

**UNIVERSITÉ DU QUÉBEC EN OUTAOUAIS**

**Réduction des Émissions de Gaz à Effet de Serre des Réseaux  
Sans Fil - Amélioration des Performances des Approches  
d'Intelligence Artificielle**

**Samah Temim**

Département d'informatique et d'ingénierie

Thèse

Présenté en vue de l'obtention du diplôme de

*Philosophie Docteur*

en Sciences et technologies de l'information

# UNIVERSITÉ DU QUÉBEC EN OUTAOUAIS (UQO)

## Réduction des Émissions de Gaz à Effet de Serre des Réseaux Sans Fil - Amélioration des Performances des Approches d'Intelligence Artificielle

Par

**Samah Temim**

Thèse présentée au

Département d'informatique et d'ingénierie

pour l'obtention du grade de

**Philosophie Docteur (PhD)**

en Sciences et technologies de l'information

### Membres du jury :

Président du jury	<i>Prof. Tinko Eftimov, UQO</i>
Examineur externe	<i>Dr. Nabil Belacel, Digital Technologies, NRC, Ottawa</i>
Examineur interne	<i>Prof. Rafaël Khoury, UQO</i>
Directeur de thèse	<i>Prof. Larbi Talbi, UQO</i>
Co-directeur	<i>Dr. Farid Bensebaa, EME, NRC, Ottawa</i>

## **REMERCIEMENTS**

En premier lieu, ma gratitude s'élève vers le Très-Haut, Dieu, pour la sagesse, la lumière et l'endurance qu'Il m'a octroyées tout au long de cette quête académique.

Je désire exprimer mon immense reconnaissance au Professeur Larbi Talbi, mon directeur de thèse. Son accompagnement assidu, sa patience inébranlable et son soutien sans faille ont été le pilier de mes années doctorales. Sa profondeur d'expertise, sa vision éclairée et son dévouement indéfectible pour la recherche ont constamment nourri ma passion et mon engagement.

Dr. Farid Bensebaa, mon co-directeur de thèse, mérite une mention spéciale pour sa guidance pertinente. Ses retours aiguisés, ses conseils judicieux et son encouragement constant ont été cruciaux pour la sculpture de cette recherche.

Ma gratitude s'étend également aux membres éminents de mon jury de thèse. Leurs disponibilités pour évaluer ce travail et leurs critiques édifiantes ont grandement enrichi le résultat final.

Je ne saurais passer sous silence l'appui indéfectible de mes collègues, de mes amis et de l'ensemble de la communauté universitaire. Leurs interrogations stimulantes, leurs perspectives variées et leur encouragement ont été une source inestimable de motivation.

Enfin, au cœur de ma reconnaissance, se trouve ma famille. Mes parents, pour qui les mots peinent à exprimer l'étendue de ma gratitude, m'ont toujours bercé de leur amour sans condition et d'une foi en moi qui a été le socle de mes ambitions.

## RESUMÉ

Dans notre époque où les nouvelles technologies sont omniprésentes, nous constatons que les réseaux sans fil sont devenus une composante incontournable de notre vie quotidienne. La croissance rapide des technologies de mise en réseau, notamment l'émergence fulgurante de la cinquième génération (5G), a engendré une augmentation exponentielle des abonnements mobiles et des utilisateurs d'Internet à l'échelle mondiale. Cette expansion sans précédent met en exergue la nécessité impérieuse de créer des infrastructures solides et d'innover sur le plan technologique pour satisfaire aux demandes grandissantes en matière de connectivité. Cependant, cet essor technologique n'est pas sans susciter des préoccupations environnementales, en particulier, l'augmentation des émissions de gaz à effet de serre (GES).

La présente thèse se concentre sur le développement et le déploiement de solutions pratiques pour réduire les émissions de GES émanant des réseaux sans fil. Une première solution consiste à une intégration intelligente et décentralisée de l'énergie solaire pour répondre à la consommation des réseaux Wi-Fi. La deuxième solution est basée sur le déploiement d'algorithmes d'apprentissage automatique utilisés pour réduire l'énergie consommés par les réseaux sans fil.

Dans la première partie de la recherche, l'attention est portée sur la problématique des émissions de GES associées aux réseaux sans fil. Une méthodologie innovante est développée pour quantifier l'impact environnemental des réseaux Wi-Fi communautaires en évaluant leur consommation d'énergie et en estimant les émissions de GES résultantes. En proposant un cadre de GES, l'étude démontre comment la transition vers des sources d'énergie plus propres, comme le solaire, peut réduire significativement l'empreinte carbone des réseaux. L'application de cette méthodologie à un déploiement élargi de Wi-Fi communautaire permet d'évaluer les avantages environnementaux potentiels à grande échelle. Cette approche suggère également une voie pour évaluer l'impact environnemental d'autres solutions technologiques propres.

Dans la deuxième partie de la thèse, on présentera une nouvelle approche d'optimisation des performances des modèles d'apprentissage profond utilisés pour la prédiction du trafic cellulaire. Un cadre d'analyse des hyperparamètres est développé pour déterminer l'influence de ces paramètres sur les performances des modèles. En recherchant un compromis entre la précision des prédictions et l'efficacité énergétique, des ensembles appropriés

d'hyperparamètres sont identifiés. Cette approche démontre l'importance cruciale de la sélection minutieuse des hyperparamètres pour améliorer à la fois la précision des modèles et leur efficacité énergétique.

## ABSTRACT

In our era where technology reigns supreme, we observe that wireless networks have become an essential component of our daily lives. The rapid growth of networking technologies, especially the swift emergence of 5G, has led to an exponential increase in global mobile subscriptions and Internet users. This unprecedented expansion highlights the urgent need to establish robust infrastructures and innovate technology to meet the growing demands for connectivity. However, this technological surge is not without environmental concerns, as greenhouse gas emissions (GHG) from wireless networks are experiencing a significant rise.

This thesis focuses on two essential aspects: the major challenges related to reducing GHG from wireless networks and the machine learning algorithms used to decrease the energy consumed by wireless networks.

In the first part of the research, attention is directed towards the issue of greenhouse gas emissions associated with wireless networks. An innovative methodology is developed to quantify the environmental impact of community Wi-Fi networks by assessing their energy consumption and estimating greenhouse gas emissions. By proposing a greenhouse gas framework, the study demonstrates how transitioning to cleaner energy sources, such as solar power, can significantly reduce the carbon footprint of networks. Applying this methodology to an extended deployment of community Wi-Fi enables the evaluation of potential large-scale environmental benefits. This approach also suggests a pathway to assess the environmental impact of other clean technology solutions.

The second part of the thesis delves into optimizing the performance of deep learning models used for cellular traffic prediction. A hyperparameter analysis framework is developed to determine the influence of these parameters on model performance. By seeking a balance between prediction accuracy and energy efficiency, suitable sets of hyperparameters are identified. This approach showcases the critical importance of meticulous hyperparameter selection to enhance both model accuracy and energy efficiency.

## LISTE DES TABLEAUX

<b>Tableau 1 :</b> Évolution des générations de systèmes cellulaires et technologies associées .....	9
<b>Tableau 2 :</b> Bande passante par service utilisé dans cette étude [47] .....	25
<b>Tableau 3:</b> Caractéristiques géographiques du site d'implémentation .....	29
<b>Tableau 4 :</b> Paramètres optimaux avec ACP .....	31
<b>Tableau 5:</b> Les résultats de simulation des quatre scénarios en termes de couverture (%) et de demande d'énergie (E) sont fournis pour différents scénarios et niveaux de signal. ....	34
<b>Tableau 6.</b> Valeurs des hyperparamètres .....	65
<b>Tableau 7:</b> Spécification de l'équipement considéré.....	68
<b>Tableau 8:</b> Résultat de l'optimisation. ....	76

