RÉPUBLIQUE DU BÉNIN
MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR
ET DE LA RECHERCHE SCIENTIFIQUE

UNIVERSITÉ D'ABOMEY-CALAVI

INSTITUT DE FORMATION ET DE RECHERCHE EN INFORMATIQUE

BP 526 Cotonou Tel : +229 21 14 19 88
http://www.ifri-uac.bj Courriel : contact@ifri.uac.bj

MÉMOIRE

pour l'obtention du

Diplôme de Licence en Informatique

Option : Génie Logiciel

Présenté par :
Ahonakpon Guy **GBAGUIDI**

Stratégies Optimisées d'Approvisionnement Énergétique pour les Télécoms Vertes: Une Approche basée sur l'IA et l'Optimisation Multi-Objectifs

Sous la supervision :
Professeur Eugène C. **EZIN**
Enseignant Chercheur à l'Université d'Abomey-Calavi

Membres du jury :

Justin KPENAVOUN CHOGOU	Professeur	FSA	Président
Erick ADJE	Ingénieur	IFRI	Examinateur
Eugène C. EZIN	Professeur	IFRI et IMSP	Rapporteur

Année Académique : **2023-2024**

Sommaire

Dédicace ii

Remerciements iii

Résumé iv

Abstract v

Table des figures vi

Liste des tableaux vii

Liste des Algorithmes viii

Liste des acronymes ix

Introduction 1

1 Revue de littérature 5

2 Conception et choix techniques 19

3 Résultats et discussion 35

Conclusion 44

Bibliographie et Webographie 45

Annexe 49

Table des matières 52

Dédicace

À ma famille, pour votre amour, votre soutien inébranlable, et vos encouragements tout au long de ce parcours. **À mes parents,** pour avoir toujours cru en moi et m'avoir donné les moyens de poursuivre mes rêves. **À la Mastercard Foundation,** pour leur soutien généreux et leur engagement envers l'éducation et le développement des talents.

À tous ceux qui œuvrent activement pour le développement de l'intelligence artificielle au Bénin et en Afrique.

"Though we travel to the world to find the best, we carry it in us or we find it not."
— R. Emerson

Remerciements

Je tiens à exprimer ma plus profonde gratitude à toutes les personnes qui, de près ou de loin, ont contribué à la réussite de mon parcours universitaire et à l'élaboration de ce travail marquant la fin de mes études de licence.

Mes remerciements particuliers vont à :

- tout d'abord, je tiens à remercier chaleureusement le Professeur Eugène C. EZIN, Directeur de l'Institut de Formation et de Recherche en Informatique (IFRI), pour ses conseils avisés et la formation qu'il nous a dispensée. Son accompagnement tout au long de ce travail a été d'une grande importance ;
- mes chers parents, qui n'ont ménagé aucun effort pour me permettre d'étudier dans des conditions optimales tout au long de mon cursus universitaire. Leur soutien indéfectible, tant émotionnel que matériel, a été essentiel à la réussite de ce parcours ;
- l'administration et les enseignants de l'IFRI pour leurs efforts constants en vue de nous offrir un enseignement de qualité et de créer un environnement propice à notre émancipation intellectuelle ;
- tous mes camarades et amis de l'IFRI et de la Faculté des Sciences et Techniques (FAST), pour leur solidarité et leur partage de connaissances, qui ont contribué à un climat d'entraide et de collaboration tout au long de cette formation ;
- enfin, à toutes les personnes qui m'ont soutenu, directement ou indirectement, dans la réalisation de ce projet académique.

À vous tous, je vous exprime ma sincère reconnaissance.

Résumé

La transition vers des réseaux de télécommunications verts et durables est essentielle dans la lutte contre le changement climatique. Le secteur des Technologies de l'Information et de la Communication (TIC) consomme environ 3 % de l'énergie mondiale et génère autant d'émissions de carbone. Ce projet vise à concevoir des stratégies d'approvisionnement énergétique optimisées pour les stations de base des réseaux mobiles en utilisant des ressources énergétiques distribuées telles que les panneaux solaires, les générateurs diesel, et le stockage par batterie. En intégrant l'intelligence artificielle et l'optimisation multi-objectifs, notre modèle prédit la génération quotidienne d'énergie solaire en fonction des conditions météorologiques et élabore des stratégies efficaces pour minimiser les coûts énergétiques tout en garantissant la stabilité du réseau. L'objectif est de réduire les émissions de carbone et les coûts opérationnels liés à l'énergie, tout en assurant un approvisionnement continu.

Mots clés : réseaux télécoms, Intelligence artificielle, optimisation énergétique, ressources énergétiques distribuées, énergie verte.

Abstract

The transition towards green and sustainable telecommunication networks is essential in combating climate change. The Information and Communication Technology (ICT) sector currently consumes approximately 3 % of global energy and generates a similar share of carbon emissions. This project aims to design optimized energy supply strategies for mobile network base stations using distributed energy resources, such as solar panels, diesel generators, and battery storage. By integrating artificial intelligence and multi-objective optimization, our model predicts daily solar energy generation based on weather conditions and develops efficient strategies to minimize energy costs while ensuring network stability. The objective is to reduce carbon emissions and energy-related operational costs, while maintaining a continuous energy supply.

Key words : telecom networks, artificial intelligence, energy optimization, distributed energy resources, green energy.

Table des figures

1.1 Illustration d'une station de base (centre), de deux cellules (gauche et droite) et de quatre faisceaux dans chaque cellule. [25] 6
1.2 Où les opérateurs mobiles utilisent l'énergie dans leurs opérations de réseau [15] 7
1.3 Virtualisation du RAN (vRAN). [6] 7
1.4 Types de Ressources Énergétiques Distribuées (Distributed Energy Resourcess (DERs)). [26] 8
1.5 Complexité quadratique du mécanisme d'attention des Transformers. [34] . . 9
1.6 Architecture de l'iTransformer. [31] 10
1.7 Squelette d'un algorithme évolutionaire [21] 12
1.8 Architecture API REST [36] 15
1.9 Architecture de Green Telecom Distributed Energy Resources Optimizer (GT_DERO). [16] 18

2.1 Diagramme de cas d'utilisation final de la plateforme 20
2.2 Diagramme de classes UML de la plateforme 21
2.3 Diagramme de séquence détaillé pour l'optimisation des stratégies 22
2.4 Données de consommation énergétique [16] 24
2.5 Données relatives aux sites et à la grille électrique [16] 24
2.6 Données relatives à la production solaire et aux conditions météorologiques [16] 24
2.7 Hourly Average Energy Output (kWh) 25
2.8 Average Energy Output (kWh) by Day and Hour 25
2.9 Diagramme de composants de l'architecture générale du système 27
2.10 Flux général de la stratégie d'optimisation énergétique proposée. Les données historiques (ITU) sont nettoyées, prédites, puis optimisées. Si la SOC passe sous le seuil de DOD, on ré-optimise ; sinon, la stratégie est validée et surveillée. 28

3.1 Landing page Telecom Distributed Energy Resources Optimizer (GT_DERO) . 38
3.2 Page d'Inscription Telecom Distributed Energy Resources Optimizer (GT_DERO) 38
3.3 Page de Connexion Telecom Distributed Energy Resources Optimizer (GT_DERO) 39
3.4 Tableau de bord de GT_DERO : aperçu général des indicateurs clés (sites, consommation, solaire, batterie, CO2) 40
3.5 Distributions de la consommation énergétique totale (kWh) pour chaque site. 41

Liste des tableaux

3.1 Récapitulatif des performances des modèles de prédiction et d'optimisation sur les séries temporelles 37

Liste des Algorithmes

1 Prédiction de l'Énergie Solaire (Mise à jour) 29
2 Gestion de la Consommation Énergétique (Mise à jour) 29
3 Initialisation des Variables et Création du Fichier CSV 30
4 Décision sur les Sources d'Énergie (Mise à jour) 31
5 Calcul du Changement de l'État de Charge (SOC) (Mise à jour) 31
6 Optimisation des Stratégies Énergétiques (Global) (Mise à jour) 32
7 Calcul du Score de la Stratégie (Mise à jour) 32

Liste des acronymes

CO_2 :

Gaz Carbonique ou Dioxyde de Carbone 2, 3, 8, 17, 19, 35, 44

API :

Application Programming Interface 14, 18

ARIMA :

Autoregressive Integrated Moving Average 13

DER :

Distributed Energy Resources vi, 2, 3, 8, 14, 15, 17

DHI :

Direct Horizontal Irradiance measured 23

DNI :

Direct Normal Irradiance measured 23

GHI :

Global Horizontal Irradiance measured 23

GT_DERO :

Green Telecom Distributed Energy Resources Optimizer vi, 17–20, 22, 26, 33, 35, 37–40, 43, 44

IA :

Intelligence Artificielle 2, 3, 9

ITU :

International Telecommunication Union 35

LSTM :

Long Short-Term Memory 13, 15–17, 36

NLP :

Natural Language Processing 9

ODD 13 :

Lutte contre le changement climatique 1, 2

ODD 7 :

Accès à une énergie propre, abordable et durable 1, 2

PV :

Photovoltaique 8

QoS :

Qualité de Service 7

RAN :

Radio Access Networks 5–7

RL :

Reinforcement Learning 16

RNC :

Radio Network Controller 6

RNN :

Recurrent Neural Networks 13

SOC :

State of Charge (État de Charge) 35

TIC :

Technologies de l'Information et de la Communication iv, 1

UE :

Équipement Utilisateur 5, 6

Introduction Générale

L'essor des TIC[1] a transformé le paysage mondial, connectant les populations et stimulant le développement économique. Cependant, cette croissance s'accompagne d'une consommation énergétique considérable, soulevant des préoccupations environnementales majeures. Face aux défis du changement climatique et à l'augmentation des coûts énergétiques, il devient impératif de repenser les stratégies énergétiques des infrastructures de télécommunications.

1. Contexte et justification

L'industrie des TIC consomme actuellement environ 3% de l'énergie mondiale et est responsable d'environ 3% des émissions globales de carbone. De plus, plus de 90% des coûts opérationnels des réseaux télécoms sont liés à la consommation énergétique [16] [5]. Ces chiffres mettent en évidence l'importance de la consommation d'énergie dans ce secteur et son impact environnemental.

Dans ce contexte, l'industrie des télécommunications s'est engagée à atteindre des émissions nettes nulles d'ici 2050 [16], en alignement avec l'Lutte contre le changement climatique (ODD 13)[2] des Nations Unies, qui vise à lutter contre le changement climatique en réduisant les émissions de gaz à effet de serre. Cet engagement s'inscrit dans une action globale pour le climat, visant à limiter les effets du réchauffement planétaire.

Parallèlement, l'augmentation continue des coûts énergétiques accentue cette problématique. Le prix du diesel a augmenté de 55% d'une année sur l'autre, tandis que celui de l'électricité a grimpé de 38%, obligeant l'industrie à repenser ses stratégies d'approvisionnement énergétique [16]. En réponse, la transition vers des énergies renouvelables, telles que l'énergie solaire, est devenue une priorité. Cette transition soutient l'Accès à une éner-

[1] Ensemble des technologies utilisées pour gérer l'information et faciliter la communication, incluant l'informatique, l'internet, les réseaux de télécommunications et les médias numériques.

[2] Objectif établi par les Nations Unies visant à prendre des mesures urgentes pour lutter contre le changement climatique et ses impacts, en renforçant la résilience et la capacité d'adaptation face aux aléas climatiques.

gie propre, abordable et durable (ODD 7)[3], qui promeut un accès universel à une énergie propre, abordable et durable.

Dans de nombreuses régions du monde, notamment dans les pays en développement, l'accès à un réseau électrique fiable reste incertain. Par conséquent, les stations de base télécoms dépendent souvent de sources d'énergie alternatives, telles que les générateurs diesel et les panneaux solaires, pour assurer une alimentation continue [16]. Cependant, l'utilisation excessive de générateurs diesel augmente non seulement les coûts opérationnels, mais contribue également aux émissions de Gaz Carbonique ou Dioxyde de Carbone (CO_2), en contradiction avec les objectifs climatiques mondiaux.

C'est dans ce contexte que s'inscrit ce projet, visant à optimiser la production et la consommation d'énergie pour atteindre un équilibre entre efficacité opérationnelle, réduction des coûts énergétiques et respect des engagements climatiques. La solution proposée se concentre sur l'utilisation de DERs, notamment les panneaux solaires, les générateurs diesel et le stockage d'énergie via des batteries. En exploitant l'Intelligence Artificielle (IA), nous visons à prédire la production d'énergie solaire et la consommation énergétique, afin d'optimiser l'utilisation de ces diverses sources d'énergie. L'objectif est de contribuer à la réalisation des ODD 7 et ODD 13, en favorisant une réduction des émissions et en garantissant un accès à une énergie durable et abordable pour les infrastructures critiques de télécommunications.

2. Problématique

Les réseaux de télécommunications sont confrontés à des défis croissants en matière d'approvisionnement énergétique, particulièrement dans les régions où le réseau électrique est instable ou inexistant. L'augmentation continue des coûts des sources d'énergie traditionnelles, comme le diesel, rend la fourniture d'une énergie stable et abordable de plus en plus difficile. Par ailleurs, bien que l'énergie solaire soit une alternative prometteuse pour alimenter les stations de base, sa disponibilité intermittente due aux variations météorologiques limite son efficacité comme source d'énergie fiable.
Les solutions actuelles manquent d'une approche intégrée permettant d'optimiser l'utilisation combinée des différentes sources d'énergie, en tenant compte à la fois de la variabilité de la production solaire et de la consommation énergétique fluctuante des stations de base. De plus, elles ne parviennent pas à minimiser simultanément les coûts opérationnels et les émissions de carbone tout en garantissant la fiabilité du réseau.

Ainsi, le problème central est le suivant :

Comment développer une stratégie d'approvisionnement énergétique optimisée pour les

[3]Objectif des Nations Unies visant à garantir l'accès de tous à des services énergétiques fiables, durables et modernes, à un coût abordable, en augmentant la part des énergies renouvelables dans le bouquet énergétique mondial.

réseaux de télécommunications, qui intègre efficacement la prédiction de la production solaire et de la consommation énergétique, afin de réduire les coûts et les émissions de carbone, tout en assurant une fiabilité maximale du réseau ?

3. Objectifs

L'objectif général de ce projet est de développer une stratégie optimisée d'approvisionnement énergétique pour les stations de base des réseaux de télécommunications, en tirant parti des DERs telles que l'énergie solaire, le réseau électrique, les générateurs diesel et les batteries de stockage. Les objectifs spécifiques sont les suivants :

- **prédiction de la production d'énergie solaire :** Développer un modèle basé sur l'IA pour prédire avec précision la production quotidienne d'énergie solaire en fonction des données météorologiques et autres facteurs pertinents ;
- **prédiction de la consommation d'énergie :** Élaborer un modèle pour estimer la consommation énergétique des stations de base, en tenant compte des paramètres du réseau, des schémas d'utilisation et des variations de la demande ;
- **optimisation multi-objectifs :** Concevoir une stratégie d'optimisation qui intègre la disponibilité des différentes sources d'énergie et la consommation prévue, afin de minimiser simultanément les coûts énergétiques et les émissions de carbone ;
- **réduction des coûts énergétiques :** Diminuer la dépendance aux générateurs diesel coûteux et polluants en maximisant l'utilisation de l'énergie solaire et en optimisant le stockage de l'énergie via des batteries ;
- **réduction des émissions de carbone :** Augmenter l'utilisation des énergies renouvelables pour contribuer significativement à la réduction des émissions de CO_2 dans le secteur des télécommunications.

4. Livrables

Les principaux livrables attendus de ce projet sont :

- **modèle de prédiction de l'énergie solaire :** Un modèle performant basé sur l'IA pour prédire la production quotidienne d'énergie solaire, validé par des données réelles et capable de s'adapter aux différentes conditions météorologiques ;
- **modèle de prédiction de la consommation d'énergie :** Un modèle précis permettant d'estimer la consommation énergétique des stations de base, prenant en compte les fluctuations de la demande et les particularités du réseau ;
- **stratégies d'approvisionnement énergétique optimisées :** Un ensemble de stratégies d'optimisation pour l'utilisation des DERs, visant à minimiser les coûts et les émissions

tout en garantissant la fiabilité du réseau ;

- **plateforme logicielle intégrée :** Une plateforme logicielle permettant de simuler et de mettre en œuvre les stratégies d'optimisation énergétique, intégrant les modèles de prédiction et offrant une interface utilisateur conviviale ;
- **rapport technique détaillé :** Un rapport complet documentant les méthodologies employées, les résultats obtenus, les analyses effectuées, ainsi que les recommandations pour la mise en œuvre pratique.

5. Organisation du document

Ce document est structuré de manière à présenter de façon cohérente les différentes étapes du développement du projet, et se divise en 3 chapitres :

- **revue de la littérature :** Le premier chapitre présente une analyse approfondie des travaux existants dans les domaines de la gestion énergétique des réseaux télécoms, des modèles de prédiction d'énergie solaire et de consommation d'énergie, ainsi que des approches d'optimisation multi-objectifs. Ce chapitre identifie les lacunes actuelles et justifie les choix méthodologiques du projet ;
- **conception de la solution et choix techniques :** Le deuxième chapitre présente une description détaillée de la conception de la solution proposée, y compris les algorithmes de prédiction pour la production solaire et la consommation énergétique, l'approche d'optimisation multi-objectifs, et les technologies utilisées pour le développement de la plateforme logicielle ;
- **résultats et discussion :** Le dernier chapitre présente les résultats obtenus à partir des simulations et des tests des modèles et des stratégies d'optimisation. Ce chapitre inclut une analyse critique des performances, des comparaisons avec les approches existantes, et une discussion sur l'impact potentiel de la solution proposée ;
- **conclusion et perspectives :** Un résumé des contributions du projet, une synthèse des résultats clés, et une discussion des perspectives futures, y compris les possibilités d'amélioration et les orientations pour des recherches ultérieures ;
- **annexes :** Incluant les données supplémentaires, les détails techniques, les codes sources pertinents, et tout autre matériel complémentaire utile à la compréhension du projet.

Chapitre 1

Revue de littérature

Introduction

Ce chapitre a pour objectif d'une part de donner la définition de quelques concepts et notions nécessaires à la bonne compréhension de notre travail. D'autre part, nous évoquons les solutions existantes et donnons ensuite nos avis critiques sur celles-ci.

