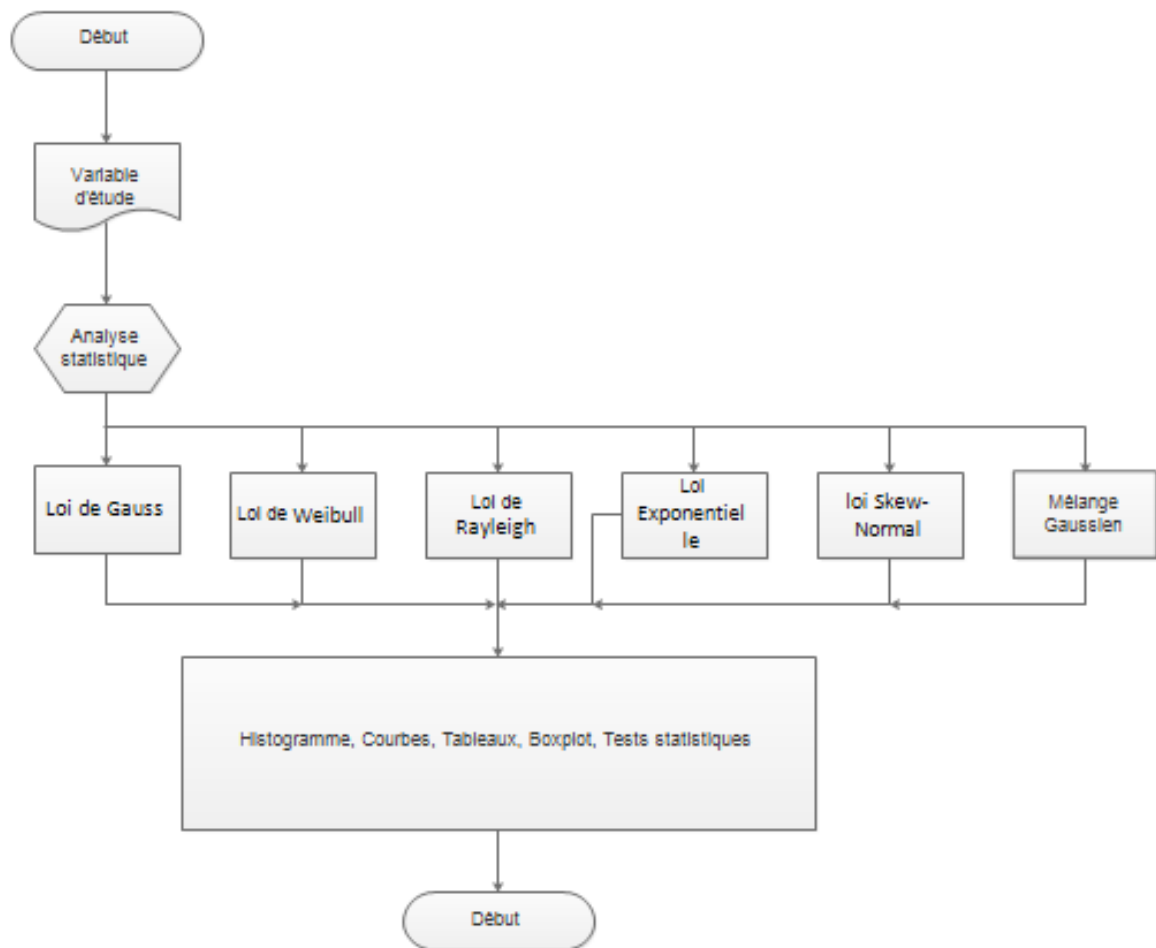


FIGURE 3.13 – Organigramme de fonctionnement du module analyse statistique des données

Python dispose des bibliothèques ou modules accessibles depuis le logiciel STCED permettent une réalisation aisée des graphiques, des statistiques, des mathématiques, etc. Ce sont les modules :

- Numpy pour manipuler les vecteurs, des matrices, des tableaux ;
- Matplotlib pour créer des graphiques depuis python ;
- Scipy qui étend les possibilités offertes par Numpy en proposant des algorithmes couramment utilisés en calcul scientifique ;
- Pandas qui est très performant pour l'analyse de données ;
- Sklearn qui intègre certains algorithmes du Machine Learning, de mélanges de distribution, de mesureurs de performance des modèles, etc.

Des tests statistiques sont effectués afin de pouvoir porter des jugements sur les hypothèses concernant la compatibilité d'une loi de probabilité ou distribution théorique proposée avec une autre de nature empirique (le coefficient de détermination R^2 , l'indicateur racine carrée de l'erreur quadratique moyenne $RMSE$, le test d'ajustement de Kolmogorov-Smirnov). Des estimations par intervalle de confiance ont permis de dégager les plages des différentes puissances électriques moyennes. Ainsi le modèle requis sera donc utilisé pour la caractérisation des sources de production d'énergie électrique.

3.4.3.1 Racine de l'erreur quadratique moyenne

La racine carrée de l'erreur quadratique moyenne est le premier indicateur statistique utilisé. Il permet de mesurer l'écart entre les distributions réelles observées et les probabilités prédites pour chaque observation. La $RMSE$ a toujours une valeur positive et est calculée selon la relation (3.1).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (F_i^* - F_i)^2} \quad (3.1)$$

Dans la relation (3.1), F_i^* est la fonction de répartition empirique, et F_i la fonction de répartition théorique. Plus la $RMSE$ est faible, plus est performant le modèle utilisé pour caractériser les données observées.

3.4.3.2 Coefficient de détermination

Le coefficient de détermination R^2 est utilisé lors de l'analyse de l'écart issu de l'ajustement des données observées par une loi de probabilité théorique tout en quantifiant la corrélation entre les probabilités cumulatives observées et les probabilités cumulatives espérées. Son expression est donnée par la relation (3.2). L'ajustement de la distribution des données est meilleur lorsque le R^2 est de plus en plus proche de

l'unité.

$$R^2 = \frac{\sum_{i=1}^n (F_i^* - \bar{F}_i^*)^2 - \sum_{i=1}^n (F_i^* - F_i)^2}{\sum_{i=1}^n (F_i^* - \bar{F}_i^*)^2} \quad (3.2)$$

Avec \bar{F}_i^* la valeur moyenne des F_i^* définie par la relation (3.3), F_i^* la fonction de répartition empirique, et F_i la fonction de répartition théorique et n la taille des données observées.

$$\bar{F}_i^* = \frac{1}{n} \sum_{i=1}^n F_i^* \quad (3.3)$$

3.4.3.3 Score de probabilité classée continue

Il généralise l'erreur absolue moyenne au cas des prévisions probabilistes. Le Score de probabilité classée continue (*CRPS*, pour Continuous Ranked Probability Scor) est de nos jours l'une des mesures la plus largement utilisée pour les prévisions probabilistes d'une observation scalaire. Il s'agit d'une mesure quadratique de la différence entre la fonction de distribution cumulative (CDF) prévue et la CDF empirique de l'observation. Des scores plus petits indiquent une meilleure performance du modèle. Il se calcule selon la relation (3.4).

$$CRPS = \int_{-\infty}^{+\infty} (F_i^* - H(F_i - 0))^2 dF_i \quad (3.4)$$

Dans l'équation (3.4), F_i^* est la fonction de répartition empirique, et F_i la fonction de répartition théorique et la fonction H , l'échelon unité de Heaviside dont la valeur est un (1) pour les arguments non négatifs et 0 pour les arguments négatifs.

3.4.4 Module de traitement du signal

Le module de traitement du signal du logiciel STCED utilise la transformée en ondelettes qui permet une représentation du signal (la charge électrique qui est fonction du temps et de l'échelle.) simultanément dans le temps (ou dans l'espace) et dans les échelles. L'analyse par transformée en ondelettes des données de la demande en

électricité nous permet de séparer les composantes de détails de celles d'approximations de ces variables. Ce qui aidera à mieux observer sur des courbes, les variations des composantes lentes et rapides des variables et les singularités qui existent dans ses composantes de les injecter à l'entrée des modèles du Machine Learning pour des fins de prévision de la charge électrique. Python dispose le module "pywt" qui permet d'implémenter toutes les familles d'ondelettes. Ce qui offre une flexibilité au logiciel STCED qui utilise la plupart de ces fonctions via ce package pour l'analyse par transformée en ondelettes des séries temporelles.

3.4.5 Module de prédiction de charge électrique

La prévision de la charge n'est pas aussi une tâche aisée pour les planificateurs des réseaux électriques si ces derniers veulent intégrer au processus de modélisation les principaux facteurs qui influencent considérablement la charge électrique. A cet effet, le Machine Learning, grâce à la forte capacité de généralisation de ses algorithmes est de plus en plus utilisé de nos jours dans l'industrie électrique pour prédire la charge électrique. Les sous modules des modèles hybrides ondelettes / Processus Gaussien, ondelette / ARIMA et de k-Means / Réseaux de Neurones sont développés dans le précédent chapitre. Après le chargement de la base de données de la charge électrique, le module prédiction affiche les courbes de prédiction et indicateurs de performances et de validation.

L'environnement de ce module que nous venons de présenter intègre de nombreuses bibliothèques à usages scientifiques (Matplotlib, Numpy, SciPy, Pandas) et spécialisée pour les processus gaussien (Sklearn). Compte tenu du nombre limité de modèles disponible dans Sklearn, nous utiliserons en parallèle la bibliothèque GPy qui n'est pas fournie par défaut. GPy est un framework du processus gaussien écrit en langage Python par l'équipe d'apprentissage automatique de Sheffield. Il est sous licence BSD et inclut plusieurs modèles tels que : le processus gaussiens à sortie multiples (Multiple Output Gaussian Processes), la classification par processus gaussien (GP Classification), le Processus Gaussien Hétéroscédastique, le Processus Gaussiens Clairsemés (Sparse Gaussian Processes), la Régression par Processus Gaussiens Paramétrique et non Paramétrique (GP Regression), L'inférence Variationnelle Stochastique pour la Régression par Processus Gaussien (Stochastic Variational Inference for GP Regression). La figure 3.14 montre quelques noyaux couramment utilisés dans la régression par GP avec 3 réalisations grâce au logiciel STCED.

Il existe plusieurs critères d'évaluation permettant de quantifier et comparer les

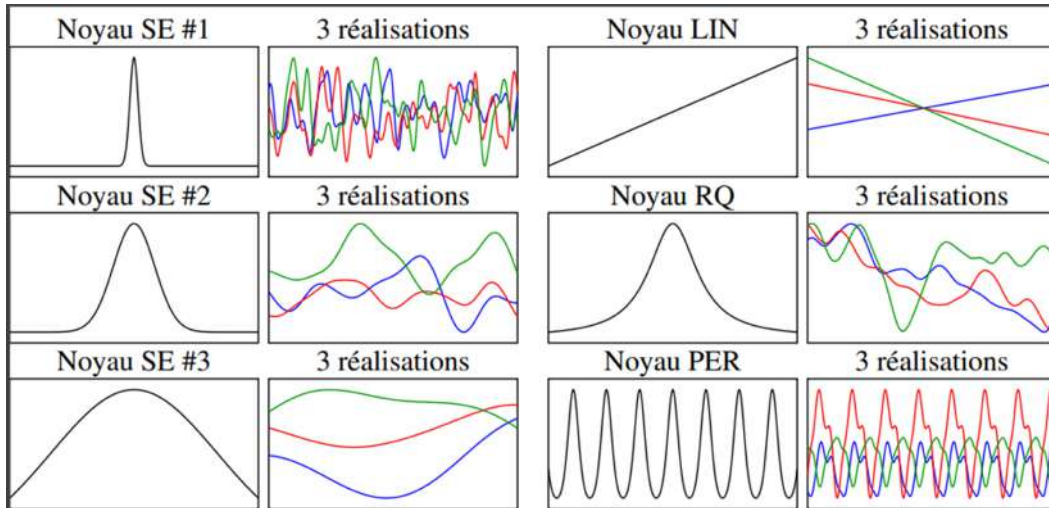


FIGURE 3.14 – Quelques Noyaux de la régression par GP avec 3 réalisations

performances des modèles. Ici nous présentons ceux que nous avons considérés dans l'évaluation de nos modèles.

3.4.5.1 Erreur absolue moyenne en pourcentage

Le critère MAPE (en anglais : Mean Absolute Percent Error) montre la différence moyenne de pourcentage entre les valeurs estimées et celles mesurées. La MAPE est calculée selon la relation (3.5).

$$MAPE = \frac{1}{n} \sum_{j=1}^n \left| \frac{Y_{j,p} - Y_{j,r}}{Y_{j,r}} \right| \quad (3.5)$$

3.4.5.2 Probabilité de Couverture d'Intervalle de Prédiction

L'indicateur Probabilité de Couverture d'Intervalle de Prédiction (*PICP*, pour Prediction Interval Coverage Probability) indique la probabilité que les valeurs prédites se situent entre les limites supérieure et inférieure, mesurées en pourcentage de l'intervalle de confiance. Il est exprimé par la relation (3.6).

$$PICP = \frac{1}{n} \sum_{i=1}^n C_i \quad (3.6)$$

où n est le nombre d'échantillons ; C_i prend la valeur 1 si la valeur prédite au point

i est située dans l'intervalle de confiance et 0 sinon.

3.4.5.3 Largeur Moyenne Normalisée de l'Intervalle de Prédiction

L'indicateur Largeur Moyenne Normalisée de l'Intervalle de Prédiction (*PINAW*, pour Prediction Interval Normalized Average Width) permet de normaliser le *PICP* en fournissant une valeur relative à celui-ci et à la largeur de l'intervalle de confiance. Le *PINAW* est donné par la relation (3.7).

$$PINAW = \frac{1}{nR} \sum_{i=1}^n (U_i - L_i) \quad (3.7)$$

où U_i et L_i correspondent respectivement à la borne supérieure et à la borne inférieure de l'intervalle de confiance, R est la position de la valeur prédite et n le nombre d'échantillons.

3.4.6 Module optimisation

La minimisation à la fois des coûts de transaction et des pertes d'énergie dans le réseau électrique, et de l'émission de CO₂ due à la production d'énergie, sont trois objectifs de la planification des réseaux électriques étroitement liés. Ainsi, de nombreuses études ont été faites pour apporter des approches de solution à chacun de ces problèmes. Le travail dont nous nous sommes rendus compte dans cette thèse, porte sur la contribution à la conduite des réseaux électriques par optimisation des coûts de transactions de l'énergie électrique et émissions de CO₂ des réseaux électriques par programmation quadratique. L'objectif principal de cet outil est d'appliquer l'outil GAMS pour proposer des solutions optimales aux problèmes coûts, d'émission de CO₂. Ceci nous a permis de faire une formulation mathématique des problèmes d'optimisation. Nous avons ensuite appliqué la formulation obtenue pour une étude de cas sur un réseau IEEE. Les résultats de sorties sont enregistrés au format Excel puis envoyés au logiciel STCED pour servir à des fins d'analyse.

3.5 Fonctionnement, validation et prototypage du logiciel

L'interaction entre le logiciel STCED et l'utilisateur s'effectue par l'emploi d'un ensemble de boutons, fenêtres de saisie ainsi que des menus déroulants. Par conséquent, nous pouvons structurer le fonctionnement du logiciel suivant trois principaux types de fenêtres à savoir :

- les fenêtres de navigation (Figure 3.15) qui permettent de naviguer entre les différents modules du logiciel ;



FIGURE 3.15 – Fenêtres de navigation des différents modules du logiciel STCED

- les fenêtres d'informations (Figure 3.16) qui permettent de spécifier les informations concernant les techniques de modélisation (lois de distributions, les tests statistiques, les modèles de prévision, les approches d'optimisation, etc. . . , tous accessibles via un menu déroulant) ;
- les fenêtres de sortie (Figure 3.17) qui permettent d'afficher les résultats sous forme de tableaux et représentations graphiques.

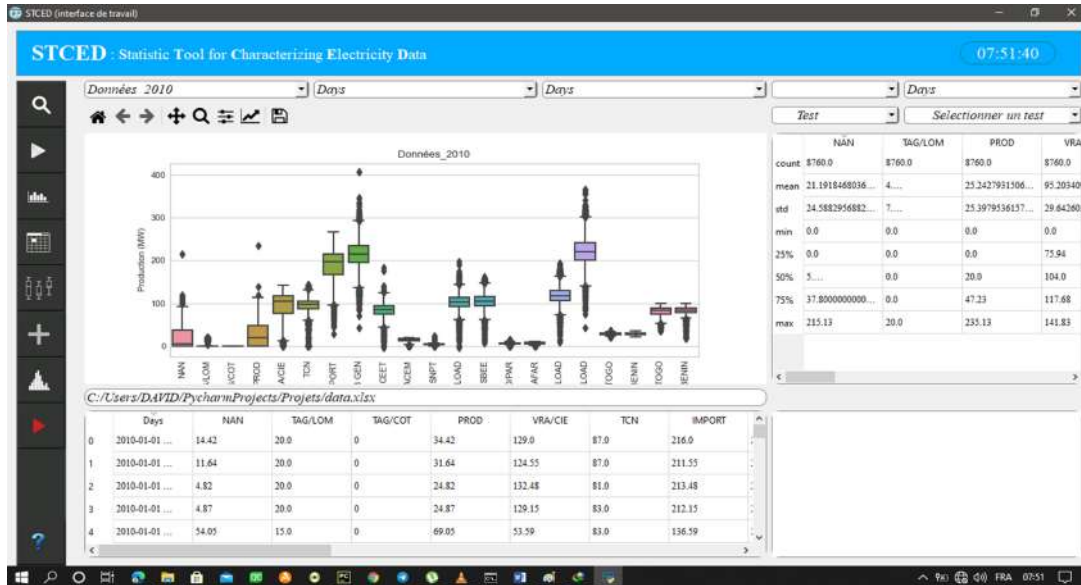


FIGURE 3.16 – Exemple de fenêtres d'information d'un module du logiciel STCED

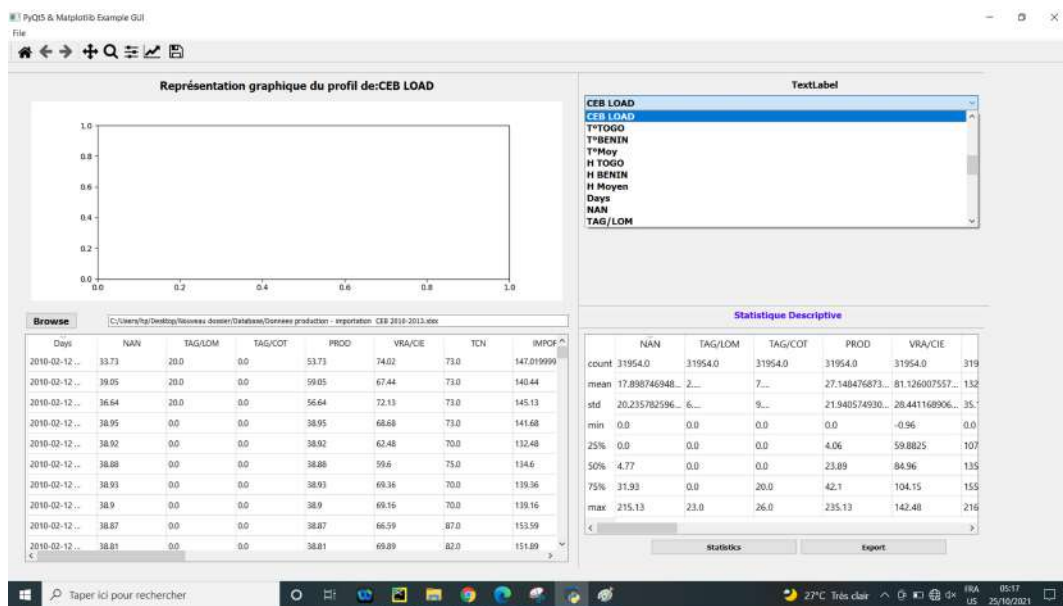


FIGURE 3.17 – Exemple de fenêtres de sortie d'un module du logiciel STCED

3.5.1 Importation et exportation

Les types de fichiers que peuvent lire notre application sont au format Excel accessibles via le bouton «Browse » (Figure 3.18). Le répertoire courant est donc par défaut utilisé pour enregistrer les résultats de modélisation ainsi que d'autres bases de données dont les formats sont de même type que celui de la base de données originales grâce au bouton « Export ». De plus, l'utilisateur a aussi la possibilité de stocker les résultats dans un répertoire spécifique. Les sorties obtenues sont sous

forme de tableau Excel, fichiers textes ou images (Figures 3.19 et 3.20).




FIGURE 3.18 – Importation d'un fichier Excel dans le logiciel STCED

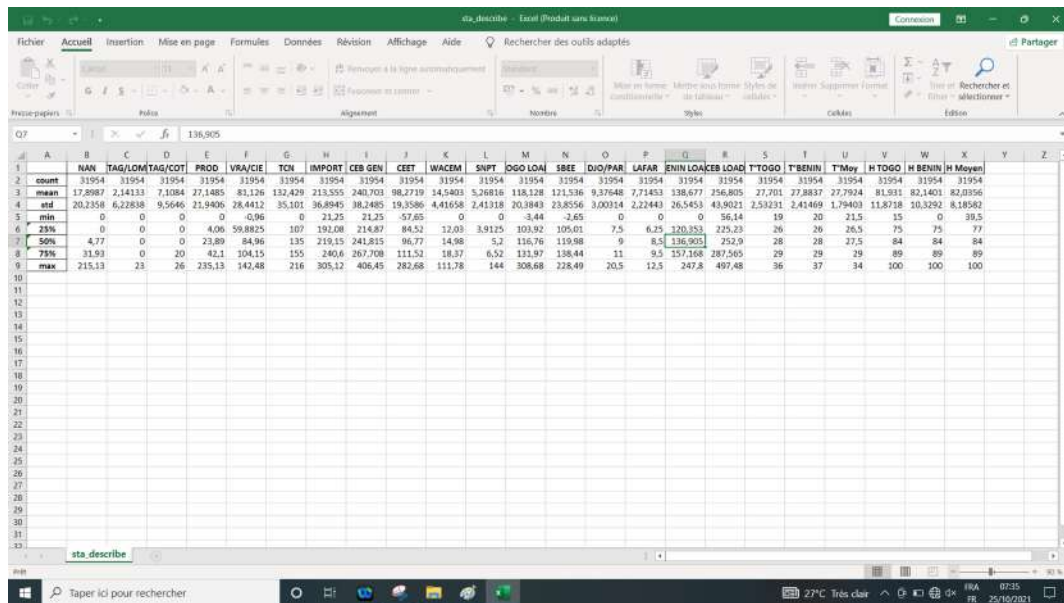


FIGURE 3.19 – Exportation d'un fichier Excel dans le logiciel STCED

3.5.2 Validation et prototypage du logiciel : résultats de quelques modules

Le logiciel dispose d'une interface principale qui constitue notre espace de travail (workspace) présentée sur la figure 3.21. Elle dispose de plusieurs éléments présents

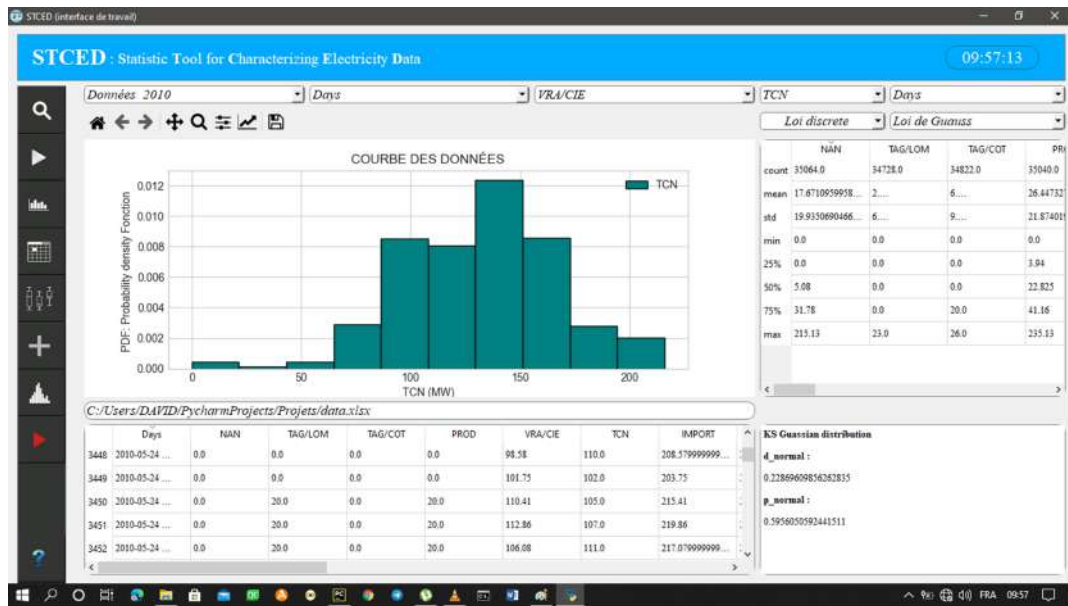


FIGURE 3.20 – Présentation d'un résultat graphique dans le logiciel STCED

qui permettent à l'utilisateur d'effectuer des tâches précises qui vont de l'importation des données (fichier Excel), du traçage des courbes, représentation des histogrammes, aux différentes analyses statistiques et de probabilités, de prévision et d'optimisation. Les différents éléments de cette interface sont présentés en détail dans le tableau 3.1.