## LISTE DES FIGURES

<b>Figure 1:</b> Estimation de l'UIT du trafic mobile mondial 2020-2030 [4]. ....	2
<b>Figure 2:</b> Exemple d'un réseau HetNet .....	12
<b>Figure 3:</b> Composants du modèle de puissance de la BS. ....	13
<b>Figure 4:</b> Méthodologie d'évaluation quantitative de la réduction des émissions de GES du Wi-Fi à énergie solaire. ....	21
<b>Figure 5:</b> Localisation géographique de l'étude de cas proposée. Wi-Fi solaire autonome .....	22
<b>Figure 6:</b> Données d'entrée-sortie de l'interface de la calculatrice MATLAB.....	27
<b>Figure 7:</b> Site optimal pour les points d'accès Wi-Fi. ....	28
<b>Figure 8:</b> Entrée-sortie de l'interface MATLAB l'estimation de la bande passante par cellule. ....	28
<b>Figure 9:</b> Carte montrant la couverture en puissance du signal (dBm) prévus sur le campus de l'ENST. ....	30
<b>Figure 10:</b> Évolution de la couverture et de la qualité du signal en fonction des itérations. ....	31
<b>Figure 11:</b> Histogramme basé sur le pourcentage de zones couvertes par (a) 3, (b) 4, (c) 5 et 6 (d) points d'accès. ....	32
<b>Figure 12:</b> Aperçu de la méthodologie pour les meilleurs technologies disponible (BAT), y compris la sélection et le classement. ....	36
<b>Figure 13:</b> Réseau de neurone artificiels ou ANN.....	39
<b>Figure 14:</b> Fonction Sigmoidale .....	48
<b>Figure 15:</b> Fonction tanh.....	49
<b>Figure 16:</b> Cellule LSTM .....	51
<b>Figure 17.</b> Représentation schématique du cadre et de la méthodologie proposés. ....	63
<b>Figure 18:</b> (a) Variation de la consommation d'énergie en fonction du nombre d'unités par couche. (b) Variation de RMSE en fonction du nombre d'unités par couche. ....	70
<b>Figure 19:</b> (a) Variation de la consommation d'énergie en fonction de la taille du lot. (b) Variation de RMSE en fonction de la taille du lot.....	71
<b>Figure 20:</b> (a) Variation de la consommation d'énergie en fonction du nombre de couches cachées. (b) Variation de RMSE en fonction du numéro de couche cachée. ....	72
<b>Figure 21:</b> ( a) Variation de la consommation d'énergie en fonction du taux de dropout. (b) Variation du RMSE en fonction du taux de dropout. ....	73
<b>Figure 22:.</b> (a) Variation de la consommation d'énergie en fonction du type d'optimiseur. (b) Variation de RMSE en fonction en tant qu'optimiseur de fonction. ....	73
<b>Figure 23:</b> Matrice de corrélation utilisée pour identifier les principales tendances. ....	75

## LISTES DES ABRÉVIATIONS

Automatic Frequency Planning	AFP
Attaques par déni de service	DDoS
Attaques par déni de service	DDoS
Automatic Cell Planning	ACP
Cinquième génération	5G
Coordonnées du système mondial de localisation	GPS
Deuxième génération	2G
Dioxyde de carbone	CO <sub>2</sub>
École Nationale Supérieure de Technologie	ENST
Gaz à Effet de Serre	GES
Gigaoctet	Go
Global System for Mobile Communication	GSM
Groupe d'experts intergouvernemental sur l'évolution du climat	GIEC
Heterogeneous network	HetNet
High PERFORMANCE radio LAN	Hiperlan
Information et des Télécommunications	IT
Intelligence Artificielle	IA
Internet des objets	IdO
Long Term Evolution	LTE
Media Access Control	MAC
Media Access Control	MAC
Multiple Input Multiple Output	MIMO
Operational Expenditure	OPEX
Première de génération	1G
Quatrième génération:	4G
Racine d'erreur quadratique moyenne	RMSE
Recherche sur grille	RG
Rectified Linear Unit	ReLU
Réseaux de neurones artificiels	ANN
Réseaux de neurones convolutifs	CNNs
Réseaux de Neurones Long Short-Term Memory	LSTM
Réseaux de neurones profonds	DNNs
Réseaux de Neurones Récurents	RNN
Station de base	BS
Système mondial de communication avec les mobiles	GSM
Tangente hyperbolique	tanh
Technologies de l'information et de la communication	TIC
Troisième génération	3G
Union Internationale des Télécommunications	UIT
Universal mobile télécommunication system	UMTS
Wireless Local Area Network	WLAN
Wireless Personal Area Network	WPAN

## Table des matières

<b>REMERCIEMENTS .....</b>	<b>i</b>
<b>RESUMÉ .....</b>	<b>ii</b>
<b>ABSTRACT .....</b>	<b>iv</b>
<b>LISTE DES TABLEAUX.....</b>	<b>v</b>
<b>LISTE DES FIGURES .....</b>	<b>v</b>
<b>LISTES DES ABRÉVIATIONS.....</b>	<b>vi</b>
<b>Chapitre 1</b>	
<b>Introduction générale .....</b>	<b>1</b>
1.1 Introduction.....	1
1.2 Motivations et objectifs .....	3
1.3 Organisation de la thèse.....	5
1.4 Publications.....	6
<b>Chapitre 2</b>	
<b>Notions fondamentales des réseaux sans fil et les approches visant à réduire leurs émissions de gaz à effet de serre .....</b>	<b>8</b>
2.1 Introduction.....	8
2.2 L'évolution des réseaux mobiles .....	8
2.3 Classification des réseaux sans fil par couverture .....	9
2.4 Architecture d'un réseau cellulaire traditionnel.....	10
2.5 Architecture du réseau HetNet ( <i>Heterogeneous network</i> ).....	10
2.6 La consommation d'énergie dans les réseaux sans fil.....	12
2.7 Les méthodes de réduction de la consommation énergétique des réseaux sans fil.....	14
2.7.1 Amélioration de l'efficacité énergétique des composants matériels .....	14
2.7.2 Éteindre les composants de manière sélective .....	15
2.7.3 Optimisation de l'efficacité énergétique du processus de transmission radio .....	16
2.7.4 Planification et déploiement de cellules hétérogènes .....	17
2.7.5 Adopter des ressources énergétiques renouvelable.....	18
2.8 Conclusion .....	18
<b>Chapitre 3</b>	
<b>Méthodologie d'évaluation quantitative de la réduction des émissions de GES du Wi-Fi à énergie solaire.....</b>	<b>19</b>
3.1 Introduction.....	19
3.2 Contexte et Justification.....	19
3.3 Méthodologie d'évaluation des émissions de GES réduites par le Wi-Fi solaire.....	20
3.3.1 Délimitation du système : Étude de cas .....	21
3.3.2 Dimensionnement et planification du réseaux Wi-Fi .....	22

3.4 Résultats et discussion .....	27
3.4.1 Couverture optimale .....	27
3.4.2 Capacité optimale .....	28
3.4.3 Réseau optimal.....	29
3.4.4. Analyse du scénario .....	32
3.5. Potentiel de réduction des GES suite au déploiement du Wi-Fi solaire .....	34
3.6. Prévion de l'atténuation des GES résultant d'un déploiement plus large du Wi-Fi à énergie solaire.....	35
3.7 Conclusion .....	37
<b>Chapitre 4</b>	
<b>Rappel sur l'apprentissage automatique profond .....</b>	<b>38</b>
4.1 Introduction.....	38
4.2 Concepts clés de l'apprentissage profond .....	39
4.2.1 Les ANNs : .....	39
4.2.2 les DNNs.....	39
4.2.3 Entraînement d'un réseau DNNs:.....	39
4.3 Hyperparamètres en apprentissage automatique.....	47
4.3.1 Le taux d'apprentissage ( <i>learning rate</i> ) .....	47
4.3.2 Le nombre de couches cachées dans le réseau.....	47
4.3.3 Le nombre de de neurones .....	47
4.3.4 La fonction d'activation .....	47
4.3.5 La taille du lot.....	49
4.3.6 Dropout .....	49
4.4 Les RNNs.....	50
4.5 Les LSTM.....	50
4.6 Métriques d'évaluations de l'efficacité de l'apprentissage automatique .....	52
4.7 Conclusion .....	52
<b>Chapitre 5</b>	
<b>Optimisation et Gestion des Réseaux Sans Fil avec de l'Intelligence Artificielle.....</b>	<b>53</b>
5.1 Introduction.....	53
5.2 Applications de l'apprentissage automatique dans les réseaux sans fil.....	53
5.2.1 Gestion des ressources .....	53
5.2.2 Prédiction de la mobilité des utilisateurs .....	54
5.2.3. Sécurité du réseau .....	55
5.2.4 Optimisation du routage.....	56
5.2.5. Amélioration des performances .....	57
5.3 La consommation énergétique des algorithmes d'apprentissage automatique .....	58

5.4 Conclusion .....	61
<b>Chapitre 6</b>	
<b>L'impact des hyperparamètres sur la consommation et les performances des algorithmes d'apprentissage automatique pour la prédiction du trafic cellulaire .....</b>	<b>62</b>
6.1 Introduction.....	62
6.2. Étude des Hyperparamètres pour la Prédiction du Trafic Cellulaire .....	63
6.2.1. Module de traitement de données .....	64
6.2.2. Module de développement .....	64
6.2.3. Module d'évaluation.....	68
6.3. Résultats et discussion .....	69
6.3.1. Impact du nombre d'unités par couche.....	69
6.3.2. Impact de la taille du lot .....	70
6.3.3. Impact du nombre de couches.....	71
6.3.4. Impact du taux de dropout .....	72
6.3.5. Impact du type d'optimiseur.....	73
6.3.6. Matrice de corrélation .....	74
6.3.7. Les meilleurs hyperparamètres .....	76
6.4 Conclusion .....	77
<b>Chapitre 7</b>	
<b>Conclusion et perspectives de recherche.....</b>	<b>78</b>
7.1 Conclusion .....	78
7.2 Perspectives de recherche .....	79
<b>Références .....</b>	<b>80</b>