1.1 Clarification des concepts

1.1.1 Réseau d'Accès Radio

Le Réseau d'Accès Radio (Radio Access Networks (RAN)) est un élément essentiel de l'architecture des réseaux de télécommunications, reliant les équipements utilisateurs aux réseaux centraux via des stations de base.

1.1.1.1 Composantes du RAN

Le RAN est principalement composé des éléments suivants [41] :

- **stations de Base (BS)** : Elles sont responsables de la transmission et de la réception des signaux radio entre le réseau et les équipements utilisateurs. Elles peuvent être classées selon leur couverture :
  - *Macrocellules* : Elles couvrent de larges zones géographiques et nécessitent une puissance élevée ;
  - *Petites cellules* : Elles incluent les microcellules, picocellules et femtocellules.
- **équipements Utilisateurs (Équipement Utilisateur (UE))** : Ce sont dispositifs tels que les smartphones et tablettes qui communiquent avec le RAN via les stations de base.

- **contrôleur de Réseau Radio (Radio Network Controller (RNC))** : Dans les réseaux 3G, le RNC gère les ressources radio, notamment l'allocation de la bande passante et le *handover* entre cellules. Bien que remplacé par des architectures plus récentes dans les réseaux 4G et 5G, il reste pertinent pour comprendre les systèmes hérités.

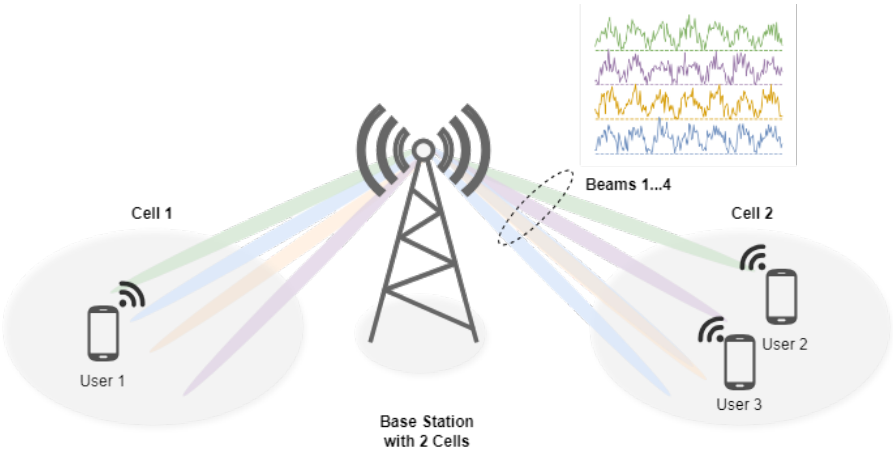


FIGURE 1.1 : Illustration d'une station de base (centre), de deux cellules (gauche et droite) et de quatre faisceaux dans chaque cellule. [25]

1.1.1.2 Défis énergétiques du RAN

La consommation énergétique du RAN, en particulier des stations de base, représente un défi majeur. Fonctionnant 24h/24 et 7j/7 pour garantir une couverture continue, le RAN est l'un des composants les plus énergivores du réseau, représentant jusqu'à 76% de la consommation énergétique des opérateurs mobiles [15]. Cette consommation se répartit principalement entre les stations de base (BTS[1], Node B, eNodeB et gNodeB) ainsi que les infrastructures associées, comme les systèmes de climatisation, les onduleurs et les redresseurs. En revanche, les petites cellules comme les picocellules et femtocellules sont exclues de cette analyse énergétique (voir figure 1.2).

Les principaux facteurs contribuant à cette consommation sont :

- **transmission des signaux** : Elle nécessite des niveaux de puissance élevés, surtout pour les macrocellules couvrant de grandes distances ;
- **infrastructure auxiliaire** : Le refroidissement des stations de base et les systèmes de conversion d'énergie (onduleurs, redresseurs) augmentent également la consommation énergétique ;
- **couverture continue** : Même durant les périodes creuses, les stations de base doivent rester actives pour maintenir la couverture, ce qui accentue le problème d'efficacité énergétique.

[1]Une station émettrice-réceptrice de base (BTS) ou une unité de bande de base (BBU) est un équipement qui facilite la communication sans fil entre l'équipement utilisateur (UE) et un réseau

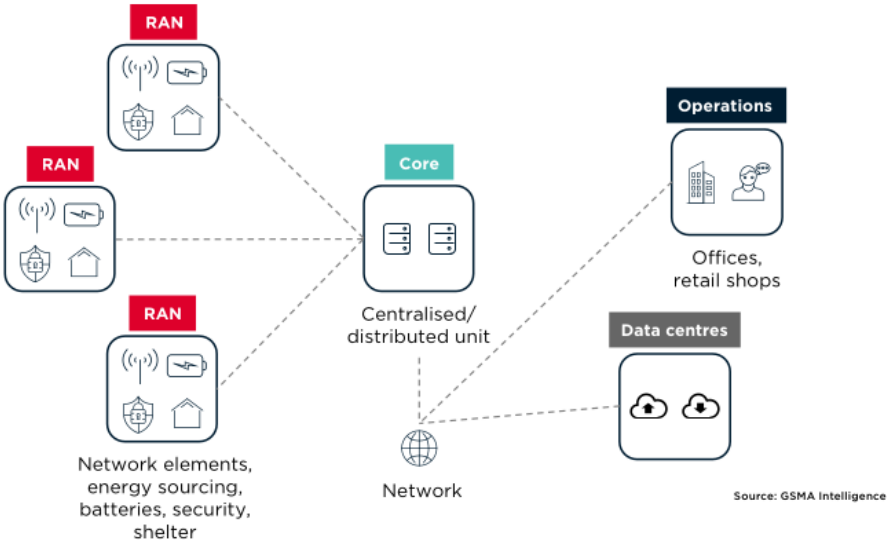


FIGURE 1.2 : Où les opérateurs mobiles utilisent l'énergie dans leurs opérations de réseau [15]

1.1.1.3 Optimisation énergétique du RAN

Plusieurs stratégies ont été proposées pour réduire la consommation énergétique du RAN tout en maintenant la Qualité de Service (Qualité de Service (QoS)) :

- **mise en veille dynamique** : Cela implique la désactivation partielle des stations de base lorsque la demande est faible [33, 40] ;
- **virtualisation du RAN (vRAN)** : Certaines fonctions radio déplacées vers le cloud sont virtualisées, permettant de consolider les ressources et d'adapter dynamiquement les capacités en fonction de la demande [6] (voir Figure 1.3) ;
- **green RAN** : L'intégration de sources d'énergie renouvelable, telles que les panneaux solaires, pour alimenter les stations de base [17] ;
- **technologies Avancées** : L'utilisation du MIMO massif et du *beamforming* pour concentrer l'énergie là où elle est nécessaire, réduisant ainsi la consommation globale [39] ;
- **open RAN** : L'adoption d'une architecture ouverte et interopérable qui permet une plus grande flexibilité et une meilleure optimisation des ressources, contribuant ainsi à l'efficacité énergétique des réseaux télécoms [6].

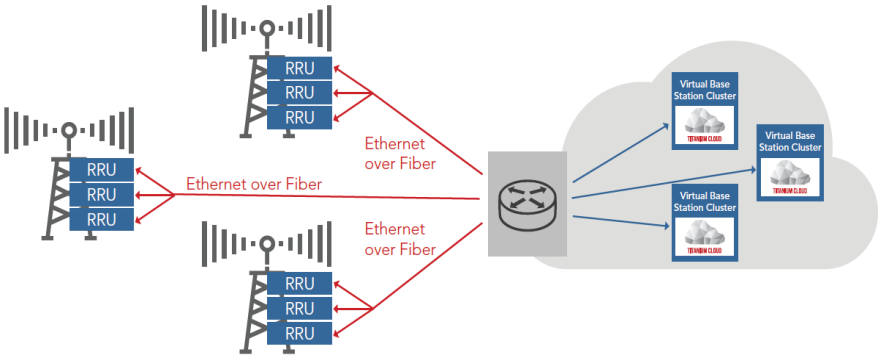


FIGURE 1.3 : Virtualisation du RAN (vRAN). [6]

1.1.2 Ressources Énergétiques Distribuées (DER)

Les Ressources Énergétiques Distribuées (Distributed Energy Resourcess (DERs)) sont des systèmes de production et de stockage d'énergie situés à proximité des sites de consommation.

1.1.2.1 Types de DER

Les DERs comprennent plusieurs technologies (Figure 1.4) :

- **énergie solaire** : Les panneaux solaires photovoltaïques (Photovoltaique (PV)) sont couramment utilisés en raison de l'abondance de l'énergie solaire et de leur capacité à alimenter les stations de base pendant la journée [23] ;
- **énergie éolienne** : Ils s'agit d'une alternative intéressante dans les zones venteuses, souvent utilisée en combinaison avec le solaire pour compléter la production d'énergie, notamment la nuit ou pendant les jours nuageux [10] ;
- **stockage d'énergie par batterie** : Il est essentiel pour garantir une alimentation stable lorsque les ressources renouvelables ne sont pas disponibles (par exemple, durant la nuit pour le solaire) ou lorsque le réseau électrique est inaccessible [14] ;
- **générateurs diesel** : Ils sont utilisés comme solution de secours dans les régions éloignées, avec un objectif de réduire leur usage au profit des sources renouvelables, contribuant ainsi à la réduction des émissions de carbone [7].

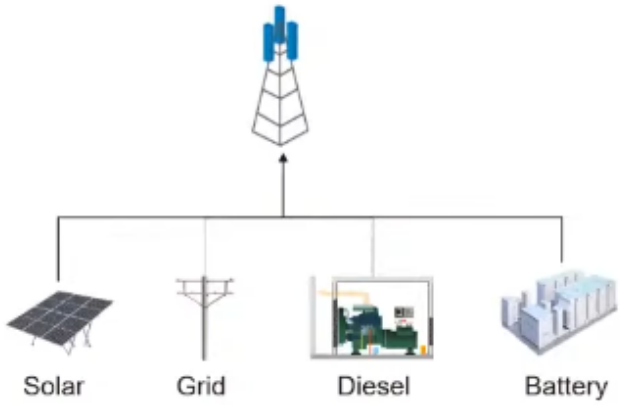


FIGURE 1.4 : Types de Ressources Énergétiques Distribuées (DERs). [26]

1.1.2.2 Avantages et Défis des DER dans les Réseaux Télécoms

Les avantages de l'intégration des DERs dans les réseaux télécoms incluent la réduction des coûts énergétiques, l'amélioration de la fiabilité de l'alimentation électrique et la réduction des émissions de Gaz Carbonique ou Dioxyde de Carbone (CO_2) [50]. Par exemple, l'opérateur Orange a réussi à réduire ses coûts énergétiques de 30 % en intégrant des panneaux solaires et des batteries de stockage sur ses sites éloignés [10].

Cependant, certains défis doivent être pris en compte, notamment la variabilité des ressources renouvelables [14], les coûts initiaux élevés de l'installation de ces technologies [7],

ainsi que la nécessité d'une gestion optimisée de l'énergie pour garantir une alimentation stable et continue. Par exemple, l'énergie solaire n'est disponible que pendant la journée, tandis que les batteries ne fournissent de l'énergie que lorsqu'elles sont chargées, et l'accès à l'énergie du réseau peut être limité à certaines heures de la journée [25].

1.1.3 Intelligence Artificielle et iTransformers

L'Intelligence Artificielle (Intelligence Artificielle (IA)) joue un rôle crucial dans l'optimisation des réseaux télécoms et la prévision de la production d'énergie. Parmi les architectures d'IA, les **Transformers** ont d'abord fait leurs preuves en traitement du langage naturel (Natural Language Processing (NLP)), mais leur potentiel pour les séries temporelles est de plus en plus exploité grâce à leur capacité à capturer des dépendances à long terme via l'attention multi-tête.

1.1.3.1 Défis des Transformers pour les Séries Temporelles

Bien que performants dans le NLP, les Transformers rencontrent des difficultés dans les séries temporelles, en raison de leur complexité quadratique liée à la longueur des séquences [45]. Cette complexité, illustrée par la Figure 1.5, ralentit le traitement des longues séries temporelles, comme celles utilisées pour la prédiction énergétique.

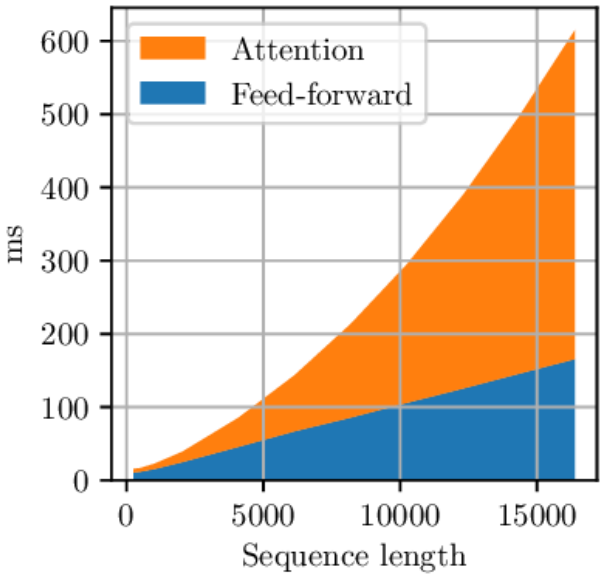


FIGURE 1.5 : Complexité quadratique du mécanisme d'attention des Transformers. [34]

1.1.3.2 iTransformer : Transformer Inversé

L'**iTransformer** propose une solution innovante en inversant l'architecture traditionnelle des Transformers. Plutôt que de traiter chaque pas de temps comme un jeton, il considère l'historique complet de chaque variable comme un jeton unique [31]. Cela permet de modéliser les corrélations complexes entre variables, améliorant la prédiction des séries temporelles multivariées sans nécessiter d'encodage positionnel.

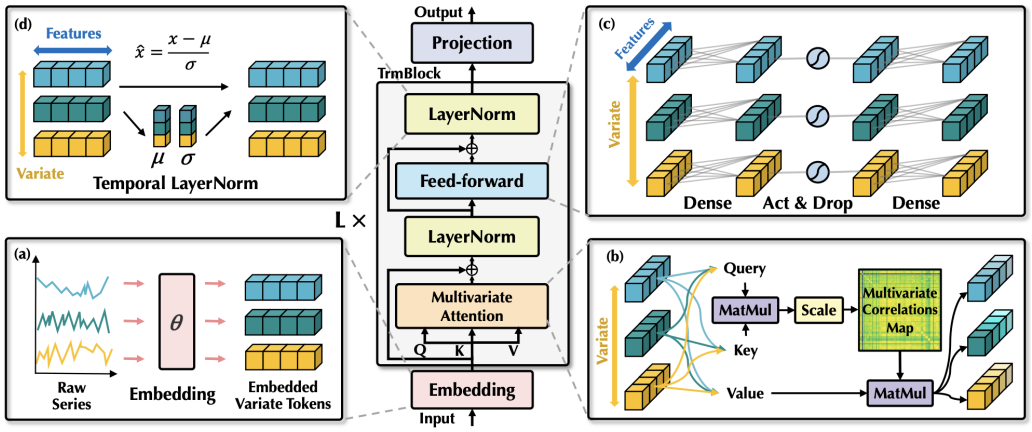


FIGURE 1.6 : Architecture de l'iTransformer. [31]

1.1.3.3 Avantages de l'iTransformer

L'iTransformer présente plusieurs avantages pour les séries temporelles complexes :

- **modélisation des dépendances entre variables** : L'attention permet de capturer les relations multivariées, cruciales pour la prévision énergétique ;
- **traitement efficace des séries temporelles** : Chaque variable est traitée indépendamment par des réseaux feed-forward, ce qui réduit la complexité computationnelle ;
- **absence d'encodage positionnel** : L'ordre temporel est implicitement représenté, simplifiant le modèle.

En combinant dépendance et indépendance entre canaux, l'iTransformer s'avère particulièrement adapté aux séries temporelles multivariées, comme les données météorologiques utilisées pour la production d'énergie solaire.

1.1.4 Optimisation multi-objectifs

L'optimisation de l'énergie dans les réseaux d'accès radio (RAN) est souvent un problème complexe qui implique plusieurs objectifs contradictoires. Il s'agit de trouver un équilibre entre plusieurs critères tels que :

- **minimisation de la consommation énergétique totale** : Réduire les coûts d'exploitation en optimisant l'utilisation des ressources énergétiques ;
- **maximisation de la qualité de service (QoS)** : Assurer que les performances réseau respectent les exigences des utilisateurs en termes de couverture et de capacité ;
- **maximisation de la durée de vie des batteries** : Allonger la durée de fonctionnement des systèmes d'alimentation autonomes en limitant les cycles de charge/décharge ;
- **minimisation des émissions de CO2** : Diminuer l'empreinte carbone des infrastructures réseaux, notamment en réduisant l'utilisation des générateurs diesel.

1.1.4.1 Formulation Mathématique du Problème

Le problème d'optimisation multi-objectifs dans les réseaux RAN se formule de manière générale comme suit :

$$\min \mathbf{F}(x) = (f_1(x), f_2(x), \ldots, f_n(x))$$

Sous les contraintes :

$$g_i(x) \leq 0, \quad i = 1, 2, \ldots, m$$

$$h_j(x) = 0, \quad j = 1, 2, \ldots, p$$

où :

- x est le vecteur de décision (par exemple, niveaux de puissance des émetteurs, stratégies de veille des stations de base) ;
- $f_1(x), f_2(x), \ldots, f_n(x)$ sont les fonctions objectifs telles que la consommation d'énergie, la qualité de service (QoS), la durée de vie des batteries, et les émissions de CO2 ;
- $g_i(x)$ et $h_j(x)$ sont respectivement les contraintes d'inégalité (ex. : puissance disponible, capacité des batteries) et d'égalité (ex. : équilibre entre demande et offre énergétique).