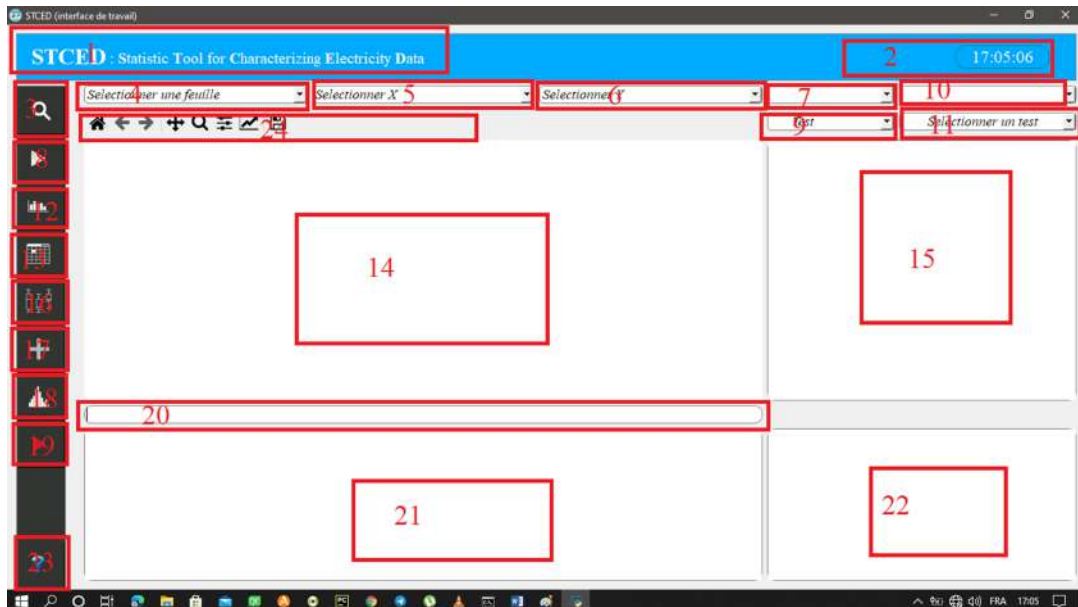


FIGURE 3.21 – Interface d'utilisateur du logiciel STCED

TABLEAU 3.1 – Détails des éléments d'espace de travail du logiciel STCED

N°	Fonctionnalité
1	Le nom de notre application
2	Affichage de L'heure
3	L'importation de données
4	nom des feuilles de notre fichier Excel (données)
5	nom des colonnes de la feuille Excel
7	nom des colonnes des feuilles Excel concaténées
8	Le bouton pour tracer nos courbes
9	tests et de lois que nous allons appliquer sur nos données
11	une septième pop menu contenant le nom des colonnes de la feuille Excel
12	Un bouton pour afficher les statistiques descriptives de notre feuille Excel
13	Le bouton pour afficher nos données
14	L'espace réservé pour afficher nos courbes
15	L'espace réservé pour afficher nos statistiques descriptives
16	Le bouton pour tracer la courbe de la boite à moustaches
17	Le bouton pour concaténer nos feuilles Excel
18	Le bouton pour tracer l'histogramme de nos données concaténées
19	Le bouton pour exécuter les lois et les tests
20	Un linkspace, il affiche le lien vers le répertoire de notre fichier Excel
21	L'espace réservé pour afficher nos données
22	L'espace réservé pour afficher les résultats de nos tests
23	Un bouton Help qui nous donne accès à la fenêtre Help
24	Une barre d'outils pour interagir sur nos courbes

3.5.2.1 Module de bases de données : analyse des profils de la demande et de la production de l'électricité

Les données utilisées proviennent de la Communauté Electrique du Bénin (CEB). Elles sont enregistrées sur la période de 01 janvier 2010 au 31 décembre 2017 avec le pas d'une heure (1h). Le logiciel STCED grâce à son module de bases de données, offre des possibilités d'étude et d'analyse des séries temporelles. La figure 3.22 présente le profil de la charge et la production électrique de la CEB sur la figure 3.23.

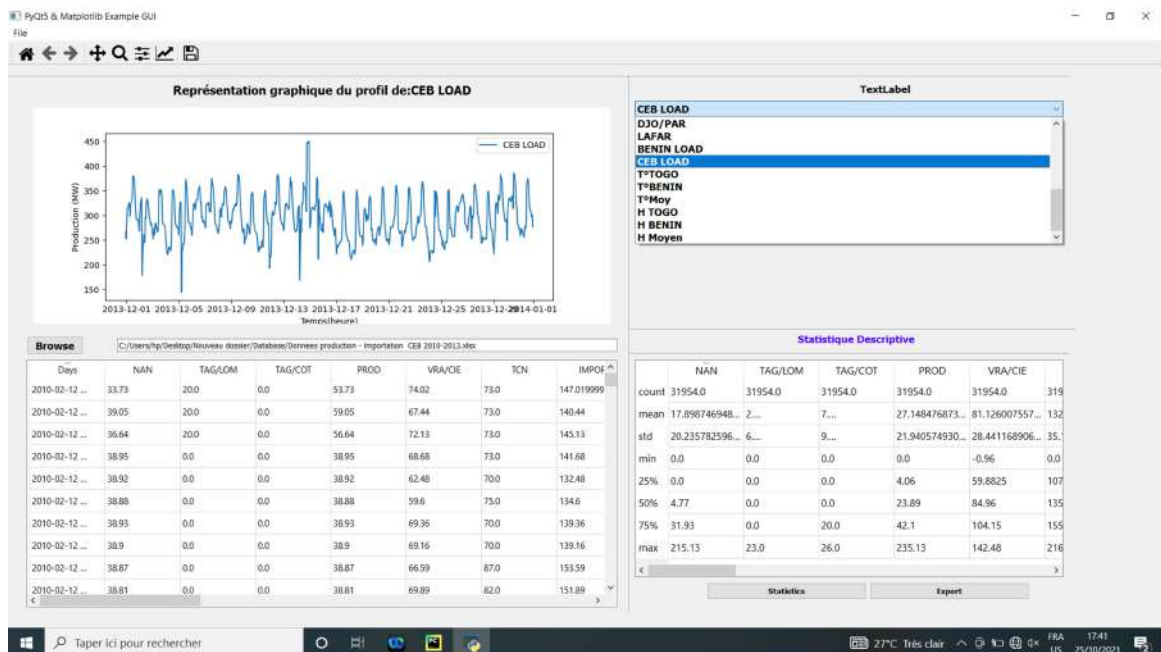


FIGURE 3.22 – Profil de la charge électrique de la CEB présenté par le logiciel STCED

3.5.2.2 Module statistique

Les valeurs des paramètres estimés pour différentes densités de probabilité utilisées pour la modélisation de la production de Nangbéto et des importations de la VRA/CIE et TCN ont permis d'ajuster les différents histogrammes. La statistique descriptive de toutes ces données sur la production et l'importation d'électricité sont également présentées ainsi que les différents tests statistiques. Les paramètres statistiques utilisés pour l'évaluation de la performance de l'ajustement des données observées par des lois de probabilité peuvent aussi être affichés par le logiciel. La figure 3.24 montre une fenêtre des résultats d'analyse statistique de la production interne de la CEB par la loi Normale.

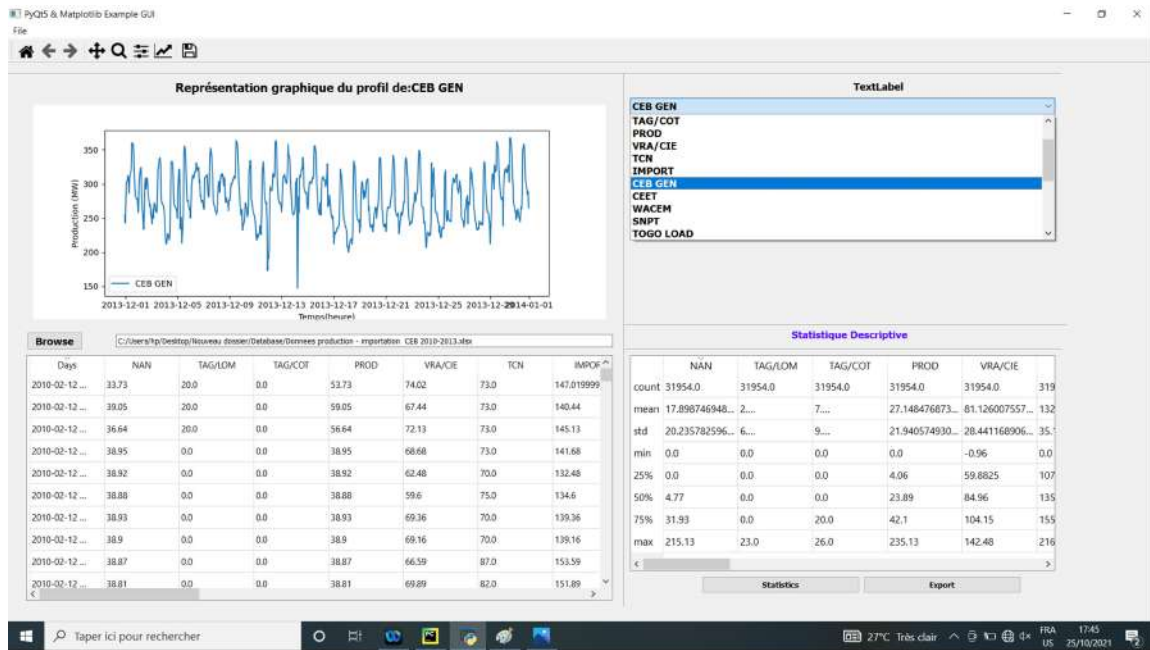


FIGURE 3.23 – Profil de la production électrique de la CEB présenté par le logiciel STCED

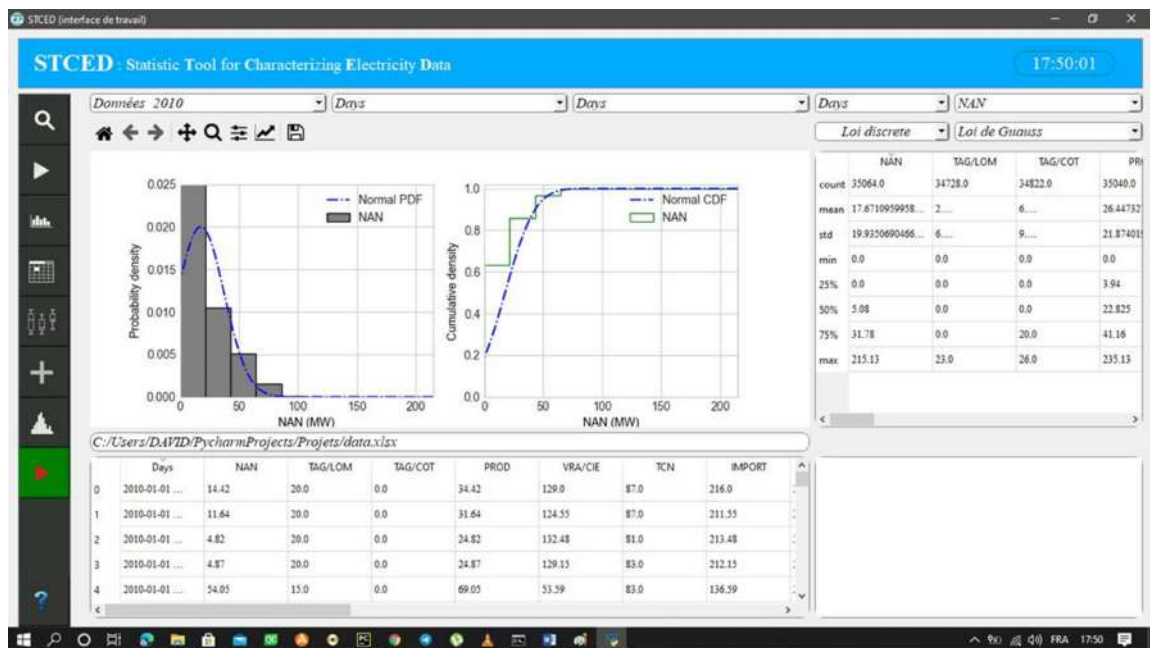


FIGURE 3.24 – Fenêtre d'analyse statistique de la production de CEB par la loi Normale

La figure 3.25 nous montre une fenêtre des résultats d'analyse statistique des importations de la CEB auprès de la Transmission Company of Nigeria (TCN) par la loi de Weibull.

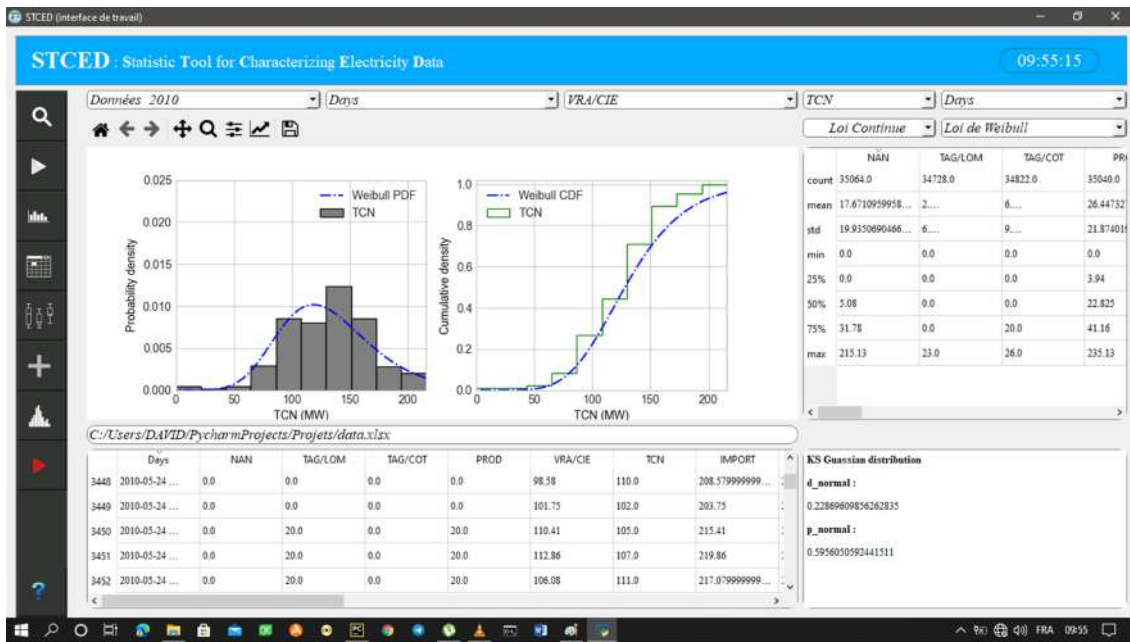


FIGURE 3.25 – Fenêtre d'analyse statistique des importations de la CEB auprès de la TCN par la loi de Weibull

La figure 3.26 nous montre une fenêtre des résultats d'analyse statistique des importations de la CEB auprès de la Volta River Authority / Compagnie Ivoirienne d'Electricité (VRA/CIE) par la loi Skewnormale.

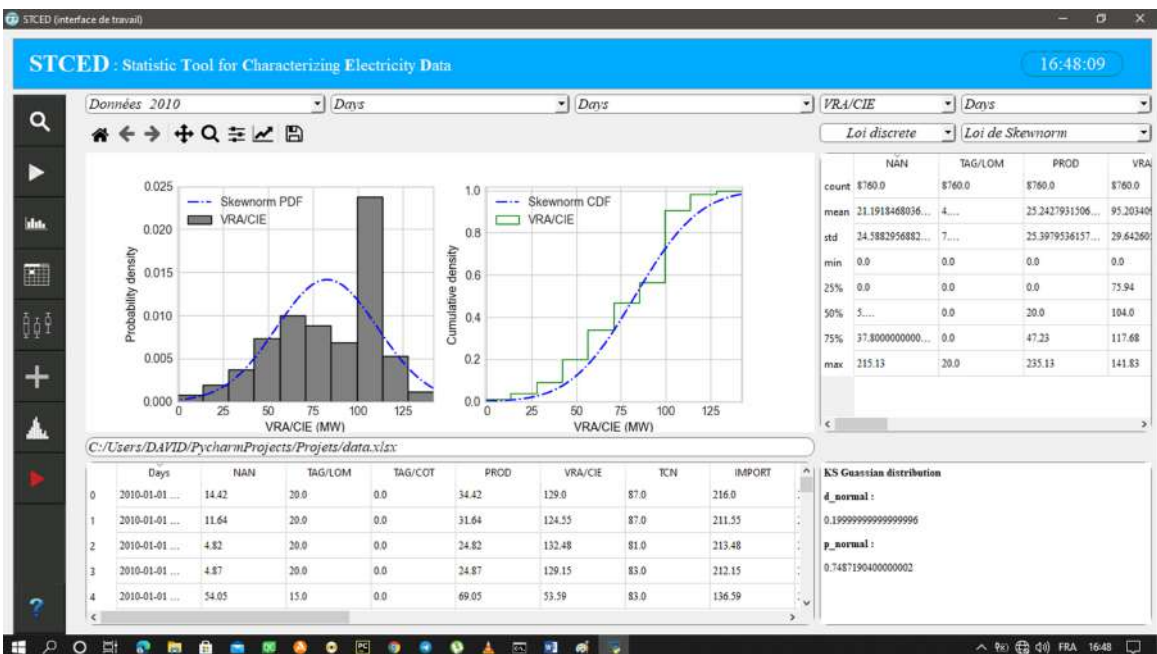


FIGURE 3.26 – Fenêtre d'analyse statistique des importations de la CEB auprès de la VRA par la loi Skewnormale

3.5.2.3 Module optimisation

Pour cette partie du travail nous avons utilisé les données de générateur thermique d'un réseau IEEE à 24 nœuds (présenté au suivant chapitre); les centrales solaires et éolienne ont été dimensionnées pour des sites de Lomé et de la CEB. Les résultats des puissances à produire (obtenus avec GAMS) par chaque centrale du réseau pour l'optimisation du coût de l'énergie et de l'émission de CO₂ sans et avec intégration des sources renouvelables sont présentés respectivement dans les tableaux 3.2 et 3.3.

Pour s'assurer de la validité des solutions obtenues, nous utilisons le logiciel ST-CED pour vérifier la satisfaction de la contrainte liée à l'équilibre de la demande. Les résultats obtenus sans intégration des énergies renouvelables sont présentés sur la figure 3.27.

TABLEAU 3.2 – Valeurs optimales obtenues dans les 24 heures pour chaque centrale sans intégration des énergies renouvelables

Heure	Charge	Pth	Heure	Charge	Pth
1	263,34	263,34	13	223,36	260,8
2	260,94	260,94	14	218,31	260,8
3	254,85	260,8	15	223,38	260,8
4	242,41	260,8	16	236,86	279,72
5	219,27	260,8	17	307,72	307,72
6	223,52	260,8	18	321,45	321,45
7	225,45	260,8	19	320,18	320,18
8	231,6	260,8	20	307,18	307,18
9	233,76	260,8	21	296,33	296,33
10	235,09	260,8	22	278,66	278,66
11	231,95	260,8	23	274,64	274,64
12	232,59	260,8	24	264,66	264,66

TABLEAU 3.3 – Valeurs optimales obtenues dans les 24 heures pour chaque centrale avec intégration des énergies renouvelables

Heure	Charge	Pth	Pw	Ps	Pop	Heure	Charge	Pth	Pw	Ps	Pop
1	263,34	260,8	2,54		263,34	13	223,36	260,8			260,8
2	260,94	260,8	0,14		260,94	14	218,31	260,8			260,8
3	254,85	260,8			260,8	15	223,38	260,8			260,8
4	242,41	260,8			260,8	16	236,86	260,8			260,8
5	219,27	260,8			260,8	17	307,72	263,6261	24,2176	19,8763	307,72
6	223,52	260,8			260,8	18	321,45	291,6261	16,2239	13,6	321,45
7	225,45	260,8			260,8	19	320,18	303,9561	16,2239		320,18
8	231,6	260,8			260,8	20	307,18	282,9624	24,2176		307,18
9	233,76	260,8			260,8	21	296,33	280,1061	16,2239		296,33
10	235,09	260,8			260,8	22	278,66	268,4432	10,2168		278,66
11	231,95	260,8			260,8	23	274,64	268,7275	5,9125		274,64
12	232,59	260,8			260,8	24	264,66	264,66			264,66

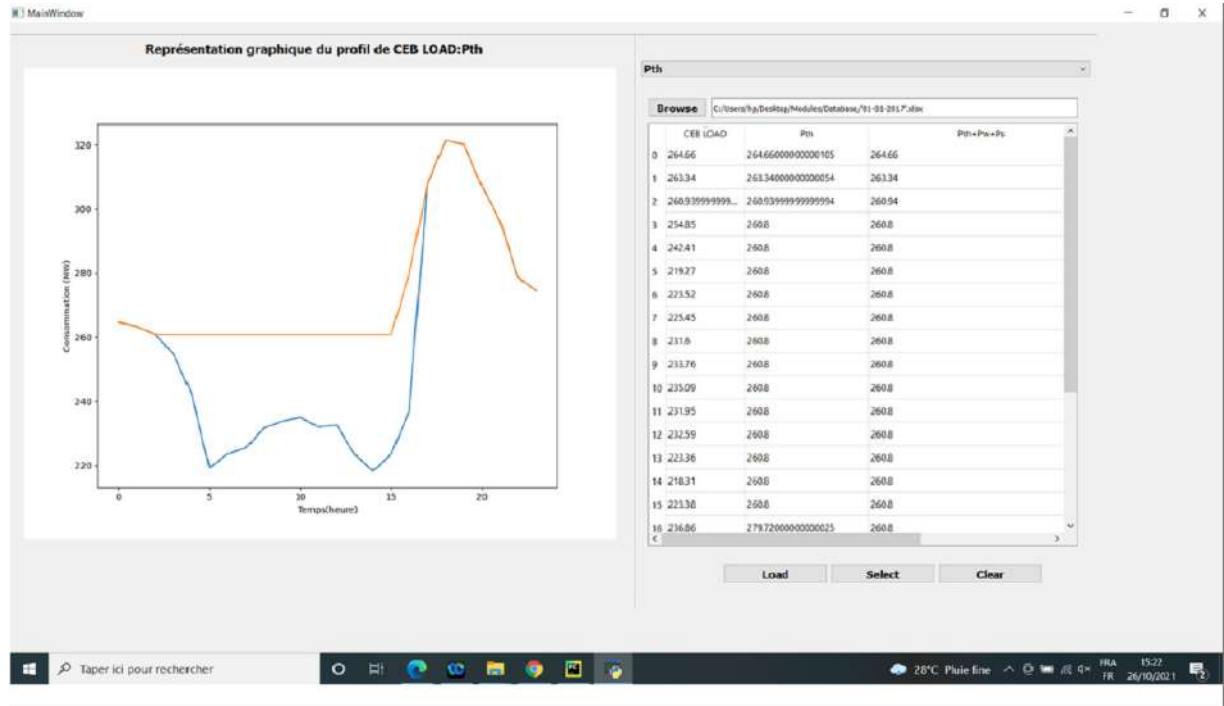


FIGURE 3.27 – Equilibre entre offre et demande électrique sans intégration des énergies renouvelables

3.6 Conclusion

Dans le présent chapitre, des outils mathématiques développés dans les chapitres précédents nous ont permis de réaliser un logiciel d'analyse, de modélisation, de prédiction et d'optimisation des données sur le marché de l'électricité. Ce logiciel est dans sa première version, et peut intégrer à l'avenir d'autres fonctionnalités relatives au Machine Learning et du Big Data pour une amélioration de la planification optimisée des réseaux électriques de transport et de distribution.

Afin d'exploiter les performances de ce logiciel, nous utilisons dans la suite de notre travail au chapitre suivant, pour des études de cas sur le réseau interconnecté de la CEB et du réseau IEEE 24 nœuds.

Chapitre 4

Mise en œuvre et contribution de l'application STCED pour la planification à court terme des réseaux électriques interconnectés

4.1 Introduction

Ce chapitre expose les résultats obtenus grâce au logiciel STCED. Il s'agit d'une part, des résultats de caractérisation des sources conventionnelles de production d'électricité par les mélanges de distributions gaussiennes. Des indicateurs de performances et d'autres critères statistiques tels que R^2 , $RMSE$, $CRPS$ et le test $K - S$ viendront par la suite appuyer la force des approches proposées. Par ailleurs, les résultats de prévision avec les approches hybrides ondelettes/ARIMA, k-means/ANN et ondelettes/GPR seront présentés dans la deuxième partie de ce chapitre. Ensuite, les résultats d'optimisation du coût de l'électricité et d'empreinte carbone seront présentés afin de mieux cerner les enjeux économiques et environnementaux liés à la planification des réseaux électriques de transport interconnectés.

4.2 Données de production d'électricité

La figure 4.1 présente les relevés horaires des importations, des productions et des charges électriques de la CEB sur la période de 01 janvier 2010 au 31 décembre 2017 avec le pas d'une heure (1h).