# Chapitre 1

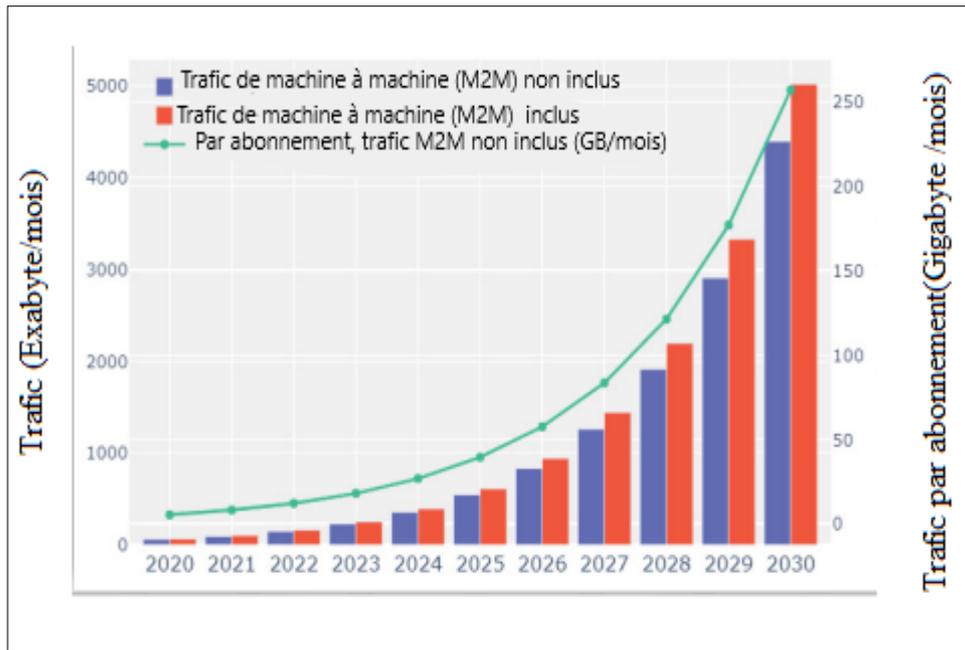
## Introduction générale

### 1.1 Introduction

De nos jours, l'omniprésence des technologies de l'information et des communications (TIC) est devenue une composante vitale de la vie humaine. En effet, le monde numérique connaît une croissance fulgurante, notamment dans le domaine des technologies de mise en réseau. Cette évolution exponentielle a engendré une croissance impressionnante des réseaux cellulaires ces dernières années. Cette hausse soudaine est due à une demande croissante en données à haut débit, couplée à une augmentation imprévue du nombre d'abonnés.

Les dernières projections d'Ericsson ont mis en lumière une forte croissance à venir de l'adoption de la technologie 5G dans le monde, avec près de 5 milliards d'abonnements attendus d'ici 2028 [1]. Cette progression impressionnante représente environ 55% de l'ensemble des abonnements mobiles, et témoigne de l'importance croissante de la connectivité sans fil rapide et fiable pour les utilisateurs. Par ailleurs, le rapport d'aperçu mondial de DIGITAL 2023 a mis en évidence une tendance similaire dans l'utilisation d'Internet, avec plus de 5 milliards d'utilisateurs attendus fin 2023 [2]. Cette croissance est particulièrement significative, car elle représente environ 64,4% de la population mondiale, soulignant ainsi l'omniprésence croissante de la technologie dans la vie quotidienne des gens. Ces données récentes confirment la nécessité d'une infrastructure solide et d'une technologie innovante pour répondre aux besoins croissants en connectivité dans le monde en constante évolution.

D'après les dernières évaluations et projections présentées dans le rapport annuel sur l'Internet de Cisco, il est prévu que le nombre de dispositifs connectés augmentera considérablement pour atteindre 75,4 milliards d'ici 2025, ce qui représente une augmentation significative par rapport à l'estimation qui avait été faite en 2020 [3]. Le nombre d'appareils connectés devrait continuer à croître dans les années à venir et atteindre plusieurs milliards la fin 2023. En outre, L'Union Internationale des Télécommunications (UIT) estime également que chaque abonné mobile consommera en moyenne 39,4 Go de trafic de données par mois en 2025, et environ 257 Go en 2030 [4].



**Figure 1:** Estimation de l'UIT du trafic mobile mondial 2020-2030 [4].

Bien que plusieurs facteurs contribuent à cette augmentation, l'un des plus importants sera le développement des réseaux sans fil de la 5G [5]. Le réseau de stations de base (BS) à déploiement dense est une architecture prometteuse pour les réseaux mobiles 5G et au-delà, car il peut améliorer la capacité et le débit du système en déployant un grand nombre de BS dans la zone de service. Cependant, une telle architecture de réseau mobile doit faire face aux problèmes d'énergie impliqués, car la consommation d'énergie des BS représente généralement une partie importante de l'ensemble du système. Les BS sont considérées comme la principale source de consommation d'énergie dans les réseaux cellulaires, représentant 57 % de l'énergie totale utilisée [6].

L'efficacité énergétique dans les réseaux cellulaires est une préoccupation croissante pour les opérateurs cellulaires, non seulement pour maintenir la rentabilité, mais aussi pour réduire les effets globaux sur l'environnement. Selon [7], la quantité de dioxyde de carbone (CO<sub>2</sub>) émise par le secteur mobile a atteint  $179 \times 10^9$  Kg en 2020 et représente 51% de l'empreinte carbone totale du secteur des technologies de l'information et des communications. Des rapports récents ont montré que dans le pire des cas, ce secteur pourrait devenir un consommateur d'énergie dominant, consommant potentiellement jusqu'à la moitié de l'électricité mondiale en 2030 [8]. Selon une étude de l'UIT publiée en 2020, le secteur des TIC est responsable d'environ 1,4 % des émissions mondiales de GES. Cependant, certaines estimations suggèrent que l'empreinte carbone des TIC pourrait augmenter considérablement à mesure que de plus

en plus de personnes dans le monde utilisent des services numériques et que l'utilisation de l'Internet des Objets (IdO) et de l'intelligence artificielle (IA) se développe. Par conséquent, les opérateurs de réseaux cellulaires sont contraints de répondre aux exigences en matière de préservation de l'environnement et de réduction des OPEX (*Operational Expenditure*). L'amélioration de l'efficacité énergétique des réseaux cellulaires pose également un défi aux chercheurs, aux fournisseurs et aux opérateurs mobiles en raison de son influence économique et écologique anticipée dans les années à venir.

## **1.2 Motivations et objectifs**

Au cours des dernières décennies, la communauté des chercheurs a multiplié les efforts pour réduire la consommation énergétique et les GES émise par les réseaux sans fil. Pour relever ces défis, deux approches se révèlent prometteuses, la première étant la discipline de recherche relativement nouvelle communément "communications vertes", tandis que la seconde consiste à gérer les ressources du réseau sans fil en utilisant l'IA pour réduire la consommation d'énergie des réseaux sans fil.

- **Communications vertes**

Les réseaux sans fil verts sont devenus un sujet émergent vu que l'empreinte carbone des TIC devrait, selon les prévisions, augmenter annuellement de 7,3%, puis dépasser 14% l'empreinte globale d'ici 2040 [9] . De plus, la croissance explosive des TICs, par exemple la 5G de réseaux mobiles, prévoit d'atteindre dix fois plus de durée de vie pour les batteries des appareils et mille fois plus de trafics de données dans les réseaux mobiles par rapport à la quatrième génération (4G).

Pour répondre à ces défis, une grande partie de l'initiative pour les communications vertes implique la réduction des émissions de carbone en introduisant des sources d'énergie renouvelables, en adoptant des technologies propres et en améliorant la capacité durable pour la production future. Des recherches sont également menées pour améliorer l'efficacité énergétique des réseaux, telles que l'optimisation des ressources du réseau et l'utilisation de l'IA pour réduire la consommation d'énergie. L'objectif ultime est de créer des réseaux sans fil plus respectueux de l'environnement, capables de répondre aux besoins croissants en matière de connectivité tout en réduisant l'impact environnemental.

- **Gestion des ressources du réseau sans fil utilisant l'IA**

Dans le contexte des réseaux sans fil, l'IA permettra à tout appareil sans fil de surveiller activement et intelligemment son environnement en apprenant et en prédisant l'évolution des diverses caractéristiques environnementales et en prenant de manière proactive des actions qui maximisent les chances de succès pour un objectif prédéfini, qui, dans un système sans fil, se rapporte à une qualité de service recherchée. L'IA permet à l'infrastructure réseau d'apprendre de l'environnement de réseau sans fil et de prendre des mesures d'optimisation adaptative du réseau. En conséquence, l'apprentissage automatique devrait jouer plusieurs rôles dans la prochaine génération de réseaux sans fil [10].