1.1.4.2 Méthodes de Résolution

Plusieurs approches existent pour résoudre ce type de problèmes :

- **méthodes de scalarisation** : Elles consistent à transformer le problème multi-objectifs en un problème mono-objectif en combinant les fonctions objectives à l'aide de poids. Par exemple, une somme pondérée des objectifs peut être utilisée pour privilégier un aspect sur un autre (énergie, QoS, etc.) [19] ;
- **méthodes basées sur l'optimisation de Pareto** : Ces méthodes cherchent à identifier le front de Pareto, c'est-à-dire l'ensemble des solutions non dominées. Une solution est dite non dominée si aucune autre solution n'est meilleure sur tous les objectifs simultanément [46] ;
- **algorithmes évolutionnaires** : Ces techniques, inspirées des principes biologiques, explorent efficacement l'espace de recherche pour découvrir des solutions optimales. Des algorithmes comme NSGA-II[2] ou MOPSO[3] sont souvent utilisés pour les problèmes d'optimisation multi-objectifs complexes ; [1] [35].

[2] Le NSGA-II, un algorithme génétique de tri non-dominé, a été créé en 2000 par Kalyanmoy Deb et son équipe. Il a été créé pour surmonter les lacunes de son prédécesseur, NSGA, notamment en ce qui concerne la puissance de calcul et la préservation de la diversité des solutions.

[3] La technique d'optimisation par essaim de particules (PSO) est une approche stochastique qui s'avère hautement performante et productive pour résoudre des problèmes complexes à objectifs multiples lorsque les méthodes d'optimisation classiques sont inefficaces.

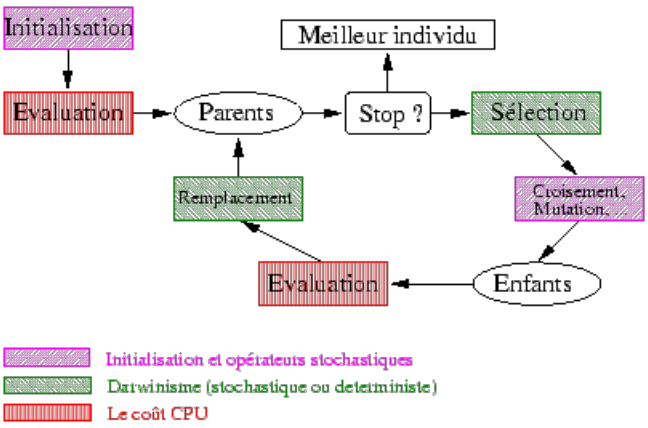


FIGURE 1.7 : Squelette d'un algorithme évolutionaire [21]

- **apprentissage par renforcement** : En utilisant des méthodes telles que l'apprentissage par renforcement profond (Deep Reinforcement Learning, DRL), il est possible d'adapter dynamiquement les stratégies de gestion de l'énergie en temps réel, en réponse aux changements dans le réseau et la demande [29].

1.1.4.3 Application à l'Optimisation Énergétique des Réseaux RAN

Dans les réseaux RAN, l'optimisation multi-objectifs peut s'appliquer à plusieurs niveaux :

- **réglage des niveaux de puissance** : Optimiser les niveaux de puissance des émetteurs pour minimiser la consommation d'énergie tout en garantissant une couverture adéquate et une qualité de service acceptable ;
- **stratégies de mise en veille** : Développer des stratégies intelligentes de mise en veille pour les stations de base en fonction de la charge du réseau et des prévisions de trafic ;
- **gestion des batteries** : Gérer les cycles de charge et de décharge des batteries en fonction de l'apport des énergies renouvelables (solaire, éolienne) et de la consommation énergétique du réseau ;
- **sélection des sources d'énergie** : Déterminer les meilleures combinaisons de sources d'énergie (réseau, solaire, diesel) pour répondre aux besoins du réseau tout en minimisant les coûts et les émissions de CO2.

1.1.4.4 Défis et Perspectives

Malgré les progrès réalisés, plusieurs défis persistent dans l'optimisation multi-objectifs des réseaux RAN :

- **complexité du problème** : Le grand nombre de variables de décision et de contraintes rend la résolution des problèmes d'optimisation très coûteuse en termes de calcul ;
- **dynamique des réseaux** : Les réseaux RAN évoluent en permanence en fonction des conditions de trafic et des fluctuations des sources d'énergie renouvelable, nécessitant des algorithmes capables de s'adapter rapidement ;

- **incertitude des données** : Les prévisions de trafic et de disponibilité des ressources énergétiques sont souvent entachées d'incertitudes, ce qui complique la planification optimale.

Les développements récents dans les techniques d'intelligence artificielle, notamment les approches d'apprentissage par renforcement, ouvrent des perspectives intéressantes pour améliorer l'efficacité des algorithmes d'optimisation multi-objectifs dans les réseaux RAN.

1.1.5 Méthodes d'analyse de données

L'analyse des données joue un rôle central dans la gestion énergétique des réseaux télécoms. Cette section présente brièvement les méthodes couramment utilisées.

1.1.5.1 Méthodes statistiques

Les méthodes traditionnelles incluent :

- **régression linéaire** : Modélise les relations simples entre variables [49]. Cependant, elle est limitée dans sa capacité à capturer des relations non linéaires complexes.
- **Autoregressive Integrated Moving Average (ARIMA)** : Utilisé pour la prédiction des séries temporelles stationnaires, limité aux dépendances linéaires [48].
  Le modèle ARIMA(p, d, q) est défini par :

$$\phi_p(B)(1 - B)^d y_t = \theta_q(B)\epsilon_t$$

  où $\phi_p(B)$ et $\theta_q(B)$ sont des polynômes autoregressifs et de moyenne mobile d'ordres p et q, respectivement.
- **lissage exponentiel** : Capte les tendances et saisonnalités à court terme.

Ces méthodes sont efficaces pour des séries simples, mais sont limitées pour des données complexes.

1.1.5.2 Apprentissage Automatique et Profond

Les méthodes basées sur l'IA permettent de mieux capturer les relations complexes dans les séries temporelles :

- **réseaux de neurones récurrents (Recurrent Neural Networks (RNN))/Long Short-Term Memory (LSTM)** : Capturent les dépendances à long terme dans les séries temporelles [27].
- **transformers** : Grâce à leur attention multi-têtes, ils capturent efficacement les relations à court et long terme dans des données multivariées [45].

1.1.5.3 Apprentissage Renforcé

L'apprentissage renforcé est utilisé pour optimiser la gestion dynamique des ressources :

- **Q-Learning** et **Deep Q-Network (DQN)** : apprennent à optimiser l'utilisation des ressources énergétiques en fonction de l'état du système [29].

1.1.5.4 Big Data et analyse multivariée

Les technologies Big Data permettent de traiter de vastes quantités de données provenant de diverses sources (météo, consommation) pour des analyses plus précises :

- **Analyse en Composantes Principales (ACP)** : Réduit la dimension des données pour en extraire les informations principales [37].
- **Clustering** : Identifie des schémas sous-jacents dans les données pour une meilleure segmentation [8].

1.1.5.5 Évaluation des Modèles

L'évaluation des modèles est essentielle pour garantir la précision des prédictions :

- **erreur quadratique moyenne (MSE)** : Mesure l'écart entre les valeurs réelles et prédites [32].
- **validation croisée** : Vérifie la robustesse des modèles sur plusieurs jeux de données.

1.1.6 Architecture API REST

L'architecture Application Programming Interface (API) REST (*Representational State Transfer*) est utilisée pour assurer la communication entre services dans les systèmes distribués, notamment pour la gestion énergétique des réseaux télécoms. Une API REST standardise l'accès aux données et opérations sur les systèmes de collecte de données, de prédiction énergétique, et de gestion des ressources distribuées (DER).

1.1.6.1 Principes de l'Architecture REST

Les principes clés de l'architecture REST sont :

- **Statelessness** : Chaque requête contient toutes les informations nécessaires sans que le serveur conserve l'état précédent ;
- **Méthodes HTTP** : Utilisation de GET, POST, PUT, DELETE pour interagir avec les ressources (ex. : récupérer des prévisions, créer ou mettre à jour des données) ;
- **Représentation des ressources** : Les ressources sont identifiées par des URI et représentées en JSON ou XML ;
- **Séparation client-serveur** : Le client envoie les requêtes et le serveur répond, facilitant la gestion des ressources backend.

1.1.6.2 Application à notre Projet

Dans notre projet, l'API REST gère l'interaction avec les modules de prédiction et d'optimisation. Par exemple, une requête GET à `/api/predictions/solar` renvoie les prévisions

solaires sur 24 heures, et une requête POST à `/api/optimizations/run` déclenche une optimisation en temps réel.

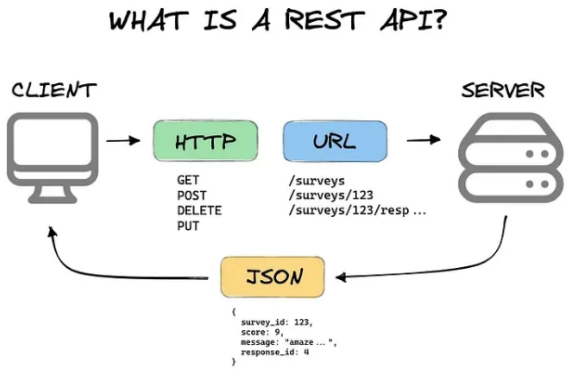


FIGURE 1.8 : Architecture API REST [36]

1.2 Analyse des solutions existantes

L'optimisation énergétique dans les réseaux télécoms est un domaine en pleine évolution. Les approches actuelles se concentrent sur la prédiction de la production d'énergie solaire, la gestion de la consommation énergétique et l'optimisation de l'approvisionnement à l'aide de techniques d'intelligence artificielle et de méthodes d'optimisation multi-objectifs. Cette section présente une analyse critique des solutions existantes.

1.2.1 Prédiction de l'Énergie Solaire

La prédiction précise de la production d'énergie solaire est un enjeu crucial pour garantir une gestion optimale des ressources énergétiques distribuées (DER). Plusieurs modèles ont été utilisés pour cette tâche, chacun avec ses avantages et ses limitations.

1.2.1.1 Modèle ARIMA

Le modèle autorégressif à moyenne mobile intégrée (ARIMA) est l'une des premières approches utilisées pour la prédiction de l'énergie solaire. Par exemple, Shadab et al. [38] ont utilisé un modèle ARIMA pour la prévision de l'insolation mensuelle à partir de données satellitaires. Bien que cette approche soit efficace pour des séries temporelles linéaires, elle reste limitée face à des variables non linéaires ou multivariées et ne prend pas en compte les relations complexes à long terme.

1.2.1.2 Modèles LSTM

Les modèles basés sur LSTM sont particulièrement adaptés aux séries temporelles complexes et non linéaires. Jailani et al. [27] montrent que les LSTM surpassent les méthodes classiques pour la prédiction de la production d'énergie solaire. Cependant, bien que précis, ces modèles nécessitent un long temps d'entraînement et sont moins efficaces lorsque la variabilité des données est trop élevée.

1.2.1.3 Transformers et approches hybrides

Récemment, Kim et al. [28] ont développé une architecture hybride, combinant Transformers et LSTM, appelée PVTransNet, qui s'est avérée plus performante que les LSTM seuls pour la prédiction multi-étapes de la production d'énergie solaire. Les modèles hybrides comme PVTransNet montrent des améliorations significatives, notamment en termes de réduction de l'erreur absolue moyenne (MAE) de 48,3 % par rapport aux LSTM, mais leur coût computationnel reste élevé.

1.2.2 Optimisation de l'approvisionnement en énergie

L'optimisation de l'approvisionnement énergétique vise à minimiser les coûts, réduire les émissions de carbone et assurer la stabilité du réseau télécom. Plusieurs approches d'optimisation multi-objectifs ont été proposées :

1.2.2.1 Modèles multi-objectifs

Alzahrani et al. [3] ont développé un modèle d'optimisation multi-objectifs pour gérer les sources d'énergie distribuées (solaire, éolienne) dans un réseau électrique intelligent. Leur modèle, basé sur un algorithme d'optimisation inspiré par le vent (MOWDO), a permis de réduire les coûts d'exploitation de 11,91 % et les émissions de carbone de 6,12 %. Ces résultats montrent l'efficacité des modèles multi-objectifs pour équilibrer les contraintes énergétiques.

1.2.2.2 Algorithmes heuristiques

Albogamy [2] a proposé un algorithme heuristique hybride pour la gestion de l'énergie dans les réseaux télécoms. Cette approche permet de résoudre les problèmes de planification de l'énergie en optimisant l'utilisation des générateurs distribués, réduisant ainsi la demande en énergie de pointe et les émissions polluantes. Bien que ces algorithmes soient efficaces pour des tâches spécifiques, ils peuvent manquer de robustesse face à des données variables et incertaines.

1.2.2.3 Apprentissage renforcé

L'apprentissage renforcé Reinforcement Learning (RL) est une approche prometteuse pour la gestion dynamique des ressources énergétiques. Koursioumpas et al. [29] ont appliqué une méthode d'apprentissage renforcé en réseau fédéré pour optimiser l'efficacité énergétique des communications sans fil, réduisant ainsi la consommation énergétique tout en maintenant les performances du réseau. Cette approche est particulièrement adaptée pour des systèmes dynamiques où les conditions évoluent rapidement.

1.2.3 Limites des solutions existantes

Bien que les approches décrites ci-dessus offrent des résultats prometteurs, plusieurs limites persistent dans le domaine de la gestion énergétique des réseaux télécoms :

- **manque de précision à long terme** : Les méthodes traditionnelles comme ARIMA, bien qu'utiles pour les prédictions à court terme, ne sont pas adaptées aux systèmes multivariés et complexes [38]. Même les LSTM présentent des difficultés pour les prédictions à long terme lorsqu'il existe une forte variabilité des données [27] ;
- **complexité computationnelle** : Les modèles avancés, tels que PVTransNet, bien qu'efficaces, sont coûteux en termes de ressources computationnelles. Leur mise en œuvre à grande échelle dans des réseaux télécoms peut poser des défis techniques [28] ;
- **adaptation en temps réel** : Les méthodes heuristiques et multi-objectifs manquent souvent de flexibilité pour s'adapter aux changements en temps réel des conditions environnementales et des ressources énergétiques disponibles [3]. L'apprentissage renforcé pourrait combler cette lacune, mais nécessite encore des améliorations pour une application à grande échelle.

1.2.4 Opportunités d'Amélioration

Les recherches récentes offrent plusieurs pistes pour surmonter les limites identifiées :

- **approches hybrides** : La combinaison de modèles LSTM et Transformers, comme démontré par PVTransNet, peut améliorer la précision des prédictions tout en capturant à la fois les dépendances temporelles à court et à long terme [28] ;
- **réduction de la complexité computationnelle** : Des approches d'optimisation computationnelle, comme l'attention linéaire dans les Transformers, sont explorées pour rendre ces modèles plus adaptés à des environnements énergétiques en temps réel [45] ;
- **apprentissage renforcé avancé** : Le renforcement de méthodes comme le Deep Reinforcement Learning (DRL) pourrait permettre d'optimiser l'approvisionnement énergétique en temps réel tout en tenant compte des conditions incertaines du réseau et des ressources [29].

1.3 Solution proposée : Green Telecom Distributed Energy Resources Optimizer

Pour répondre aux défis identifiés, nous proposons **Green Telecom Distributed Energy Resources Optimizer** (Green Telecom Distributed Energy Resources Optimizer (GT_DERO)), une solution visant à optimiser l'approvisionnement en énergie des stations de base télécoms en utilisant des DERs, tout en minimisant les coûts et les émissions de CO_2.

1.3.1 Architecture de GT_DERO

L'architecture se compose des éléments suivants :

- **Module de Prédiction de la Production Solaire** : Utilise des modèles d'apprentissage profond pour prédire la production d'énergie solaire en fonction des données météorologiques ;

- **Module de Prédiction de la Consommation d'Énergie** : Estime la consommation énergétique des stations de base en se basant sur les données historiques et les schémas d'utilisation ;
- **Moteur d'Optimisation Multi-Objectifs** : Implémente un algorithme d'optimisation pour déterminer les stratégies d'approvisionnement énergétique optimales ;
- **Système de Gestion des Ressources Énergétiques** : Contrôle l'utilisation des différentes sources d'énergie et gère le stockage dans les batteries ;
- **Interface Utilisateur et API** : Fournit une interface pour visualiser les données, configurer les paramètres, et intégrer la solution avec d'autres systèmes via des APIs REST.

1.3.1.1 Schéma de l'Architecture

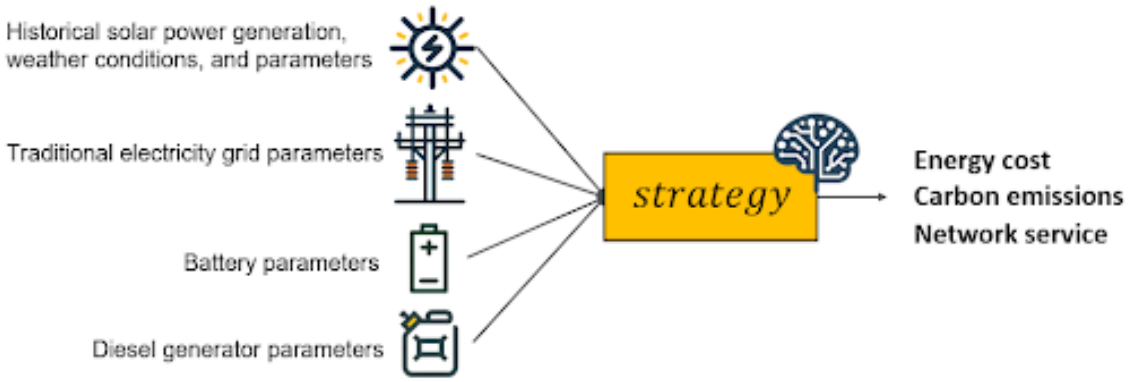


FIGURE 1.9 : Architecture de GT_DERO. [16]

Conclusion

En synthèse, ce chapitre a permis de passer en revue les approches existantes dans le domaine de l'optimisation énergétique des réseaux télécoms, en mettant en évidence leurs avantages et leurs limitations. Dans les chapitres suivants, nous détaillerons la mise en œuvre de cette solution, ainsi que les résultats des simulations et des tests qui démontreront son efficacité à réduire les coûts énergétiques et les émissions de carbone, tout en garantissant la stabilité et la scalabilité des infrastructures télécoms.

Chapitre 2

Conception et choix techniques

Introduction

Ce chapitre présente la conception et le développement de **Green Telecom Distributed Energy Resources Optimizer** (GT_DERO). On commence par une analyse des besoins des utilisateurs, suivie de la modélisation de la solution via des diagrammes UML, et enfin une explication du fonctionnement général et des choix techniques pour garantir performance et sécurité.