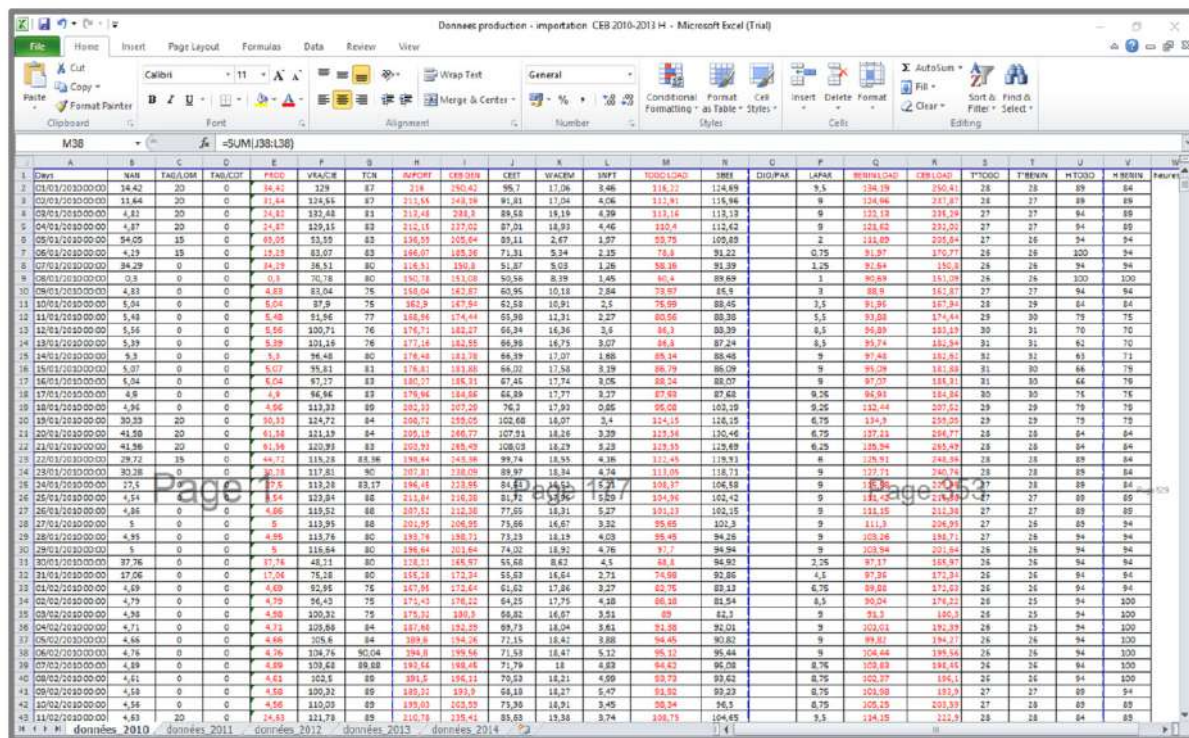


FIGURE 4.1 – Aperçu des données électriques de la CEB dans une feuille Excel

La CEB est une société de production et de transport de l'énergie électrique dont la principale mission est de desservir les républiques du Bénin et du Togo. Elle dispose d'un barrage hydroélectrique à Nangbéto de capacité moyenne de production annuelle égale à 170 GW h. Des turbines à gaz (2 gpes x 32,5 MW) de Lomé et de Cotonou sont installées en 1998 avec une puissance de 20 MW chacune d'une productivité annuelle moyenne estimée à 150 GW h. Pour répondre à la demande globale de ces deux pays voisins, la CEB en dehors de sa propre production, importe grâce aux interconnexions :

- une puissance garantie de 60 MW avec une énergie annuelle garantie de 500 GW h jusqu'en 2012, 700 GW h de 2012 à 2014 et de 1000 GW h de 2015 à 2017 auprès de la Volta River Authority (VRA) du Ghana ;
- une puissance garantie de 75 MW avec une énergie annuelle garantie de 300 GW h pour une durée contractuelle de 10 ans avec la Transmission Company of Nigeria (TNC) ;
- une puissance garantie de 102 MW avec une énergie annuelle de 100 GW h pour une durée contractuelle de trois (03) ans avec la Compagnie Ivoirienne d'Electricité (CIE) ;
- une énergie de 2 à 4 GW h pour l'alimentation de la ville de Malanville au

Bénin avec l'Electricité du Niger (NIGELEC).

Des variables météorologiques à savoir la température et l'humidité relative sont également présentées sur la figure 4.1. Dans cette étude de caractérisation, nous nous intéresserons aux importations d'énergie électrique de la TCN et VRA/CIE, ainsi que la production interne de la centrale électrique de Nangbéto.

4.3 Statistique descriptive des données de production d'électricité

Le tableau 4.1 présente la statistique descriptive des importations d'énergie électrique de la TCN et VRA/CIE, ainsi que la production d'énergie de la centrale électrique de Nangbéto. Ce tableau contient les paramètres de position (mode, médiane et moyenne) qui permettent de savoir autour de quelles valeurs se situent la moyenne de production interne et des importations de la CEB. Les paramètres de dispersion à savoir l'écart-type et de formes tels que les coefficients d'asymétrie (skewness) et d'aplatissement (kurtosis) sont également présentés dans ce tableau.

Il faut noter que le skewness est négatif lorsque la distribution est étalée à gauche, ou positif lorsqu'elle est plus étalée à droite. Il est égal à zéro (0) si la distribution des données suit la loi normale. Le kurtosis évalue la dispersion des valeurs externes par rapport à la distribution normale. Pour une distribution normale, il vaut 3. S'il est supérieur à 3, la distribution a une queue plus grosse et plus longue que celle de la distribution normale, avec un pic plus net. Dans le cas où le kurtosis est inférieur à 3, la distribution a un pic plus arrondi avec des queues plus courtes et plus fines.

L'analyse des résultats du tableau 4.1 montre que la moyenne des productions internes de la CEB (Nangbéto) est de 22,35 MW. Elle se situe entre le 2^{ème} et le 3^{ème} quartiles (16,67 MW et 31,78 MW). On remarque aussi que la puissance produite quitte d'une valeur minimale de 0,01 MW et atteint un maximum de 215,1 MW. La faible puissance produite peut s'expliquer par les périodes de crue d'eau où la centrale ne produit pas assez d'énergie électrique nécessaire pour satisfaire la demande, et l'arrêt de certaines unités de production.

TABLEAU 4.1 – Indices statistiques des sources de production et d'importation de la CEB

Sources	Indices statistiques des puissances produites et importées									
	min	max	mode	moyenne	écart-type	25%	50%	75%	skewness	kurtosis
Production Nangbeto	0,01	215,1	1,96	22,35	17,12	10,5	17,67	31,78	0,96	0,77
Importation VRA/CIE	-1	142,5	104,2	82,97	28,15	62	89,54	104,2	-0,56	-0,5
Importation TCN	0,43	216	150	132,44	32,72	106	135	154	0,006	-0,26

La puissance maximale s'explique par une forte demande des consommateurs satisfaite par la mise en marche de la centrale avec ses différentes unités de production. Les valeurs de skewness (0,96) montrent que la distribution de la puissance électrique produite par la centrale de Nangbéto s'étale vers la droite. La faible valeur de kurtosis (0,77) indique un pic plus net avec une queue plus courte et plus fine que la distribution normale.

L'analyse des importations de VRA/CIE montre une puissance moyenne négative (-1 MW). Ceci est dû aux exportations de la CEB vers VRA/CIE. La puissance maximale sollicitée auprès de VRA est de 142,5 MW avec une moyenne de 104,2 MW. Les valeurs de kurtosis (-0,5) et de skewness (-0,56) montrent que la distribution des importations de VRA/CIE est étalée à gauche avec un pic plus arrondi avec des queues plus courtes et plus fines.

La distribution des importations de TCN, atteint un maximum de 216 MW avec une puissance importée moyenne de 132,44 MW. Le skewness et le kurtosis sont pratiquement nuls. Nous pouvons donc conclure que cette distribution des puissances importées de TCN est proche de la loi normale.

Un constat fait suite à l'analyse des données du tableau 4.1, montre que plus de 80% de l'énergie électrique est importé par la CEB pour satisfaire les besoins énergétiques de ses clients. Pour une prise de décision sur les incertitudes associées à la distribution des productions des différentes sources de la CEB, nous allons procéder à l'ajustement par des lois statistiques.

4.4 Ajustements statistique des données de production d'électricité

Dans cette partie, il sera présenté une analyse des données utilisées pour les sources de production afin de prévoir leurs disponibilités dans le réseau électrique. Il permet d'accepter ou de refuser une prévision lors d'une évaluation des erreurs, de favoriser le développement de l'apprentissage efficace grâce à l'examen de la performance d'un modèle, ou décider des données à utiliser pour maximiser les intervalles de prédiction.

4.4.1 Ajustement par des lois de distributions classiques

Le tableau 4.2 montre toutes les lois de probabilité utilisées pour ajuster la production et des importations de la CEB. Pour une analyse exhaustive des résultats avec le logiciel STCED, des critères de performance (R^2 et $RMSE$) ainsi que le test statistique $K - S$ utilisés.

Nous remarquons que toutes les lois de distribution (Skewnormale, Exponentielle, Rayleigh) sauf la loi de Gauss, décrivent mieux la distribution de l'énergie électrique produite par le barrage de Nangbéto. Le test $K - S$ fait sur ces données avec un seuil de risque $\alpha = 5\%$ donne une $p - valeur = 2,6\%$ avec la loi normale. D'où l'hypothèse H_0 selon laquelle la production de la centrale de Nangbéto suit une loi normale est rejetée. Ce qui s'explique par un faible R^2 (0,58) et une forte $RMSE$ (0,006) par rapport aux autres lois de distribution sauf la loi exponentielle qui est acceptée par le test $K - S$ ($p - valeur = 12,3\%$) avec ($R^2 = 0,5$ et $RMSE = 0,0065$). Toutefois, nous notons quand même que la loi normale asymétrique (Skewnormale) est celle qui présente la meilleure performance pour l'ajustement de la production de Nangbéto.

Pour les importations VRA/CIE et TCN, toutes les lois de distribution utilisées (Skewnormale et Normale pour VRA/CIE; Normale, Skewnormale et Weibull pour TCN) sont acceptées par le test $K - S$. En se basant sur les indicateurs de performance, la loi normale ou Skewnormale convient mieux aux importations VRA/CIE. Quant aux importations TCN, il est recommandé d'utiliser la distribution de Weibull.

En résumé, les lois de distribution utilisées pour la caractérisation des importations et production de la CEB sont liées à la nature de ces données. Une question à se poser est que faire si ces données sont bruitées, présente des variables latentes, informations cachées des données manquantes ou aberrantes. Dans ce cas, la distribution des données présente une hétérogénéité qui ne pourra pas être modélisée par les lois de probabilités classiques. Dans cette circonstance, des mélanges de distribution peuvent être appliqués pour pallier à ce problème. L'approche que nous proposons se base sur des mélanges de distributions gaussiennes pour renforcer la prévision des disponibilités des différentes sources de production dans un réseau électrique interconnecté.

TABEAU 4.2 – Résultats des tests statistiques sur les fonctions de distributions sélectionnées

Source	Densité de probabilité	Indicateur de performance					Decision
		R^2	RMSE	D	p – valeur	d	
Nangbéto	Normale	0,58283	0,00573	0,4301	0,02566	0,44497	Rejetée
	Skewnormal	0,88184	0,00305	0,4301	0,08011	0,38243	Acceptée
	Rayleigh	0,70777	0,0048	0,4301	0,05367	0,40554	Acceptée
	Exponentielle	0,5	0,00658	0,4301	0,12304	0,356	Acceptée
VRA/CIE	Normale	0,96944	0,064759	0,4301	0,77109	0,2	Acceptée
	Skewnormal	0,96944	0,064759	0,4301	0,77109	0,2	Acceptée
TCN	Normale	0,98319	0,051184	0,4301	0,61288	0,2287	Acceptée
	Skewnormal	0,98098	0,054448	0,4301	0,78523	0,1973	Acceptée
	Weibull	0,98463	0,04894	0,4301	0,4913	0,2512	Acceptée

4.4.2 Ajustement par les mélanges gaussiens

Pour trouver le nombre de composantes optimales $\{\pi_i, \mu_i, \Sigma_i\}_{i=1}^m$ estimées par l'algorithme de l'Espérance-Maximisation. Les estimations des paramètres (composantes) sont arrêtées lorsque la différence entre les valeurs issues de deux itérations est inférieure au seuil ϵ fixé (obtention de la convergence), c'est-à-dire $|\gamma^{s+1} - \gamma^s| < \epsilon$. Dans cette étude $\epsilon = 0,01$. Le tableau 4.3 présente les résultats de modélisation des distributions des sources de production de Nangbéto et importation de VRA/CIE et TCN par des mélanges de distributions gaussiennes.

TABLEAU 4.3 – Choix du nombre de composantes pour les mélanges de distributions Gaussiennes

Sources	Nombre de composantes	Indicateurs de performance		
		R^2	$RMSE$	$CRPS$
Nangbéto	1	0,58283	0,00573	0,085461
	2	0,4168	0,18256	0,088102
TCN	1	0,97844	0,05838	0,039689
	2	0,9793	0,05721	0,407073
	3	0,97975	0,05658	0,037913
	4	0,9892	0,03731	0,037891
	5	0,97857	0,05821	0,038034
VRA/CIE	1	0,9694	0,06482	0,055672
	2	0,97371	0,06007	0,407073
	3	0,97535	0,05818	0,039913
	4	0,98588	0,04404	0,038607

Pour la puissance produite par le barrage de Nangbéto, la loi normale offre de meilleures performances. Ce résultat se traduit par un R^2 moyen (0,58) et une $RMSE$ faible(0,006). Le $CRPS$ qui évalue la performance des prévisions probabilistes par rapport aux observations atteste ce résultat par une valeur proches de zéro (0,085). L'utilisation des mélanges gaussiens à quatre composantes convient aux données de puissances importées chez TCN et VRA/CIE. Les différents $CRPS$ indiquent des valeurs proches de zéro pour chaque données de puissance importée (0,0378 pour TCN et 0,386 pour VRA/CIE). Ce qui s'explique par un fort R^2 (0,99 pour TCN et VRA/CIE) et une faible $RMSE$ (0,037 pour TCN et 0,044 pour VRA/CIE). Par conséquent, le mélange gaussien à quatre composantes, convient à la prévision probabiliste des importations de la CEB (chez TCN et VRA/CIE). Par ailleurs, il y a une légère modification des indicateurs $RMSE$ et R^2 pour les importations TCN avec les mélanges gaussiens à un composant. La provenance de cette différence est due à l'utilisation de l'algorithme de maximum de vraisemblance pour

l'estimation des paramètres de la loi normale comparée au mélange gaussien qui utilise l'algorithme E-M). Le tableau 4.4 présente le résumé des différents paramètres estimés par l'algorithme E-M pour le mélange gaussien.

TABLEAU 4.4 – Paramètres du mélange Gaussien avec le nombre de composantes optimums

Source	π_i		μ_i		σ_i	
Nangbéto	π_1	1	μ_1	22,34	σ_1	17,12
TCN	π_1	0,397939	μ_1	101,849027	σ_1	19,609013
	π_2	0,32112	μ_2	152,497077	σ_2	10,085061
	π_3	0,098995	μ_3	191,672348	σ_3	9,788155
	π_4	0,181944	μ_4	131,769562	σ_4	14,04827
VRA/CIE	π_1	0,167198	μ_1	43,854934	σ_1	19,275812
	π_2	0,249129	μ_2	104,15	σ_2	2,41E-11
	π_3	0,146872	μ_3	115,521739	σ_3	9,857438
	π_4	0,436799	μ_4	74,908763	σ_4	19,433861

Les résultats de tests statistiques sont présentés dans le tableau 4.5 afin d'appuyer nos conclusions sur la caractérisation de la production et importation de la CEB par le mélange de distributions gaussiennes.

TABLEAU 4.5 – Mesures de performances des modèles

Source	Distributions	R^2	$RMSE$	$K - S$ avec $\alpha=0.05$			$CRPS$
				D	$p - valeur$	d	
Nangbéto	GMM	0,58283	0,00573	0,43013	0,0525	0,4267	0,085461
	Skewnormal	0,88184	0,00305	0,43013	0,8011	0,3824	0,077283
TCN	GMM	0,9892	0,03731	0,43013	0,75546	0,2129	0,038015
	Skewnormal	0,98098	0,054448	0,43013	0,99145	0,1377	0,7266189
	Weibull	0,98463	0,04894	0,43013	0,4913	0,2521	0,7284967
VRA/CIE	GMM	0,9859	0,04404	0,43013	0,99981	0,108	0,038608
	Skewnormal	0,96944	0,064759	0,43013	0,99509	0,1317	0,6637193

Sur les figures 4.2 à 4.4, nous présentons les ajustements des histogrammes des importations et production CEB par les différentes lois de distributions : (skew normale et mélange gaussien à une composante pour la production de Nangbéto ; Skewnormale, Weibull et mélange gaussien à quatre composantes pour TCN ; Skewnormale et mélange gaussien à quatre composantes pour VRA/CIE). Ces figures présentent la fonction de distribution (PDF, pour Probability, Density Function) et la fonction de répartition (CDF, pour Cumulative Density Function).

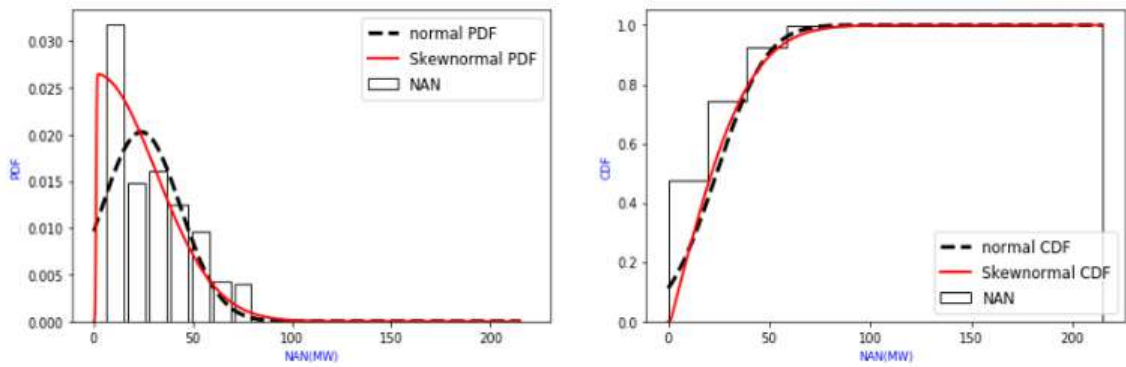


FIGURE 4.2 – Comparaison des PDF et CDF de Skew-normale et de GMM à 1 composante : cas de Nangbété

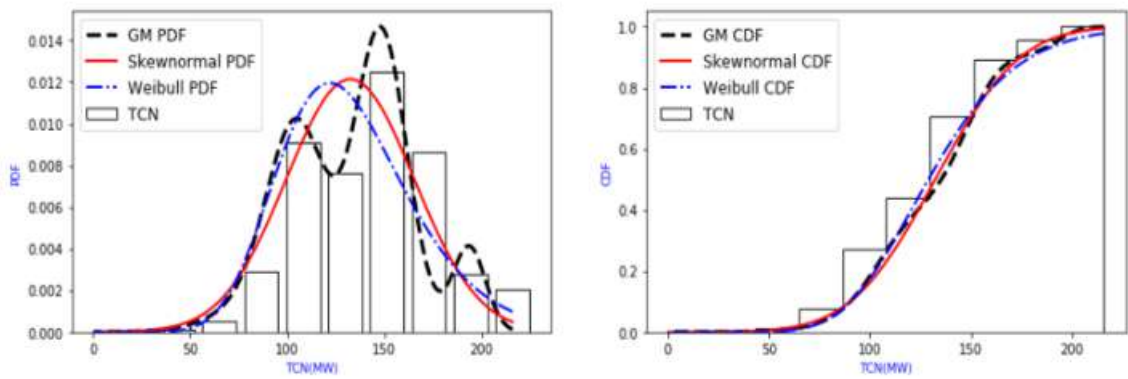


FIGURE 4.3 – Comparaison du modèle de mélange gaussien à 4 composantes aux modèles de distribution Skew-normale et de Weibull : cas de TCN

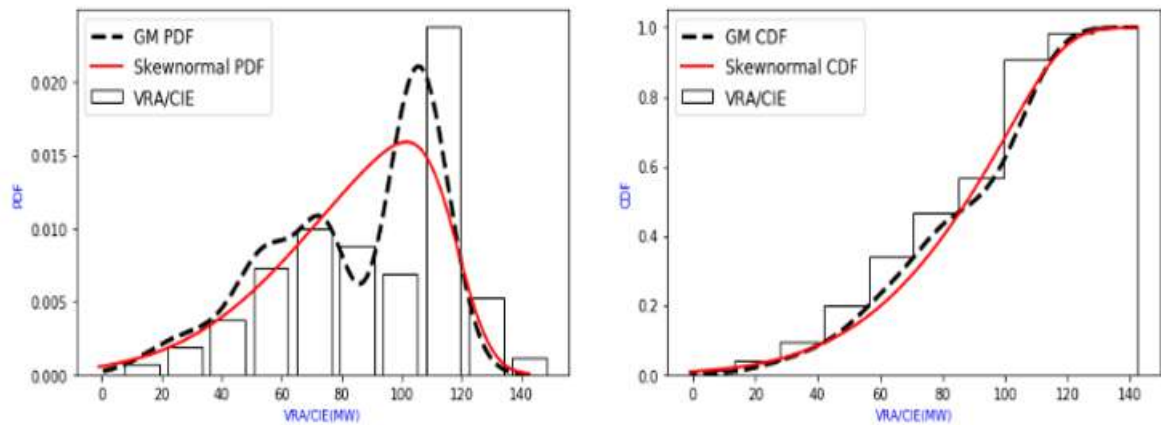


FIGURE 4.4 – Comparaison des PDF et CDF de Skew-normale et de GMM à 4 composantes : cas de VRA/CIE

4.5 Prédiction de la charge électrique

Cette section présente les résultats de prédiction de la charge électrique à une heure (1h) d'avance avec les modules ondelettes/ARIMA et k-means/ANN; et multi-horizons avec le module ondelettes/GPR du logiciel STCED.

4.5.1 Modèle ondelettes/ARIMA

Pour trouver les hyperparamètres du modèle ARIMA, le logiciel procède par la recherche de grille. Le critère d'information AIC est utilisé pour déterminer le modèle optimal qui dispose d'une forte capacité de généralisation. Les coefficients d'approximation CA_j et de détails CD_j obtenus, sont additionnés pour obtenir une fonction $f(t)$ afin de prévoir les données de consommations relatives à un niveau de décomposition k suivant la relation (4.1). Dans cette thèse, la charge de la CEB est décomposée en quatre niveaux avec Daubechies d'ordre 3 (dB3) utilisée comme ondelette mère.

$$f(t) = (CA_k) + \sum_{j=1}^k (CD_j) \quad (4.1)$$

4.5.1.1 Préparation des données d'étude

Dans ce travail, l'ensemble des données est collecté auprès de la CEB. La collecte de ces données couvre la période du 01 janvier 2010 au 31 décembre 2017. Les données des sept (07) premières années sont utilisées pour entraîner le modèle. Celles de la dernière année sont utilisées pour la validation du modèle. Nous rappelons que plusieurs facteurs influencent la charge électrique. Toutefois, le modèle que nous avons développé est un modèle univarié.

La figure 4.5 présente le processus de décomposition en ondelettes de la charge électrique de la CEB. Les parties approximations qui proviennent du filtre passe bas indiquent la tendance de la série. Quant aux parties détails issues du filtre passe haut, elles indiquent les fluctuations de la série.

Les coefficients CA_4 , CD_1 , CD_2 , CD_3 et CD_4 du 4^e niveau de décomposition en ondelettes de la charge électrique de la CEB présentés sur la figure 4.6, sont séparément modélisés par le modèle ARIMA (p, d, q) pour avoir des composantes prédites. Ensuite, les sorties prévues sont finalement additionnées pour prédire la charge électrique de la CEB.

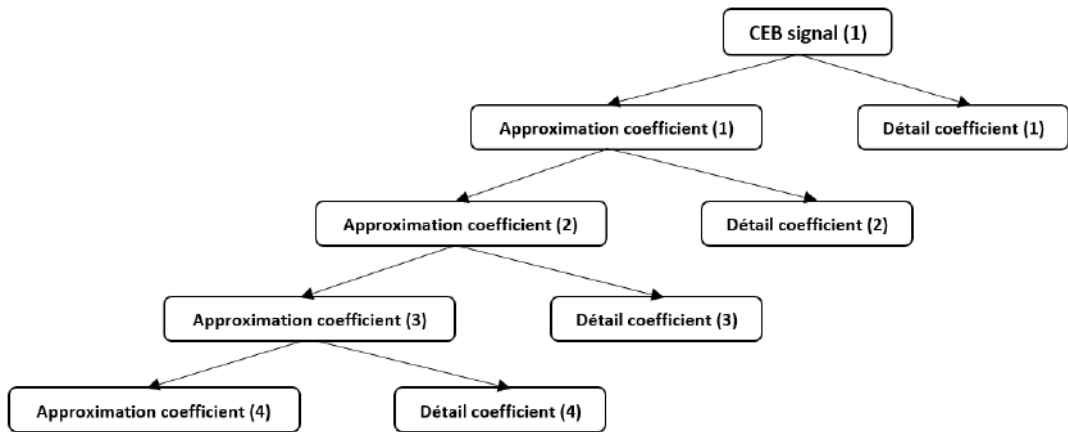


FIGURE 4.5 – Décomposition en ondelette de niveau 4 de la charge électrique de la CEB




FIGURE 4.6 – Décomposition en ondelette de niveau 4 de la charge électrique de la CEB

4.5.1.2 Choix des hyperparamètres optimaux

Par la recherche de grille, le logiciel STCED a permis d'identifier le jeu de paramètres qui permettent au modèle ARIMA (p, d, q) de s'adapter mieux aux données de la charge électrique de la CEB. Pour le modèle de référence ARIMA (p, d, q) et les composantes d'approximation et de détails, les valeurs des différents hyperparamètres optimaux obtenus sont présentées dans le tableau 4.6.