L'application la plus naturelle de l'IA dans un système sans fil consiste à exploiter l'analyse de données intelligente et prédictive pour améliorer la connaissance de la situation et les opérations globales du réseau. Dans ce contexte, l'IA fournira au réseau sans fil la capacité d'analyser des quantités massives de données, générées à partir de plusieurs sources allant des mesures de canaux sans fil et des lectures de capteurs aux drones et aux images de surveillance, afin de créer une carte opérationnelle complète du grand nombre d'appareils au sein du réseau [11]. Cette carte peut, à son tour, être exploitée pour optimiser diverses fonctions, telles que la surveillance des pannes et le suivi des utilisateurs, sur le réseau sans fil. Ces algorithmes, bien qu'ils puissent contribuer à la réduction de la consommation d'énergie des réseaux sans fil, peuvent également augmenter la demande en énergie, souvent d'origine fossile, et par conséquent, accroître l'émission de GES. C'est pourquoi il est important de trouver des solutions durables et efficaces pour réduire les émissions de GES liées aux réseaux sans fil et aux algorithmes d'apprentissage automatique associés. L'optimisation des algorithmes d'apprentissage automatique dans le but de réduire davantage la consommation d'énergie est donc cruciale et mérite une attention particulière. Cependant, ce facteur n'est pas souvent pris en compte par les développeurs des algorithmes d'apprentissage automatique. Malheureusement, la précision du modèle et la capacité à générer de nouvelles données sont des critères de sélection clés lors de la phase de développement des algorithmes d'apprentissage automatique. L'absence d'une méthodologie de quantification de la consommation d'énergie des algorithmes d'apprentissage automatique entrave le déploiement d'une solution à long terme pour réduire les émissions de GES dans le secteur de TIC.

Malgré tous les efforts et les initiatives pour réduire les émissions de GES des réseaux sans fil, il reste encore beaucoup à faire pour atteindre des objectifs environnementaux ambitieux.

Dans le cadre de cette thèse, notre intérêt se porte sur les défis majeurs liés à la réduction des émissions de GES émanant des réseaux sans fil ainsi que les algorithmes d'apprentissage automatique utilisés pour réduire l'énergie consommés par les réseaux sans fil.

Pour réduire l'empreinte carbone des réseaux sans fil, Nous avons élaboré un cadre innovant de modélisation pour quantifier la réduction possible des émissions de GES résultant de l'utilisation de Wi-Fi à énergie solaire comme point d'accès Internet. Notre objectif est de contribuer à la réduction de l'empreinte carbone des réseaux sans fil, en offrant une alternative durable et respectueuse de l'environnement pour l'accès à Internet. Nous sommes convaincus que cette approche peut aider à encourager l'adoption de pratiques écoresponsables dans le domaine de TIC, en répondant aux besoins de connectivité tout en réduisant les émissions de GES.

Parallèlement, dans le but de minimiser l'empreinte carbone des algorithmes d'apprentissage automatique utilisés pour la gestion des ressources des réseaux sans fil, nous avons mené une analyse de l'impact des hyperparamètres sur leur consommation d'énergie et leurs performances. Pour ce faire, nous avons défini un ensemble de valeurs réalisables pour chaque hyperparamètre (nombre de couches, nombre de neurones par couche, algorithme d'optimisation, taille de lot et taux de dropout), puis entraîné notre modèle pour chaque combinaison d'hyperparamètres et analysé la consommation d'énergie et les performances résultantes. Cette approche vise à rendre les algorithmes d'apprentissage automatique plus respectueux de l'environnement dans le contexte des réseaux sans fil, complétant ainsi notre démarche globale pour une connectivité durable.

### **1.3 Organisation de la thèse**

Cette thèse est organisée en sept chapitres de la manière suivante :

**Le chapitre 1** présente la définition du sujet et la formulation du problème. Nous avons commencé par une introduction générale sur le développement rapide des réseaux sans fil et leurs empreinte Carbone. Par la suite nous avons formulé la problématique et le défi de réduction de GES des réseaux sans fil. Nous avons conclu ce chapitre tout en exposant nos objectifs, motivations, contributions de cette thèse ainsi que les publications scientifiques associées.

**Le chapitre 2** présente les notions fondamentales des réseaux sans fil et examine les approches visant à réduire les émissions de GES liées à ces réseaux.

**Le chapitre 3** fournit notre cadre de modélisation pour quantifier la réduction possible des émissions de GES résultant de l'utilisation de Wi-Fi à énergie solaire comme point d'accès Internet. Nous décrivons en détail la méthodologie utilisée et les résultats de notre modélisation. Nous discutons également des avantages et des limitations de cette approche.

**Le chapitre 4** explore en détail les concepts fondamentaux de l'apprentissage automatique profond ainsi que les algorithmes utilisés dans nos approches. Il se penche sur plusieurs types de réseaux de neurones, notamment les Réseaux de Neurones Profonds, les Réseaux de Neurones Récurrents (RNNs) et les Réseaux de Neurones *Long Short-Term Memory* (LSTM). De plus, il aborde la notion cruciale des hyperparamètres en apprentissage automatique, qui jouent un rôle essentiel dans la configuration et l'optimisation des modèles. Enfin, le chapitre examine également les différentes métriques utilisées pour évaluer les performances des modèles d'IA, permettant ainsi de mesurer leur efficacité et leur précision.

**Le chapitre 5** présente une revue de la littérature sur les algorithmes d'apprentissage automatique utilisés dans les réseaux sans fil et leurs consommations énergétiques.

**Le chapitre 6** se concentre sur l'analyse de l'impact des hyperparamètres des algorithmes d'apprentissage automatique utilisés dans les réseaux sans fil sur leur consommation d'énergie et leurs performances. Nous détaillons les différentes expériences que nous avons menées pour évaluer l'effet des hyperparamètres, ainsi que les résultats obtenus. Nous discutons des implications de ces résultats et des recommandations pour une utilisation plus écoénergétique des algorithmes d'apprentissage automatique.

**Le chapitre 7** conclut la thèse en résumant les principaux résultats et en soulignant les contributions de notre travail. Nous discutons également des perspectives futures pour la recherche sur l'efficacité énergétique des réseaux cellulaires et l'utilisation de l'IA dans la gestion des ressources du réseau sans fil.

## **1.4 Publications**

Cette thèse a produit deux publications :

**1-** Temim, S. ; Bensebaa, F. ; Talbi, L. Methodology for Quantitative Assessment of Greenhouse Gas Emissions Reduction of Solar-Powered Wi-Fi. *Electronics* 2021, 10, 2829. [https://doi.org/ 10.3390/electronics10222829](https://doi.org/10.3390/electronics10222829)

**2-** Temim, S.; Talbi, L.; Bensebaa, F. Analysis and Multiobjective Optimization of a Machine Learning Algorithm for Wireless Telecommunication. *Telecom* 2023, 4, 219–235. [https://doi.org/ 10.3390/telecom4020013](https://doi.org/10.3390/telecom4020013)

## Chapitre 2

### Notions fondamentales des réseaux sans fil et les approches visant à réduire leurs émissions de gaz à effet de serre

#### 2.1 Introduction

Ce chapitre se focalise sur les notions fondamentales des réseaux sans fil. Dans un premier temps, nous abordons de manière succincte l'évolution des réseaux sans fil, les différentes classifications qui leur sont associées, les architectures typiques ainsi que la consommation énergétique inhérente à ces réseaux. Ensuite, nous approfondissons la discussion en présentant de manière détaillée les méthodes visant à réduire la consommation énergétique des réseaux sans fil. Cette section met en évidence les stratégies et techniques efficaces qui permettent d'optimiser l'utilisation de l'énergie dans ces réseaux.

#### 2.2 L'évolution des réseaux mobiles

L'évolution des réseaux mobiles a été remarquable depuis la première génération (1G) des années 1980 jusqu'à la 5G qui est en cours de déploiement. Le Tableau 1 résume les différentes générations de systèmes cellulaires et les technologies associées.

**Première génération:** La 1G de réseaux mobiles était analogique et ne permettait que des appels vocaux de base. La qualité de la voix était souvent médiocre et les appels pouvaient être facilement interceptés [12].

**Deuxième génération:** La 2G de réseaux mobiles a introduit la technologie numérique, ce qui a permis une amélioration significative de la qualité de la voix et la possibilité d'envoyer des messages texte. Les réseaux 2G ont également offert des fonctionnalités de roaming et de messagerie internationale [13].

**Troisième génération:** La 3G de réseaux mobiles a permis d'accéder à Internet à haut débit et a permis l'introduction de services de données tels que la vidéoconférence et la diffusion en continu de contenu multimédia. Les réseaux 3G ont également permis des vitesses de téléchargement plus rapides [14].

**Quatrième génération:** La 4G de réseaux mobiles, également connue sous le nom de LTE (*Long Term Evolution*), a considérablement augmenté les vitesses de données mobiles en permettant des vitesses de téléchargement allant jusqu'à 1 Gbit/s. Les réseaux 4G ont

également offert des capacités améliorées pour la diffusion en continu de contenu multimédia et la réalité virtuelle [15] .

**Cinquième génération** : La 5G de réseaux mobiles est actuellement en cours de déploiement dans le monde entier. Les réseaux 5G offrent des vitesses de données mobiles encore plus rapides, avec des vitesses de téléchargement allant jusqu'à 20 Gbit/s. La 5G promet également une latence extrêmement faible, ce qui permettra des applications en temps réel telles que la réalité virtuelle, les véhicules autonomes et la télémédecine [16] .