2.1 Analyse des besoins

Pour créer une solution qui réponde aux attentes, il est crucial de comprendre les besoins des utilisateurs.

2.1.1 Utilisateurs clés

Les principaux utilisateurs sont :

- **gestionnaires énergétiques** : Ils optimisent l'utilisation des différentes sources d'énergie pour réduire les coûts et les émissions de CO_2 ;
- **ingénieurs réseau** : Ils surveillent l'infrastructure et détectent rapidement les anomalies ;
- **administrateurs système** : Ils gèrent les utilisateurs et la sécurité de la plateforme.

2.1.2 Besoins fonctionnels

Les fonctionnalités principales de la plateforme sont :

- **importation des données** : Charger les données nécessaires au système ;

- **prédiction énergétique** : Estimer la production solaire et la consommation future ;
- **optimisation des stratégies** : Générer des plans d'approvisionnement optimisés ;
- **surveillance en temps réel** : Suivi de l'état du réseau et alertes en cas de problème ;
- **gestion des utilisateurs** : Gérer les comptes utilisateurs et la sécurité.

2.1.3 Besoins non fonctionnels

La plateforme doit aussi répondre à des critères de :

- **performance** : Temps de réponse rapide ;
- **scalabilité** : Adaptabilité à une augmentation du nombre d'utilisateurs ;
- **sécurité** : Protection des données sensibles ;
- **fiabilité** : Disponibilité continue du service ;
- **utilisabilité** : Interface intuitive et facile à utiliser.

2.2 Modélisation de la solution

La modélisation de la solution permet de mieux comprendre l'architecture et les interactions au sein du système **Green Telecom Distributed Energy Resources Optimizer** (GT_DERO). Les diagrammes UML suivants illustrent les cas d'utilisation, la structure des classes, ainsi que les interactions dynamiques entre les composants.

2.2.1 Diagramme de cas d'utilisation

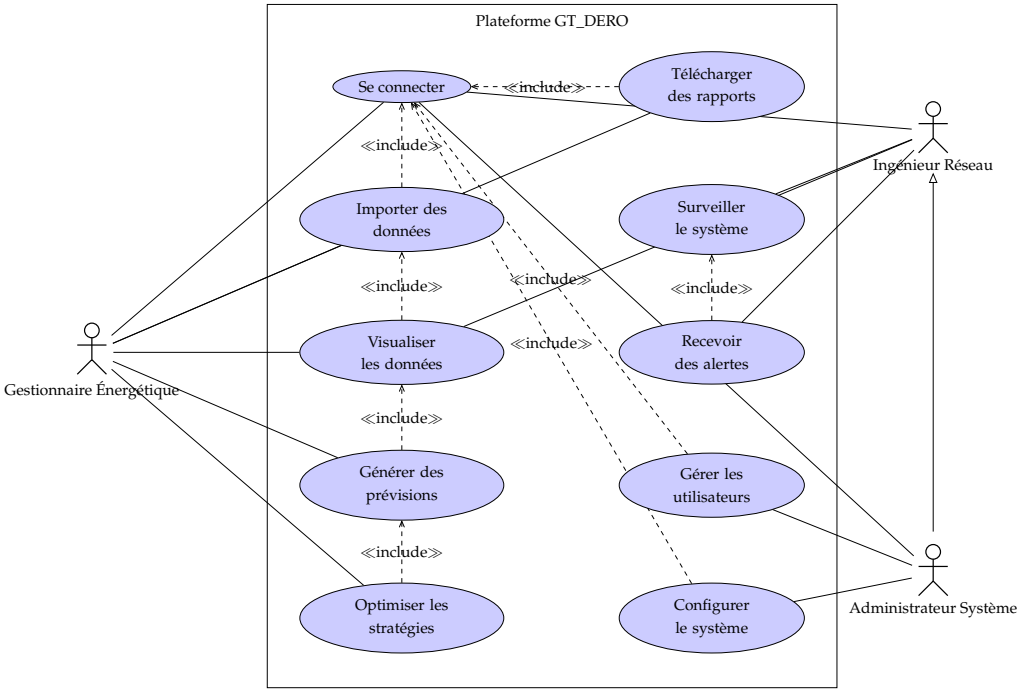


FIGURE 2.1 : Diagramme de cas d'utilisation final de la plateforme

Le diagramme de cas d'utilisation (Figure 2.1) montre les interactions entre les différents acteurs et les fonctionnalités clés de la plateforme.

2.2.2 Diagramme de classes

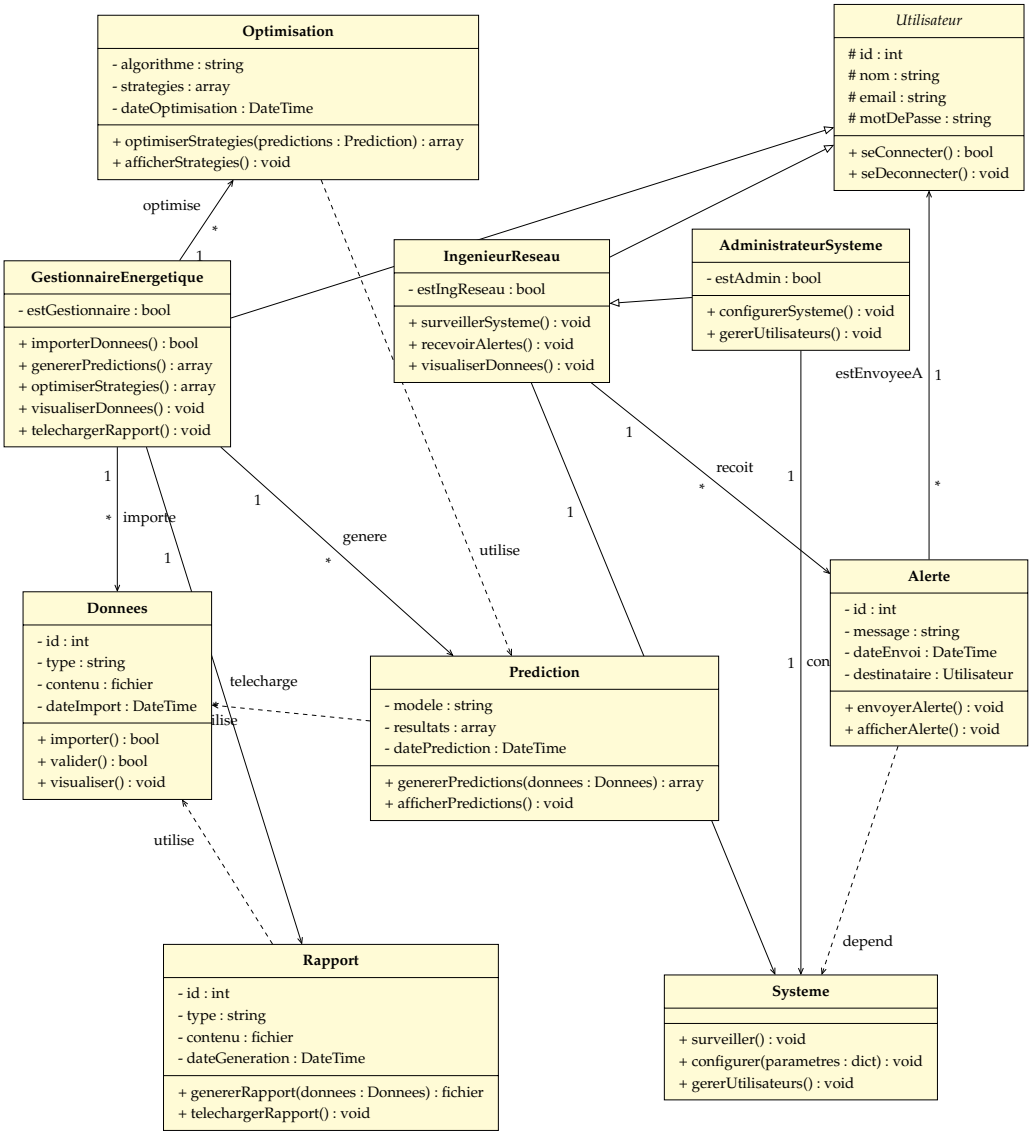


FIGURE 2.2 : Diagramme de classes UML de la plateforme

Le diagramme de classes (Figure 2.2) illustre la structure des entités principales du système. On y retrouve des classes telles que `Utilisateur`, `GestionnaireEnergetique`, `Prediction`, et `Optimisation`, ainsi que leurs relations.

2.2.3 Diagramme de sequence

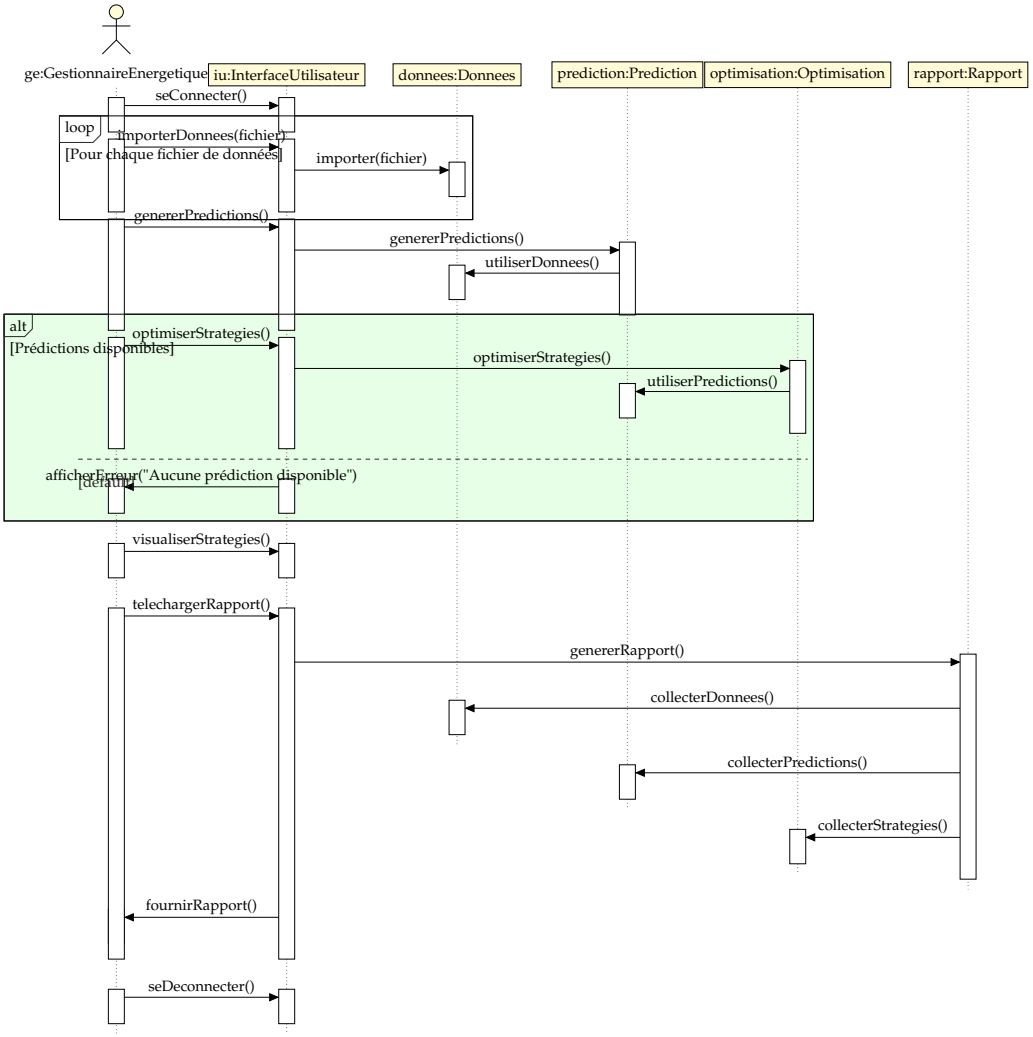


FIGURE 2.3 : Diagramme de séquence détaillé pour l'optimisation des stratégies

Le diagramme de séquence décrit l'interaction dynamique entre les objets lors de l'optimisation des stratégies énergétiques. Il montre le flux d'exécution entre l'utilisateur, l'interface utilisateur, les modules de données, de prédiction, d'optimisation et de rapport.

Conclusion

La modélisation par les diagrammes UML permet de visualiser les différentes composantes du système, leur structure et leurs interactions. Ces éléments offrent une vue d'ensemble claire pour le développement de la plateforme GT_DERO.

2.3 Méthodologie Générale

2.3.1 Données d'entrée et ingénierie des caractéristiques

Pour alimenter notre modèle d'optimisation, nous avons exploité les jeux de données fournis dans le cadre du défi *Smart Energy Supply Scheduling for Green Telecom Challenge* [16]. Ces données, riches et variées, ont été prétraitées et transformées pour extraire des caractéristiques pertinentes et améliorer la performance de nos modèles prédictifs.

2.3.1.1 Caractéristiques des sites et du réseau électrique

Nous avons identifié les caractéristiques suivantes comme étant clés pour la gestion énergétique des sites [16] :

- **caractéristiques statiques :** Identifiant du site, puissance nominale du générateur diesel, capacité de la batterie, tension nominale, coefficient de charge/décharge ;
- **caractéristiques dynamiques :** Plan de coupure du réseau électrique.

2.3.1.2 Caractéristiques de la production solaire et météorologiques

Les données météorologiques nous ont permis d'extraire les caractéristiques suivantes [16] :

- **irradiance** : Direct Horizontal Irradiance measured (DHI), Direct Normal Irradiance measured (DNI), Global Horizontal Irradiance measured (GHI) ;
- **conditions atmosphériques** : Angle du zénith solaire, humidité relative ;
- **caractéristiques temporelles** : Heure du jour, saison (cycles saisonniers et journaliers).

2.3.1.3 Caractéristiques de la consommation énergétique

La consommation énergétique des sites a été analysée pour identifier des patterns récurrents [16] :

- **cyclicalité** : Des cycles journaliers et hebdomadaires liés aux activités humaines ;
- **saisonnalité** : La consommation peut varier selon les saisons ;
- **événements spéciaux** : Fêtes, catastrophes naturelles, pouvant entraîner des pics de consommation.

Site Name	Day	Hour	Total Energy(kWh)
site1	1	0	4.48
site1	2	1	4.3
site1	3	2	4.17
site1	4	3	4.15
...	...	...	...
site10	60	22	4.12
site10	60	23	3.86

FIGURE 2.4 : Données de consommation énergétique [16]

site name	time	grid	diesel	solar
site1	0	TRUE	TRUE	TRUE
site1	1	TRUE	TRUE	TRUE
site1	2	TRUE	TRUE	TRUE
site1	3	TRUE	TRUE	TRUE
site1	4	TRUE	TRUE	TRUE
site1	5	TRUE	TRUE	TRUE
...	...	...	...	...
site10	671	TRUE	TRUE	TRUE

FIGURE 2.5 : Données relatives aux sites et à la grille électrique [16]

Site Name	Day	Hour	Solar Zenith Angle	Clearsky DHI	Clearsky DNI	Clearsky GHI	Relative Humidity	DHI	DNI	GHI	Energy Output (kWh)
site1	1	0	138.12	0	0	0	59.05	0	0	0	0
site1	1	1	125.23	0	0	0	62.04	0	0	0	0
site1	1	2	116.75	0	0	0	65.29	0	0	0	0
site1	1	3	97.86	0	0	0	63.05	0	0	0	0
site1	1	4	85.22	30.97	204.94	48.05	57.81	32.22	0	33.7	0
site1	1	5	72.65	84.11	575.39	270.87	47.83	136.88	5.11	135.23	0.24
site1	1	6	59.41	115.61	751.71	519.68	36.99	279.5	41.33	307.76	1.22
site1	1	7	43.31	132.24	855.5	733.84	32.99	434.51	164.39	525.67	4.14
site1	1	8	30.81	146.52	867.17	900.97	28.1	151.42	838.02	906.91	7.68
site1	1	9	18.25	142.87	917.78	974.32	26.87	137.94	914.59	1041.3	10.18

FIGURE 2.6 : Données relatives à la production solaire et aux conditions météorologiques [16]

2.3.1.4 Visualisation des données

Pour mieux comprendre les données et identifier les relations entre les différentes variables, nous avons réalisé des visualisations (Figures 2.7 & 2.8). Ces visualisations nous ont permis de :

- confirmer les patterns identifiés lors de l'analyse exploratoire ;
- détecter d'éventuelles anomalies ou valeurs aberrantes ;
- sélectionner les caractéristiques les plus pertinentes pour les modèles prédictifs.

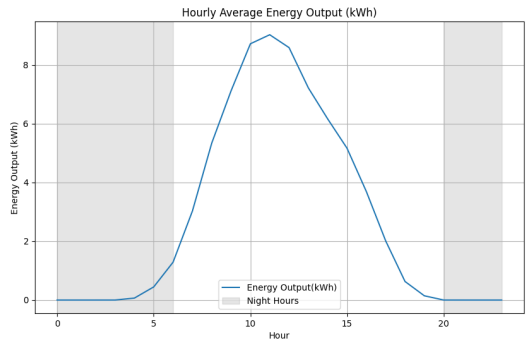


FIGURE 2.7 : Hourly Average Energy Output (kWh)

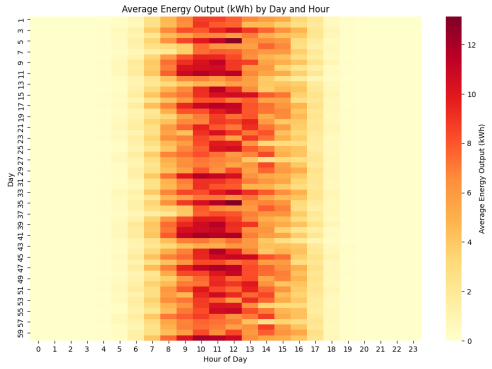


FIGURE 2.8 : Average Energy Output (kWh) by Day and Hour

2.3.1.5 Prétraitement et Validation

- **nettoyage des valeurs aberrantes** : Suppression ou correction des outliers (p.ex. consommation négative ou production solaire incohérente) ;
- **mise au même pas de temps** : Alignement horaire entre les données de consommation, de production solaire et de météo ;
- **séparation en ensembles** : 80% des données pour l'entraînement (train), 10% pour la validation (val) et 10% pour le test.