TABLEAU 4.6 – Hyperparamètres optimaux des modèles ARIMA et ondelettes/ARIMA

Paramètres	ARIMA	CA ₄	CD ₄	CD ₃	CD ₂	CD ₁
p	2	2	2	2	2	2
d	1	2	1	0	0	0
q	2	2	2	2	2	2

4.5.1.3 Résultats de prévision avec ondelettes/ARIMA

Les modèles issus de la décomposition discrète des ondelettes combinées à ARIMA sont appliqués aux données de test pour prédire la charge électrique de la CEB. Les performances du modèle hybride développé comparées à ARIMA simple pris comme modèle de référence sont présentées dans le tableau 4.7 pour le 2^e, 3^e et 4^e niveaux de décomposition avec Daubechies d'ordre 3 (db3) comme ondelette mère.

TABLEAU 4.7 – Performance prédictive des modèles ARIMA et ondelette-ARIMA

Indicateur	ARIMA	Modèle hybride ARIMA-Ondelettes		
		4 niveau db3	3 niveau db3	2 niveau db3
RMSE	34,9415	4,08238	4,1531624	4,1784922
MAPE	0,09104	0,009495	0,0097497	0,0099447
R2	0,716538	0,990448	0,990089	0,9901878

L'analyse du tableau 4.7 montre que le modèle hybride (ondelette/ARIMA) minimise les erreurs de prévision par rapport au modèle ARIMA. Une RMSE qui passe de 34,94 MW (pour ARIMA) à 4,08 MW (pour ondelettes/ARIMA). Le coefficient R^2 varie de 71,65% (pour ARIMA) à 99% (pour ondelettes/ARIMA). Le MAPE est réduit de 90% (pratiquement nul).

En conclusion, le modèle hybride ondelettes/ARIMA (ondelette discrète) avec le niveau de décomposition 4, 3 ou 2 et db3 comme ondelette mère offre de meilleures

perspectives grâce à ses performances dans la prévision de la charge électrique CEB. Ce constat se fait sur la figure 4.7 qui présente les profils des charges électriques de la CEB et ceux prédits par le modèle ARIMA et ondelettes/ARIMA.




FIGURE 4.7 – Sorties générées par le modèle ARIMA et le modèle hybride CA4+CD

4.5.2 Modèle K-means/ANN

Dans un premier temps la méthode k-means est appliquée aux données pour les partitionner selon les profils journaliers. Les consommations journalières similaires vont se regrouper dans une même classe. Enfin, l'approche neuronale sera appliquée à chaque classe de consommation électrique pour faire des prévisions. Les résultats de l'approche k-means/ANN vont être comparés à ceux des ANNs (modèle de référence) que nous nommons modèle généraliste.

4.5.2.1 Application de l'algorithme de k-means clustering

Un des critères à vérifier avant d'appliquer la méthode des k-means est le choix du nombre de clusters (classe). Le logiciel STCED utilise la méthode des silhouettes pour trouver le nombre de clusters. Elle permet de déterminer la similitude d'un point avec son propre cluster par rapport à d'autres clusters. La figure 4.8 présente la variation des coefficients de silhouette en fonction du nombre de clusters pour le

cas de la charge électrique de la CEB. Une valeur plus élevée de ce coefficient indique qu'un point a une bonne correspondance avec le cluster auquel il appartient.




FIGURE 4.8 – Variation de la silhouette en fonction du nombre de clusters

L'analyse des résultats présentés sur la figure 4.8 montre que le nombre optimal de cluster est $k = 2$. Par conséquent, l'ensemble des données de charge électrique de la CEB, sera partitionné en deux (02) classes dont l'une correspond aux jours ouvrables et l'autre aux jours non ouvrables. Pour valider les résultats de k-means clustering, la réduction de dimensionnalité (24 à 2 dans notre cas) et la représentation des points dans un plan 2D pourraient être utilisées.

Sur la figure 4.9, chaque point représente un profil de charge quotidien. Théoriquement, la distance entre les points dans l'espace dimensionnel a été présentée de sorte que ceux qui sont rapprochés, se réfèrent aux profils des charges similaires. Le fait que la plupart des pointillés rouges et verts soient proches les uns des autres indiquent une bonne réussite du partitionnement.

Les deux courbes en pointillés sur la figure 4.10 représentent les moyennes de chaque profil. Le cluster en vert correspond à des charges où l'on est resté à la maison (weekend, jours spéciaux ou jours fériés). La consommation est pratiquement constante et présente un pic dans la nuit. Le cluster en rouge présente un pic le matin, une petite baisse l'après-midi, et un pic à nouveau la nuit. Il s'agit des jours ouvrables




FIGURE 4.9 – Représentation en 2D des différents profils de jours des données

où les gens partent au travail ou à l'école. Les éclairages, les climatisations et les usines sont dans ce cas opérationnels.




FIGURE 4.10 – Répartition suivant les différents profils de jour des données

Une fois le partitionnement fait, les données de la charge électrique partitionnées seront introduites dans nos modèles ANN pour faire des prévisions à horizon d'une

heure d'avance.

4.5.2.2 Prédiction avec les ANNs

Après avoir classé les données, des modèles ANNs du type MLP seront utilisés pour prévoir la charge électrique des jours ouvrables et des jours non ouvrables. Nous avons utilisé les données des 48 heures passées pour construire l'ensemble d'apprentissage et de test du modèle. Ce nombre n'est pas choisi au hasard. Plusieurs tests et mesures d'erreur de validation ont été faits. Le chiffre 48 apparaît comme le nombre optimal d'observations pour lequel le modèle k-means /ANN pour prédire la charge électrique de la CEB à horizon d'une heure (1h). La fonction *Relu* est utilisée comme fonction d'activation et l'algorithme de rétropropagation du gradient d'erreur comme algorithme d'apprentissage.

Les données utilisées sont celles présentées à précédemment (§ 4.5.1.1). Elles sont normalisées afin d'éliminer les valeurs aberrantes, puis ramenées à la même échelle. Après plusieurs tests, nous obtenons différentes topologies des ANN de type MLP présentées dans les tableaux 4.8, 4.9 et 4.10.

TABLEAU 4.8 – Erreurs de prévision avec le modèle des jours ouvrables

Architecture du réseau			Indicateur		
Entrée	Nombre de neurones dans la couche cachée		Sortie	RMSE (MW)	MAPE (%)
48	60	-	1	20,46	8,235
48	80	-	1	18,25	6,013
48	100	-	1	17,73	5,84
48	120	-	1	17,61	5,524
48	128	-	1	16,96	4,834
48	140	-	1	17,02	4,913
48	128	80	1	13,63	3,74
48	128	100	1	11,2	3,524
48	128	110	1	10,8	3,024
48	128	115	1	9,944	2,856
48	128	140	1	10,9	3,027
48	128	150	1	11,4	3,124

L'analyse des résultats du tableau 4.10 montre que la configuration [48 84 75 1] présente la plus faible erreur vis-à-vis des autres configurations pour le modèle généraliste. Les figures 4.11, 4.12 et 4.13 présentent respectivement les profils des charges prédites et réelles pour le mois de janvier 2017 avec les modèles généraliste et hybrides.

TABLEAU 4.9 – Erreurs de prévision avec le modèle des jours non ouvrables

Architecture du réseau			Indicateur		
Entrée	Nombre de neurones dans la couche cachée		Sortie	RMSE (MW)	MAPE (%)
48	60	-	1	22,477	8,735
48	80	-	1	21,268	8,314
48	100	-	1	19,788	7,944
48	120	-	1	18,712	5,424
48	128	-	1	18,457	5,184
48	140	-	1	18,915	5,613
48	128	80	1	15,628	4,464
48	128	100	1	14,901	4,044
48	128	110	1	13,96	3,814
48	128	115	1	12,85	3,341
48	128	140	1	13,801	3,607
48	128	150	1	13,901	3,892

TABLEAU 4.10 – Erreurs de prévision pour le modèle généraliste

Architecture du réseau			Indicateur		
Entrée	Nombre de neurones dans la couche cachée		Sortie	RMSE (MW)	MAPE (%)
48	40	-	1	18,457	5,865
48	70	-	1	17,588	5,314
48	84	-	1	16,805	4,14
48	100	-	1	16,915	4,513
48	84	60	1	13,123	3,98
48	84	75	1	12,684	3,263
48	84	100	1	13,001	3,877
48	84	110	1	13,531	3,992




FIGURE 4.11 – Charges réelles et prédites avec le modèle généraliste




FIGURE 4.12 – Charges réelles et prédites des jours ouvrables avec K-Mean et ANNs

Pour la validation des modèles hybrides, l'erreur pondérée de chaque modèle est calculée et présentée dans le tableau 4.11 ainsi que celle de modèle généraliste. Il apparaît que le modèle hybride est plus performant que le modèle généraliste (3,105% contre 3,263% pour le MAPE ; et 11,443 MW contre 12,684 MW pour la RMSE). Par conséquent, le modèle hybride k-means/ANN de type MLP d'architecture [48 128 115 1] apparaît donc comme le plus approprié pour prédire la charge électrique




FIGURE 4.13 – Charges réelles et prédites des jours non ouvrables avec k-means et ANNs

de la CEB.

TABLEAU 4.11 – Comparaison des performances des modèles de prédiction

Modèles	RMSE (MW)	MAPE (%)
Modèle des jours ouvrables	9,944	2,856
Modèle des jours non ouvrables	12,851	3,341
Modèle hybride	11,443	3,105
Modèles généraliste	12,684	3,263

4.6 Modèle ondelettes/GPR

Dans cette section, il est question de présenter les résultats de prévision de la charge électrique avec la Régression par Processus Gaussien (GPR) grâce au logiciel STCED. Pour justifier le choix du support de données, une caractérisation statistique est faite sur les données de la charge électrique de la CEB. Par ailleurs, la forte capacité de généralisation du Processus Gaussien nous permet d'exempter des facteurs météorologiques.

4.6.1 Choix de la base de données d'étude

La figure 4.14 présente la distribution de la charge électrique sur la période du 01 janvier 2010 au 31 Décembre 2017. Les analyses montrent que la distribution des données de la charge électrique est proche de la loi normale. Cependant, il y'a une

légère asymétrie par rapport à la moyenne (skewness=0,1) avec un kurtosis égale à 2,93 indiquant la netteté du pic présenté par la distribution des données.




FIGURE 4.14 – Ajustement de l’histogramme par la loi normale sur l’ensemble des données de charge

Comme rappel, le GPR a un avantage d’interpolation des données manquantes. Par conséquent, peu de données sont nécessaires pour apprendre le modèle. Cependant, le coût de calcul informatique croît rapidement avec la taille de support. Pour cette raison, la taille de données que nous avons utilisée dans cette étude, couvre la période du 01 janvier au 21 avril 2017. Le tableau 4.12 résume les différents paramètres statistiques calculés. Nous remarquons que les coefficients skewness(0,12) et kurtosis (2,45) ne sont pas trop écartés de ceux de la loi normale (skewness=0 et kurtosis = 3). La figure 4.15 présente l’ajustement de l’histogramme des données de la nouvelle base de données considérée par la loi normale.

TABLEAU 4.12 – Statistique descriptive la fenêtre de données

Années	Min	Max	μ	σ	Médiane	Mode	Skewness	Kurtosis
2010-2017	42,17	390	248,34	39,42	245,37	241,92	0,1	2,93
2017*	120,9	390	260,22	34,89	256,7	241,92	0,23	2,54
01/01/2017 21/04/2017	165,1	390	269,9	34,64	266,84	274,64	0,12	2,45




FIGURE 4.15 – Ajustement de l'histogramme par la loi normale sur la fenêtre de données

L'analyse des résultats du tableau 4.12 montre que les différentes valeurs de la moyenne et d'écart type sont de même ordre de grandeur respectif pour les séries de 01 Janvier 2010 au 31 décembre 2017, de l'année 2017 et de la période d'étude considérée; contrairement aux valeurs extrêmes (min et max) qui sont différentes. Pour s'assurer que les données d'études sont normalement distribuées, nous avons procédé par un test statistique. Dans cette logique, nous considérons l'hypothèse H_0 selon laquelle deux bases de données suivent une même loi de distribution. Le test de Student est appliqué pour savoir si leurs moyennes correspondent ou pas. Le seuil de risque $\alpha = 5\%$. Les conditions du test sont fixées comme suit :

- les données sont considérées comme normalement distribuées ;
- les données sont normalisées
- la taille de l'échantillon $n \geq 30$.

La *p - valeur* obtenue est égale à 0,99 avec une statistique égale à $3,049 \times 10^{-14}$. Donc l'hypothèse nulle qui stipule que les moyennes des deux bases de données correspondent peut être acceptée.

4.6.2 Choix du noyau de GPR

La figure 4.16 présente la méthodologie de choix du noyau adapté aux données de la charge électrique avec le modèle GPR. Les sept (07) noyaux présentés sur l'organigramme sont ceux qui offrent de meilleurs résultats (meilleure performance) avec les données de charge de la CEB. Ce sont les noyaux RBF, Exp, M32, M52, MLP, RQ et Per.

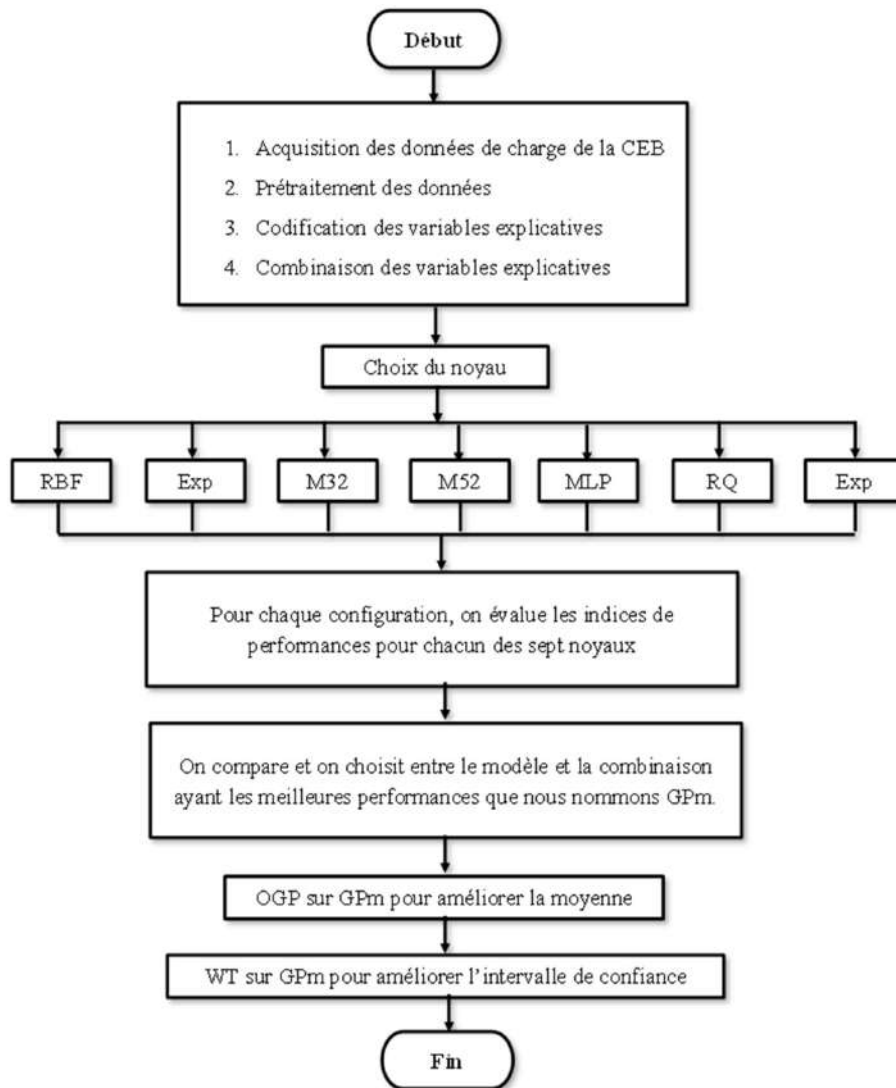


FIGURE 4.16 – Méthodologie adoptée pour la modélisation de la charge électrique avec le GPR

4.6.3 Présentation des variables d'entrées et de sorties

Pour prédire la charge électrique de la CEB, il faut des paramètres qui expliquent exhaustivement l'évolution du profil de la charge électrique. Pour le faire une approche

première consiste à trouver le coefficient de corrélation inter variable compte tenue d'une non-exhaustivité de la liste diversifiée des variables explicatives, nous procédons par plusieurs combinaisons avec les variables explicatives dont nous disposons. Des combinaisons qui peuvent être redondantes ou fournissant peu d'informations sont éliminées sur la base d'évolution et d'analyse de critère de performance. La liste des variables d'entrées requise pour modéliser la charge électrique de la CEB est présentée dans le tableau 4.13. Les différentes configurations obtenues avec leurs variables sont présentées dans le tableau 4.14.

TABLEAU 4.13 – Liste des variables explicatives, leur explication mathématique et leur codification

Données	Formulation mathématique	Code
Variables temporelles		
Jour de travail	Weekend = 0 ; jour ouvrable = 1	A
Jour de la semaine	Lundi = 1 ; Mardi = 2 ; ... ; Dimanche = 7	B
Les heures par jours	janv-24	C
Le temps présent convertis en valeur numérique	$X = t_{num}$	D
Variables historiques		
Les 24 h passées	Pour i allant de 0 à 24 : $X_i = Y_{h-i}$	E
Les 12 h passées	Pour i allant de 0 à 12 : $X_i = Y_{h-i}$	F
Les 4 h passées	Pour i allant de 0 à 4 : $X_i = Y_{h-i}$	G
Même heure de la journée passée	$X = Y_{h-24}$	H
Même heure de la semaine passée	$X = Y_{h-168}$	I
Moyenne des 24h passées	$X = Mean \left(\sum_{i=1}^{24} Y_{h-i} \right)$	J

Pour l'élaboration du modèle, les données de charge électrique sont divisées en deux groupes. Le premier groupe de données est destinées pour l'apprentissage du modèle pour l'estimation des paramètres de la fonction de covariance (variance, écart-type, période,..). Il représente 90% des données et correspond aux valeurs de la charge dont les indexes débute du 01-01-2017 au 31-03-2017. Le second groupe (du 01-04-2017 au 30-04-2017) qui sert à tester la prédiction, représente les 10% restants. Pour

TABLEAU 4.14 – Liste des configurations

N	Configuration	Dimension
1	[G H I]	6
2	[A G H I]	7
3	[A B C G H I]	9
4	[A C G H I]	8
5	[A B C G I]	8
6	[A B C J]	4
7	[B C G H I J]	9
8	[B G H I J]	8
9	[A B C G]	7
10	[B C H J]	4
11	[D]	1
12	[E]	24
13	[A B C F J]	16
14	[A B C G J]	8
15	[A B C E J]	28

l'initialisation des paramètres du noyau, nous avons procédé comme suit :

- son écart-type est initialement égale à celui des données d'entraînement ;
- sa variance est initialement égale à celle des données d'entraînement ;
- la période par défaut est 1.0 ;
- l'optimisation des hyperparamètres est faite en minimisant l'opposé du logarithme de vraisemblance.

4.6.4 Résultats de prévisions avec différentes configurations

Dans cette section, il s'agit principalement d'exposer les résultats issus de nos recherches afin de choisir le modèle (combinaison et noyau) le plus adapté pour la prévision de la charge électrique. En cas de conflit de performance, le modèle qui a la meilleure *RMSE* est choisie.

Les tableaux 4.15 à 4.29 présentent les résultats obtenus pour chacune des différentes configurations. Les deux meilleures performances de chaque configuration sont mises en exergue par des astérisques (* pour la meilleure et ** pour la seconde). À titre indicatif, la complexité de chaque modèle en seconde est aussi présentée.

Pour l'analyse des résultats issus de la GPR appliquée sur les données de la charge électrique de la CEB, un compromis doit être trouvé entre les erreurs *RMSE*, *MAPE*, le coefficient R^2 , *PICP*, *PINAW* et le temps de calcul pour l'entraîne-

TABLEAU 4.15 – Performances de la configuration 1 - [G H I]

Noyaux	RMSE	MAPE(%)	R2(%)	PICP	PINAW	TEMPS (s)
RBF	15,164	14,116	80,895	1	4,351	53
Exp**	15,034	14,159	81,223	1	4,164	64
M32	15,041	14,151	81,204	1	4,139	54
M52	15,065	14,137	81,145	1	4,193	61
MLP*	14,982	14,186	81,35	1	4,142	87
RQ	15,086	14,158	81,093	1	4,145	180
Per	34,814	10,918	-0,7	1	27,353	367

TABLEAU 4.16 – Performances de la configuration 2 - [A G H I]

Noyaux	RMSE	MAPE(%)	R2(%)	PICP	PINAW	TEMPS (s)
RBF	15,186	14,1	80,839	1	4,31	61
Exp**	15,035	14,158	81,22	1	4,16	60
M32	15,047	14,145	81,19	1	4,123	77
M52	15,073	14,125	81,123	1	4,169	53
MLP*	14,982	14,183	81,352	1	4,152	98
RQ	15,086	14,156	81,091	1	4,138	150
Per	45,566	13,089	-72,505	1	10,057	93

TABLEAU 4.17 – Performances de la configuration 3 - [A B C G H I]

Noyaux	RMSE	MAPE(%)	R2(%)	PICP	PINAW	TEMPS (s)
RBF	15,034	14,146	81,221	1	4,231	67
Exp**	14,958	14,177	81,411	1	4,067	62
M32	14,961	14,17	81,404	1	4,055	51
M52	14,987	14,159	81,338	1	4,106	56
MLP*	14,895	14,194	81,568	1	4,054	107
RQ	14,984	14,17	81,347	1	4,083	118
Per	34,047	11,289	3,69	1	24,383	352

TABLEAU 4.18 – Performances de la configuration 4 - [A C G H I]

Noyaux	RMSE	MAPE(%)	R2(%)	PICP	PINAW	TEMPS (s)
RBF	15,024	14,152	81,247	1	4,228	60
Exp	14,952	14,186	81,425	1	4,085	62
M32**	14,946	14,177	81,44	1	4,061	51
M52	14,971	14,166	81,379	1	4,109	60
MLP*	14,89	14,211	81,579	1	4,065	81
RQ	14,982	14,186	81,351	1	4,078	190
Per	34,873	10,944	-1,036	1	27,208	390

TABLEAU 4.19 – Performances de la configuration 5 - [A B C G I]

Noyaux	RMSE	MAPE(%)	R2(%)	PICP	PINAW	TEMPS (s)
RBF	16,229	14,054	78,117	1	5,435	67
Exp*	16,171	14,029	78,273	1	5,262	63
M32	16,205	14,032	78,182	1	5,329	53
M52	16,268	14,029	78,013	1	5,385	73
MLP**	16,19	14,084	78,224	1	4,984	73
RQ	16,277	14,004	77,987	1	5,483	103
Per	34,473	11,139	1,264	1	25,66	360

TABLEAU 4.20 – Performances de la configuration 6 - [A B C J]

Noyaux	RMSE	MAPE(%)	R2(%)	PICP	PINAW	TEMPS (s)
RBF**	21,116	13,427	62,956	1	7,126	85
Exp	22,214	13,353	59,001	1	7,059	68
M32	21,679	13,453	60,952	1	6,813	64
M52	21,634	13,453	61,115	1	6,888	125
MLP*	18,597	13,66	71,265	1	5,689	98
RQ	21,905	13,445	60,134	1	6,898	145
Per	21,241	13,358	62,515	1	9,305	174

TABLEAU 4.21 – Performances de la configuration 7 - [B C G H I J]

Noyaux	RMSE	MAPE(%)	R2(%)	PICP	PINAW	TEMPS (s)
RBF	14,822	14,144	81,747	1	4,18	61
Exp	14,786	14,219	81,836	1	3,932	79
M32*	14,733	14,203	81,966	1	3,929	50
M52**	14,767	14,189	81,882	1	3,993	56
MLP	14,811	14,256	81,774	1	3,915	93
RQ	14,827	14,206	81,735	1	3,938	175
Per	31,992	11,497	14,964	1	22,277	300

TABLEAU 4.22 – Performances de la configuration 8 - [B G H I J]

Noyaux	RMSE	MAPE(%)	R2(%)	PICP	PINAW	TEMPS (s)
RBF	14,885	14,097	81,593	1	4,242	54
Exp*	14,759	14,189	81,902	1	3,924	51
M32**	14,775	14,176	81,864	1	3,964	50
M52	14,816	14,153	81,763	1	4,031	52
MLP	14,814	14,252	81,768	1	3,952	87
RQ	14,856	14,19	81,664	1	3,966	154
Per	40,176	12,555	-34,107	1	11,409	97