**Tableau 1** : Évolution des générations de systèmes cellulaires et technologies associées

Génération	Caractéristiques principales	Technologies utilisées
<b>1G</b>	Voix analogique	AMPS ( <i>Advanced Mobile Phone System</i> )
<b>2G</b>	Voix numérique, SMS	GSM ( <i>Global System for Mobile Communications</i> )
<b>3G</b>	Données mobiles, internet mobile, vidéo appels	UMTS ( <i>Universal Mobile Telecommunications System</i> )
<b>4G</b>	Haut débit mobile, IP multi-services, streaming vidéo	LTE
<b>5G</b>	Très haut débit, faible latence, IoT massif, réalité virtuelle.	NR ( <i>New Radio</i> )

### 2.3 Classification des réseaux sans fil par couverture

Actuellement, il existe une variété de standards et de technologies sans fil qui peuvent être classés en fonction de leur couverture. Les réseaux personnels sans fil WPAN (*Wireless Personal Area Network*), tels que le Bluetooth (*IEEE 802.15.1*), sont caractérisés par une portée radio très courte. Ce type de réseau permet d'interconnecter des appareils sur de courtes distances, de l'ordre de quelques centimètres, tels que les imprimantes, les claviers, les téléphones, etc. La deuxième catégorie de réseaux sans fil est celle des réseaux locaux sans fil WLAN (*Wireless Local Area Network*), tels que Hiperlan (*HIGH PERFORMANCE radio LAN*) et Wi-Fi (*IEEE 802.11*). Ces réseaux offrent une portée de communication radio variant entre 10 et 300 mètres. Ils sont déployés dans les entreprises, les campus universitaires, les maisons, les aéroports. Les débits de communication offerts par ces réseaux peuvent atteindre jusqu'à 300 Mbps (*802.11n*). Enfin, il existe une catégorie de réseaux à grande échelle, où la portée de communication radio peut atteindre plusieurs kilomètres. Parmi ces réseaux, on retrouve les réseaux cellulaires qui ont connu un développement rapide, passant du système mondial de communication avec les mobiles (GSM) de la 2G à l'Universal mobile télécommunication

system (UMTS) de 3G, et aujourd'hui le LTE-Advanced est considéré comme la 4G de ces réseaux. À chaque nouvelle génération, des services supplémentaires et une certaine qualité de service sont ajoutés pour répondre aux exigences croissantes des utilisateurs. Ces avancées technologiques ont permis d'offrir des services supplémentaires et une meilleure expérience utilisateur dans les réseaux cellulaires, accompagnés d'une amélioration constante de la qualité et de la vitesse des connexions. Ainsi, les réseaux sans fil se sont adaptés aux besoins toujours plus exigeants des utilisateurs et ont contribué à une évolution significative des possibilités de communication à différentes échelles [17].

## **2.4 Architecture d'un réseau cellulaire traditionnel**

Les systèmes cellulaires traditionnels utilisent un nombre de cellules relativement faible pour assurer la couverture des zones urbaines ou régionales étendues. Les BS sont installées sur de grands bâtiments ou des collines et transmettent à très haute puissance avec des zones de couverture cellulaire de plusieurs kilomètres carrés. Ces grandes cellules sont appelées macrocellules. La puissance du signal a été rayonnée uniformément dans toutes les directions, de sorte qu'un mobile en mouvement circulaire autour de la BS aurait une puissance reçue approximativement constante si le signal n'est pas bloqué par un objet atténuant. Ce contour circulaire de puissance constante donne au système, une forme de cellule hexagonale, car un hexagone est la forme régulière la plus proche d'un cercle pouvant couvrir une zone donnée avec plusieurs cellules non chevauchantes. Cette configuration en forme de cellule hexagonale présente plusieurs avantages. Tout d'abord, elle permet d'optimiser l'utilisation des fréquences radio disponibles, car les cellules adjacentes utilisent généralement des fréquences différentes pour éviter les interférences mutuelles. De plus, la forme régulière des cellules hexagonales facilite la planification et l'optimisation du réseau, en permettant une répartition équilibrée des ressources et une gestion efficace du trafic. Cependant, les cellules ne sont pas toujours parfaitement hexagonales en raison de contraintes physiques et de la topographie de la région. Des ajustements peuvent être nécessaires pour s'adapter aux contraintes locales, ce qui peut entraîner des cellules de formes et de tailles variables [18].

## **2.5 Architecture du réseau HetNet (*Heterogeneous network*)**

Le réseau HetNet est une architecture de réseau sans fil qui intègre différents types de cellules et de technologies de communication afin de répondre aux diverses demandes des utilisateurs et d'optimiser les performances du réseau. L'architecture du réseau HetNet est caractérisée par

l'intégration de cellules de différentes tailles et capacités, permettant une meilleure adaptation aux conditions de trafic et de couverture spécifiques à chaque secteur.

La mise en œuvre de la technologie 5G a pour objectif de fournir une connectivité rapide et omniprésente, ce qui génère une augmentation de la demande en données. Pour satisfaire cette exigence en termes de capacité et de vitesse, le réseau nécessite une modification de son infrastructure. À cet effet, une stratégie de déploiement dense de plusieurs BS de différents rayons de couverture s'est avérée rentable. En effet, l'installation d'une seule BS peut être très coûteuse, ce qui incite les opérateurs à réutiliser leurs ressources existantes en termes de BS traditionnelles, telles que les macrocellules qui offrent une couverture étendue et une puissance de rayonnement uniforme. D'autres types de BS, tels que les picocellules et les femtocellules, offrent une couverture plus réduite, adaptée aux zones à faible densité de trafic.

Cette transformation de l'infrastructure réseau permet de mieux satisfaire les demandes de la 5G, en améliorant la capacité de transfert de données tout en assurant un haut niveau de qualité de service. Les BS ayant différentes zones de couverture sont dynamiquement utilisées pour gérer la charge de trafic en fonction des besoins, optimisant ainsi l'utilisation des ressources disponibles (Figure 2). De plus, cette stratégie garantit une connectivité ininterrompue pour les utilisateurs, indépendamment de leur localisation, en recourant à la BS la plus adaptée en termes de couverture et de capacité [19].

**2.5.1 Les microcellules** : ce sont des BS de petite taille qui couvrent une zone géographique limitée, généralement de quelques centaines de mètres. Les microcellules sont souvent utilisées dans les zones urbaines denses où la capacité est limitée.

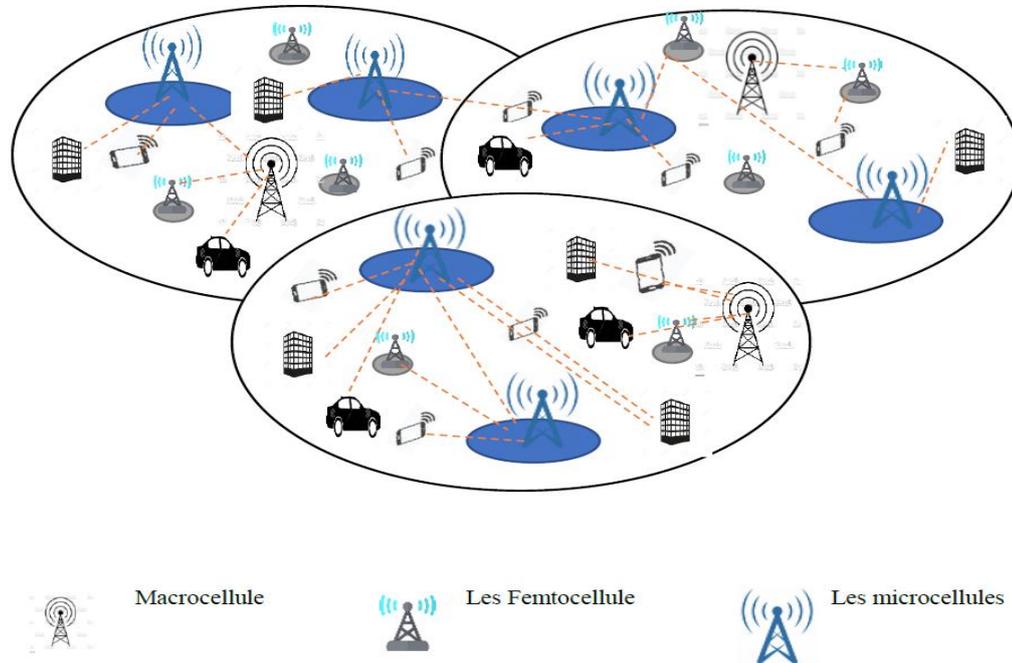
**2.5.2 Les macrocellules** : ce sont des BS plus grandes qui couvrent une zone géographique plus grande, généralement de plusieurs kilomètres. Les macrocellules sont utilisées pour fournir une couverture dans les zones rurales ou moins denses.