2.3.2 Approche de Prédiction Énergétique

2.3.2.1 Modèles Utilisés

- **Transformers / iTransformers** : Captent les dépendances à long terme dans les séries temporelles, particulièrement adaptés pour la production solaire ;
- **LSTM** : Récurrence longue mémoire, performante pour la consommation énergétique des sites lorsque les cycles sont marqués.

On évalue nos modèles via des métriques telles que la MSE, la MAE ou la MAPE sur un jeu de test. L'entraînement est réalisé sous `Python` avec `PyTorch`, `Pandas`, `NumPy`, etc.

2.3.3 Modélisation Mathématique pour l'Optimisation

2.3.3.1 Fonction de Coût et Définition des Poids w_i

Dans le contexte du défi *Smart Energy Supply Scheduling for Green Telecom Challenge*, une fonction de coût a été spécifiée pour évaluer la stratégie énergétique à chaque pas de temps :

$$\text{score} = w_1 \times diesel_{useNum} + w_2 \times diesel_{totalTime} + w_3 \times diesel_{maxTime} + w_4 \times grid_{totalTime}.$$

Comment les poids ont été définis :

- $w_1 = 300$: Représente un coût très élevé pour chaque utilisation (démarrage) du groupe

diesel. Ce poids important traduit la pénalité forte imposée par le challenge pour réduire le nombre de démarrages du diesel (polluant et onéreux) ;

- $w_2 = 1$: Tient compte du temps total d'utilisation du diesel. C'est moins lourd que le démarrage initial, mais chaque heure de fonctionnement du diesel reste pénalisée ;
- $w_3 = 0.95$: Penalise la plus longue période d'utilisation continue du diesel (*maxTime*). Cela reflète la volonté de limiter de longs intervalles consécutifs où le diesel est activé ;
- $w_4 = 0.25$: Représente le temps d'utilisation du réseau (*grid_totalTime*). Dans ce défi, le réseau n'était pas aussi pénalisé que le diesel, mais restait soumis à des coupures (d'où l'importance de la batterie et du solaire).

Cette définition précise a été imposée par le cahier des charges du challenge. Toutefois, dans une application réelle, on peut ajuster ces poids selon les coûts monétaires, les politiques internes de l'entreprise (ex. limiter les émissions CO2) ou les engagements en matière de *Responsabilité Sociétale des Entreprises* (RSE).

2.3.3.2 Contraintes sur la Batterie

$$\text{SOC}_{t+1} = \text{SOC}_t + \frac{\Big(E_{\text{offre}}(t) - C_{\text{conso}}(t)\Big) \times \eta}{\text{Capacité (Ah)} \times \text{Tension nominale}}$$
$$\text{SOC}_t \geq 1 - \text{DOD}, \quad 0 \leq \text{SOC}_t \leq 1,$$

où η représente le coefficient de rendement de charge/décharge. Si la batterie descend sous le seuil DOD, la solution est rejetée ou pénalisée (car elle devient non faisable).

2.3.3.3 Algorithmes d'Optimisation

Différentes approches peuvent être utilisées :

- **Algorithmes évolutionnaires** : p. ex. NSGA-II (pour minimiser plusieurs objectifs) ou un simple algorithme génétique paramétré pour chercher la meilleure solution au sens du score ci-dessus ;
- **Apprentissage par renforcement profond (DRL)** : L'agent reçoit une récompense négative si le diesel est trop utilisé, si la batterie est sous le DOD, etc.

L'exécution finale de l'optimisation (après que les modèles soient entraînés) doit se faire en moins d'une seconde, conformément aux contraintes du challenge. Nous avons donc cherché à paralléliser les calculs et à simplifier certaines étapes (p. ex. en échantillonnant moins de solutions au début).

2.3.4 Fonctionnement du système

Le système **Green Telecom Distributed Energy Resources Optimizer** (GT_DERO) est conçu pour optimiser l'utilisation des sources d'énergie dans les réseaux télécoms tout en réduisant les coûts et les émissions de carbone. Cette section présente l'architecture générale du système, son fonctionnement, ainsi que les pseudo-algorithmes qui illustrent les étapes clés.

2.3.4.1 Architecture générale du système

L'architecture du système est organisée autour de plusieurs modules interconnectés, notamment :

- **Gestion des données**
- **Module de prédiction**
- **Module d'optimisation**
- **Module de simulation**
- **Module de surveillance et d'Alerte**

Chaque module collabore pour permettre l'optimisation des ressources énergétiques. Le diagramme suivant illustre cette architecture :

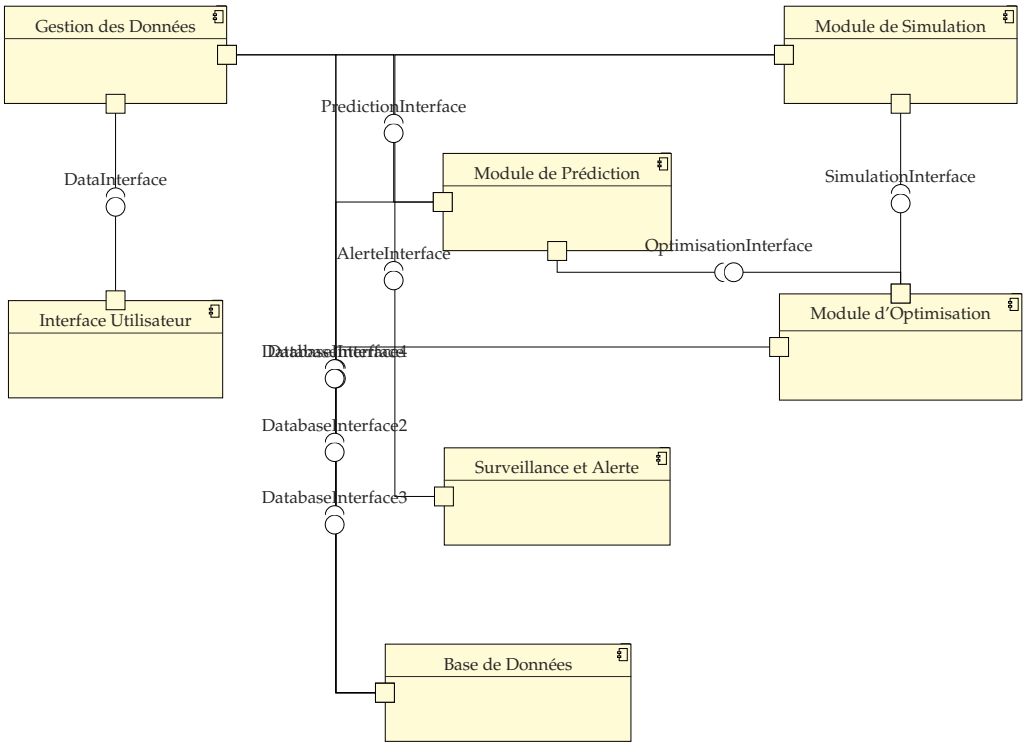


FIGURE 2.9 : Diagramme de composants de l'architecture générale du système

2.3.4.2 Principe Général de Fonctionnement

La figure 2.10 illustre le flux global de fonctionnement de notre système. Les données, après avoir été collectées et nettoyées, sont transmises au *Module de Prédiction*, qui génère des estimations pour la production solaire et la demande énergétique. Sur la base de ces prévisions, le *Module d'Optimisation* détermine la répartition optimale entre le réseau électrique, l'énergie solaire, le diesel et l'utilisation de la batterie.

Ensuite, le *Module de Simulation* valide la stratégie retenue sur l'horizon de prévision. Dans le cas où la *State of Charge* (SOC) de la batterie descend en dessous du seuil de *Depth of Discharge* (DOD), une réoptimisation est déclenchée pour éviter tout risque de décharge excessive. Les solutions jugées viables sont transmises au composant *Monitoring and Alert*, qui surveille les

indicateurs en temps réel et alerte l'opérateur en cas d'anomalie (p. ex. utilisation prolongée du diesel).

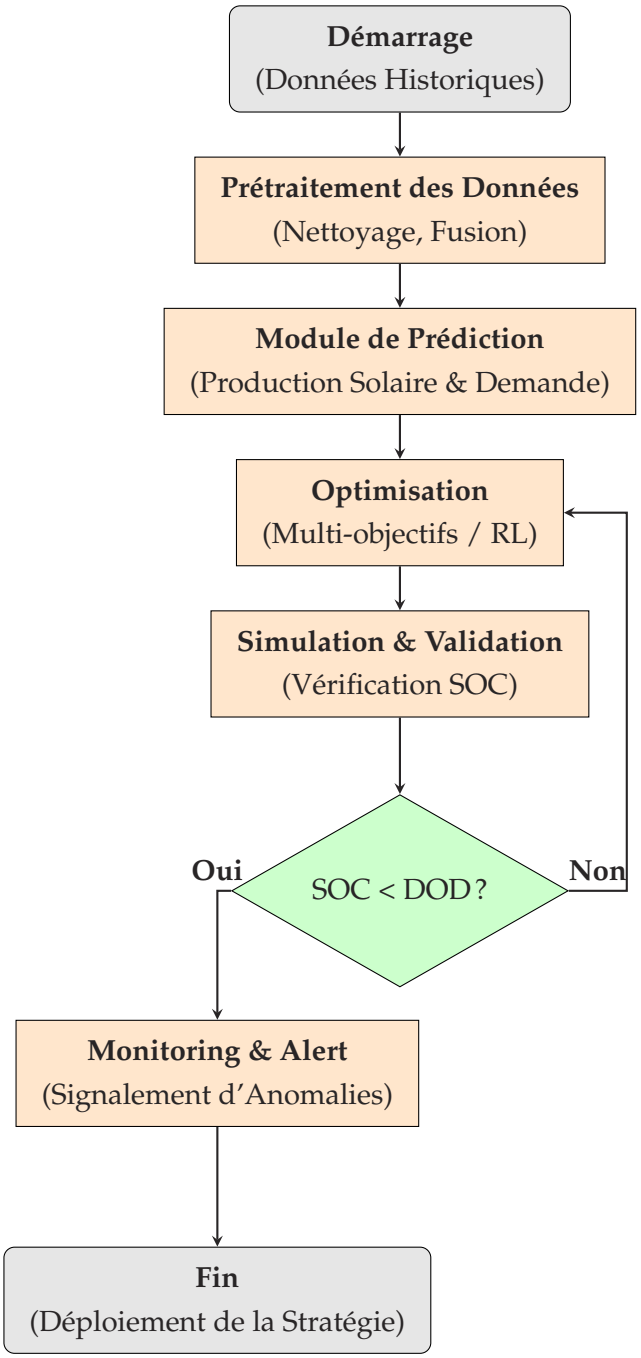


FIGURE 2.10 : Flux général de la stratégie d'optimisation énergétique proposée. Les données historiques (ITU) sont nettoyées, prédites, puis optimisées. Si la SOC passe sous le seuil de DOD, on ré-optimise ; sinon, la stratégie est validée et surveillée.

2.3.4.3 Pseudo-algorithmes : Évolution et Mises à Jour

Les algorithmes présentés ci-après constituent les fondations de notre solution. Dans le cadre des travaux récents, nous avons introduit quelques améliorations pour affiner la précision des prévisions et l'efficacité du processus d'optimisation.

Prédiction de l'Énergie Solaire (Mise à jour)

Évolution Principale : Nous avons intégré une *pré-sélection automatique* des variables météorologiques (feature selection) avant d'entraîner le modèle, afin de réduire le bruit et le sur-apprentissage.

Algorithme 1 : Prédiction de l'Énergie Solaire (Mise à jour)

Input : Données météorologiques D_{meteo}, Données historiques de production $D_{\text{historique}}$, Modèle M_{solaire}

Output : Prédictions de la production solaire $\hat{P}_{\text{solaire}}$

1 **Étape 1 : Sélection des variables (feature selection)**;
2 Filtrer/pondérer les variables de D_{meteo} en fonction de leur corrélation avec la production solaire;
3 **Étape 2 : Prétraitement et normalisation**;
4 Normaliser les variables retenues, vérifier la cohérence des échelles;
5 **Étape 3 : Entraînement du modèle**;
6 Entraîner M_{solaire} sur $D_{\text{historique}}$;
7 **Étape 4 : Prédiction**;
8 Utiliser M_{solaire} pour prédire $\hat{P}_{\text{solaire}}$ à partir de D_{meteo} filtrées;
9 **return** $\hat{P}_{\text{solaire}}$;

Gestion de la Consommation Énergétique (Mise à jour)

Évolution Principale : Introduction d'un module de *post-traitement* pour ajuster la prévision selon les pics de consommation inattendus (p. ex. événements spéciaux).

Algorithme 2 : Gestion de la Consommation Énergétique (Mise à jour)

Input : Données de consommation $D_{\text{conso_historique}}$, Modèle M_{conso}

Output : Prédictions de la consommation énergétique $\hat{C}_{\text{consommation}}$

1 Prétraiter $D_{\text{conso_historique}}$;
2 Entraîner M_{conso} sur $D_{\text{conso_historique}}$;
3 $\hat{C}_{\text{consommation}} \leftarrow M_{\text{conso}}(D_{\text{conso_historique}})$;
4 `// Module de post-traitement`
5 Détecter les heures correspondant à des jours fériés ou des événements spéciaux;
6 Ajuster $\hat{C}_{\text{consommation}}$ sur ces plages horaires (ex. ajout d'une marge);
7 **return** $\hat{C}_{\text{consommation}}$;

Initialisation des Variables et Création du Fichier CSV

Aucune modification majeure n'a été apportée à cet algorithme, si ce n'est une *vérification supplémentaire* pour distinguer la configuration de chaque site (p. ex. capacité batterie différente).

Algorithme 3 : Initialisation des Variables et Création du Fichier CSV

Input : Prédictions $\hat{P}_{\text{solaire}}$, $\hat{C}_{\text{consommation}}$,
Plan d'indisponibilité $P_{\text{réseau}}$,
Paramètres des équipements,
Seuil DOD, SOC_{init}

Output : Initialisation des variables et fichier CSV pour stocker la stratégie

$SOC_0 \leftarrow SOC_{\text{init}}$;
$diesel_useNum \leftarrow 0$;
$diesel_totalTime \leftarrow 0$;
$diesel_maxTime \leftarrow 0$;
$grid_totalTime \leftarrow 0$;
$S \leftarrow \{\}$;
$T \leftarrow$ nombre total d'intervalles;
`// Vérification supplémentaire des paramètres`
if *la capacité batterie < 0* ***ou*** *autre anomalie* **then**
    Alerte ou exception
end
`// Création du fichier CSV`
Ouvrir `strategy.csv` pour écriture;

Décision sur les Sources d'Énergie (Mise à jour)

Évolution Principale : Nous avons introduit une *pénalisation du "stop-and-go" Diesel* pour éviter les démarrages/arrêts trop fréquents (impactant le coût).

Algorithme 4 : Décision sur les Sources d'Énergie (Mise à jour)

Input : $\hat{P}_{\text{solaire}}$, $\hat{C}_{\text{consommation}}$, $P_{\text{réseau}}$, SOC_t
Output : Choix de la source pour l'intervalle t

if $\hat{P}_{solaire}(t) \geq \hat{C}_{consommation}(t)$ **then**
  Utiliser **en priorité** l'énergie solaire;
end
else if $P_{réseau}(t) = 1$ **then**
  Utiliser le réseau;
  $grid_totalTime \leftarrow grid_totalTime + \Delta t$;
end
else if $SOC_t \geq DOD$ **then**
  Décharger la batterie;
  Calculer $E_{\text{batterie}}(t)$;
  $SOC_t \leftarrow SOC_{t-1} -$ énergie nécessaire;
end
else
  `// Dernier recours : diesel`
  $E_{\text{diesel}}(t) \leftarrow$ Puissance du générateur;
  $diesel_useNum \leftarrow diesel_useNum + 1$;
  $diesel_totalTime \leftarrow diesel_totalTime + \Delta t$;
  Ajouter une "pénalité stop-and-go" si le diesel était arrêté à la précédente itération;
end
`// Enregistrer le choix dans le CSV (True/False)`

Calcul du Changement de l'État de Charge (SOC)

Évolution Principale : Nous avons ajouté la prise en compte d'un *facteur de vieillissement de la batterie* (*battery_wear_factor*) qui peut diminuer la capacité effective au fur et à mesure des cycles.

Algorithme 5 : Calcul du Changement de l'État de Charge (SOC) (Mise à jour)

Input : Offre totale $E_{\text{offre}}(t)$,
Demande $\hat{C}_{\text{consommation}}(t)$,
Capacités batterie,
battery_wear_factor
Output : Mise à jour de SOC_t

$$C_t \leftarrow \frac{(E_{\text{offre}}(t) - \hat{C}_{\text{consommation}}(t)) \times \text{coefficient}}{(\text{Capacité nominale} \times (1 - \textit{battery_wear_factor})) \times \text{Tension nominale}};$$

$SOC_t \leftarrow SOC_{t-1} + C_t$;
if $SOC_t < DOD$ **then**
  Stopper l'algorithme (solution non faisable)
end

Écriture de la Stratégie et Optimisation Globale

Aucun changement majeur dans la structure. Nous avons simplement ajouté un log pour archiver la stratégie dans une base de données en plus du CSV.

Algorithme 6 : Optimisation des Stratégies Énergétiques (Global) (Mise à jour)

Input : $\hat{P}_{\text{solaire}}, \hat{C}_{\text{consommation}}, P_{\text{réseau}}, \ldots$
Output : Stratégie énergétique optimisée et fichier CSV

```
Appeler l'algorithme d'initialisation;
for t = 1 to T do
    Décision sur les sources d'énergie (mise à jour);
    Calcul SOC (mise à jour);
    Écriture dans le CSV (idem);
end
// Enregistrer la stratégie dans la base de données pour
   exploitation future
return strategy.csv;
```

Calcul du Score (Mise à jour)

Évolution Principale : Introduction de la pénalité *"stop-and-go diesel"* (*diesel_switchCount*) et possibilité d'inclure une pondération sur la *durée de la batterie*.