TABLEAU 4.23 – Performances de la configuration 9 - [A B C G]

Noyaux	RMSE	MAPE(%)	R2(%)	PICP	PINAW	TEMPS (s)
RBF	16,26	14,204	78,034	1	5,575	62
Exp**	16,069	14,204	78,548	1	5,289	57
M32	16,077	14,191	78,525	1	5,464	61
M52	16,152	14,194	78,324	1	5,544	65
MLP*	15,701	14,235	79,518	1	4,922	88
RQ	16,219	14,146	78,144	1	5,372	228
Per	44,064	13,658	-61,319	1	8,364	225

TABLEAU 4.24 – Performances de la configuration 10 - [B C H J]

Noyaux	RMSE	MAPE(%)	R2(%)	PICP	PINAW	TEMPS (s)
RBF**	21,8	13,577	60,514	1	7,418	79
Exp	22,074	13,577	59,516	1	7,645	60
M32	21,993	13,65	59,814	1	7,455	100
M52	21,973	13,664	59,888	1	7,423	95
MLP*	20,153	13,638	66,256	1	6,698	102
RQ	21,951	13,499	59,968	1	7,907	207
Per	22,266	13,317	58,81	1	9,908	170

TABLEAU 4.25 – Performances de la configuration 11 - [D]

Noyaux	RMSE	MAPE(%)	R2(%)	PICP	PINAW	TEMPS (s)
RBF	35,055	11,352	-2,098	1	25,703	78
Exp	138,34	44,604	-1490	1	1001,91	100
M32	271,4	98,325	-6019,7	1	2114,0	153
M52	224,79	75,405	-4098,4	1	680,036	210
MLP*	34,808	10,921	-0,662	1	27,151	72
RQ**	34,821	11,192	-0,739	1	56,317	175
Per	34,84	10,932	-0,846	1	27,032	159

TABLEAU 4.26 – Performances de la configuration 12 - [E]

Noyaux	RMSE	MAPE(%)	R2(%)	PICP	PINAW	TEMPS (s)
RBF	14,174	14,502	83,309	1	4,083	44
Exp**	13,767	14,353	84,254	1	3,726	45
M32	13,871	14,425	84,014	1	3,83	48
M52	13,897	14,436	83,954	1	3,918	50
MLP*	13,643	14,365	84,535	1	3,771	110
RQ	13,878	14,333	83,997	1	3,827	162
Per	36,138	11,487	-8,501	1	16,406	190

TABLEAU 4.27 – Performances de la configuration 13 - [A B C F J]

Noyaux	RMSE	MAPE(%)	R2(%)	PICP	PINAW	TEMPS (s)
RBF_EQ	15,017	14,312	81,263	1	4,946	46
Exp**	14,898	14,257	81,56	1	4,44	74
M32	14,982	14,355	81,352	1	4,546	41
M52	15,058	14,389	81,162	1	4,702	50
MLP*	14,701	14,259	82,043	1	4,361	77
RQ	15,078	14,258	81,111	1	4,446	141
Per	27,707	12,896	36,221	1	10,474	182

TABLEAU 4.28 – Performances de la configuration 14 - [A B C G J]

Noyaux	RMSE	MAPE(%)	R2(%)	PICP	PINAW	TEMPS (s)
RBF_EQ	16,206	14,092	78,18	1	5,583	58
Exp	16,165	14,21	78,29	1	4,952	50
M32*	16,063	14,198	78,563	1	5,096	49
M52**	16,087	14,19	78,499	1	5,221	64
MLP	16,25	14,235	78,06	1	4,746	79
RQ	16,274	14,168	77,997	1	4,986	130
Per	27,852	13,785	35,549	1	6,494	191

TABLEAU 4.29 – Performances de la configuration 15 - [A B C E J]

Noyaux	RMSE	MAPE(%)	R2(%)	PICP	PINAW	TEMPS (s)
RBF_EQ	14,218	14,471	83,204	1	4,05	51
Exp**	13,822	14,349	84,128	1	3,768	61
M32	13,919	14,405	83,904	1	3,819	52
M52	13,944	14,414	83,845	1	3,903	50
MLP*	13,655	14,358	84,508	1	3,767	71
RQ	13,898	14,326	83,952	1	3,823	168
Per	32,21	12,417	13,804	1	14,363	395

ment des différents modèles. Sur la base de la prévision d'une heure (1h), les modèles présentés dans les tableaux 4.15, 4.16, 4.17, 4.23, 4.26, 4.27, 4.29 produisent des résultats similaires selon le critère $RMSE$, sauf le modèle GPR fondé sur le noyau périodique qui fournit le moins bon résultat. Néanmoins, on note une légère supériorité du modèle GPR fondé sur le noyau MLP. Ce constat est confirmé par les critères $MAPE$ et R^2 . En examinant les valeurs de $PICP$ pour tous les modèles considérés dans cette étude comparative, elle est égale à 1. Ce qui montre que les données de test se trouvent dans l'intervalle de confiance fourni par ces modèles. Ce qui indique la qualité des prévisions faites par les modèles. Le noyau Exponentiel (Exp) occupe la deuxième place pour tous les résultats présentés dans ce tableau. Toutefois, il faut retenir que le temps de calcul informatique varie en fonction des modèles utilisés. Certains sont plus rapides que d'autres. Cela s'explique par le nombre d'hyperparamètres impliqués dans l'entraînement des modèles.

Pour le tableau 4.19, les constats sont les mêmes sauf que le modèle GPR fondé sur le noyau exponentiel (Exp) prime sur le noyau MLP.

Les tableaux 4.20 et 4.24 montrent les résultats des prévisions faites avec le modèle GPR avec les sept noyaux en question. Il ressort d'après l'analyse des résultats obtenus que le modèle GPR fondé sur le noyau MLP suivi par le modèle RBF à noyau RBF offre de meilleurs résultats de prévisions de la charge électrique de la CEB. Ce qui se traduit par de meilleures valeurs des indicateurs de performances d'une part et de fortes valeurs de $PICP$ et faibles valeurs de $PINAW$ montrant ainsi une corrélation entre les données de test et de prévision. Par ailleurs, le modèle GPR fondé sur le noyau périodique (Per) est celui qui offre de résultats moins probants; toutefois, le noyau M32 est le plus rapide comparé au GPR fondé sur le noyau Per.

Pour les tableaux 4.21, 4.22 et 4.28, les noyaux Matern d'ordre 1 (Exp), M32 et M52 fournissent de meilleurs indicateurs de performances qui se trouvent tous dans le même ordre de grandeur. La plus forte valeur de $PICP$ (proche de 1) et la plus faible valeur de $PINAW$ montre une meilleure fiabilité des résultats de prévisions de la charge électrique par le modèle GPR fondé sur ces noyaux. Pour tous les modèles, le modèle GPR fondé sur le noyau périodique reste toujours le moins bon avec un temps de calcul assez important.

Pour le tableau 4.18, le modèle GPR à noyau MLP vient au premier rang dans

la prévision de la charge électrique de la CEB. Il est suivi par GPR à noyau M32. Les erreurs ainsi que les coefficients de détermination de chaque modèle se trouve dans une même plage de valeur. Ce qui s'explique par de bonnes valeurs de *PICP* et de *PINAW*. Le noyau périodique est celui qui est le moins performant par rapport à d'autres modèles.

Par ailleurs, Les résultats du tableau 4.25 sont tous dépréciés compte tenu des valeurs négatives du coefficient R^2 présentées.

En résumé, le bilan des meilleures performances pour chaque configuration est présenté dans le tableau 4.30. L'analyse des résultats présentés, montre que la configuration 12 sur laquelle est appliquée le modèle GPR fondé sur le noyau MLP, est celle qui offre les meilleurs résultats prévisions de la charge de la CEB ($RMSE = 13,63$ GWh ; $MAPE = 14,372\%$; $R^2 = 84,54\%$; $PICP=1$ et $PINAW = 3,77$). Le temps de calcul pour l'entraînement du modèle est de 110 s (environ 2 min). Ce modèle sera retenu par la suite pour les études de prévisions à horizons multiples par processus gaussiens avec mise à jour OGP. Nous utilisons la terminologie GP_MLP12 pour désigner le modèle obtenu. La figure 4.17 montre le résultat de prévision horaire par GPR sans mise à jour, de la charge électrique de la CEB. Sur la figure 4.18, nous pouvons observer une corrélation entre les données observées et celles prédites.

TABLEAU 4.30 – Bilan des meilleures performances de toutes les configurations

Config.	Noyaux	RMSE	MAPE(%)	R2(%)	PICP	PINAW
1	MLP	14,98	14,186	81,35	1	4,142
2	MLP	14,98	14,183	81,35	1	4,152
3	MLP	14,9	14,194	81,57	1	4,054
4	MLP	14,89	14,211	81,58	1	4,065
5	Exp	16,17	14,029	78,27	1	5,262
6	MLP	18,6	13,66	71,27	1	5,689
7	M32	14,73	14,203	81,97	1	3,929
8	Exp	14,76	14,189	81,9	1	3,924
9	MLP	15,7	14,235	79,52	1	4,922
10	MLP	20,15	13,638	66,26	1	6,698
11	MLP	34,81	10,921	-0,662	1	27,151
12*	MLP	13,64	14,365	84,54	1	3,771
13	MLP	14,7	14,259	82,04	1	4,361
14	M32	16,06	14,198	78,56	1	5,096
15	MLP	13,66	14,358	84,51	1	3,767




FIGURE 4.17 – Charge réelle et prédite sur une durée de 48 heures (01 au 02 Avril 2017)




FIGURE 4.18 – Corrélation entre les valeurs mesurées et prédites avec GP

4.6.5 Processus gaussien avec mis à jour (OGP)

La mise à jour consiste à réinjecter les données observées (prédites) dans le modèle, pour renforcer l'apprentissage afin d'améliorer la moyenne des observations (prévi-

sions) sur la grande base de données. Une amélioration a été observée sur notre base de donnée utilisée(légère). La $RMSE$ passe de 13,51 à 13,64 MW, le R^2 passe de 84,535% à 84,846%. Les figures 4.19 et 4.20 montrent respectivement les résultats de prévision de la charge électrique de la CEB et son intervalle de confiance (IC).




FIGURE 4.19 – Charge réelle et prédite sur les trois semaines de test avec OGP




FIGURE 4.20 – intervalle de confiance à 95%

Les valeurs de $PICP$, de $PINAW$ du tableau 4.30, il est évident que les points de données prédits sont situés à l'intérieur de l'intervalle de confiance. Cependant, le $PINAW$ montre un intervalle de confiance assez large. Ce qui s'explique par les résultats de la figure 4.20. Cette grande largeur de l'IC est due à l'écart type du bruit (166,513 MW en moyenne). Pour améliorer l'IC (réduire sa largeur) des prévisions, nous avons utilisé la décomposition en ondelettes continues.

4.6.6 Améliorations de l'IC des prévisions

Les démarches consistent à décomposer les données d'entraînement en ondelettes continues. Nous avons utilisé db3 comme ondelette mère. Chaque composante (détails et approximation), CA_3 , CD_3 , CD_2 et CD_1 en vue de prédire la composante appropriée aux données de test. Enfin, les composantes prédites seront utilisées (somme) pour la transformée inverse en ondelettes. La figure 4.21 montre les composantes de détails et d'approximation issues de la décomposition en ondelettes continue de la charge électrique de la CEB. Les résultats de prévision sont présentés sur les figures 4.22 et 4.23. Seuls les deux premiers jours du mois d'Avril 2017 ont leurs profils de charges électriques représentés. L'analyse de ces figures montre une parfaite corrélation entre les valeurs des charges électrique observées et celles prédites. De plus, il y a une grande amélioration de l'intervalle de confiance des données prédites. Le tableau 4.31 confirme ce résultat à travers les différentes valeurs $PICP$ et de $PINAW$. Les indicateurs de performance $RMSE$, $MAPE$ et R^2 ont vu leurs valeurs améliorées.

TABLEAU 4.31 – Bilan des erreurs pour le modèle avant et après décomposition

Modèle	RMSE	MAPE(%)	R2(%)	PICP	PINAW
GP_MLP12	13,64	14,365	84,54	1	3,771
OGP_MLP12	13,51	14,399	84,85	1	3,739
GP_MLP12_WAV	11,89	3.133	88,25	0,87	0,294

En résumé, le modèle issu de la configuration 12 à noyau MLP combiné avec la décomposition continue de niveau de décomposition et qui utilise db3 comme ondelette mère est recommandé pour prévoir la charge électrique de la CEB. Ce modèle peut être stable sous d'autres cieux selon la nature des données dont nous disposons. Toutefois, il est très important de procéder à une analyse poussée des configurations afin de retrouver le modèle GPR fondé sur un noyau approprié. La figure ?? permet de juger la performance de chacun des modèles GP_MLP, OGP_MLP12 et GP_MLP12_WAV sur la période d'une semaine. Pour chaque modèle, les er-




FIGURE 4.21 – Vue dilatée des composantes CA3, CD3, CD2 et CD1




FIGURE 4.22 – Nouvelle prédiction sur une durée de 48 heures (01 au 02 Avril 2017) avec un intervalle de confiance réduit.




FIGURE 4.23 – Corrélation entre les valeurs mesurées et prédites avec GP_MLP12_WAV

reurs RMSE sont calculées. Nous remarquons que tous ces modèles en particulier GP_MLP12_WAV modélisent mieux la charge électrique de la CEB avec une faible RMSE égale à 13,083 MW.




FIGURE 4.24 – Charge réelle et prédite pour les différents modèles (pour la semaine du 01 au 07 avril 2017) avec un intervalle de confiance réduit.

4.6.7 Prédiction multihorizon

Dans cette section, la consommation électrique sera prédite à plusieurs heures en avance. De plus, l'impact de l'horizon sur la prédiction sera examiné. Le tableau 4.32 présente l'évolution des erreurs de prédiction en fonctions de l'horizon.

TABLEAU 4.32 – Erreurs de prédiction suivant l'horizon

Horizon (h)	RMSE	NRMSE (%)	MAPE (%)	R2 (%)
1	13,643	5,012	14,365	84,535
2	17,295	6,354	14,146	75,148
3	18,971	6,97	14,011	70,1
4	20,13	7,395	13,944	66,334
5	20,856	7,662	13,573	63,862
6	21,917	8,052	13,676	60,089
7	22,363	8,216	13,286	58,45
8	23,371	8,586	13,466	54,618
9	23,797	8,743	13,394	52,95
10	23,444	8,613	13,126	54,335
11	23,633	8,683	13,078	53,595
12	23,725	8,716	13,016	53,235
13	24,727	9,085	13,14	49,201
14	23,715	8,713	13,019	53,275
15	23,76	8,729	13,034	53,096
16	23,842	8,759	13,058	52,771
17	23,913	8,786	13,043	52,489
18	23,97	8,806	13,034	52,263
19	24,078	8,846	13,045	51,832
20	24,241	8,906	13,033	51,18
21	24,243	8,907	13,025	51,171
22	25,059	9,206	13,224	47,828
23	25,016	9,191	13,247	48,006
24	25,074	9,212	13,278	47,766

L'analyse des résultats du tableau montre que la *RMSE* croît vite avec l'horizon de prédiction (13,643 MW à 23,371 MW respectivement pour 1h et 8h en avant). Elle tend à se stabiliser au-delà de huit pas en avant avec une *RMSE* qui tourne autour de 24 MW. Ce même constat est réalisé chez les autres indicateurs de performance (8% pour la *NRMSE* ; 13% pour le *MAPE* et 50% pour le R^2). Ceci se traduit par l'accumulation des erreurs de prédiction et des fonctions noyaux qui présentent des comportements asymptotiques.

4.7 Optimisation du coût de l'électricité et d'emprunte carbone

Dans cette partie, nous présentons les résultats des problèmes d'optimisation formulés au chapitre précédent. Des études de cas sont faites sur les réseaux IEEE à 24 nœuds [29] et de la CEB. Le réseau IEEE peut être mis à jour vers une version qui peut être facilement utilisée pour les études sur le marché d'électricité et aussi d'exploitation du système électrique. Comme hypothèse, nous supposons qu'il est modifiable pour accueillir des parcs éoliens et solaires afin d'avoir une forte capacité d'intégration des énergies renouvelables et d'autres sources de production.

4.7.1 Description du réseau IEEE à 24 nœuds

Pour les simulations, le réseau standard IEEE à nœuds que nous avons utilisé, est présenté sur la figure 4.25. Il s'agit d'un réseau de tension 138 kV, 230 kV avec $S_{base} = 100$ MV A. Les données techniques de ce réseau sont recensées dans les tableaux 4.33 et 4.34 [185]. Nous désignons par x la réactance, r la résistance, b la susceptance de charge totale de ligne et les puissances nominales (capacité de ligne) en MV A. Les données des unités de production de ce réseau sont tirées de [186,187]. Le nœud slack est le bus 13. Les lignes sont constituées de nœuds connectés avec dix (10) unités de production. Les données relatives au coût du combustible et d'émission carbone sont indiquées dans le tableau 4.35. Ces générateurs du réseau sont répertoriés dans les tableaux 4.36 et 4.37.




FIGURE 4.25 – Topologie du réseau IEEE à 24 Bus

TABLEAU 4.33 – Données des lignes de transport du réseau IEEE à 24 nœuds

Nœud		Ligne			
Départ	Arrivée	r(pu)	x(pu)	b(pu)	S (MVA)
1	2	0,0026	0,0139	0,4611	175
1	3	0,0546	0,2112	0,0572	175
1	5	0,0218	0,0845	0,0229	175
2	4	0,0328	0,1267	0,0343	175
2	6	0,0497	0,1920	0,0520	175
3	9	0,0308	0,1190	0,0322	175
3	24	0,0023	0,0839	0,0000	400
4	9	0,0268	0,1037	0,0281	175
5	10	0,0228	0,0883	0,0239	175
6	10	0,0139	0,0605	2,4590	175
7	8	0,0159	0,0614	0,0166	175
8	9	0,0427	0,1651	0,0447	175
8	10	0,0427	0,1651	0,0447	175
9	11	0,0023	0,0839	0,0000	400
9	12	0,0023	0,0839	0,0000	400
10	11	0,0023	0,0839	0,0000	400
10	12	0,0023	0,0839	0,0000	400

TABLEAU 4.34 – Données des lignes de transport du réseau IEEE à 24 nœuds (suite)

Nœud		Ligne			
Départ	Arrivée	r(pu)	x(pu)	b(pu)	S (MVA)
11	13	0,0061	0,0476	0,0999	500
11	14	0,0054	0,0418	0,0879	500
12	13	0,0061	0,0476	0,0999	500
12	23	0,0124	0,0966	0,2030	500
13	23	0,0111	0,0865	0,1818	500
14	16	0,0050	0,0389	0,0818	500
15	16	0,0022	0,0173	0,0364	500
15	21	0,0032	0,0245	0,2060	1000
15	24	0,0067	0,051	0,1091	500
16	17	0,0033	0,025	0,0545	500
16	19	0,0030	0,0231	0,0485	500
17	18	0,0018	0,0144	0,0303	500
17	22	0,0135	0,1053	0,2212	500
18	21	0,0017	0,0130	0,1090	1000
19	20	0,0026	0,0198	0,1666	1000
20	23	0,0014	0,0108	0,0910	1000
21	22	0,0087	0,0678	0,1424	500

TABLEAU 4.35 – Données de coefficients de coûts des carburants et d'émissions pour un système IEEE 24 bus

i	a	b	c	d	e	f
g1	3	20	100	2	-5	3
g2	4,05	18,07	98,87	3,82	-4,24	6,09
g3	4,05	15,55	104,26	5,01	-2,15	5,69
g4	3,99	19,21	107,21	1,10	-3,99	6,20
g5	3,88	26,18	95,31	3,55	-6,88	5,57
g6	0,12	14,8	89	1,2	-5	3
g7	0,17	16,57	83	2,3	-4,24	6,09
g8	0,15	15,55	100	1,1	-2,15	5,69
g9	2,4375	13,00	70	0,0126	-0,9	22,983
g10	11,375	11,05	89	0,02	-0,1	25,313
g11	0,12	14,80	89	1,2	-5	3
g12	0,17	16,57	16,57	2,3	-4,24	6,09

TABLEAU 4.36 – Caractéristiques des générateurs du réseau IEEE 24 bus

Gen	Bus	Pmax(MW)	Pmin(MW)	bi (\$/MW)	Csi (\$)	Cdi (\$)	RU _i (MWh-1)	RD _i (MWh-1)
g1	18	400	100	5,47	0	0	47	47
g2	21	400	100	5,47	0	0	47	47
g3	1	152	30,4	13,32	1430,4	1430,4	14	14
g4	2	152	30,4	13,32	1430,4	1430,4	14	14
g5	15	155	54,25	16	0	0	21	21
g6	16	155	54,25	10,52	312	312	21	21
g7	23	310	108,5	10,52	624	624	21	21
g8	23	350	140	10,89	2298	2298	28	28
g9	7	350	75	20,7	1725	1725	49	49
g10	13	591	206,85	20,93	3056,7	3056,7	21	21
g11	15	60	12	26,11	437	437	7	7
g12	22	300	0	0	0	0	35	35

TABLEAU 4.37 – Caractéristiques des générateurs du réseau IEEE 24 bus(suite)

Gen	Bus	SUi (MWh-1)	SDi (MWh-1)	UTi (h)	DTi (h)	Uif=0	Ui0(h)	Si0(h)
g1	18	105	108	1	1	1	5	0
g2	21	106	112	1	1	1	6	0
g3	1	43	45	8	4	1	2	0
g4	2	44	57	8	4	1	2	0
g5	15	65	77	8	8	0	0	2
g6	16	66	73	8	8	1	10	0
g7	23	112	125	8	8	1	10	0
g8	23	154	162	8	8	1	5	0
g9	7	77	80	8	8	0	0	2
g10	13	213	228	12	10	0	0	8
g11	15	19	31	4	2	0	0	1
g12	22	315	326	0	0	1	2	0

4.7.2 Présentation des données d'étude d'optimisation

Les données du vent de cette étude sont collectées sur le site de l'université de Wyoming (à Laramie aux États-Unis) et couvrent la période du 19 Novembre 2017 pour le site de Lomé-Tokoin. Le parc éolien est de 200 unités de turbines de puissance nominale 200 kW chacune, connectées au réseau électrique [188]. Les pâles de ces éoliennes couvrent une surface de 880 m². Les puissances moyennes extractibles du parc éolien à différentes heures de la journée sont regroupées dans le tableau 4.38.

TABLEAU 4.38 – Puissance moyenne extractible de la ferme éolienne aux différentes heures de la journée du 19 Novembre 2017

Heure	Vitesse(m/s)	Puissance(MW)	Heure	Vitesse(m/s)	Puissance(MW)
1	6	10,216	13	11	62,95
2	4	3,027	14	12	81,7
3	2	0	15	10	47,3
4	3	0	16	9	34,48
5	2	0	17	8	24,21
6	3	0	18	7	16,22
7	4	3,027	19	7	16,22
8	4	3,027	20	8	24,21
9	5	3,027	21	7	16,22
10	11	5,912	22	6	10,21
11	11	62,956	23	5	5,91
12	11	62,956	24	3	0

Le champ solaire considéré est d'une puissance nominale équivalent égale à 40MW. Pour l'étude, nous avons utilisé les données horaires fournies par Waether Spark pour la journée du 19 Novembre 2017 [189]. Les puissances moyennes extractibles aux différentes heures de la journée se résument dans le tableau 4.39.

Le profil journalier de la charge de la CEB pour la journée du 19 Novembre 2017 est présenté dans le tableau 4.40.

Dans la suite, nous supposons que les générateurs thermiques sont différents de ceux (sources) des centrales renouvelables. Quelques scénarii de test sur le réseau IEEE 24 nœuds et de la CEB sont présentés dans le tableau 4.41.

4.7.3 Résultats d'optimisation du coût de l'électricité et de l'emprunte carbone

Une vue détaillée des résultats d'optimisations de coût de l'électricité et de CO₂ est présentée dans le tableau 4.42. Les résultats montrent l'écart entre les émissions de

TABLEAU 4.39 – Puissance moyenne extractible de la centrale solaire aux différentes heures durant la journée de 19 Novembre 2017

Heure	Irradiance (W/m ²)	Puissance (MW)	Heure	Irradiance (W/m ²)	Puissance (MW)
1	0	0	13	685	54,8
2	0	0	14	685	54,8
3	0	0	15	600	48
4	0	0	16	490	39,2
5	0	0	17	350	28
6	0	0	18	170	13,6
7	0	0	19	0	0
8	62,5	2,083	20	0	0
9	197,5	15,8	21	0	0
10	522	29,8	22	0	0
11	620	41,8	23	0	0
12	685	49,6	24	0	0

TABLEAU 4.40 – Profil de la charge électrique de la CEB durant la journée de 19 Novembre 2017

Heure	Charge (MW)	Heure	Charge (MW)
1	263,34	13	223,36
2	260,94	14	218,31
3	254,85	15	223,38
4	242,41	16	236,86
5	219,27	17	307,72
6	223,52	18	321,45
7	225,45	19	320,18
8	231,6	20	307,18
9	233,76	21	296,33
10	235,09	22	278,66
11	231,95	23	274,64
12	232,59	24	264,66

TABLEAU 4.41 – Détail des différents scénarii avec les sources thermiques, solaires et éoliennes

Scénario	Sources themiques	Intégration
1	[1,2]	[solaire,éolienne]
2	[1,2,3]	[solaire,éolienne]
3	[1,2,3,4]	[solaire,éolienne]
4	[1,2,3,4,5]	[solaire,éolienne]
5	[1,2,3,4,5,6]	[solaire,éolienne]
6	[1,2,3,4,5,6,7]	[solaire,éolienne]
7	[1,2,3,4,5,6,7',8]	[solaire,éolienne]
8	[1,2,3,4,5,6,7',8,9]	[solaire,éolienne]
9	[1,2,3,4,5,6,7',8,9,10]	[solaire,éolienne]
10	[1,2,3,4,5,6,7',8,9,10,11]	[solaire,éolienne]
11	[1,2,3,4,5,6,7',8,9,10,11,12]	[solaire,éolienne]

CO₂ dans les réseaux optimisé et non optimisé. Le réseau optimisé est celui issu des intégrations de l'énergie renouvelable. L'émission totale passe de 889706,677 kg à 873528,87 kg de CO₂. Soit une réduction de 16177,805 kg de CO₂ pour le scénario 3 où les unités g1, g2, g3 et g4 en marche sont appuyées par les centrales solaires et éoliennes. Ainsi, l'intégration des sources renouvelables réduit les émissions de CO₂ dans un réseau électrique.