**2.5.3 Les femtocellules** : ce sont des points d'accès Wi-Fi de petite taille qui sont installés dans des bâtiments pour fournir une couverture supplémentaire à l'intérieur. Les femtocellules peuvent être utilisées pour améliorer la couverture dans des zones où la couverture est faible.

**2.5.4 Les relais de signal** : ce sont des nœuds de transmission qui relaient le signal d'une BS vers une zone où le signal est faible. Les relais de signal sont souvent utilisés pour étendre la couverture dans des zones où les signaux ne peuvent pas atteindre les BS.

**2.5.5 Technologies de communication** : Le réseau HetNet peut intégrer différentes technologies de communication sans fil, telles que le Wi-Fi, la 4G, la 5G, etc. Cela permet

une utilisation optimale des ressources et une connectivité transparente pour les utilisateurs, en exploitant les avantages de chaque technologie en fonction des besoins spécifiques de la zone.



**Figure 2:** Exemple d'un réseau HetNet

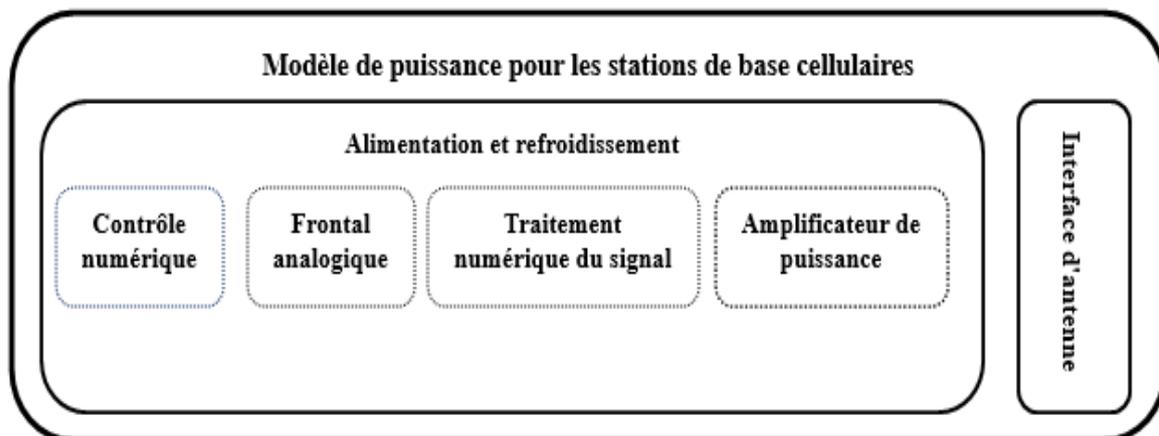
## 2.6 La consommation d'énergie dans les réseaux sans fil

La consommation d'énergie dans les réseaux sans fil est un aspect crucial en raison de l'ampleur croissante de ces réseaux et de l'impact environnemental associé. Les éléments clés concernant la consommation d'énergie dans les réseaux mobiles sont :

- **BS** : Les BS sont l'un des principaux consommateurs d'énergie dans les réseaux mobiles. Elles nécessitent de l'énergie pour alimenter les antennes, les équipements de transmission et de traitement du signal, ainsi que pour maintenir les systèmes de refroidissement nécessaires pour prévenir la surchauffe des équipements. Le modèle de consommation d'énergie quantifie la consommation d'énergie d'une BS et de ses sous-composants. Une architecture typique d'une BS est représentée dans la Figure 3 et comprend les composants et sous-composants suivants :
  - Amplificateur de puissance.
  - Frontal analogique, comprenant : amplificateurs et filtres (basebande analogique et radio fréquence), mélangeurs de conversion

montante/descendante, synthétiseur de fréquence et convertisseur numérique/analogique/analogique/numérique.

- Interface d'antenne, comprenant : les filtres Tx/Rx (par exemple, duplexeur), la perte d'alimentation (connexion entre l'antenne et l'émetteur-récepteur) et les antennes.
- Traitement numérique du signal, comprenant : filtrage en bande de base, suréchantillonnage/sous-échantillonnage pré-distorsion numérique, compensation numérique des non-idéalités du système, modulation/démodulation, canal encodage/décodage, estimation de canal, synchronisation et traitement pour MIMO (*Multiple Input Multiple Output*) et égalisation.
- Contrôle numérique, comprenant : le processeur de contrôle de plateforme, interface de liaison série dorsale et processeur de couche MAC (*Media Access Control*) et réseau.
- Alimentation, comprenant : convertisseur et refroidissement actif.



**Figure 3:** Composants du modèle de puissance de la BS.

En fonction du type de BS et de la zone de déploiement ainsi que de la taille de la cellule, certains sous-composants pourraient être absents et seront donc modélisés comme ayant une consommation d'énergie nulle. Il est important de préciser que pour les composants numériques, le terme "sous-composants" se réfère à différentes étapes de traitement du signal qui ne correspondent pas forcément à des éléments matériels distincts.

- **Équipements Utilisateur:** Les dispositifs mobiles tels que les smartphones, les tablettes et les ordinateurs portables ont également un impact sur la consommation d'énergie des réseaux sans fil. Ces appareils consomment de l'énergie pour établir une communication avec les BS, traiter les données, illuminer l'écran, exécuter des applications, etc. Les applications et fonctionnalités qui nécessitent beaucoup de ressources, comme le streaming vidéo, peuvent entraîner une consommation d'énergie accrue.

## **2.7 Les méthodes de réduction de la consommation énergétique des réseaux sans fil**

Différentes approches distinctes sont disponibles pour réduire la consommation d'énergie dans les réseaux cellulaires mobiles. Les recherches antérieures ont généralement classé ces approches en cinq catégories principales : l'amélioration de l'efficacité énergétique des composants matériels, l'extinction sélective des composants, l'optimisation de l'efficacité énergétique du processus de transmission radio, la planification et le déploiement de cellules hétérogènes, ainsi que l'adoption de ressources énergétiques renouvelables. Ces catégories englobent les différentes stratégies qui ont été développées pour minimiser la consommation d'énergie et promouvoir une utilisation plus durable des réseaux sans fil.

### **2.7.1 Amélioration de l'efficacité énergétique des composants matériels**

Les approches de la première catégorie visent à améliorer les composants matériels (tels que l'amplificateur de puissance) avec une conception plus économe en énergie [20, 21]. Les performances de la plupart des composants utilisés dans l'architecture actuelle des réseaux cellulaires ne sont pas satisfaisantes du point de vue de l'efficacité énergétique. Si l'on considère, par exemple, l'amplificateur de puissance, le composant consommant la plus grande quantité d'énergie dans une BS cellulaire typique, plus de 80 % de l'énergie d'entrée est dissipée sous forme de chaleur. Généralement, la puissance de sortie utile n'est que d'environ 5% à 20% de la puissance d'entrée [22]. Des études ont montré que le rapport potentiellement optimisé entre la puissance de sortie et la puissance d'entrée pour les amplificateurs de puissance (efficacité énergétique) pouvait atteindre 70%. En conséquence, une quantité substantielle d'économie d'énergie peut être réalisée si des composants plus économes en énergie sont adoptés dans le réseau. Cependant, le coût de mise en œuvre de ces approches est élevé. Par exemple, un module d'amplification de puissance avec une efficacité énergétique de 35% pour les petites cellules ou LTE BS (couvrant au maximum une zone d'un rayon de 2

km) coûte environ 75 \$ [23] . Le coût sera encore plus élevé pour une plus grande couverture ou une plus grande efficacité énergétique. Par conséquent, un examen attentif des aspects opérationnels et économiques par les opérateurs de réseau est nécessaire avant que des décisions sur le remplacement du matériel ne soient prises.

### **2.7.2 Éteindre les composants de manière sélective**

La deuxième catégorie couvre les approches qui désactivent sélectivement certaines ressources dans l'architecture de réseau existante pendant les heures creuses de trafic [24]. Les approches de cette catégorie tentent généralement d'économiser de l'énergie en surveillant la charge de trafic sur le réseau, puis décident de s'éteindre (ou de passer en mode veille, également appelé mode basse consommation ou mode ralenti profond dans certaines publications), ou d'allumer (ou passer en mode actif, en mode prêt ou en mode veille) certains éléments du réseau. Les consommations d'énergie inutiles, par exemple, les BS sous-chargées de la climatisation, peuvent être évitées en adoptant de tels mécanismes de mode veille. Ces approches impliquent généralement la commutation de certains éléments, y compris, mais sans s'y limiter, les amplificateurs de puissance, l'unité de traitement du signal, l'équipement de refroidissement, l'ensemble de la BS ou l'ensemble du réseau dans les deux sens entre le mode veille et le mode actif [25]. Le plus souvent, les techniques du mode veille visent à économiser de l'énergie en éteignant sélectivement les BS pendant les heures « creuses ». Les BS consomment la plus grande proportion d'énergie dans les réseaux cellulaires. D'autre part, les déploiements de BS denses conduisent aujourd'hui à une petite zone de couverture et à des modèles de trafic plus aléatoires pour les BS individuelles, ce qui rend les opérations en mode veille plus souhaitables. Compte tenu de la contrainte selon laquelle certains composants (par exemple, un nombre minimum de BS) doivent toujours rester allumés pour prendre en charge le fonctionnement de base du réseau, ainsi que l'exécution de l'opération de commutation dépend des fluctuations du profil de trafic, l'économie d'énergie rapportée est pas aussi élevée que celui des approches à base de composants. De plus, bien qu'il soit bon d'économiser de l'énergie, la mise en veille BS pourrait avoir un impact négatif sur la qualité de service dans le réseau en raison de la diminution de la capacité, à moins que des solutions correctives spécifiques ne soient adoptées simultanément [26, 27]. Néanmoins, comme les techniques du mode veille sont basées sur l'architecture actuelle, elles ont l'avantage d'être plus faciles à tester et à mettre en œuvre car aucun remplacement de matériel n'est nécessaire et les performances peuvent être évaluées par simulation informatique.