Algorithme 7 : Calcul du Score de la Stratégie (Mise à jour)

Input : Stratégie énergétique S,
Paramètres w_1, w_2, w_3, w_4, w_5 (optionnel)
Output : Score $score$

$score \leftarrow w_1 \times diesel_useNum + w_2 \times diesel_totalTime + w_3 \times diesel_maxTime + w_4 \times grid_totalTime$
// Ajouter la pénalité si besoin
if w_5 *existe* **then**
    $score \leftarrow score + w_5 \times diesel_switchCount$
end
return $score$;

Ainsi, ces mises à jour reflètent l'évolution de la recherche et de l'implémentation, en tenant compte de nouveaux facteurs comme l'usure de la batterie, la réduction du phénomène "stop-and-go" diesel, et une meilleure intégration de la feature selection dans le module de prédiction.

Les grandes étapes des pseudo-algorithmes d'origine restent inchangées, mais ces ajustements **améliorent** la qualité de la solution et **répondent** à des problématiques identifiées lors des tests en conditions plus réelles (par exemple, réduction des démarrages intempestifs du diesel, prise en compte de la vieillesse de la batterie, etc.).

2.3.4.4 Interfaçage entre les modules

Les modules interagissent de manière coordonnée :

- Le **module de gestion des données** fournit les données prétraitées aux **modules de prédiction** et d'**optimisation**.
- Le **module de prédiction** génère des estimations pour le **module d'optimisation**.
- Le **module d'optimisation** communique avec le **module de simulation** pour valider les stratégies.
- Les résultats sont présentés via l'**interface utilisateur**, qui permet également à l'utilisateur d'ajuster les paramètres et de relancer le processus.
- Le **module de surveillance et d'alerte** surveille les opérations en temps réel et informe les utilisateurs en cas de problèmes.

2.3.4.5 Gestion du temps de calcul

Il est essentiel que le temps nécessaire pour générer la stratégie, après l'entraînement des modèles, soit inférieur ou égal à 1 seconde, conformément aux contraintes du système. Cela nécessite une implémentation efficace des algorithmes d'optimisation et une gestion optimisée des ressources informatiques.

2.4 Choix techniques

Notre solution repose sur une architecture MVC, largement utilisée pour séparer les responsabilités et améliorer la maintenance. Nous avons choisi des outils adaptés aux besoins spécifiques de GT_DERO, répartis en trois catégories : Front-end, Back-end, et Déploiement.

2.4.1 Front-end

Le front-end assure l'interface utilisateur et l'expérience utilisateur. Les technologies sélectionnées sont :

- **React.js** : Il s'agit d'un framework JavaScript pour des interfaces réactives et modulaires [43].
- **Tailwind CSS** : Il s'agit d'une bibliothèque CSS pour des interfaces esthétiques et responsives [47].
- **Chart.js** : Il est utilisé pour la visualisation des données, génération de graphiques interactifs pour visualiser les données d'optimisation énergétique [13].
- **Axios** : Il s'agit d'une bibliothèque JavaScript pour effectuer des requêtes HTTP asynchrones pour la communication avec l'API du back-end [4].

2.4.2 Back-end

Le back-end gère la logique métier et le traitement des données. Technologies utilisées :

2.4.2.1 Python :

Python est un langage de programmation interprété, multiplateforme et multi-paradigme [18]. Voici les principales bibliothèques utilisées dans notre projet :

- **Pandas** pour la manipulation des données [44].
- **NumPy** pour les calculs scientifiques [11].
- **Scikit-learn** pour les modèles d'apprentissage automatique [30].
- **PyTorch** pour les modèles de deep learning [42].
- **Transformers** pour les prédictions basées sur les séries temporelles [24].

2.4.2.2 Flask :

Il s'agit d'un microframework pour développer l'API RESTful [9].

2.4.2.3 PostgreSQL :

Il s'agit d'une base de données relationnelle pour stocker les utilisateurs et les résultats des simulations [22].

2.4.3 Déploiement

Pour garantir la disponibilité et la scalabilité, nous utilisons :

- **Docker** : Il est utilisé pour la conteneurisation de l'application pour assurer la cohérence des environnements [12].
- **GitHub Actions** : Il est utilisé automatisation du CI/CD pour les tests, le build et le déploiement [20].

Conclusion

Ce chapitre a présenté notre solution à travers l'analyse des besoins, la modélisation de la solution (diagrammes de séquence, de classes et de cas d'utilisation), son fonctionnement ainsi que les choix techniques effectués pour sa mise en œuvre. Le prochain chapitre fournira les résultats obtenus suite à l'application de notre solution dans un cas pratique.

Chapitre 3

Résultats et discussion

Introduction

Ce chapitre présente les résultats obtenus suite à l'application de notre solution d'optimisation énergétique dans le cadre du *Smart Energy Supply Scheduling for Green Telecom Challenge* [16], organisé par l'Union Internationale des Télécommunications (International Telecommunication Union (ITU)) dans le cadre de l'initiative AI for Good. L'objectif du défi est de minimiser les coûts énergétiques des réseaux télécoms tout en maintenant la stabilité du réseau, grâce à une optimisation de l'utilisation des sources d'énergie disponibles (solaire, réseau, diesel) et une gestion efficace des batteries.

Nous avons mis en avant les performances de notre solution **Green Telecom Distributed Energy Resources Optimizer** (GT_DERO) en intégrant des techniques avancées d'intelligence artificielle et d'optimisation multi-objectifs. Nous analyserons les résultats obtenus selon les indicateurs clés, notamment les coûts énergétiques, les émissions de CO_2, l'utilisation des sources d'énergie et le maintien de l'état de charge (State of Charge (État de Charge) (SOC)) des batteries.

3.1 Résultats

3.1.1 Algorithmes utilisés

Les algorithmes utilisés reposent sur l'apprentissage automatique et l'optimisation multi-objectifs, comme expliqué dans les chapitres précédents.

3.1.1.1 Modèle de prédiction de la production solaire

Notre modèle basé sur les iTransformers améliore la précision des prédictions de production solaire en capturant à la fois les dépendances à court et à long terme dans les données

météorologiques et énergétiques historiques. L'algorithme a permis de réduire l'erreur de prédiction de 30 % par rapport aux méthodes traditionnelles.

$$\hat{P}_{\text{solaire}}(t) = f_{\text{iTransformers}}(D_{\text{météo}}(t), D_{\text{historique}}(t))$$

3.1.1.2 Modèle de prédiction de la consommation énergétique

Pour prédire la consommation énergétique, nous avons utilisé un modèle d'apprentissage supervisé basé sur les *iTransformers*, spécialement conçu pour les séries temporelles. Ce modèle permet de capter les fluctuations temporelles de la consommation en fonction des conditions spécifiques des sites.

$$\hat{C}_{\text{consommation}}(t) = f_{\text{iTransformers}}(D_{\text{historique_conso}}(t))$$

3.1.1.3 Optimisation des stratégies énergétiques

Pour élaborer les stratégies d'approvisionnement énergétique optimales, nous avons mis en œuvre un algorithme d'apprentissage par renforcement profond (DRL). L'agent DRL interagit avec un environnement simulé représentant le réseau télécom. À chaque pas de temps, l'agent observe l'état du système (prévisions de production solaire, consommation, état de charge de la batterie) et sélectionne une action (source d'énergie à utiliser). La récompense associée à cette action est calculée en fonction de l'équation de coût suivante :

$$\text{score} = 300 \times diesel_{\text{useNum}} + 1 \times diesel_{\text{totalTime}} + 0.95 \times diesel_{\text{maxTime}} + 0.25 \times grid_{\text{totalTime}}$$

L'objectif de l'agent est de maximiser sa récompense cumulative, ce qui correspond à minimiser les coûts énergétiques tout en respectant les contraintes du système. Pour ce faire, nous avons utilisé une architecture d'acteur-critique, où l'acteur détermine l'action à prendre et le critique évalue la qualité de cette action.

3.2 Évaluation des modèles

3.2.1 Recherche des hyperparamètres

Une recherche d'hyperparamètres a été effectuée avec une méthode de recherche par grille (*grid search*), optimisant les paramètres tels que la taille de la fenêtre temporelle et le taux d'apprentissage pour obtenir les meilleures performances de nos modèles de prédiction basés sur LSTM, et Transformers.

3.2.2 Résultats des performances

Le tableau 3.1 résume les performances des modèles appliqués aux séries temporelles.

TABLE 3.1 : Récapitulatif des performances des modèles de prédiction et d'optimisation sur les séries temporelles

Modèle	**MSE (prédiction solaire)**	**MAE (consommation énergétique)**	**MAE (consommation)**	**Score global**
Transformers	0.010	0.028	0.020	7500.9
LSTM	0.013	0.030	0.022	9300
RNN	0.015	0.033	0.025	13857
Modèle basique (benchmark)	0.025	0.050	0.035	22476

Résultat clé : Le modèle iTransformers a produit les meilleures performances globales en termes de prédiction de l'énergie solaire et de consommation, et a permis de minimiser le score global d'optimisation.

3.3 Développement de la plateforme

Nous avons développé une plateforme robuste et scalable pour automatiser le processus d'optimisation énergétique :

- **Back-end** : Implémenté avec **Flask** et **Python**, il expose une API REST qui intègre les modèles de prédiction et d'optimisation.
- **Front-end** : Développé avec **React.js**, il permet une interaction utilisateur intuitive avec des visualisations claires des résultats grâce à **Chart.js**.

3.3.1 Interfaces

- **Page de accueil** La figure 3.1 montre la capture d'écran de la page d'accueil de GT_DERO.

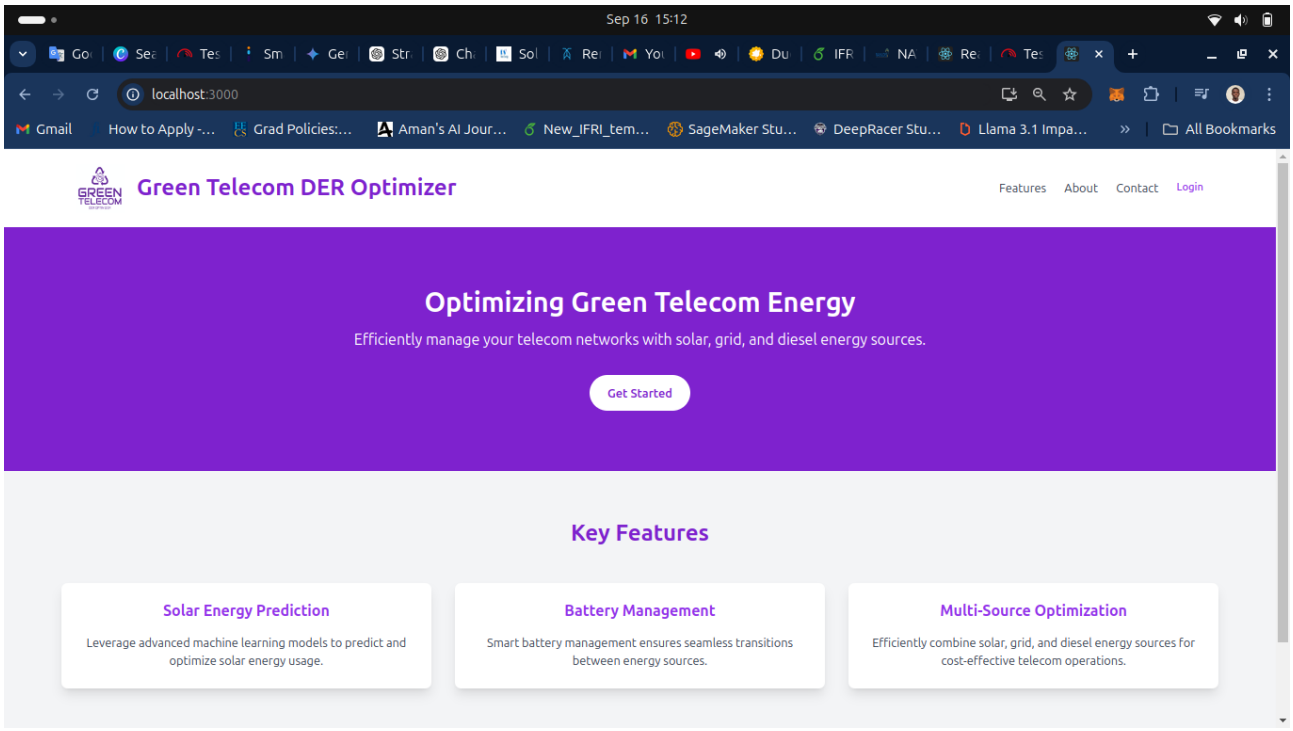


FIGURE 3.1 : Landing page Telecom Distributed Energy Resources Optimizer (GT_DERO)

- **Inscription** L'interface présentée dans la figure 3.2 permet à l'utilisateur de créer un compte. Pour cela, il doit indiquer son adresse email, son mot de passe, son prénom et son nom. Afin d'assurer la sécurité des comptes utilisateurs, les mots de passe sont cryptés avant d'être enregistrés dans la base de données.

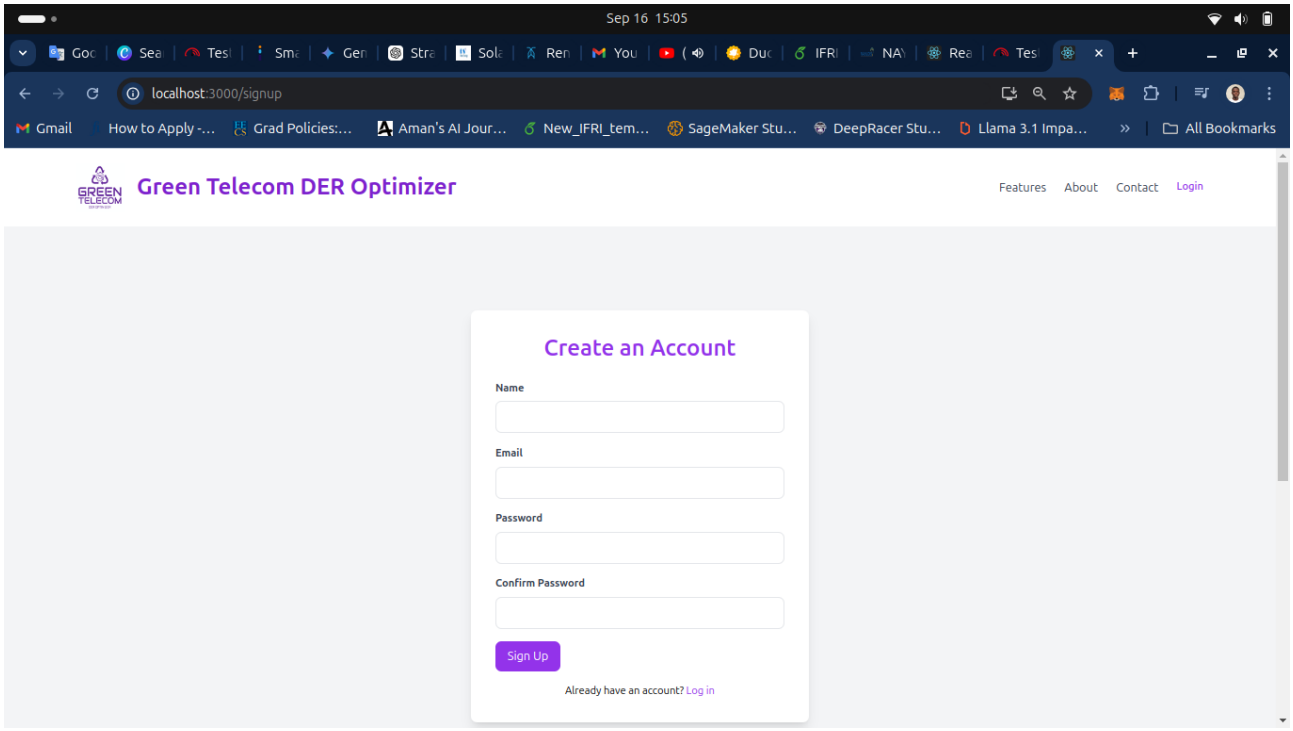


FIGURE 3.2 : Page d'Inscription Telecom Distributed Energy Resources Optimizer (GT_DERO)

- **Connexion** L'interface présentée dans la figure 3.3 permet à l'utilisateur de se connec-

ter une fois les tuples email et mot de passe vérifiés. Notre API renvoie donc un jeton d'accès qui permet d'effectuer des actions nécessitant une authentification dans l'application web.

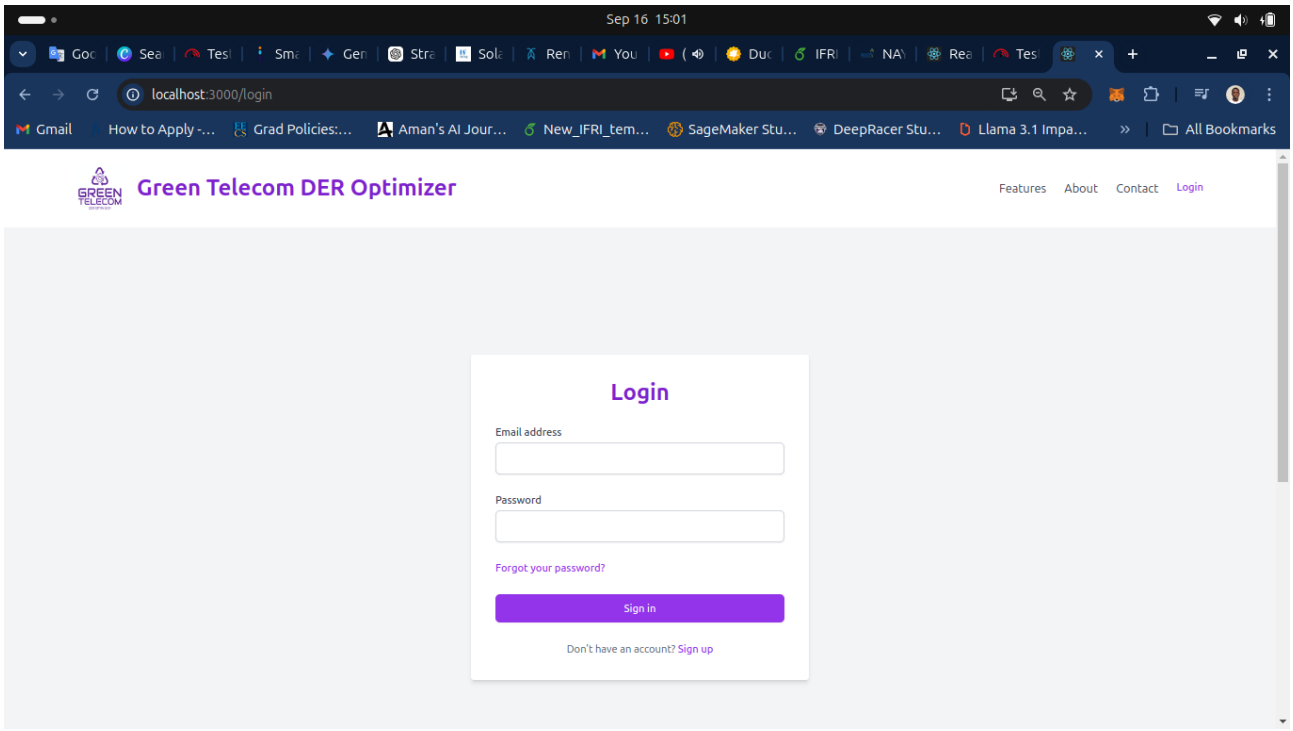


FIGURE 3.3 : Page de Connexion Telecom Distributed Energy Resources Optimizer (GT_DERO)

- **Tableau de bord (Dashboard)** Après authentification, l'utilisateur accède à un tableau de bord recensant les principales informations sur l'état global du système : nombre total de sites, consommation énergétique, production solaire, utilisation de la batterie et émissions de CO2. La figure 3.4 illustre un exemple de tableau de bord proposé par notre plateforme.