Les résultats d'optimisation des coûts de puissance générée par chaque centrale du tableau 4.42 montre qu'il y a un écart considérable entre le coût d'énergie dans le réseau optimisé et non optimisé pour le scénario 3. Nous avons le coût qui passe de 2104579,831 \$ US à 2047357,004 \$ US lors de l'intégration des sources renouvelables, soit une optimisation de 57222, 827 \$ US.

En conclusion, pour la journée du 19 Novembre 2017, le choix des producteurs g1, g2, g3 et g4 permettra à la compagnie électrique (CEB) de réduire considérablement le coût d'achat de l'électricité et une optimisation du CO₂ via l'intégration des énergies renouvelables dans le réseau électrique. Une fois le meilleur scénario choisi, l'évaluation du coût associé aux pertes en ligne lors du transport de l'énergie électrique peut être faite en interne par la planification du réseau en utilisant la théorie des graphes (non couverte par cette thèse). Ceci permettra d'évaluer la rentabilité économique, environnementale et thermique de l'approche proposée. Pour tester la validité de notre approche, nous procédons par le critère de satisfaction à la demande durant la journée du 19 Novembre 2017 à travers la représentation graphique de la figure 4.26. La stratégie proposée dans notre cas, montre que la charge est totalement satisfaite à moindre coût dans le respect des exigences environnementales.

TABLEAU 4.42 – Résultats des tests de coût et emission CO₂ optimisés sur le réseau IEEE 24 nœuds

Scénario	coût énergies sans éner- gies renouvelables	Coût énergies avec énergies renouve- lables	Emission CO ₂ sans énergie renouve- lables	Emission CO ₂ avec énergies renouvelables
1	2892837,581	2678422,589	1250125,496	302098,448
2	2233427,591	124260,765	936068,373	38210,209
3	2104579,831	57222,827	889706,677	16177,805
4	2310491,017	2134767,786	941737,586	609313,206
5	2337216,37	2170304,63	1098048,354	827325,937
6	2430387,43	2272922,626	1403373,714	1168588,456
7	2555595,43	2402170,29	1907556,114	1682728,086
8	2909737,93	2760273,169	2049022,914	1846442,631
9	1,46E+07	14498690,32	3256536,282	3052008,782
10	1,47E+07	14499820,72	3263410,122	3052231,507
11	1,47E+07	14490450,75	3263521,468	3038213,123




FIGURE 4.26 – Profil journalier de la charge couvert en 24 heure

La CEB dans le souci de moderniser son dispatching dispose d'un nouveau système de gestion du réseau (ITERA) incluant un système de prévision basé sur les outils classiques. Mais, elle est encore loin de résoudre ce problème. Pour apporter une solution à cette difficulté, notre logiciel STCED propose des modèles de prévision à court terme de la charge électrique de la CEB. Ainsi, les résultats obtenus avec STCED sont comparés avec ceux des modèles développés dans [106] et celui d'ITERA. Les résultats obtenus sont pertinents et prouvent la force du logiciel STCED que nous développons.

4.8 Conclusion

Dans ce chapitre, les résultats des études de cas obtenus avec le logiciel STCED ont été représentés. Dans un premier temps, une caractérisation des sources de production et d'importation de la CEB a permis de recommander les mélanges de distributions gaussiennes pour les importations TCN et VRA/CIE et la loi normale asymétrique (skewnormale) sous la production interne (Nangbéto) sur la base des critères de performance et test de K-S. Par la suite, pour la prévision de la charge électrique, trois modèles hybrides ont été implémentés sous STCED. Il s'agit de : ondelettes / ARIMA, k-means / ANNs et ondelettes / Processus Gaussien pour prévoir 1h à l'avance, la charge électrique de la CEB. Les résultats obtenus démontrent la performance des approches supposées. Pour la prévision multi-horizon seul le GP a été utilisé. Enfin du côté de l'optimisation, les tests effectués sur le réseau standard IEEE à nœuds et celui de la CEB ont contribué à la conduite des réseaux électriques

par optimisation du coût de l'électricité et de l'empreinte carbone pour une journée de 24h à travers divers scénarii relatifs aux plans de production en accord avec la courbe prévisionnelle de la demande. Les résultats obtenus ont démontré la perspicacité de la démarche proposée avec des résultats probants sur l'intégration des énergies renouvelables. Ceci pourra aider la compagnie électrique (CEB) à réaliser d'énormes marges bénéficiaires en termes de coût et d'exigences environnementales. Ce logiciel constitue pour le gestionnaire du réseau électrique, un puissant outil d'aide à la décision pour la planification des réseaux électriques interconnectés.

Conclusion générale et perspectives

L'équilibre permanent entre l'offre et la demande en électricité est d'une importance capitale pour les compagnies électriques. De ce fait, cela suscite la mise en place des infrastructures d'interconnexion des réseaux électriques, la libéralisation et l'ouverture du marché de l'électricité, l'intégration des énergies renouvelables dans le mix énergétique pour répondre aux problématiques d'émission des GES et d'épuisement des sources fossiles. Il se pose un grand défi au GRT dans le cadre de la mise en place d'un réseau électrique durable avec une forte intégration des énergies renouvelables pour assurer à chacun l'accès à l'électricité à moindre coût, une étude de planification s'avère indispensable. Dans notre cas d'étude, nous nous sommes limités au court terme dont les principes sont axés autour de ces trois (03) objectifs à savoir :

- assurer la sécurité d'approvisionnement en énergie électrique ;
- promouvoir le développement durable et le respect de l'environnement ;
- prôner l'efficacité économique grâce à la libéralisation du marché de l'électricité.

Dans les pays du Nord où la maîtrise de la planification des réseaux électriques interconnectés est très poussée, plusieurs objectifs sont visés. Il s'agit de :

- l'analyse des données de production et de la demande en électricité ;
- la caractérisation des sources de production en énergie électrique ;
- la prédiction de la charge électrique ;
- l'optimisation du dispatching économique environnemental.

Pour atteindre ces objectifs dans les pays du Nord, on utilise des outils de planification des réseaux électriques basés sur l'utilisation :

- des méthodes d'analyse statistique descriptive ;
- de l'inférence statistique en se basant sur la théorie des probabilités ;

- du traitement de signal (méthodes d'analyse par la transformée en ondelettes);
- des techniques de l'IA ou du Machine Learning;
- de l'économétrie des séries temporelles;
- des méthodes d'optimisation (stochastiques et déterministes).

Le souci est d'amener les pays du sud, notamment le Togo à rechercher les mêmes objectifs que ceux du Nord comme mentionné précédemment a justifié le contexte actuel de cette étude. Ainsi, les outils d'analyse et de modélisation utilisés dans la planification des réseaux électriques interconnectés ont été appliqués sur les données du réseau électrique interconnecté de la CEB. Il en ressort que :

- pour la caractérisation des sources de production et d'importation de l'énergie électrique de la CEB, la fonction de distribution Skewnormale ajuste mieux l'histogramme des distributions des puissances générées par la source de Nangbéto avec un $R^2 = 0,882$, une $RMSE = 0,00305$ et un $CRPS = 0,077$. Quant aux importations VRA/CIE et TCN, il est respectivement recommandé les lois normale ou Skewnormale ($R^2 = 0,97$, une $RMSE = 0,06$ et un $CRPS = 0,664$) et celle de Weibull ($R^2 = 0,984$, une $RMSE = 0,049$ et un $CRPS = 0,728$) pour l'ajustement de la distribution des données de puissances importées;
- concernant la prévision à court terme de la charge électrique de la CEB, l'utilisation du modèle ARIMA de Box & Jenkins nous donne au cours de sa validation une $RMSE = 34,9415$, une $MAPE = 0,09104$ et un $R^2 = 0,716$. Les réseaux de neurones artificiels présentent pour la validation, une $RMSE = 12,684$ et une $MAPE = 0,03263$. Le Processus Gaussien, grâce à ses performances de prévisions sur une base de données de taille réduite (pratiquement 1 mois dans notre cas d'étude) qui peut présenter des données manquantes nous donne avec le noyau MLP pour une configuration basée sur la charge des 24h passées pour la validation, une $RMSE = 13,64$ et une $MAPE = 0,14365$ sans mise à jour, et une $RMSE = 13,51$ et une $MAPE = 0,14399$ avec mise à jour.

A partir de ces résultats obtenus, nous remarquons que :

- les fonctions de distribution classiques ne sont pas bien adaptées à l'histogramme de fréquences des puissances générées par les sources externes de la CEB. Dans cette circonstance, l'utilisation du mélange Gaussien réduirait des erreurs d'ajustement non négligeables;

- le modèle ARIMA est limité par des variables exogènes prises en compte dans le processus de la modélisation de la charge électrique. Ce qui se traduit par ses mauvais indicateurs de performance. Ainsi, le modèle hybride constitué de la transformée en ondelettes et du modèle ARIMA réalise des exploits ces derniers temps en montrant de faibles erreurs de prévision qui pourront se rivaliser avec celles obtenues avec les méthodes du Machine Learning ;
- les ANNs présentent de meilleurs résultats de prévision. Toutefois, l'utilisation du modèle k-means pourrait améliorer les performances des ANNs à travers sa capacité de retrouver les patterns contenus dans les données grâce au clustering ;
- le Processus gaussien, sans ou avec mise à jour donne de meilleurs résultats de prévision. Malgré cela, les fortes valeurs de $PINAW$ et de $PICP$ traduisent un IC à 95% plus large. Cela entrainera des erreurs de prévision qui pourront engendrer des retombées au gestionnaire du réseau électrique. Dans le but de contribuer à améliorer cet IC , la transformée en ondelettes sera appliquée. De plus, le Processus Gaussien est utilisé pour la prévision multi-horizon de la charge électrique.

Dans le but d'avoir des modèles robustes de caractérisation des sources de production et de prévision de la demande en énergie électrique du réseau interconnecté de la CEB, nous avons proposé l'utilisation de :

- loi Skewnormale ou normale asymétrique pour l'ajustement de l'histogramme des distributions des puissances produites par la source de Nangbéto ;
- mélange Gaussien à 4 composantes pour ajuster l'histogramme des distributions des puissances importées auprès de VRA/CIE et TCN dont les paramètres de modèle sont estimés par l'algorithme E-M basé sur la théorie de Bayes ;
- modèle ondelettes/ARIMA issue du 4^{ème} niveau de décomposition avec Daubechies d'ordre 3 (db3) comme ondelette mère pour prédire à court terme la charge électrique de la CEB. Les critères de performance comme la $RMSE$, $MAPE$ et le R^2 utilisés pour valider le modèle hybride proposé nous donne respectivement 4,082, 0,0095 et 0,9904 ;
- modèle hybride k-means/ANNs constitué de deux sous modèles hybrides (pour les jours ouvrables et non) pour prédire à court terme la charge électrique de la CEB avec des ($RMSE$ et $MAPE$) respectivement égales à (9,944 et 0,02856) et (12,851 et 0,03341). Pour la validation des modèles hybrides proposés, les erreurs pondérées $RMSE$ et $MAPE$ sont calculées. On obtient

une $RMSE = 11,443$ et une $MAPE = 0,03105$;

- modèle ondelettes/GP avec un intervalle de confiance à 95% plus réduit montre de la prévision avec une $RMSE$ de 11,89 et une $MAPE$ de 0,03133.

Ces résultats obtenus comparés aux précédents nous permettent de recommander :

- la loi de distribution Skewnormale pour la caractérisation des sources internes de la CEB et le mélange Gaussien à quatre (04) composantes pour les sources externes ;
- les modèles hybrides comme ondelettes / ARIMA, ondelettes / Processus Gaussien et k-means clustering/ANNs pour la prévision à court terme de la charge électrique de la CEB.

Enfin, La minimisation à la fois des coûts d'énergie dans le réseau électrique et de l'émission de CO_2 due à la production d'énergie sont deux objectifs d'importances capitales d'un point de vue à la fois économique et environnemental. Aussi de nombreuses études ont été faites pour apporter des approches de solution à chacun de ces problèmes. Le travail dont nous avons rendu compte dans cette thèse porte sur la contribution à la conduite des réseaux électriques par optimisation des coûts et émissions de CO_2 dans les réseaux électriques. De plus, cette partie de la thèse applique l'outil de modélisation mathématique GAMS pour proposer des solutions optimales aux problèmes d'émission de CO_2 et des coûts dans les réseaux électriques. Nous avons fait une étude du réseau électrique et une revue sur les méthodes d'optimisation. Ce qui nous a permis de faire une formulation mathématique des problèmes d'optimisation des coûts d'électricité et des émissions de CO_2 . Nous avons ensuite appliqué la formulation obtenue pour optimiser un réseau IEEE 24 nœuds. Ces résultats sont assez satisfaisants notamment pour ce qui concerne l'optimisation de coûts de l'énergie électrique et de l'émission CO_2 .

Vue l'importance de la planification des réseaux électriques dans les pays en voie de développement qui ont encore une bonne partie de son avenir et de son réseau à construire, nous avons senti le besoin de développer un outil scientifique et informatique robuste qui servira à des fins professionnelles en aidant les Techniciens et Ingénieurs à une meilleure prise de décision dans l'étude et l'élaboration des projets de développement et de planification des réseaux électriques. Sur le plan éducatif, ce logiciel constitue un matériel didactique pour nos écoles d'ingénieur afin de réaliser des travaux pratiques dans les cours de planification des réseaux électriques et d'introduction au marché de l'électricité.

Cet outil informatique est un logiciel dénommé STCED développé sous Python 3.8 dans l'environnement Microsoft Windows 10. Le logiciel STCED offre une bonne prévision vis à vis des différents utilisateurs (Chercheurs, Ingénieurs, Techniciens, Etudiants, Planificateurs et Gestionnaires du Réseau Electrique) pour :

- l'analyse statistique des données électriques ;
- l'analyse par transformée en ondelettes de la charge électrique ;
- la caractérisation des sources électriques par des fonctions de distributions de Gauss, de Weibull, de Rayleigh, Exponentielle, Normale asymétrique et mélange Gaussien ;
- la caractérisation des charges électriques par une loi de probabilité ;
- la prédiction à 1h d'avance de la charge électrique par les modèles ARIMA, ANNs, GP avec ou sans mise à jour, ondelettes/ARIMA, k-means clustering / ANNs et ondelettes / GP, et à plusieurs heures d'avance avec le modèle ondelettes / GP ;
- l'optimisation à la fois le coût de l'électricité et d'empreinte carbone par programmation quadratique.

Le logiciel STCED qui n'est qu'à sa première version présente à ses utilisateurs un environnement de travail souple et convivial. Par la suite, il sera amélioré en intégrant d'autres fonctionnalités telles que la gestion et la planification optimisée des réseaux électriques et leurs évaluations technico-économiques et environnementales en temps réel, journalière, infra journalière ou à la minute à l'avance et infra horaire.

L'originalité du logiciel STCED réside dans le fait qu'il a intégré dans un seul outil, les méthodes d'analyse, de modélisation des sources de production et de la demande en énergie électrique, d'optimisation du coût de l'électricité et d'émission du CO₂.

Tous les travaux que nous avons réalisés dans cette thèse se situent dans le cadre de la recherche appliquée au développement qui vise l'élaboration d'un outil pour une gestion optimale des réseaux électriques interconnectés avec une forte pénétration importante des énergies renouvelables.

Ce logiciel constitue pour les utilisateurs potentiels (GRT, Planificateurs, Bureaux d'études, Chercheurs, Ingénieurs, Techniciens, Etudiants), un puissant outil d'aide à la décision pour la planification des réseaux électriques. Toutefois, il convient de noter que les résultats peuvent être améliorés. Ainsi, comme perspectives de ce travail, nous faisons les recommandations suivantes.

Au niveau de la caractérisation :

- la prise en compte d'autres variables comme la température et l'humidité influent sur la production électrique ;
- l'utilisation des mélanges de distributions différentes ;
- l'utilisation des approches non paramétriques ;
- l'utilisation des méthodes du Machine Learning.

Concernant la prévision :

- élargir le pas de la prédiction de la charge électrique par les réseaux de neurone artificiels ;
- faire une classification en tenant compte de la similitude des pointe et creux ;
- utiliser d'autres types de réseaux de neurones artificiels comme les réseaux récurrents et ou réseau de neurones à convolution pour prédire plusieurs pas en avant ;
- utiliser d'autres modèles de Machine Learning ;
- augmenter la quantité de données en appliquant la méthode de régression par Processus Gaussien clairsemée ;
- étudier les composantes tendancielle, saisonnières et périodiques de la charge électrique en composant plusieurs noyaux ;
- faire une étude sur les facteurs qui influent la charge électrique tels que le prix de l'électricité, l'indice du développement d'un pays, surtout la température et l'humidité et les utiliser dans la modélisation de la charge électrique.

En ce qui concerne l'optimisation :

- faire une étude comparative entre l'optimisation par GAMS et les méthodes stochastiques ou d'intelligence artificielle ;
- combiner les deux problèmes ensemble sous forme de problème multicritère en vue d'obtenir un réseau plus optimisé ;
- faire une application sur un réseau réel ;
- tester aussi les modèles fondés sur les outils de l'apprentissage par renforcement.

Bibliographie

- [1] Z. Zhongming, L. Linong, Z. Wangqiang, L. Wei, and Others, “Tracking SDG7 : The Energy Progress Report 2020,” 2020.
- [2] B. X. Lee, F. Kjaerulf, S. Turner, L. Cohen, P. D. Donnelly, R. Muggah, R. Davis, A. Realini, B. Kieselbach, L. S. MacGregor, and Others, “Transforming our world : implementing the 2030 agenda through sustainable development goal indicators,” *Journal of public health policy*, vol. 37, no. 1, pp. 13–31, 2016.
- [3] Y. Bokovi, “Planification optimale des réseaux électriques haute tension par les algorithmes génétiques avec insertion des sources d’énergie électrique renouvelables,” Ph.D. dissertation, Sciences de l’Ingénieur de Université de Lomé, Option : Génie Electrique. Soutenue le jeudi 19 décembre 2013.
- [4] D. Burpee, H. Dabaghi, L. Jackson, F. Kwamena, J. Richter, T. Rusnov, K. Friedman, L. Mansueti, and D. Meyer, “Us-canada power system outage task force : final report on the implementation of task force recommendations,” 2006.
- [5] “Le Bénin et le Togo en panne de courant électrique,” consulté le 21 janvier 2020. [Online]. Available : https://www.afrik.com/le-benin-et-le-togo-en-panne-de-courant-electrique?__cf_chl_f_tk=wYrJaW9AHU2S69t.PE33ytBPzJkLme.hCrVJGbkIVrw-1642399932-0-gaNycGzNCdE
- [6] A. A. Salami, “Modélisation du vent à partir des méthodes d’analyse de données imparfaites : étude et réalisation d’un outil d’aide à la décision pour la caractérisation du potentiel éolien, La prédiction de vitesses du vent et l’optimisation du Dimensionnement des aérogénérateurs,” Ph.D. dissertation, Université de Lomé, Option : Génie Electrique. Soutenue en 2008.
- [7] P. A. Trotter, M. C. McManus, and R. Maconachie, “Electricity planning and implementation in sub-Saharan Africa : A systematic review,” *Renewable and Sustainable Energy Reviews*, vol. 74, pp. 1189–1209, 2017.

- [8] M. Farzadi, F. N. Heris, F. M. Shahir, and A. Sedighmanesh, “The role of the intelligent reconfiguration of distribution network on reduction the energy not supplied costs in the electricity market through case studies using softwares NEPLAN & DIgSILENT Power Factory,” in *2015 9th International Conference on Electrical and Electronics Engineering (ELECO)*. IEEE, 2015, pp. 445–447.
- [9] Y. S. Brar, J. S. Randhawa, and Others, “Optimal power flow using power world simulator,” in *2010 iee electrical power & energy conference*. IEEE, 2010, pp. 1–6.
- [10] R. Franco-Manrique, E. Gómez-Luna, and C. A. Ramos-Sánchez, “Smart grid analysis and management in Colombia towards ETAP Real Time solution.” *Ingeniare. Revista chilena de ingeniería*, vol. 26, no. 4, 2018.
- [11] L. Bam and W. Jewell, “Power system analysis software tools,” in *IEEE Power Engineering Society General Meeting, 2005*. IEEE, 2005, pp. 139–144.
- [12] “Analyse et planification strategique,” consulté le 21 janvier 2021. [Online]. Available : <https://www.ied-sa.com/solutions/planification.html>
- [13] K.-Y. Chen, “Combining linear and nonlinear model in forecasting tourism demand,” *Expert Systems with Applications*, vol. 38, no. 8, pp. 10 368–10 376, 2011.
- [14] N. Terui and H. K. Van Dijk, “Combined forecasts from linear and nonlinear time series models,” *International Journal of Forecasting*, vol. 18, no. 3, pp. 421–438, 2002.
- [15] J. Munkhammar, J. Rydén, and J. Widén, “Characterizing probability density distributions for household electricity load profiles from high-resolution electricity use data,” *Applied energy*, vol. 135, pp. 382–390, 2014.
- [16] R. Singh, B. C. Pal, and R. A. Jabr, “Statistical representation of distribution system loads using Gaussian mixture model,” *IEEE Transactions on Power Systems*, vol. 25, no. 1, pp. 29–37, 2009.
- [17] A. Guenoukpati, A. Salami, K. Koffi Mawugno, and K. Napo, “Statistical Characterization of Electric Power Production and Importation : Case Study of Benin Electricity Community (CEB),” 2019, pp. 1–6.
- [18] A. Guenoukpati, A. A. Salami, M. K. Kodjo, and K. Napo, “Short-Term Electricity Generation Forecasting Using Machine Learning Algorithms : A Case Study of the Benin Electricity Community (CEB),” *TH Wildau Engineering and Natural Sciences Proceedings*, vol. 1, 2021.