### 2.7.3 Optimisation de l'efficacité énergétique du processus de transmission radio

La troisième catégorie travaille sur le processus de transmission radio. Les approches appartenant à cette catégorie travaillent sur la couche physique ou MAC. Des techniques avancées, notamment la technique MIMO, la transmission radio cognitive, le relais coopératif, le codage de canal et l'allocation de ressources pour la signalisation ont été étudiées pour améliorer l'efficacité énergétique des réseaux de télécommunication [28-30]. Diverses approches ont été proposées pour utiliser efficacement les ressources dans les domaines temporel, fréquentiel et spatial afin de réaliser des économies d'énergie. Semblable aux approches basées sur le mode veille, cette famille d'approches ne nécessite généralement pas de mise à niveau des composants matériels du système. Cependant, les compromis entre l'efficacité énergétique et d'autres paramètres de performance du réseau sont probablement inévitables. De plus, les erreurs de mesure dues à des problèmes d'incertitude compliqués tels que le bruit et les interférences ont encore été bien corrigées.

Sur la base de la théorie de l'information, quatre compromis fondamentaux liés à l'efficacité énergétique sur les réseaux sans fil ont été reconnus [31, 32] :

- Efficacité du déploiement - efficacité énergétique : Ce compromis traite de la manière dont les dispositifs sans fil sont disposés géographiquement (par exemple, densité des stations de base, répartition spatiale des antennes). La contrepartie ici est qu'une plus grande densité de déploiement peut améliorer la couverture et la capacité du réseau, mais cela augmentera également la consommation énergétique globale.
- Efficacité du spectre - efficacité énergétique : Ce compromis porte sur l'utilisation du spectre radiofréquence. L'efficacité spectrale fait référence à la quantité de données qui peut être transmise sur une bande de fréquence donnée. La contrepartie est que l'augmentation de l'efficacité spectrale peut souvent nécessiter une augmentation de la consommation d'énergie, en raison de l'utilisation de techniques de modulation plus complexes ou de puissances de transmission plus élevées.
- Bande passante - puissance : Ici, le compromis est entre la quantité de bande passante (la gamme des fréquences utilisées pour transmettre des informations) et la puissance nécessaire pour transmettre sur cette bande passante. Plus de bande passante peut permettre des débits de données plus élevés, mais peut aussi nécessiter une puissance de transmission plus importante, ce qui se traduit par une plus grande consommation d'énergie.

- Délai - puissance : Ce compromis concerne la relation entre la latence (le temps de délai dans la communication) et la consommation d'énergie. Diminuer la latence signifie souvent transmettre des données plus rapidement, ce qui peut requérir une puissance de traitement et de transmission plus élevée, entraînant une consommation d'énergie accrue.

Quant au compromis le plus prometteur, cela dépend des besoins spécifiques du réseau et des objectifs de performance. Par exemple, dans un environnement où la disponibilité du spectre est limitée, l'efficacité du spectre pourrait être prioritaire. Dans d'autres cas, la minimisation de la consommation d'énergie peut être plus critique, mettant ainsi l'accent sur l'efficacité du déploiement. La sélection du compromis optimal dépendra donc du contexte et des contraintes spécifiques de chaque réseau sans fil.

#### **2.7.4 Planification et déploiement de cellules hétérogènes**

La quatrième catégorie s'attaque au problème en déployant de petites cellules, y compris des micros, pico et femto cellules, dans le réseau cellulaire. Ces cellules plus petites desservent de petites zones à trafic dense avec des BS à faible consommation d'énergie par exemple, [21, 33-35], qui sont abordables pour le déploiement des utilisateurs et prennent généralement en charge le branchement et la fonction de jeu. Contrairement au déploiement de macrocellules homogènes classiques, un tel déploiement hétérogène réduit la consommation d'énergie dans le réseau en raccourcissant la distance de propagation entre les nœuds du réseau et en utilisant des bandes de fréquences plus élevées pour prendre en charge des débits de données plus élevés. La principale contrainte de ces approches est que les très petites cellules apportent des interférences radio supplémentaires par rapport aux réseaux de macrocellules homogènes conventionnels, ce qui pourrait affecter négativement l'expérience de l'utilisateur. Pendant ce temps, si trop de cellules micro, pico ou femto sont déployées, la tendance à l'économie peut même être inversée en raison de l'énergie intrinsèque supplémentaire consommée par les cellules nouvellement déployées ainsi que des frais généraux introduits dans la transmission. Par conséquent, le nombre de cellules supplémentaires plus petites, ainsi que leurs emplacements, doivent être soigneusement planifiés afin de réduire la consommation totale d'énergie. Il a également été remarqué que l'intégration du déploiement de réseaux hétérogènes avec des schémas en mode veille peut potentiellement réaliser des gains significatifs en terme d'économie d'énergie [36-38].

### **2.7.5 Adopter des ressources énergétiques renouvelable**

La dernière catégorie comprend des approches qui adoptent des ressources énergétiques renouvelables à faible intensité énergétique. Par rapport aux ressources énergétiques actuellement largement utilisées telles que les hydrocarbures qui produisent des GES, les ressources renouvelables telles que l'énergie hydraulique, éolienne et solaire se distinguent par leur durabilité et leur faible empreinte carbone [39, 40]. L'intégration de sources telles que des panneaux solaires et des éoliennes offre des avantages considérables. Les panneaux solaires exploitent l'énergie du soleil, produisant de l'électricité propre pour alimenter les stations de base, les antennes et d'autres équipements. De même, les éoliennes convertissent l'énergie cinétique du vent en électricité, offrant une source d'énergie stable. Les fabricants des composants pour les télécommunications ont prévu la fourniture de BS fonctionnant à l'énergie solaire dans des zones sous-développées et rurales, où les routes sont en mauvais état et dangereuses, de sorte que la fourniture de ressources énergétiques traditionnelles pour les BS hors réseau (par exemple, le diesel) ne peut être garantie [41, 42].

## **2.8 Conclusion**

En conclusion, ce chapitre a abordé divers aspects des réseaux sans fil, en mettant l'accent sur l'évolution des réseaux mobiles, la classification des réseaux sans fil par couverture, l'architecture des réseaux cellulaires traditionnels, l'architecture du réseau HetNet, ainsi que la consommation d'énergie dans les réseaux sans fil. Des méthodes de réduction de la consommation d'énergie ont été présentées, mettant en évidence les stratégies et techniques efficaces pour optimiser l'utilisation de l'énergie dans les réseaux sans fil. On a aussi expliqué le rôle potentiel des énergies renouvelables dans la réduction de l'empreinte carbone des réseaux de télécommunications. Dans le prochain chapitre, nous explorerons le cadre de modélisation pour quantifier la réduction possible des émissions de GES résultant de l'utilisation de Wi-Fi à énergie solaire comme point d'accès Internet.

## Chapitre 3

### Méthodologie d'évaluation quantitative de la réduction des émissions de GES du Wi-Fi à énergie solaire

#### 3.1 Introduction

Dans ce chapitre, nous nous concentrons sur la méthodologie d'évaluation quantitative de la réduction des émissions de GES du Wi-Fi à énergie solaire. Dans un contexte mondial où la réduction des émissions de GES est devenue une priorité, il est crucial d'explorer des solutions durables pour minimiser l'impact environnemental des technologies de communication, notamment le Wi-Fi. Le Wi-Fi à énergie solaire émerge comme une alternative prometteuse, combinant la connectivité sans fil avec l'utilisation de l'énergie solaire renouvelable. L'objectif de ce chapitre est de présenter en détail la méthodologie développée dans notre publication intitulée "*Methodology for Quantitative Assessment of Greenhouse Gas Emissions Reduction of Solar-Powered Wi-Fi*" en fournissant un cadre solide pour évaluer de manière quantitative cette réduction des émissions de GES.