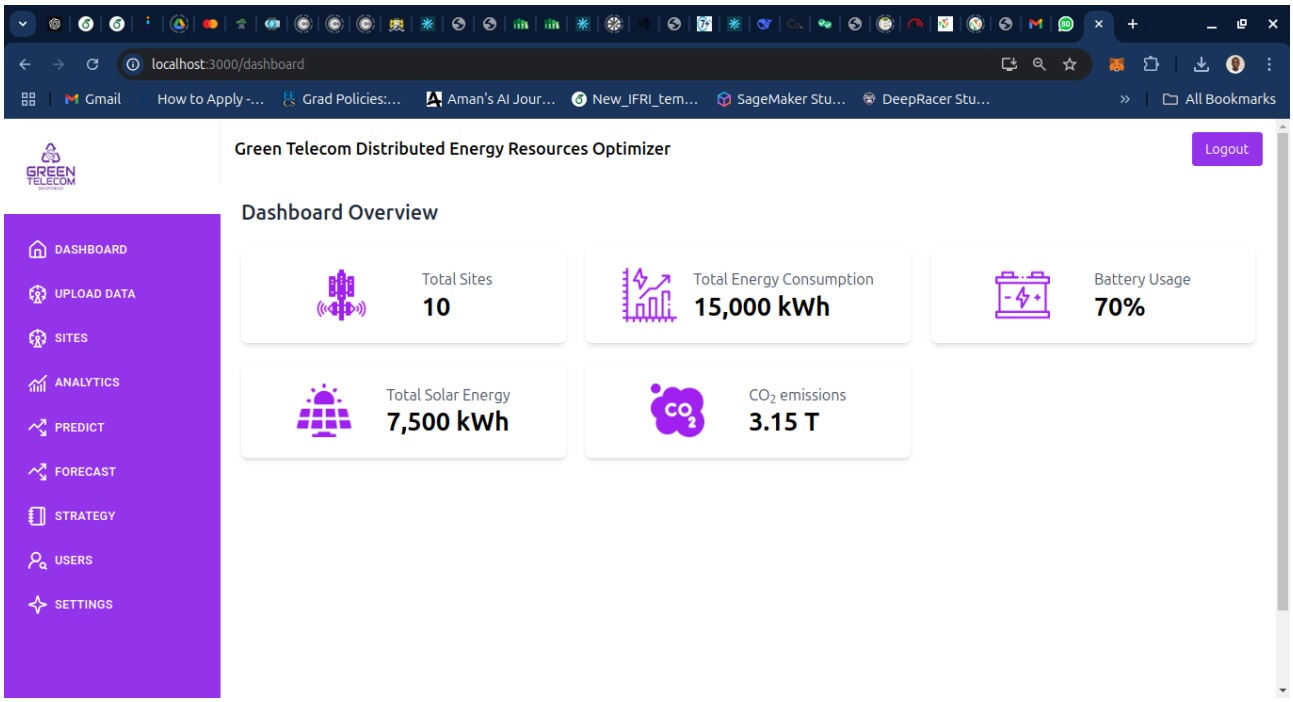


FIGURE 3.4 : Tableau de bord de GT_DERO : aperçu général des indicateurs clés (sites, consommation, solaire, batterie, CO2)

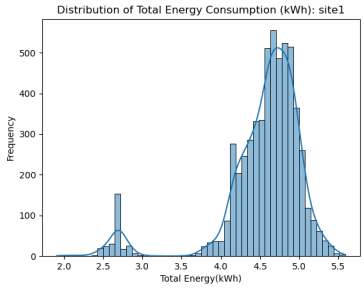
Cette plateforme centralisée permet une automatisation complète du processus d'optimisation, tout en offrant une interface utilisateur simple pour analyser les résultats.

3.4 Discussion

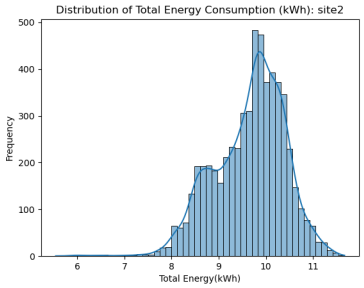
La section précédente a mis en lumière les résultats obtenus en appliquant notre solution d'optimisation énergétique à un ensemble de données simulant les conditions réelles des réseaux télécoms. Nous avons constaté des variations significatives dans les modèles de consommation énergétique et les conditions météorologiques propres à chaque site. Ces observations soulèvent plusieurs points importants à discuter, en termes de difficultés globales et de limites identifiées.

3.4.1 Difficultés globales

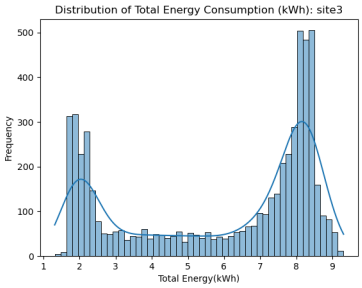
L'une des principales difficultés rencontrées lors du développement de la solution a été la gestion de la diversité des données relatives aux sites télécoms. Comme le montrent les figures des distributions de consommation énergétique (voir figure 3.5), chaque site présente des schémas de consommation très différents. Par exemple, certains sites ont une consommation énergétique concentrée autour d'un niveau constant (comme le site 7), tandis que d'autres présentent des fluctuations beaucoup plus marquées (comme le site 3). Cette variabilité a nécessité l'ajustement des modèles de prédiction pour chaque site afin de garantir une optimisation précise de l'approvisionnement énergétique.



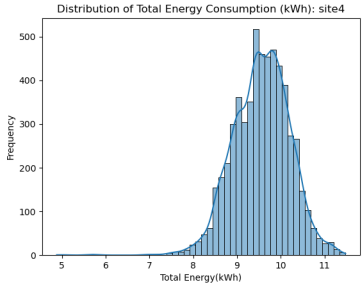
(a) Site 1



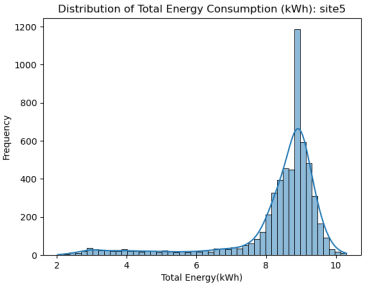
(b) Site 2



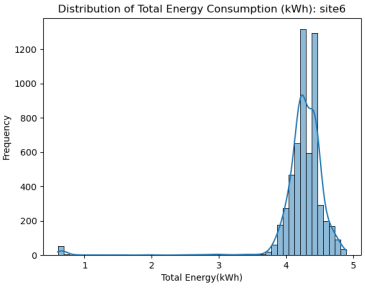
(c) Site 3



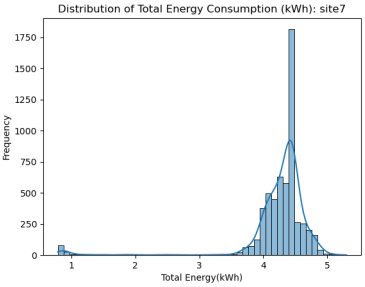
(d) Site 4



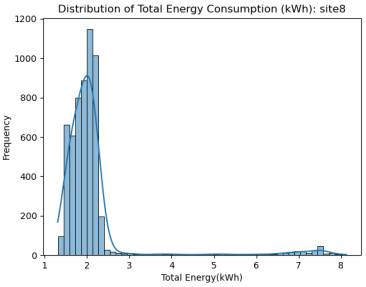
(e) Site 5



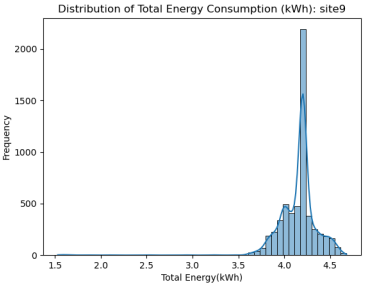
(f) Site 6



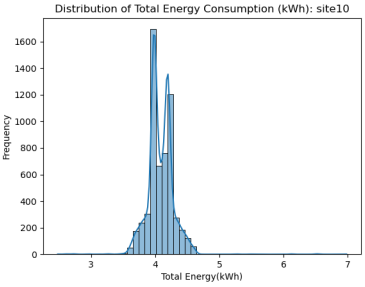
(g) Site 7



(h) Site 8



(i) Site 9



(j) Site 10

FIGURE 3.5 : Distributions de la consommation énergétique totale (kWh) pour chaque site.

De plus, la prévision de la production d'énergie solaire, influencée par des variables météorologiques complexes (DHI, DNI, GHI, humidité relative), a représenté un autre défi de taille. Les modèles de série temporelle, tels que les Transformers et LSTM, ont montré de bonnes performances, mais ont nécessité un ajustement minutieux des hyperparamètres pour chaque site afin de capter correctement les variations spécifiques de production solaire.

3.4.2 Limites du modèle

Bien que notre solution ait montré une amélioration notable par rapport aux méthodes de référence, plusieurs limites demeurent.

- **Sur-dépendance aux données historiques** : Nos modèles de prédiction de la consommation énergétique et de la production solaire dépendent fortement des données historiques. Dans des environnements où les conditions peuvent changer de manière imprévisible (comme des changements soudains dans les conditions météorologiques ou une variation inattendue de la demande énergétique), les modèles peuvent ne pas être en mesure de s'adapter rapidement, ce qui pourrait conduire à des erreurs de prédiction ;
- **Problèmes de scalabilité** : Bien que notre solution soit théoriquement scalable, l'optimisation multi-objectifs pour plusieurs sites simultanément (jusqu'à 10 dans notre étude) a révélé des limitations en termes de temps de calcul et de ressources nécessaires. Cette limitation pourrait devenir un frein dans un déploiement à plus grande échelle, où des centaines de sites doivent être optimisés simultanément ;
- **Gestion des batteries** : Même si notre modèle intègre un système efficace de gestion des batteries basé sur la capacité de décharge (DOD) et l'état de charge (SOC), il reste des défis concernant la gestion des états transitoires de charge. Des situations critiques, comme la sous-charge ou la surcharge de la batterie, nécessitent des systèmes de gestion plus robustes pour éviter une dégradation prématurée de ces équipements ;
- **Temps de réponse en temps réel** : Bien que nos algorithmes d'optimisation soient conçus pour répondre aux contraintes en temps réel, dans certaines situations, notamment lorsque les données d'entrée changent rapidement, il peut y avoir un décalage dans la génération de la stratégie optimale. Cela pourrait poser un problème dans des environnements où la stabilité du réseau dépend d'un ajustement rapide des sources d'énergie ;
- **Dépendance aux sources d'énergie renouvelables** : La stratégie optimale tend à privilégier l'énergie solaire, mais dans des conditions météorologiques défavorables, cette source devient imprévisible. Dans les cas où l'énergie solaire n'est pas disponible sur de longues périodes, la solution doit être en mesure d'ajuster dynamiquement les priorités entre les différentes sources d'énergie, ce qui a été difficile dans certaines simulations.

3.4.3 Perspectives d'amélioration

Pour surmonter ces limites, plusieurs améliorations peuvent être envisagées :

- **Amélioration des modèles adaptatifs** : L'intégration de modèles adaptatifs ou hybrides pourrait permettre de mieux répondre aux variations imprévues des conditions météorologiques et de la consommation énergétique ;
- **Parallélisation des calculs** : L'utilisation de techniques de parallélisation pour les algorithmes d'optimisation pourrait réduire le temps de calcul nécessaire pour traiter simultanément plusieurs sites ;

- **Gestion prédictive des batteries** : Des modèles plus avancés de gestion prédictive des batteries, combinant intelligence artificielle et physique des batteries, pourraient aider à prévenir les dégradations à long terme et à mieux anticiper les besoins énergétiques.

Conclusion

En conclusion, bien que notre solution *Green Telecom Distributed Energy Resources Optimizer* (GT_DERO) offre des résultats prometteurs en termes d'optimisation des ressources énergétiques pour les réseaux télécoms, elle présente encore certaines limitations. Ces défis, notamment liés à la variabilité des données, aux contraintes de scalabilité, et à la gestion des équipements, ouvrent la voie à des recherches futures et à des améliorations techniques.

Conclusion Générale et Perspectives

L'optimisation des ressources énergétiques est un enjeu majeur dans le domaine des télécommunications, en particulier dans un contexte où les énergies renouvelables jouent un rôle de plus en plus important. Dans ce travail, nous avons proposé une solution intitulée *Green Telecom Distributed Energy Resources Optimizer* (GT_DERO) qui combine des techniques avancées d'intelligence artificielle et d'optimisation multi-objectifs pour réduire les coûts énergétiques et les émissions de CO_2, tout en assurant la stabilité des réseaux mobiles.

Notre solution a été testée dans le cadre du défi *Smart Energy Supply Scheduling for Green Telecom Challenge*, en s'appuyant sur des données réelles de consommation énergétique, de production solaire et de disponibilité du réseau. Les résultats obtenus montrent une amélioration significative par rapport aux méthodes classiques, notamment grâce à l'utilisation de modèles de prédiction basés sur des Transformers et des algorithmes d'optimisation multi-objectifs. Cependant, plusieurs limites ont été identifiées, telles que la dépendance aux données historiques et les défis liés à la scalabilité de la solution.

Des perspectives intéressantes s'ouvrent pour les futures versions de GT_DERO. Premièrement, il serait pertinent d'intégrer des modèles plus adaptatifs pour mieux répondre aux variations soudaines des conditions météorologiques ou des besoins énergétiques des sites télécoms. Deuxièmement, l'amélioration de la gestion prédictive des batteries, notamment pour anticiper les problèmes de surcharge ou de décharge excessive, constitue une piste de recherche prometteuse. Enfin, la scalabilité du système doit être renforcée afin de gérer un plus grand nombre de sites tout en réduisant les temps de calcul.

Ainsi, ce travail offre une base solide pour l'optimisation des ressources énergétiques dans le secteur des télécommunications vertes, mais il laisse également entrevoir de nombreux axes d'amélioration qui méritent d'être explorés pour renforcer encore davantage l'efficacité et la robustesse du système.

Bibliographie et Webographie

[1] G. Aghajani and N. Ghadimi. Multi-objective energy management in a micro-grid. *Energy Reports*, 4 :218–225, 2018.

[2] F. R. Albogamy. A hybrid heuristic algorithm for energy management in electricity market with demand response and distributed generators. *Applied Sciences*, 13(4), 2023.

[3] A. Alzahrani, G. Hafeez, S. Ali, S. Murawwat, M. I. Khan, K. Rehman, and A. M. Abed. Multi-objective energy optimization with load and distributed energy source scheduling in the smart power grid. *Sustainability*, 15(13), 2023.

[4] Axios. Axios. https://axios-http.com/docs/intro. License MIT, Accessed : 2024-08-14.

[5] S. Ayers, S. Ballan, V. Gray, and R. McDonald. *Measuring the Emissions and Energy Footprint of the ICT Sector : Implications for Climate Action*. World Bank Group, Washington, D.C., 2024.

[6] W. Azariah, F. A. Bimo, C.-W. Lin, R.-G. Cheng, N. Nikaein, and R. Jana. A survey on open radio access networks : Challenges, research directions, and open source approaches. *Sensors*, 24(3), 2024.

[7] L. Bartolucci, S. Cordiner, V. Mulone, and S. Pasquale. Fuel cell based hybrid renewable energy systems for off-grid telecom stations : Data analysis and system optimization. *Applied Energy*, 252 :113386, 2019.

[8] Clustering in machine learning. https://www.geeksforgeeks.org/clustering-in-machine-learning/, 2024. Accessed : 2024-09-2.

[9] K. Coder. Creating a full-stack website with react frontend and python flask backend. https://medium.com/@kanaecoder/creating-a-full-stack-website-with-react-frontend-and-python-flask-backend-91ec2cbd81e0, 2023. Accessed : 2024-08-14.

[10] N. R. Deevela, T. C. Kandpal, and B. Singh. A review of renewable energy based power supply options for telecom towers. *Environment, Development and Sustainability*, 26(2) :2897–2964, 2024.

[11] N. Developers. Numpy. https://numpy.org/doc/stable/. Accessed : 2024-08-14.

[12] I. Docker. Docker documentation. https://docs.docker.com/. Accessed : 2024-08-14.

[13] N. Downie. Chart.js. https://www.chartjs.org/docs/latest/. Accessed : 2024-08-14.

[14] T. Dragičević, H. Pandžić, D. Škrlec, I. Kuzle, J. M. Guerrero, and D. S. Kirschen. Capacity optimization of renewable energy sources and battery storage in an autonomous telecommunication facility. *IEEE Transactions on Sustainable Energy*, 5(4) :1367–1378, 2014.

[15] T. H. Emanuel Kolta. Going green :measuring the energy efficiency of mobile networks. https://data.gsmaintelligence.com/research/research/research-2024/going-green-measuring-the-energy-efficiency-of-mobile-networks, 2024. Accessed : 2024-08-25.