- [19] C. Edward, “Rasmussen and Christopher KI Williams. Gaussian processes for machine learning,” *MIT Press*, vol. 211, p. 212, 2006.
- [20] I. Ahmadianfar, M. Jamei, and X. Chu, “A novel Hybrid Wavelet-Locally Weighted Linear Regression (W-LWLR) Model for Electrical Conductivity (EC) Prediction in Surface Water,” *Journal of contaminant hydrology*, vol. 232, p. 103641, 2020.
- [21] S. Singh, K. S. Parmar, J. Kumar, and S. J. S. Makkhan, “Development of new hybrid model of discrete wavelet decomposition and autoregressive integrated moving average (ARIMA) models in application to one month forecast the casualties cases of COVID-19,” *Chaos, Solitons & Fractals*, vol. 135, p. 109866, 2020.
- [22] F.-M. Tseng, G.-H. Tzeng, H.-C. Yu, and B. J. C. Yuan, “Fuzzy ARIMA model for forecasting the foreign exchange market,” *Fuzzy sets and systems*, vol. 118, no. 1, pp. 9–19, 2001.
- [23] S. Ismail and A. Shabri, “Time series forecasting using least square support vector machine for canadian lynx data,” *Jurnal Teknologi*, vol. 70, no. 5, 2014.
- [24] S. Bisgaard and M. Kulahci, *Time series analysis and forecasting by example*. John Wiley & Sons, 2011.
- [25] J. Jin and J. Kim, “Forecasting natural gas prices using wavelets, time series, and artificial neural networks,” *PloS one*, vol. 10, no. 11, p. e0142064, 2015.
- [26] Z. Tan, J. Zhang, J. Wang, and J. Xu, “Day-ahead electricity price forecasting using wavelet transform combined with ARIMA and GARCH models,” *Applied energy*, vol. 87, no. 11, pp. 3606–3610, 2010.
- [27] Y. Bokovi, S. Ajavon, M. Kodjo, A. Salami, and K. Bedja, “Planification optimisee des reseaux electriques par la methode des algorithmes genetiques avec prise en compte uniquement de l’insertion des sources d’energies electriques renouvelables (eolien, solaire photovoltaïque et hydroelectrique),” *Journal de la Recherche Scientifique de l’Université de Lomé*, vol. 14, no. 1, pp. 35–55, 2012.
- [28] S. R. Cherkaoui, “Méthodes heuristiques pour la recherche de configurations optimales d’un réseau électrique de distribution,” EPFL, Tech. Rep., 1992.
- [29] A. Soroudi, *Power system optimization modeling in GAMS*. Springer, 2017, vol. 78.
- [30] K. El Yassini, R. Zine, and M. Raïssouli, “Outils d’aide à la décision pour la planification des réseaux de distribution de l’énergie électrique,” *Revue Afri-*

- caïne de la Recherche en Informatique et Mathématiques Appliquées*, vol. Volume 13, pp. 105–118, 2010.
- [31] T. T. H. PHAM, “Influences De La Production Decentralisee Sur La Gestion Des Infrastructures Critiques Des Reseaux De Puissance,” Ph.D. dissertation, Institut National Polytechnique de Grenoble-INPG, 2006.
- [32] K. Gajowniczek and T. Z\kaskowski, “Two-stage electricity demand modeling using machine learning algorithms,” *Energies*, vol. 10, no. 10, p. 1547, 2017.
- [33] M. Goodwin and A. Yazidi, “A pattern recognition approach for peak prediction of electrical consumption,” in *IFIP International Conference on Artificial Intelligence Applications and Innovations*. Springer, 2014, pp. 265–275.
- [34] A. Goia, C. May, and G. Fusai, “Functional clustering and linear regression for peak load forecasting,” *International Journal of Forecasting*, vol. 26, no. 4, pp. 700–711, 2010.
- [35] R. J. Hyndman and S. Fan, “Density forecasting for long-term peak electricity demand,” *IEEE Transactions on Power Systems*, vol. 25, no. 2, pp. 1142–1153, 2009.
- [36] “World gross electricity production, by source, 2018,” consulté le 27 juillet 2021. [Online]. Available : <https://www.iea.org/data-and-statistics/charts/world-gross-electricity-production-by-source-2018#>
- [37] Ecomet, “Les ressources énergétiques non renouvelables,” consulté le 27 juillet 2021. [Online]. Available : http://www.ecomet.fr/V32b_ressources_non_renouvelables.html
- [38] “Les ressources énergétiques renouvelables,” consulté le 27 juillet 2021. [Online]. Available : http://www.ecomet.fr/V32a_ressources_renouvelables.html
- [39] Ddmagazine, “Plus de 60% de rendement pour une centrale électrique!” consulté le 27 juillet 2021. [Online]. Available : <https://www.sortirdunucleaire.org/Plus-de-60-de-rendement-pour-une>
- [40] S. S. Reddy, “Optimal power flow with renewable energy resources including storage,” *Electrical Engineering*, vol. 99, no. 2, pp. 685–695, 2017.
- [41] R. Bharathi, M. J. Kumar, D. Sunitha, and S. Premalatha, “Optimization of combined economic and emission dispatch problem—A comparative study,” in *2007 International Power Engineering Conference (IPEC 2007)*. IEEE, 2007, pp. 134–139.

- [42] M. A. Mac Kinnon, J. Brouwer, and S. Samuelsen, “The role of natural gas and its infrastructure in mitigating greenhouse gas emissions, improving regional air quality, and renewable resource integration,” *Progress in Energy and Combustion science*, vol. 64, pp. 62–92, 2018.
- [43] N. S. Perabi, I. A. Moukengue, E. S. Ndjakomo, and O. G. Abessolo, “Résolution du problème d’engagement d’unités de production d’énergie électrique, de dispatching économique et environnemental sélectif par la méthode des couloirs d’observations,” *Afrique Science : Revue Internationale des Sciences et Technologie*, vol. 11, no. 1, pp. 74–85, 2015.
- [44] A. A. El-Keib, H. Ma, and J. L. Hart, “Economic dispatch in view of the clean air act of 1990,” *IEEE Transactions on Power Systems*, vol. 9, no. 2, pp. 972–978, 1994.
- [45] J.-M. Percebois, “Le guide du chauffage Géothermique,” 2011, consulté le 27 juillet 2021. [Online]. Available : <https://www.leguiteduchauffage.com/>
- [46] S. Kus, “De Tchernobyl à Fukushima, 25 ans d’évolution du droit nucléaire international et après...,” *Bulletin de droit nucléaire*, vol. 2011, no. 1, pp. 7–29, 2011.
- [47] A. A. Salami, A. S. A. Ajavon, K. M. Kodjo, and K.-S. Bedja, “Supercapacitors modeling and simulation in MATLAB/SIMULINK : studying the influence of model elements on the duration of self-discharge,” *Caspian Journal Management and High Technologies*, no. 3, pp. 42–58, 2016.
- [48] A. Guenoukpati, A. A. Salami, M. K. Kodjo, and K. Napo, “Estimating Weibull Parameters for Wind Energy Applications Using Seven Numerical Methods : Case studies of Three Coastal Sites in West Africa.” *International Journal of Renewable Energy Development*, vol. 9, no. 2, 2020.
- [49] “En théorie, 10.000 kilomètres carrés dans le Sahara pourraient fournir toute l’électricité dont le monde a besoin,” p. 2, 2020, consulté le 15 mars 2022. [Online]. Available : <https://www.transitionsenergies.com/sahara-solaire-electricite-monde/>
- [50] D. Mackay, *Sustainable Energy—Without the Hot Air Sustainable Energy—Without the Hot Air*. UIT cambridge, 2010, vol. 78, no. 2, consulté le 15 mars 2022. [Online]. Available : www.withouthotair.com.
- [51] M. Nasser, “Supervision de sources de production d’électricité hybrides éolien/hydraulique dans les réseaux d’énergie interconnectés ou isolés,” Ph.D. dissertation, Arts et Métiers ParisTech, 2011.

- [52] C. Dumbs, “Développement d’outils pour l’analyse des systèmes hybrides photovoltaïque-diesel,” Ph.D. dissertation, ENSMP, 1999.
- [53] C. Voyant, “Prédiction de séries temporelles de rayonnement solaire global et de production d’énergie photovoltaïque à partir de réseaux de neurones artificiels,” Ph.D. dissertation, Université Pascal Paoli, 2011.
- [54] M. P. Kazmierkowski, “Renewable Energy Devices and Systems with Simulations in MATLAB and ANSYS [Book News],” *IEEE Industrial Electronics Magazine*, vol. 12, no. 2, pp. 80–83, 2018.
- [55] F. A. L. Jowder, “Wind power analysis and site matching of wind turbine generators in Kingdom of Bahrain,” *Applied Energy*, vol. 86, no. 4, pp. 538–545, 2009.
- [56] M. K. Kodjo, K. Bedja, A. S. A. Ajavon, and A. A. Salami, “Modélisation de la conversion électromécanique des machines électriques tournantes sous Simulink,” *Journal de la Recherche Scientifique de l’Université de Lomé*, vol. 7, no. 1, 2005.
- [57] L. Thiaw, G. Sow, P. Ndiaye, G. Sissoko, S. Fall, and K. Tall, “Modélisation et évaluation du potentiel éolien : méthodologie de traitement et d’analyse des données de vitesses du vent,” *Journal des sciences pour l’Ingénieur*, no. 2, pp. 23–27, 2002.
- [58] O. Gergaud, “Modélisation énergétique et optimisation économique d’un système de production éolien et photovoltaïque couplé au réseau et associé à un accumulateur,” Ph.D. dissertation, École normale supérieure de Cachan-ENS Cachan, 2002.
- [59] D. Le Gourières and D. Legourieres, *Énergie éolienne : Théorie, conception et calcul pratique des installations*. Eyrolles, 1980.
- [60] B. Multon, J. Seigneurbieux, M. Ruellan, and H. B. Ahmed, “Energie et développement durable,” *l’ENSET/ENS de Cachan*, 2006.
- [61] C.-L. Chen, T.-Y. Lee, and R.-M. Jan, “Optimal wind-thermal coordination dispatch in isolated power systems with large integration of wind capacity,” *Energy conversion and management*, vol. 47, no. 18-19, pp. 3456–3472, 2006.
- [62] A. Guenoukpati, A. A. Salami, M. K. Kodjo, K. A. Dotche, and K. Bedja, “Computational method for the charging time of supercapacitors,” in *2017 IEEE PES PowerAfrica*. IEEE, 2017, pp. 186–191.
- [63] J.-c. Kaltenbach, J. Peschon, and E. H. Gehrig, “A mathematical optimization technique for the expansion of electric power transmission systems,” *IEEE Transactions on Power Apparatus and Systems*, no. 1, pp. 113–119, 1970.

- [64] E. Gladkikh, “Optimisation de l’architecture des réseaux de distribution d’énergie électrique,” Ph.D. dissertation, Université Grenoble Alpes, 2015.
- [65] B. Berseneff, “Réglage de la tension dans les réseaux de distribution du futur,” Ph.D. dissertation, Université de Grenoble, 2010.
- [66] O. Richardot, “Réglage Coordonné de Tension dans les Réseaux de Distribution à l’aide de la Production Décentralisée,” Ph.D. dissertation, Institut National Polytechnique de Grenoble-INPG, 2006.
- [67] S. Touré, “Optimisation des réseaux : réseau actif et flexible,” Ph.D. dissertation, Université de Grenoble, 2014.
- [68] M. P. Kerur and R. L. Chakrasali, “Shortest Power Flow Paths in Deregulated Scenario Using Graph Theory,” *International Journal of Advanced Science and Engineering*, vol. 6, pp. 1272–1277, 2019.
- [69] M. P. Kerur and R. Chakrasali, “Graph Theory Algorithm to Find Minimum Cost Power Flow Path in Deregulated Scenario under Line Outage Contingency,” pp. 755–761, 2020.
- [70] A. Stasiakowska, “Le marché intérieur d’électricité. Entre la libéralisation et la sécurité d’approvisionnement en électricité,” 2009.
- [71] M. Saguan and O. Sautel, “L’ouverture à la concurrence du secteur électrique : rôle et gains du client,” *Flux*, vol. n° 84, p. 8, 2011.
- [72] S. Hunt, *Making competition work in electricity*. John Wiley & Sons, 2002, vol. 146.
- [73] L. A. Barroso, T. H. Cavalcanti, P. Giesbertz, and K. Purchala, “Classification of electricity market models worldwide,” in *International Symposium CIGRE/IEEE PES, 2005*. IEEE, 2005, pp. 9–16.
- [74] N. Li, “Stakeholder Behaviours and Grid-Source Coordinated Planning Mode under Market Circumstance,” in *IOP Conference Series : Earth and Environmental Science*, vol. 634, no. 1. IOP Publishing, 2021, p. 12062.
- [75] S. H. Zeng M, “Research on the coordinated planning of renewable and traditional power sources under the cross regional electricity trading environment,” *Water Resources and Power*, vol. 4, no. 32, pp. 199–203, 2014.
- [76] N. Li, F. Zhang, and J. Feng, “Study on Power System Planning Modes under Market Environment at Home and Abroad,” in *IOP Conference Series : Earth and Environmental Science*, vol. 634, no. 1. IOP Publishing, 2021, p. 12079.
- [77] W. Wei, M. Yi, Y. Feng, and X. Lei, “Application of individual differences ant colony algorithm in transmission network expansion planning,” in *2011*

- International Conference on Electric Information and Control Engineering*. IEEE, 2011, pp. 4798–4802.
- [78] L. Ogunwolu, O. Ero, and O. Ibidapo-Obe, “Modeling and optimization of an electric power distribution network planning system using mixed binary integer programming,” *Nigerian Journal of Technology*, vol. 36, no. 2, pp. 552–562, 2017.
- [79] R. E. Bohn, M. C. Caramanis, and F. C. Schweppe, “Optimal pricing in electrical networks over space and time,” *The Rand Journal of Economics*, pp. 360–376, 1984.
- [80] S.-K. Chai and A. Sekar, “Graph theory application to deregulated power system,” 2001, pp. 117–121.
- [81] J. Dipama, “Optimisation multi-objectif des systèmes énergétiques,” Ph.D. dissertation, École Polytechnique de Montréal, 2010.
- [82] T. Sueyoshi and M. Goto, “Can environmental investment and expenditure enhance financial performance of US electric utility firms under the clean air act amendment of 1990?” *Energy Policy*, vol. 37, no. 11, pp. 4819–4826, 2009.
- [83] J. Di, T. Chen, and Y. Hou, “Review of transmission network planning in market environment,” in *2013 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC)*. IEEE, 2013, pp. 1–5.
- [84] C. Shiguang, L. Zhuo, and Y. Erkeng, “Research on outage cost and reliability planning,” *Power system technology*, vol. 9, 1997.
- [85] M. T. Schillinn and A. M. Silva, “Bibliography on power system probabilistic analysis,” *IEEE Trans on Power Systems*, vol. 5, no. 4, pp. 1047–1053, 1990.
- [86] H.-z. Cheng, H.-f. Zhu, J.-m. Wang, C. L. Chen, L. F. Fang, and F. Q. Jiang, “Electric power networks flexible planning via the blind model (BM) of unascertained number,” *Journal-Shanghai Jiaotong University-Chinese Edition-*, vol. 37, no. 9, pp. 1347–1350, 2003.
- [87] H.-Z. Jin, H.-Z. Cheng, D.-J. Zeng, and L.-T. Teng, “Novel method of flexible transmission network planning based on set pair analysis,” vol. 26, pp. 7–12, 2006.
- [88] H.-z. Cheng, H.-f. Zhu, Z.-l. Ma, Z.-l. ZHU, and J. XU, “A novel method of electric power network flexible planning based on the equal incremental principle,” *Journal-Shanghai Jiaotong University-Chinese Edition-*, vol. 37, no. 9, pp. 1351–1354, 2003.
- [89] Z. Hongming and L. Peihong, “A Grey Optimization Model of Transmission Network Expansion,” *Journal of Shanghai Jiaotong University*, vol. 3, 1995.

- [90] A. Seppälä, *Load research and load estimation in electricity distribution*. Technical Research Centre of Finland, 1996.
- [91] M. Shukla and G. Radman, "Optimal power flow using probabilistic load model," in *Proceedings of the Thirty-Seventh Southeastern Symposium on System Theory, 2005. SSST'05*. IEEE, 2005, pp. 439–442.
- [92] S. Conti and S. Raiti, "Probabilistic load flow for distribution networks with photovoltaic generators part 1 : Theoretical concepts and models," in *2007 International Conference on Clean Electrical Power*. IEEE, 2007, pp. 132–136.
- [93] S. H. Karaki, R. B. Chedid, and R. Ramadan, "Probabilistic performance assessment of autonomous solar-wind energy conversion systems," *IEEE Transactions on energy conversion*, vol. 14, no. 3, pp. 766–772, 1999.
- [94] B. R. Prusty and D. Jena, "Modeling of correlated photovoltaic generations and load demands in probabilistic load flow," in *2015 Annual IEEE India Conference (INDICON)*. IEEE, 2015, pp. 1–6.
- [95] T. Zhang, X. Song, X. Meng, J. Yu, and X. Chen, "A probabilistic load model based on chi-square method for distribution network," 2013.
- [96] M. Svensén and C. M. Bishop, "Pattern recognition and machine learning," 2007.
- [97] Z. Zhang, C. Chen, J. Sun, and K. L. Chan, "EM algorithms for Gaussian mixtures with split-and-merge operation," *Pattern recognition*, vol. 36, no. 9, pp. 1973–1983, 2003.
- [98] N. Ueda, R. Nakano, Z. Ghahramani, and G. E. Hinton, "Split and merge EM algorithm for improving Gaussian mixture density estimates," *Journal of VLSI signal processing systems for signal, image and video technology*, vol. 26, no. 1, pp. 133–140, 2000.
- [99] E. Romero and D. Toppo, "Comparing support vector machines and feedforward neural networks with similar hidden-layer weights," *IEEE Transactions on Neural Networks*, vol. 18, no. 3, pp. 959–963, 2007.
- [100] R. Lippmann, "Book Review : " Neural Networks, A Comprehensive Foundation", by Simon Haykin," *International Journal of Neural Systems*, vol. 5, no. 04, pp. 363–364, 1994.
- [101] H. Drucker, C. J. C. Burges, L. Kaufman, A. Smola, V. Vapnik, and Others, "Support vector regression machines," *Advances in neural information processing systems*, vol. 9, pp. 155–161, 1997.

- [102] M. T. Cao, T. T. Pham, T. C. Kuo, D. M. Bui, H. V. Nguyen, and T. H. Nguyen, "Short-Term Load Forecasting Enhanced With Statistical Data-Filtering Method," in *2020 IEEE International Conference on Power Electronics, Smart Grid and Renewable Energy (PESGRE2020)*. IEEE, 2020, pp. 1–8.
- [103] D. Palchak, "Energy management of a university campus utilizing short-term load forecasting with an artificial neural network," Ph.D. dissertation, Colorado State University, 2012.
- [104] B. F. Hobbs, S. Jitprapaikulsarn, S. Konda, V. Chankong, K. A. Loparo, and D. J. Maratukulam, "Analysis of the value for unit commitment of improved load forecasts," *IEEE Transactions on Power Systems*, vol. 14, no. 4, pp. 1342–1348, 1999.
- [105] M. A. Hammad, B. Jereb, B. Rosi, D. Dragan, and Others, "Methods and models for electric load forecasting : A comprehensive review," *Logist. Sustain. Transp*, vol. 11, no. 1, pp. 51–76, 2020.
- [106] A. A. Salami, A. S. A. Ajavon, K. A. Dotche, and K.-S. Bedja, "Electrical load forecasting using artificial neural network : The case study of the grid inter-connected network of benin electricity community (CEB)," *Am. J. Eng. Appl. Sci*, vol. 11, no. 2, pp. 471–481, 2018.
- [107] M. Blum and M. Riedmiller, "Electricity demand forecasting using gaussian processes," in *Workshops at the Twenty-Seventh AAAI Conference on Artificial Intelligence*. Citeseer, 2013.
- [108] C. Adjamagbo, P. Ngae, A. Vianou, and V. Vigneron, "Modélisation de la demande en énergie électrique au Togo," *Journal of Renewable Energies*, vol. 14, no. 1, pp. 67–83, 2011.
- [109] B. A. Swastanto, "Gaussian process regression for long-term time series forecasting," 2016.
- [110] Y.-Y. Hsu and C.-C. Yang, "Electrical load forecasting," in *Applications of Neural Networks*. Springer, 1995, pp. 157–189.
- [111] G. Sudheer and A. Suseelatha, "Short term load forecasting using wavelet transform combined with Holt–Winters and weighted nearest neighbor models," *International Journal of Electrical Power & Energy Systems*, vol. 64, pp. 340–346, 2015.
- [112] X. Kong, C. Li, C. Wang, Y. Zhang, and J. Zhang, "Short-term electrical load forecasting based on error correction using dynamic mode decomposition," *Applied Energy*, vol. 261, p. 114368, 2020.

- [113] K. Y. Lee, Y. T. Cha, and J. H. Park, "Short-term load forecasting using an artificial neural network," *IEEE transactions on power systems*, vol. 7, no. 1, pp. 124–132, 1992.
- [114] M. Q. Raza and A. Khosravi, "A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings," *Renewable and Sustainable Energy Reviews*, vol. 50, pp. 1352–1372, 2015.
- [115] J. V. Ringwood, D. Bofelli, and F. T. Murray, "Forecasting electricity demand on short, medium and long time scales using neural networks," *Journal of Intelligent and Robotic Systems*, vol. 31, no. 1, pp. 129–147, 2001.
- [116] D. Duvenaud, "Automatic model construction with Gaussian processes," Ph.D. dissertation, University of Cambridge, 2014.
- [117] D. Bunn and E. D. Farmer, "Comparative models for electrical load forecasting," 1985.
- [118] S. Tatsa, "Modélisation et prévision de la consommation horaire d'électricité au Québec : comparaison de méthodes de séries temporelles," 2014.
- [119] G. Pełka Paweł and Dudek, "Pattern-based forecasting monthly electricity demand using multilayer perceptron," in *International Conference on Artificial Intelligence and Soft Computing*. Springer, 2019, pp. 663–672.
- [120] I. Moghram and S. Rahman, "Analysis and evaluation of five short-term load forecasting techniques," *IEEE Transactions on power systems*, vol. 4, no. 4, pp. 1484–1491, 1989.
- [121] T. Hong, M. Gui, M. E. Baran, and H. L. Willis, "Modeling and forecasting hourly electric load by multiple linear regression with interactions," in *Ieee pes general meeting*. IEEE, 2010, pp. 1–8.
- [122] B. Dhaval and A. Deshpande, "Short-term load forecasting with using multiple linear regression," *International Journal of Electrical and Computer Engineering*, vol. 10, no. 4, p. 3911, 2020.
- [123] O. Hyde and P. F. Hodnett, "An adaptable automated procedure for short-term electricity load forecasting," *IEEE Transactions on Power Systems*, vol. 12, no. 1, pp. 84–94, 1997.
- [124] R.-J. Park, K.-B. Song, and B.-S. Kwon, "Short-term load forecasting algorithm using a similar day selection method based on reinforcement learning," *Energies*, vol. 13, no. 10, p. 2640, 2020.
- [125] H. M. Al-Hamadi and S. A. Soliman, "Short-term electric load forecasting based on Kalman filtering algorithm with moving window weather and load model," *Electric power systems research*, vol. 68, no. 1, pp. 47–59, 2004.

- [126] F. Song, J. Liu, T. Zhang, J. Guo, S. Tian, and D. Xiong, "The Grey Forecasting Model for the Medium-and Long-Term Load Forecasting," in *Journal of Physics : Conference Series*, vol. 1654, no. 1. IOP Publishing, 2020, p. 12104.
- [127] M. Aiolfi and A. Timmermann, "Persistence in forecasting performance and conditional combination strategies," *Journal of Econometrics*, vol. 135, no. 1-2, pp. 31–53, 2006.
- [128] N. Amjady, "Short-term hourly load forecasting using time-series modeling with peak load estimation capability," *IEEE Transactions on power systems*, vol. 16, no. 3, pp. 498–505, 2001.
- [129] B. Nepal, M. Yamaha, A. Yokoe, and T. Yamaji, "Electricity load forecasting using clustering and ARIMA model for energy management in buildings," *Japan Architectural Review*, vol. 3, no. 1, pp. 62–76, 2020.
- [130] Y. Man, Y. Hu, and J. Ren, "Forecasting COD load in municipal sewage based on ARMA and VAR algorithms," *Resources, Conservation and Recycling*, vol. 144, pp. 56–64, 2019.
- [131] E. H. Barakat, J. M. Al-Qassim, and S. A. Al Rashed, "New model for peak demand forecasting applied to highly complex load characteristics of a fast developing area," in *IEE Proceedings C (Generation, Transmission and Distribution)*, vol. 139, no. 2. IET, 1992, pp. 136–140.
- [132] A. A. El-Keib, X. Ma, and H. Ma, "Advancement of statistical based modeling techniques for short-term load forecasting," *Electric Power Systems Research*, vol. 35, no. 1, pp. 51–58, 1995.
- [133] G. A. N. Mbamalu and M. E. El-Hawary, "Load forecasting via suboptimal seasonal autoregressive models and iteratively reweighted least squares estimation," *IEEE Transactions on Power Systems*, vol. 8, no. 1, pp. 343–348, 1993.
- [134] Š. Svoboda, "Short-term electricity price forecasting-evaluation of selected hybrid models," 2017.
- [135] Y. Aragon, *Séries temporelles avec R*. EDP sciences, 2021.
- [136] Z. S. Elrazaz and A. A. Mazi, "Unified weekly peak load forecasting for fast growing power system," in *IEE Proceedings C (Generation, Transmission and Distribution)*, vol. 136, no. 1. IET, 1989, pp. 29–34.
- [137] G. Juberias, R. Yunta, J. G. Moreno, and C. Mendivil, "A new ARIMA model for hourly load forecasting," in *1999 IEEE Transmission and Distribution Conference (Cat. No. 99CH36333)*, vol. 1. IEEE, 1999, pp. 314–319.

- [138] A. Mosavi, M. Salimi, S. Faizollahzadeh Ardabili, T. Rabczuk, S. Shamshirband, and A. R. Varkonyi-Koczy, “State of the art of machine learning models in energy systems, a systematic review,” *Energies*, vol. 12, no. 7, p. 1301, 2019.
- [139] C.-A. Azencott, *Introduction au machine learning*. Dunod, 2019.
- [140] L. Guo, J. Chen, F. Wu, and M. Wang, “An electric power generation forecasting method using support vector machine,” *Systems Science & Control Engineering*, vol. 6, no. 3, pp. 191–199, 2018.
- [141] B. Liu, *Web data mining : exploring hyperlinks, contents, and usage data*. Springer, 2011, vol. 1.
- [142] T. Hastie, “Robert Tibshirani and Jerome Friedman,” *The elements of statistical learning : data mining, inference, and prediction*, vol. 2, 2001.
- [143] R. Veysseyre, “Aide-mémoire Statistique et probabilités pour l’ingénieur, Dunod, 2006,” *Détection CFCAR en Milieux Non-Gaussiens Corrélés*.
- [144] A. El Attar, “Estimation robuste des modeles de melange sur des donnees distribuees,” Ph.D. dissertation, Université de Nantes, 2012.
- [145] G. Celeux and G. Govaert, “A classification EM algorithm for clustering and two stochastic versions,” *Computational statistics & Data analysis*, vol. 14, no. 3, pp. 315–332, 1992.
- [146] R. M. Neal and G. E. Hinton, “A view of the EM algorithm that justifies incremental, sparse, and other variants,” in *Learning in graphical models*. Springer, 1998, pp. 355–368.
- [147] C. K. I. Williams and M. A. Arbib, “Handbook of brain theory and neural networks,” 2002.
- [148] A. Apicella, F. Donnarumma, F. Isgrò, and R. Prevete, “A survey on modern trainable activation functions,” *Neural Networks*, 2021.
- [149] J. F. Coates, “Forecasting and planning today plus or minus twenty years,” *Technological Forecasting and Social Change*, vol. 36, no. 1-2, pp. 15–20, 1989.
- [150] A. Draïdi and D. Labeled, “Répartition optimale des puissances utilisant les techniques de l’intelligence artificielle,” Ph.D. dissertation, University of Constantine 3, 2016.
- [151] A. K. Singh, S. Khatoon, M. Muazzam, D. K. Chaturvedi, and Others, “Load forecasting techniques and methodologies : A review,” in *2012 2nd International Conference on Power, Control and Embedded Systems*. IEEE, 2012, pp. 1–10.

- [152] C. Xia, J. Wang, and K. McMenemy, “Short, medium and long term load forecasting model and virtual load forecaster based on radial basis function neural networks,” *International Journal of Electrical Power & Energy Systems*, vol. 32, no. 7, pp. 743–750, 2010.
- [153] Z. Bingyu, L. I. U. Bo, and W. Dan, “Clustering analysis of user power interaction behavior based on self-organizing center K-means algorithm,” *Electric Power Construction*, vol. 40, no. 1, pp. 68–76, 2019.
- [154] F. M. Khan and R. Gupta, “ARIMA and NAR based prediction model for time series analysis of COVID-19 cases in India,” *Journal of Safety Science and Resilience*, vol. 1, no. 1, pp. 12–18, 2020.
- [155] J. S. Erkelens, A. Tejada, and J. Arnold, “Identification of Time Series Models From Segments—Application to Scanning Transmission Electron Microscopy Images,” *IEEE Transactions on Instrumentation and Measurement*, vol. 62, no. 12, pp. 3231–3242, 2013.
- [156] Z.-Z. Long, G. Xu, J. Du, H. Zhu, T. Yan, and Y.-F. Yu, “Flexible Subspace Clustering : A Joint Feature Selection and K-Means Clustering Framework,” *Big Data Research*, vol. 23, p. 100170, 2021.
- [157] A. J. R. Reis and A. P. A. Da Silva, “Feature extraction via multiresolution analysis for short-term load forecasting,” *IEEE Transactions on power systems*, vol. 20, no. 1, pp. 189–198, 2005.
- [158] L. Xue and W. Luan, “Improved K-means algorithm in user behavior analysis,” in *2015 Ninth International Conference on Frontier of Computer Science and Technology*. IEEE, 2015, pp. 339–342.
- [159] K. Soni, K. S. Parmar, S. Kapoor, and N. Kumar, “Statistical variability comparison in MODIS and AERONET derived aerosol optical depth over Indo-Gangetic Plains using time series modeling,” *Science of the Total Environment*, vol. 553, pp. 258–265, 2016.
- [160] J.-P. Benzécri and Others, *L’analyse des données*. Dunod Paris, 1973, vol. 2.
- [161] M. CHEIN, “L’intelligence artificielle? Un domaine de la science informatique,” *Bull. Acad. Sc. Lett. Montp*, vol. 50, 2019.
- [162] P. S. Addison, *The illustrated wavelet transform handbook : introductory theory and applications in science, engineering, medicine and finance*. CRC press, 2017.
- [163] W. Ma, S. Fang, G. Liu, and R. Zhou, “Modeling of district load forecasting for distributed energy system,” *Applied Energy*, vol. 204, pp. 181–205, 2017.

- [164] N. Chen, Z. Qian, and X. Meng, “Multistep wind speed forecasting based on wavelet and gaussian processes,” *Mathematical Problems in Engineering*, vol. 2013, 2013.
- [165] R. M. Nezzar, N. Farah, M. T. Khadir, and L. Chouireb, “Mid-long term load forecasting using multi-model artificial neural networks,” *International Journal on Electrical Engineering and Informatics*, vol. 8, no. 2, p. 389, 2016.
- [166] K. P. Murphy, *Machine learning : a probabilistic perspective*. MIT press, 2012.
- [167] I. Committee and Others, “International Performance Measurement and Verification Protocol : Concepts and options for determining energy and water savings, Volume I,” National Renewable Energy Lab., Golden, CO (US), Tech. Rep., 2001.
- [168] H. Carstens, X. Xia, and S. Yadavalli, “Bayesian energy measurement and verification analysis,” *Energies*, vol. 11, no. 2, p. 380, 2018.
- [169] M. Farooq and A. Salhi, “Improving the solvability of ill-conditioned systems of linear equations by reducing the condition number of their matrices,” *Journal of the Korean Mathematical Society*, vol. 48, no. 5, pp. 939–952, 2011.
- [170] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, and Others, “Scikit-learn : Machine learning in Python,” *the Journal of machine Learning research*, vol. 12, pp. 2825–2830, 2011.
- [171] N. Dkhili, S. Thil, J. Eynard, and S. Grieu, “Comparative study between Gaussian process regression and long short-term memory neural networks for intraday grid load forecasting,” in *2020 IEEE International Conference on Environment and Electrical Engineering and 2020 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe)*. IEEE, 2020, pp. 1–6.
- [172] M. Vanithasri, R. Balamurugan, and L. Lakshminarasimman, “Implementation of Radial Movement Optimization (RMO) algorithm for solving economic dispatch and fixed head hydrothermal generation scheduling,” in *Classical and Recent Aspects of Power System Optimization*. Elsevier, 2018, pp. 63–97.
- [173] F. Z. Gherbi and F. Lakdja, “Environmentally constrained economic dispatch via quadratic programming,” in *2011 International Conference on Communications, Computing and Control Applications (CCCA)*. IEEE, 2011, pp. 1–5.
- [174] A. Al-Qes, “Optimisation of run of river production forecasting using aiolos forecast studio,” *TVVRR20/5012*, 2020.

- [175] L. Anastasakis and N. Mort, “The development of self-organization techniques in modelling : a review of the group method of data handling (gmdh),” *Research report-university of sheffield department of automatic control and systems engineering*, 2001.
- [176] R. Mehra, “Group method of data handling (gmdh) : review and experience,” in *1977 IEEE conference on decision and control including the 16th symposium on adaptive processes and a special symposium on fuzzy set theory and applications*. IEEE, 1977, pp. 29–34.
- [177] J. Á. González Ordiano, S. Waczowicz, V. Hagenmeyer, and R. Mikut, “Energy forecasting tools and services,” *Wiley Interdisciplinary Reviews : Data Mining and Knowledge Discovery*, vol. 8, no. 2, p. e1235, 2018.
- [178] P.-N. Kouroupetroglou and G. Tsoumakas, “Machine learning techniques for short-term electric load forecasting,” *Thessaloniki. Aristotle University of Thessaloniki*, 2017.
- [179] N. Saleem, A. Akbar, A. R. Imon, and A. S. M. Al Mamun, “Time series analysis modeling and forecasting of gross domestic product of pakistan.”
- [180] P. A. Mohammed, S. A. Obed, I. M. Ali, and D. H. Kadir, “Us dollar/iq dinar currency exchange rates time series forecasting using arima model,” *Cihan University-Erbil Scientific Journal*, vol. 6, no. 1, pp. 12–19, 2022.
- [181] T. E. Salais-Fierro and J. A. S. Martínez, “Demand forecasting for freight transport applying machine learning into the logistic distribution,” *Mobile Networks and Applications*, pp. 1–10, 2022.
- [182] P. Denis and T. Cuvelier, *Créer des applications graphiques en Python avec PyQt5*. Éditions D-BookeR, 2017.
- [183] B. Prieur, *PyQt5-Développez vos interfaces graphiques en Python*. Éditions ENI, 2021.
- [184] Q. N. Islam, *Mastering PyCharm*. Packt Publishing Ltd, 2015.
- [185] R. D. Zimmerman, C. E. Murillo-Sánchez, and R. J. Thomas, “MATPOWER : Steady-state operations, planning, and analysis tools for power systems research and education,” *IEEE Transactions on power systems*, vol. 26, no. 1, pp. 12–19, 2010.
- [186] A. J. Conejo, M. Carrión, J. M. Morales, and Others, *Decision making under uncertainty in electricity markets*. Springer, 2010, vol. 1.
- [187] F. Bouffard, F. D. Galiana, and A. J. Conejo, “Market-clearing with stochastic security-part II : case studies,” *IEEE Transactions on Power Systems*, vol. 20, no. 4, pp. 1827–1835, 2005.

- [188] “Welcome to wind-turbine-models,” consulté le 15 mars 2022. [Online]. Available : <https://en.wind-turbine-models.com/turbines/339-ades-ades-200>
- [189] “Climate and Average Weather Year Round in Lome,” consulté le 15 mars 2020. [Online]. Available : <https://weatherspark.com/y/147894/Average-Weather-at-Lome-T1\textendashTokoin-Airport-Togo-Year-Round\Sections-Sun>

Annexes

Modèle Ondelettes-Processus Gaussien

```
import GPY
from GPY.kern import MLP
from GPY.models import GPRegression as gpr
dim = len(X_train.columns)
def Xy_trans(dset):
    X = dset.drop(dset.columns[0], axis=1)
    y = dset[dset.columns[0]]
    X = np.atleast_2d(X)
    y = np.atleast_2d(y).T
    return X, y
X_traind = X_train.index
X_testd = X_test.index
%%time
X_train_cA3, y_train_cA3 = Xy_trans(cA3_trainset)
m_cA3 = gpr(X=X_train_cA3, Y=y_train_cA3, kernel=MLP(input_dim=dim, variance=np.var(y_train_cA3)),
normalizer=True)
m_cA3.optimize(messages=True)
%%time
X_train_cD3, y_train_cD3 = Xy_trans(cD3_trainset)
m_cD3 = gpr(X=X_train_cD3, Y=y_train_cD3, kernel=MLP(input_dim=dim, variance=np.var(y_train_cD3)),
normalizer=True)
m_cD3.optimize(messages=True)
%%time
X_train_cD2, y_train_cD2 = Xy_trans(cD2_trainset)
m_cD2 = gpr(X=X_train_cD2, Y=y_train_cD2, kernel=MLP(input_dim=dim, variance=np.var(y_train_cD2)),
normalizer=True)
m_cD2.optimize(messages=True)
# prediction de cD2
cD2_pred, sigma_cD2 = m_cD2.predict(np.atleast_2d(X_test))
%%time
X_train_cD1, y_train_cD1 = Xy_trans(cD1_trainset)
m_cD1 = gpr(X=X_train_cD1, Y=y_train_cD1, kernel=MLP(input_dim=dim, variance=np.var(y_train_cD1)),
normalizer=True)
m_cD1.optimize(messages=True)
# prediction de cD1
cD1_pred, sigma_cD1 = m_cD1.predict(np.atleast_2d(X_test))
# reconstitution de la charge
coef_load_rec = [(np.ravel(cA3_pred), np.ravel(cD3_pred)), (np.zeros((len(cD2))), np.ravel(cD2_pred)),
(np.zeros((len(cA1))), np.ravel(cD1_pred))]
load_rec = pywt.iswt(coef_load_rec, 'db3')
# reconstitution de sigma
coef_sigma_rec = [(np.ravel(sigma_cA3), np.ravel(sigma_cD3)), (np.zeros((len(cD2))), np.ravel(sigma_cD2)),
(np.zeros((len(cA1))), np.ravel(sigma_cD1))]
sigma_rec = pywt.iswt(coef_sigma_rec, 'db3')
plt.figure(figsize=(8, 5))
plt.plot(y_test, 'r-', label='Charge réelle')
plt.plot(X_testd, load_rec, 'b-', label='Charge prédite OGP_WAV')
plt.plot(X_testd, np.array(load_rec) - 1.96*np.array(sigma_rec), 'k-', alpha = 0.5)
plt.plot(X_testd, np.array(load_rec) + 1.96*np.array(sigma_rec), 'k-', alpha = 0.5)
plt.fill_between(X_testd, np.array(load_rec) - 1.96*np.array(sigma_rec), np.array(load_rec) +
1.96*np.array(sigma_rec),
color='b', alpha = 0.1, label='Intervalle de confiance 95%')
#plt.title('TEST', fontsize=10)
plt.xlabel('Temps (H)')
```

Annexes

```
plt.ylabel('Charge (MW)')
plt.legend(loc='best')
plt.grid()
#plt.savefig(fname='C:\\Users\\HP\\Desktop\\Prediction WAV_OGP.jpg',quality=95)
```

Annexes

Modèle K-Means Clustering-Réseau de Neurones Artificiels

```
sc = MinMaxScaler()
X = sc.fit_transform(X)
for n_cluster in n_cluster_list:
    kmeans = KMeans(n_clusters=n_cluster)
    cluster_found = kmeans.fit_predict(X)
    sillhouette_scores.append(silhouette_score(X, kmeans.labels_))
plt.scatter(n_cluster_list,sillhouette_scores,color='green', alpha=0.4,
            linestyle="-")
plt.xlabel('Nombre de clusters (k)')
plt.ylabel('Sillhouette')
plt.legend()
plt.show()
kmeans = KMeans(n_clusters=2)
cluster_found = kmeans.fit_predict(X)
cluster_found_sr = pd.Series(cluster_found, name='cluster')
df_uci_pivot = df_uci_pivot.set_index(cluster_found_sr, append=True )
fig, ax= plt.subplots(1,1, figsize=(18,10))
color_list = ['red','green']
cluster_values = sorted(df_uci_pivot.index.get_level_values('cluster').unique())
for cluster, color in zip(cluster_values, color_list):
    df_uci_pivot.xs(cluster, level=1).T.plot(
        ax=ax, legend=False, alpha=0.02, color=color, label= f'Cluster {cluster}'
    )
    df_uci_pivot.xs(cluster, level=1).median().plot(
        ax=ax, color=color, alpha=0.9, ls='--')
tsne = TSNE()
results_tsne = tsne.fit_transform(X)
cmap = matplotlib.colors.LinearSegmentedColormap.from_list(cluster_values, color_list)
plt.scatter(results_tsne[:,0], results_tsne[:,1],
            c=df_uci_pivot.index.get_level_values('cluster'),
            cmap=cmap,
            alpha=0.6,
            )
# extraction
#Données d'entraînement
df_uci_pivot['cluster'] = cluster_found
dfp0 = df_uci_pivot[df_uci_pivot.cluster==0]
dfp1 = df_uci_pivot[df_uci_pivot.cluster==1]
#dfp2 = df_uci_pivot[df_uci_pivot.cluster==2]
df = dfp1.drop(['cluster'], axis=1)
df = np.array(df)
data = df.reshape(df.shape[0]*24,1)
y = data.reshape(-1,1)
data = np.ravel(data)
dataset = pd.Series(data, name='CEB LOAD')
#Données de test
df_uci_pivot['cluster'] = cluster_found
data2013_lot1 = df_uci_pivot[df_uci_pivot.cluster==0]
data2013_lot2 = df_uci_pivot[df_uci_pivot.cluster==1]
#data2013_lot3 = df_uci_pivot[df_uci_pivot.cluster==2]
df_test = data2013_lot2.drop(['cluster'], axis=1)
df_test = np.array(df_test)
data_test = df_test.reshape(df_test.shape[0]*24,1)
data_test = np.ravel(data_test)
```

Annexes

```
datasetest = pd.Series(data_test, name='CEB LOAD')
# Jeu de données
dataset_train = dataset
dataset_test = datasetest
Real_load = np.array(dataset_test)
#RNA model
training_set = np.array(dataset_train)
training_set = training_set.reshape(-1,1)
from sklearn.preprocessing import MinMaxScaler
sc = MinMaxScaler(feature_range = (0, 1))
training_set_scaled = sc.fit_transform(training_set)
# Creation de la structure avec 48 timesteps et 1 sortie
X_train = []
Y_train = []
for i in range(48,4800):
    X_train.append(training_set_scaled[(i-48):i, 0])
    Y_train.append(training_set_scaled[i, 0])
X_train = np.array(X_train)
Y_train = np.array(Y_train)
# Partie 2: construction du réseau de neurone
# Librairies
from keras.models import Sequential
from keras.layers.core import Dense, Dropout, Activation
from keras.optimizers import SGD
model = Sequential()
model.add(Dense(48, input_dim= X_train.shape[1], activation='tanh'))
#model.add(Dropout(0.2))
model.add(Dense(128, activation='relu'))
#model.add(Dropout(0.1))
model.add(Dense(128, activation='relu'))
#model.add(Dropout(0.1))
model.add(Dense(1, activation = 'linear'))
model.summary()
model.compile(optimizer="adam", loss="mean_squared_error")
model.fit(X_train, Y_train, batch_size=24, nb_epoch=500)
# Prédiction pour 2011
dataset_total = pd.concat((dataset_train, dataset_test), axis=0)
inputs = dataset_total[len(dataset_total) - len(dataset_test) -48:].values
inputs = inputs.reshape(-1, 1)
inputs = sc.transform(inputs)
X_test = []
for i in range(48,408):
    X_test.append(inputs[(i-48):i, 0])
X_test = np.array(X_test)
predicted_load = model.predict(X_test)
predicted_load = sc.inverse_transform(predicted_load)
# Visualisation des resultats
plt.figure(figsize=(20,8))
plt.plot(Real_load, color="green", label="Charge réelle", lw=1.5)
plt.plot(predicted_load, color="red", label="Charge prédite",lw = 1.5,linestyle = '-.')
plt.title("Prédiction avec le modèle choisi")
plt.xlabel("Heure")
plt.ylabel("Charge consommée")
plt.legend()
plt.grid()
plt.show()
```

Annexes

```
# Calcul de indicateurs de performance
from sklearn.metrics import mean_squared_error, mean_absolute_error, r2_score
from numpy import math
MSE = mean_squared_error(Real_load,predicted_load)
RMSE = math.sqrt(MSE)
print('RMSE=',RMSE)
MAE = mean_absolute_error(Real_load,predicted_load)
MAP = (MAE/Real_load)*100
MAPE = np.average(MAP)
print('MAPE=',MAPE)
R2 = r2_score(Real_load,predicted_load)
print('R2=',R2)
```


Liste des publications

- [1] A. Guenoupkati, A. A. Salami, M. K. Kodjo and K. Napo "Short-Term Electricity Load Forecasting Using K-Means Clustering - Artificial Neural Networks Hybrid Model : Case Study Of Benin Electricity Community (CEB)," 2021 IV International Conference on High Technology for Sustainable Development (HiTech), 2021, pp. 01-05, doi : 10.1109/HiTech53072.2021.9614236.

- [2] Guenoupkati A, Salami AA, Kodjo MK, Napo K. *Short-Term Electricity Generation Forecasting Using Machine Learning Algorithms : A Case Study of the Benin Electricity Community (CEB)*. TH Wildau Engineering and Natural Sciences Proceedings. 2021 Jun 15 ;1.

- [3] Guenoukpati A, Salami AA, Kodjo MK, Napo K. *Estimating Weibull Parameters for Wind Energy Applications Using Seven Numerical Methods : Case studies of Three Coastal Sites in West Africa*. International Journal of Renewable Energy Development. 2020 Jul 1 ;9(2).

- [4] Guenoupkati A, Salami AA, Kodjo MK, Napo K. *Statistical Characterization of Electric Power Production and Importation : Case Study of Benin Electricity Community (CEB)*. In2019 II International Conference on High Technology for Sustainable Development (HiTech) 2019 Oct 10 (pp. 1-6). IEEE.

- [5] Salami AA, Kodjo KM, Boureima S, Guenoupkati A, Dotche KA, Bedja KS. *Alumina's Effect as Blocking Layer on Self-discharge Process : Case Study of Supercapacitors as Energy storage Devices*. In2019 IEEE PES/IAS PowerAfrica 2019 Aug 20 (pp. 470-475). IEEE.

- [6] Guenoukpati A, Salami AA, Kodjo MK, Dotche KA, Bedja K. *Computational method for the charging time of supercapacitors*. In2017 IEEE PES PowerAfrica 2017 Jun 27 (pp. 186-191). IEEE.



UNIVERSITE DE LOME

FACULTE DES SCIENCES

THESE

Présentée par :

GUENOUKPATI Agbassou

Pour obtenir le grade de :

Doctorat Unique en Sciences de l'Ingénieur

Development of a short-term optimal planning tool for interconnected power grids

Abstract

Electricity is a difficult non-storable product that requires a permanent adjustment between supply and demand. Unfortunately, it is a volatile product that exceptionally keeps growing at a random rate. In order to keep up with this fast pace, to ensure quality and continuity of service, and to make access to electricity available to the user at all times, electric power companies must address the problem of power system planning. Solving this problem involves several related activities : demand forecasting, market opening, grid stability, security of people and goods, security of cross-border networks, taking into account current energy policies and regulations, combating climate change and promoting sustainable development. This is a complex problem that requires probabilistic, optimization and machine learning approaches.

The contribution of our approach is to find a compromise in the formulation and global resolution of the problem by taking into account all its different components. Thus, we propose an approach that consists in a first step to forecast the availability of the generation sources present in the electrical system by statistical distribution laws (Gaussian mixture and other models), followed by the short-term forecast of the electrical load by Machine Learning approach (k-means clustering / ANN, wavelets / ARIMA and wavelets / Gaussian process) finished by a third approach based on the economic efficiency which consists in the optimization of the electricity transaction cost and CO₂ emission cost by quadratic programming. The whole integrated in a software named STCED (Statistical Tool for Characterizing Electricity Data) developed under Python 3.9.

In order to validate the performance of the developed program, tests were carried out on the interconnected network of the CEB (Communauté Electrique du Bénin) and that of IEEE with 24 buses. The results obtained are promising and show the strength of the developed tool in optimized planning of electrical energy exchanges between different interconnected electrical networks. Therefore, this tool could be used by Transmission System Operators (TSOs), planners for optimal management of their power systems in the market to make better decisions in the short term related to power load forecasting, power purchase and generation, load switching, market assessment, and infrastructure development, all in compliance with environmental imperatives, policies and Current Regulations.

Keywords : Power grid planning, Machine Learning, Electric power exchanges, Interconnected transmission power systems, Carbon footprint, Short-term load forecasting, Statistical modeling, Optimization, Software.



UNIVERSITE DE LOME

FACULTE DES SCIENCES

THESE

Présentée par :

GUENOUKPATI Agbassou

Pour obtenir le grade de :

Doctorat Unique en Sciences de l'Ingénieur

Élaboration d'un outil d'aide pour la planification optimale à court terme des réseaux électriques interconnectés

Résumé

L'électricité est un produit dont le stockage est onéreux qui nécessite un ajustement permanent entre l'offre et la demande. Malheureusement, c'est un produit dont la demande exceptionnellement ne cesse de croître de façon aléatoire. Pour suivre ce rythme effréné afin d'assurer la qualité et la continuité de service, et rendre toujours disponible l'accès à l'électricité chez l'utilisateur, les compagnies d'énergie électrique doivent répondre à la problématique de la planification des réseaux électriques. La résolution de ce problème sous-tend plusieurs activités connexes à savoir la gestion prévisionnelle de la demande, l'ouverture du marché, la stabilité du réseau, la sécurité des personnes et des biens, la sécurité des réseaux transfrontaliers, la prise en compte des politiques énergétiques et réglementations en vigueur, la lutte contre le changement climatique et la promotion d'un développement durable. Il s'agit d'un problème complexe dont la résolution fait appel à des approches probabilistes, d'optimisation et d'apprentissage automatique.

La contribution qu'apporte notre démarche dans ce travail est de trouver un compromis dans la formulation et résolution globale du problème en tenant compte de toutes ses différentes composantes. Ainsi, nous proposons une démarche qui consiste dans un premier temps à prévoir la disponibilité des sources de production présentes au sein du système électrique par des lois de distribution statistiques (mélange gaussien et autres modèles), suivi de la prévision à court terme de la charge électrique par approche apprentissage automatique (clustering k-means / ANN, ondelettes / ARIMA et ondelettes / processus gaussien), terminer par une troisième approche basée sur l'efficacité économique qui permet à l'optimisation du coût de transaction de l'électricité et d'émission de CO₂ par programmation quadratique. Le tout intégré dans un logiciel dénommé STCED (Statistical Tool for Characterizing Electricity Data) développé sous Python 3.9.

Afin de valider la performance du programme développé, des tests ont été réalisés sur le réseau interconnecté de la CEB (Communauté Electrique du Bénin) et celui d'IEEE à 24 bus. Les résultats obtenus sont prometteurs et montrent la force de l'outil développé dans la planification optimisée des échanges de l'énergie électrique entre différents réseaux électriques interconnectés. Par conséquent, cet outil pourrait être utilisé par le gestionnaire de réseaux de transport (GRT), les planificateurs pour une gestion optimale de leurs réseaux électriques sur le marché pour prendre de meilleures décisions dans le court terme liées à la prévision de la charge électrique, l'achat d'énergie et de la production, la commutation des charges, l'évaluation du marché, et le développement des infrastructures, tout ceci dans le respect des impératifs environnementaux, politiques et réglementations en vigueur.

Mots clés : Planification des réseaux électriques, Machine Learning, Echanges de l'énergie électrique, Réseaux électriques de transport interconnectés, Empreinte carbone, Prédiction à court terme de la charge électrique, Modélisation statistique, Optimisation, Logiciel.