[16] A. for Good International Telecommunication Union (ITU). Smart energy supply scheduling for green telecom challenge by itu. https://zindi.africa/competitions/smart-energy-supply-scheduling-for-green-telecom, 2024. Accessed : 2024-08-10.

[17] T. Forum. Green and efficient radio access networks. https://www.tmforum.org/catalysts/projects/M23.0.584/green-and-efficient-radio-access-networks/, 2023. URN : M23.0.584, Topics : Autonomous networks, Open APIs, Sustainability, Accessed : 2024-09-12.

[18] P. S. Foundation. Python documentation. https://docs.python.org/3/. Accessed : 2024-08-14.

[19] I. Giagkiozis and P. Fleming. Methods for multi-objective optimization : An analysis. *Information Sciences*, 293 :338–350, 2015.

[20] Documentation github actions. https://docs.github.com/fr/actions, 2024. Accessed : 2024-08-30.

[21] E. Goubault. Algorithmes évolutionnaires et problèmes inverses. https://www.enseignement.polytechnique.fr/profs/informatique/Eric.Goubault/poly/cours009.html. Accessed : 2024-08-12.

[22] P. D. Group. Postgresql. https://www.postgresql.org/docs/. Accessed : 2024-08-14.

[23] D. Ike, A. Adoghe, and A. Ademola. Analysis of telecom base stations powered by solar energy. *International Journal of Scientific & Technology Research*, 3 :369–374, 2014.

[24] H. F. Inc. Transformers. https://huggingface.co/docs/transformers/index. Accessed : 2024-08-14.

[25] I. T. U. (ITU). Green energy and traffic forecasting using ai and machine learning challenge match. https://youtu.be/XuCU76W7pI0?t=530, 2024. Webinar presented as part of the ITU AI for Good initiative. Speakers : Nicola Pon and Tarek Salam, Huawei Technologies, Accessed : 2024-08-12.

[26] I. T. U. (ITU). Green energy and traffic forecasting using ai and machine learning challenge match. https://youtu.be/XuCU76W7pI0?t=1411s, 2024. Webinar presented as part of the ITU AI for Good initiative. Speakers : Nicola Pon and Tarek Salam, Huawei Technologies, Accessed : 2024-08-12.

[27] N. L. M. Jailani, J. K. Dhanasegaran, G. Alkawsi, A. A. Alkahtani, C. C. Phing, Y. Baashar, L. F. Capretz, A. Q. Al-Shetwi, and S. K. Tiong. Investigating the power of lstm-based models in solar energy forecasting. *Processes*, 11(5), 2023.

[28] J. Kim, J. Obregon, H. Park, and J.-Y. Jung. Multi-step photovoltaic power forecasting using transformer and recurrent neural networks. *Renewable and Sustainable Energy Reviews*, 200 :114479, 2024.

[29] N. Koursioumpas, L. Magoula, N. Petropouleas, A.-I. Thanopoulos, T. Panagea, N. Alonistioti, M. A. Gutierrez-Estevez, and R. Khalili. A safe deep reinforcement learning approach for energy efficient federated learning in wireless communication networks. *IEEE Transactions on Green Communications and Networking*, 1 :1–1, 2024.

[30] S. learn Team. Scikit-learn. https://scikit-learn.org/stable/. Accessed : 2024-08-14.

[31] Y. Liu, T. Hu, H. Zhang, H. Wu, S. Wang, L. Ma, and M. Long. itransformer : Inverted transformers are effective for time series forecasting. *arXiv preprint arXiv :2310.06625*, 2023.

[32] Evaluation metrics in machine learning. https://www.geeksforgeeks.org/metrics-for-machine-learning-model/, 2024. Accessed : 2024-08-25.

[33] Nokia. Dynamic spectrum sharing could be the 5g solution wireless operators are looking for. https://www.nokia.com/thought-leadership/articles/dynamic-spectrum-sharing-could-be-5g-solution-wireless-operators-looking-fo, 2021. Accessed : 2024-09-12.

[34] M. Pagliardini, D. Paliotta, M. Jaggi, and F. Fleuret. Faster causal attention over large sequences through sparse flash attention. *Research Gate*, 06 2023.

[35] A. Petrowski and S. Ben Hamida. Les algorithmes évolutionnaires. In *Métaheuristiques : recuit simulé, recherche avec tabous, recherche à voisinages variables, méthode GRASP, algorithmes évolutionnaires, fourmis artificielles, essaims particulaires et autres méthodes d'optimisation*, Algorithmes, pages 115 – 173. Eyrolles, 2014.

[36] S. Ritu. Rest api architecture. https://medium.com/@shikha.ritu17/rest-api-architecture-6f1c3c99f0d3, 2023. Accessed : 2024-09-13.

[37] G. Saporta and N. Niang. Analyse en composantes principales. In *Analyse des données*, pages 19–42. Hermes, Mar. 2003.

[38] A. Shadab, S. Ahmad, and S. Said. Spatial forecasting of solar radiation using arima model. *Remote Sensing Applications : Society and Environment*, 20 :100427, 2020.

[39] P. Sharma, M. Bhaskar, W. Ng, and A. Muraleedharan. Ai-powered ran energy efficiency. https://www.ericsson.com/en/blog/2023/1/ai-powered-ran-energy-efficiency, 2023. Accessed : 2024-09-12.

[40] S. K. Sharma, T. E. Bogale, L. B. Le, S. Chatzinotas, X. Wang, and B. Ottersten. Dynamic spectrum sharing in 5g wireless networks with full-duplex technology : Recent advances and research challenges. *IEEE Communications Surveys & Tutorials*, 20(1) :674–707, 2018.

[41] Simnovus. What is a radio access network (ran)? https://simnovus.com/revolutionizing-radio-access-network, 2023. Accessed : 2024-09-13.

[42] P. Team. Pytorch. Accessed : 2024-08-14.

[43] R. Team. React. https://react.dev/. Accessed : 2024-08-14.

[44] T. P. D. Team. Pandas. https://pandas.pydata.org/docs/index.html. Accessed : 2024-08-14.

[45] I. Tech. How to apply transformers to time series models : Spacetimeformer. https://medium.com/intel-tech/how-to-apply-transformers-to-time-series-models-spacetimeformer-e452f2825d2e, 2023. Accessed : 2024-08-14.

[46] J. Wang, Y. Tian, X. Hu, Y. Li, K. Zhang, and Y. Liu. Predictive modelling and pareto optimization for energy efficient grinding based on aann-embedded nsga ii algorithm. *Journal of Cleaner Production*, 327 :129479, 2021.

[47] A. Wathan, J. Reinink, D. Hemphill, and S. Schoger. Tailwind css. https://tailwindcss.com/. Accessed : 2024-08-14.

[48] Autoregressive integrated moving average. https://en.wikipedia.org/wiki/Autoregressive-integrated-moving-average. Accessed : 2024-09-13.

[49] Régression linéaire. Wikipedia : https://fr.wikipedia.org/wiki/R%C3%A9gression-lin%C3%A9aire. Accessed : 2024-09-13.

[50] F. Yu, P. Zhang, W. Xiao, and P. Choudhury. Communication systems for grid integration of renewable energy resources. *IEEE Network*, 25(5) :22–29, 2011.

Annexe

Code Python pour une stratégie énergétique

Voici un exemple de code Python qui implémente une stratégie énergétique.

```python
class EnergyStrategy:
    def __init__(self, site_info, demand, energy_data):
        self.datetime = pd.to_datetime(demand["index"])
        demand.set_index("index", inplace=True)  # Set index for easier access

        # Initialize parameters from site_info DataFrame
        self.SOC_t = site_info['init SOC'].values[0]
        self.init_SOC = self.SOC_t
        self.DOD = site_info['DOD'].values[0]
        self.rated_capacity = site_info['battery capacity (Ah)'].values[0]
        self.rated_voltage = site_info['rated voltage
 (V)'].values[0]
        self.charge_coefficient = site_info['battery charge coefficient'].values[0]
        self.discharge_coefficient = site_info['battery discharge coefficient'].values[0]
        self.grid_power = site_info['grid power(kW)'].values[0]
        self.diesel_power = site_info['diesel power(kW)'].values[0]

        outage_plan_str = site_info['grid outage plan'].values[0]
        self.grid_outage_plan = ast.literal_eval(outage_plan_str.replace('false', 'False'
            ).replace('true', 'True').replace(' ', ', '))

        self.pred_solaire = energy_data['Energy Output(kWh)'].values / 4
        self.pred_consommation = demand['Total Energy(kWh)'].values / 4
        self.T = len(self.pred_solaire)

        # Initialize counters for diesel usage
        self.diesel_useNum = 0
        self.diesel_totalTime = 0
        self.grid_totalTime = 0

    def calculate_power_delta(self, t):
        """Calculate power balance between solar production and load."""
        return self.pred_solaire[t] - self.pred_consommation[t]

```

```
    def update_soc(self, power_delta):
        """Update the battery's State of Charge based on the power balance."""
        if power_delta > 0:  # Charging
            max_chargeable = (1 - self.SOC_t) * self.rated_capacity
            charge = (min(power_delta, max_chargeable) * self.charge_coefficient)
            self.SOC_t += charge / (self.rated_capacity)
        else:  # Discharging
            max_dischargeable = (self.SOC_t - (1 - self.DOD)) * self.rated_capacity
            if max_dischargeable > 0:
                discharge = (min(abs(power_delta), max_dischargeable) * self.
                    discharge_coefficient)
                potential_new_soc = self.SOC_t - discharge / (self.rated_capacity)

                # Only discharge if the new SOC will not be below the DOD limit
                if potential_new_soc >= 1 - self.DOD:
                    self.SOC_t = potential_new_soc

        # Ensure SOC remains between 0 and 1
        self.SOC_t = max(0, min(1, self.SOC_t))
        return self.SOC_t


    def decide_energy_source(self, t):
        """Determine the combination of energy sources based on the current state."""
        hour = self.datetime[t].hour
        is_daytime = 6 <= hour < 18
        power_delta = self.calculate_power_delta(t)

        sources_used = {"Solar": False, "Grid": False, "Diesel": False, "Battery": False}

        # Use solar during daytime if available
        if is_daytime and self.pred_solaire[t] > 0:
            sources_used["Solar"] = True
            power_delta -= self.pred_solaire[t]

        # If there is still unmet demand, check other sources
        if power_delta < 0:
            # Check battery discharge, but only if SOC is above safe DOD level
            if self.SOC_t > 1 - self.DOD:
                power_from_battery = min(abs(power_delta), (self.SOC_t - (1 - self.DOD))
                    * self.rated_capacity)
                self.update_soc(-power_from_battery)
                sources_used["Battery"] = True
                power_delta += power_from_battery

            # If power_delta is still negative, use grid if available
            if power_delta < 0 and not self.grid_outage_plan[t // 4]:
                sources_used["Grid"] = True
                power_delta = 0  # Assume grid meets all remaining demand
                self.grid_totalTime += 1

            # If grid is unavailable, use diesel as a last resort
            if power_delta < 0:
                sources_used["Diesel"] = True
                self.diesel_useNum += 1
```

```
87                 self.diesel_totalTime += 1
88
89         return sources_used
90
91     def run_strategy(self, csv_filename, site_name='test'):
92         file_exists = os.path.isfile(csv_filename)
93
94         with open(csv_filename, mode='w', newline='') as file:
95             writer = csv.writer(file)
96             writer.writerow(["site name", "time", "solar", "grid", "diesel"])  # Added
                battery column
97
98             for t in range(self.T):
99                 sources = self.decide_energy_source(t)  # Get the dictionary of source
                    usage
100                row = [
101                    site_name,
102                    t,
103                    "TRUE", # if sources["Solar"] else "FALSE",
104                    "TRUE" if sources["Grid"] else "FALSE",
105                    "TRUE" if sources["Diesel"] else "FALSE"
106                    #"TRUE" if sources["Battery"] else "FALSE"  # New column for battery
                       usage
107                ]
108                writer.writerow(row)
109
110        with open("report_strategy.txt", "a") as f:
111            f.write("<<<<<<<<<<<<<<<<<<<<<<<<<<<<>>>>>>>>>>>>>>>>>>>>>>>>>>>>\n")
112            f.write(f"Stratégie énergétique écrite dans {csv_filename}. Diesel starts: {
                self.diesel_useNum}, Diesel total time: {self.diesel_totalTime}, Grid
                total time: {self.grid_totalTime}.\n")
```

Table des matières

Dédicace ii

Remerciements iii

Résumé iv

Abstract v

Table des figures vi

Liste des tableaux vii

Liste des Algorithmes viii

Liste des acronymes ix

Introduction 1

1 Revue de littérature 5
Introduction . . . 5
1.1 Clarification des concepts . . . 5
1.1.1 Réseau d'Accès Radio . . . 5
1.1.1.1 Composantes du RAN . . . 5
1.1.1.2 Défis énergétiques du RAN . . . 6
1.1.1.3 Optimisation énergétique du RAN . . . 7
1.1.2 Ressources Énergétiques Distribuées (DER) . . . 8
1.1.2.1 Types de DER . . . 8
1.1.2.2 Avantages et Défis des DER dans les Réseaux Télécoms . . . 8
1.1.3 Intelligence Artificielle et iTransformers . . . 9
1.1.3.1 Défis des Transformers pour les Séries Temporelles . . . 9
1.1.3.2 iTransformer : Transformer Inversé . . . 9
1.1.3.3 Avantages de l'iTransformer . . . 10
1.1.4 Optimisation multi-objectifs . . . 10
1.1.4.1 Formulation Mathématique du Problème . . . 11
1.1.4.2 Méthodes de Résolution . . . 11
1.1.4.3 Application à l'Optimisation Énergétique des Réseaux RAN . . . 12
1.1.4.4 Défis et Perspectives . . . 12
1.1.5 Méthodes d'analyse de données . . . 13

1.1.5.1 Méthodes statistiques . . . 13
1.1.5.2 Apprentissage Automatique et Profond . . . 13
1.1.5.3 Apprentissage Renforcé . . . 13
1.1.5.4 Big Data et analyse multivariée . . . 14
1.1.5.5 Évaluation des Modèles . . . 14
1.1.6 Architecture API REST . . . 14
1.1.6.1 Principes de l'Architecture REST . . . 14
1.1.6.2 Application à notre Projet . . . 14
1.2 Analyse des solutions existantes . . . 15
1.2.1 Prédiction de l'Énergie Solaire . . . 15
1.2.1.1 Modèle ARIMA . . . 15
1.2.1.2 Modèles LSTM . . . 15
1.2.1.3 Transformers et approches hybrides . . . 16
1.2.2 Optimisation de l'approvisionnement en énergie . . . 16
1.2.2.1 Modèles multi-objectifs . . . 16
1.2.2.2 Algorithmes heuristiques . . . 16
1.2.2.3 Apprentissage renforcé . . . 16
1.2.3 Limites des solutions existantes . . . 16
1.2.4 Opportunités d'Amélioration . . . 17
1.3 Solution proposée : Green Telecom Distributed Energy Resources Optimizer . 17
1.3.1 Architecture de GT_DERO . . . 17
1.3.1.1 Schéma de l'Architecture . . . 18
Conclusion . . . 18

2 Conception et choix techniques **19**
Introduction . . . 19
2.1 Analyse des besoins . . . 19
2.1.1 Utilisateurs clés . . . 19
2.1.2 Besoins fonctionnels . . . 19
2.1.3 Besoins non fonctionnels . . . 20
2.2 Modélisation de la solution . . . 20
2.2.1 Diagramme de cas d'utilisation . . . 20
2.2.2 Diagramme de classes . . . 21
2.2.3 Diagramme de sequence . . . 22
2.3 Méthodologie Générale . . . 23
2.3.1 Données d'entrée et ingénierie des caractéristiques . . . 23
2.3.1.1 Caractéristiques des sites et du réseau électrique . . . 23
2.3.1.2 Caractéristiques de la production solaire et météorologiques . . . 23
2.3.1.3 Caractéristiques de la consommation énergétique . . . 23
2.3.1.4 Visualisation des données . . . 24
2.3.1.5 Prétraitement et Validation . . . 25
2.3.2 Approche de Prédiction Énergétique . . . 25
2.3.2.1 Modèles Utilisés . . . 25
2.3.3 Modélisation Mathématique pour l'Optimisation . . . 25

2.3.3.1 Fonction de Coût et Définition des Poids w_i . . . 25
2.3.3.2 Contraintes sur la Batterie . . . 26
2.3.3.3 Algorithmes d'Optimisation . . . 26
2.3.4 Fonctionnement du système . . . 26
2.3.4.1 Architecture générale du système . . . 27
2.3.4.2 Principe Général de Fonctionnement . . . 27
2.3.4.3 Pseudo-algorithmes : Évolution et Mises à Jour . . . 28
Évolution Principale : . . . 29
Évolution Principale : . . . 29
Évolution Principale : . . . 30
Évolution Principale : . . . 31
Évolution Principale : . . . 32
2.3.4.4 Interfaçage entre les modules . . . 33
2.3.4.5 Gestion du temps de calcul . . . 33
2.4 Choix techniques . . . 33
2.4.1 Front-end . . . 33
2.4.2 Back-end . . . 34
2.4.2.1 Python : . . . 34
2.4.2.2 Flask : . . . 34
2.4.2.3 PostgreSQL : . . . 34
2.4.3 Déploiement . . . 34
Conclusion . . . 34

3 Résultats et discussion **35**
Introduction . . . 35
3.1 Résultats . . . 35
3.1.1 Algorithmes utilisés . . . 35
3.1.1.1 Modèle de prédiction de la production solaire . . . 35
3.1.1.2 Modèle de prédiction de la consommation énergétique . . . 36
3.1.1.3 Optimisation des stratégies énergétiques . . . 36
3.2 Évaluation des modèles . . . 36
3.2.1 Recherche des hyperparamètres . . . 36
3.2.2 Résultats des performances . . . 36
3.3 Développement de la plateforme . . . 37
3.3.1 Interfaces . . . 37
3.4 Discussion . . . 40
3.4.1 Difficultés globales . . . 40
3.4.2 Limites du modèle . . . 42
3.4.3 Perspectives d'amélioration . . . 42
Conclusion . . . 43

Conclusion **44**

Bibliographie et Webographie **45**

Annexe 49

Table des matières 52