#### 3.2 Contexte et Justification

Les changements climatiques constituent une réalité accablante de notre époque, largement alimentée par les émissions de GES provenant de l'activité humaine, en particulier, la production et l'utilisation de sources d'énergie fossiles. Le groupe d'experts intergouvernemental sur l'évolution du climat a exhorté à limiter le réchauffement climatique à 1,5 °C par rapport aux niveaux préindustriels, une mesure qui exige l'exploration et l'adoption de technologies énergétiques plus propres. Bien que les efforts soient largement concentrés sur les secteurs des transports, de l'industrie et du bâtiment, qui sont de grands consommateurs d'énergie fossile, le secteur des TIC a tendance à être négligé. Pourtant, les données suggèrent que le secteur des TIC pourrait consommer jusqu'à la moitié de l'électricité mondiale d'ici 2030. La croissance de la demande d'énergie dans ce secteur est stimulée par le déploiement des réseaux 5G et la prévalence des appareils de l'IdO.

La hausse de la consommation d'énergie dans le secteur des TIC ajoute une pression supplémentaire sur les efforts visant à réduire les émissions de GES. Cette situation est exacerbée par une demande énergétique mondiale croissante, le manque de production d'énergie renouvelable à grande échelle et à des prix compétitifs. Dans ces conditions, la

demande croissante d'électricité va probablement conduire à une consommation accrue de charbon et de gaz naturel.

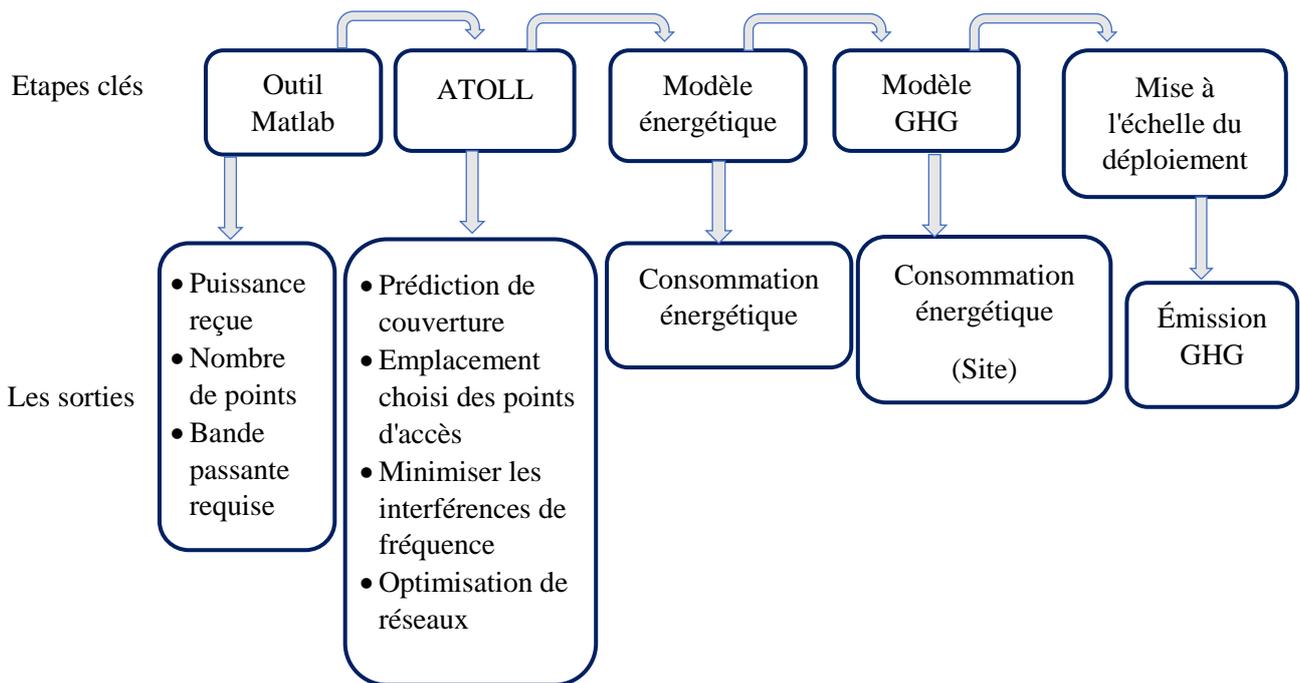
La tendance croissante de la demande d'énergie dans le secteur des TIC, en particulier pour alimenter les points d'accès Wi-Fi, appelle à l'intégration de solutions d'énergie propre dans les réseaux sans fil dès la phase de planification. En ce sens, l'énergie solaire a démontré son potentiel en tant que source d'énergie principale pour les points d'accès Internet. Cependant, l'optimisation de ces systèmes Wi-Fi solaires communautaires, y compris l'estimation détaillée de GES, reste une zone grise.

L'énergie verte décentralisée est une solution idéale pour alimenter les points d'accès Wi-Fi, d'autant plus que leur utilisation devrait quadrupler entre 2018 et 2023. Cette exigence est particulièrement pertinente dans les pays en développement, où l'utilisation de réseaux sans fil est en augmentation, mais souvent alimentée par des sources fossiles. Les réseaux sans fil photovoltaïques pourraient permettre un déploiement durable du Wi-Fi dans de nombreuses communautés.

Dans ce contexte, il est nécessaire de développer un cadre de prévision des GES qui tient compte du déploiement de l'énergie solaire communautaire alimentée par le Wi-Fi. Le développement d'un tel cadre et sa validation à travers des études de cas spécifiques aideront non seulement à comprendre l'impact potentiel des solutions Wi-Fi solaires sur la réduction des émissions de GES, mais contribueront également à la mise en œuvre de solutions énergétiques durables et propres dans le secteur des TIC.

### **3.3 Méthodologie d'évaluation des émissions de GES réduites par le Wi-Fi solaire**

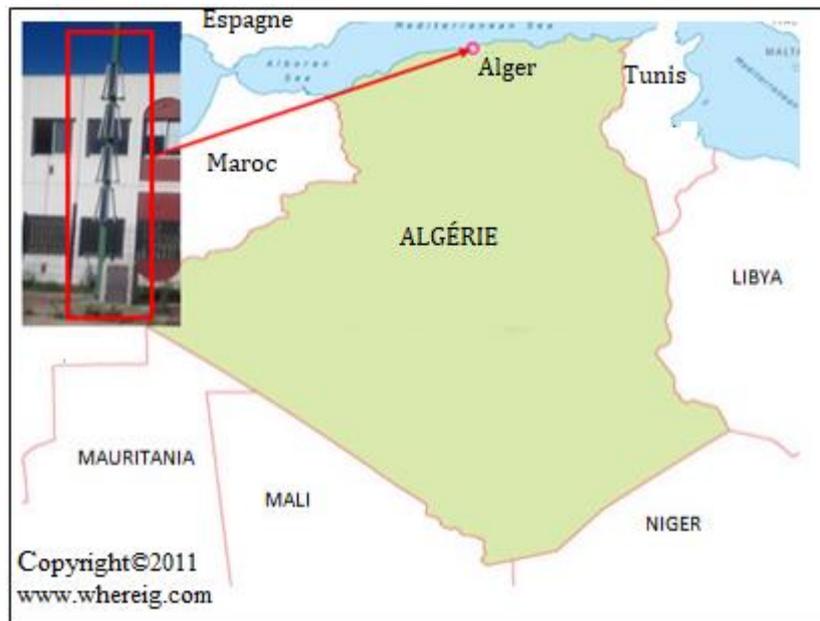
La méthodologie élaborée dans cette recherche offre un cadre exhaustif pour quantifier la diminution des émissions de GES induites par l'utilisation du Wi-Fi alimenté à l'énergie solaire. Ce processus inclut plusieurs étapes cruciales. La Figure 4 présente ces étapes essentielles et les résultats correspondants à chaque étape sont également mentionnés.



**Figure 4:** Méthodologie d'évaluation quantitative de la réduction des émissions de GES du Wi-Fi à énergie solaire.

### 3.3.1 Délimitation du système : Étude de cas

Nous avons adopté une approche ascendante pour évaluer l'impact possible sur les émissions de GES du déploiement de la technologie Wi-Fi alimentée par l'énergie solaire dans les campus universitaires. Afin d'élaborer cette méthodologie, une étude de cas concrète a été mise en place. Un système Wi-Fi autonome (Figure 5) a été conçu et installé sur le campus de l'École Nationale Supérieure de Technologie (ENST) situé près d'Alger, en Algérie. Des mini-panneaux solaires ont été disposés à proximité du point d'accès Wi-Fi. Cette configuration permet une plus grande adaptabilité pour répondre aux fluctuations de la demande énergétique.



**Figure 5:** Localisation géographique de l'étude de cas proposée.

Dans cette étude de cas, nous avons modélisé la portée du signal et les exigences énergétiques nécessaires pour couvrir l'intégralité du campus de l'ENST en utilisant la technologie Wi-Fi basée sur des points d'accès autonomes. Chaque point d'accès Wi-Fi est désigné comme une BS dans le cadre de cette étude. Chaque composant du réseau a été analysé pour estimer la consommation d'énergie totale du réseau. Par la suite, l'empreinte carbone de la consommation d'électricité a été calculée en utilisant deux sources d'énergie différentes : l'énergie fossile (en tant que référence) et l'énergie solaire. Cela permettra d'estimer la réduction potentielle des émissions de GES que pourrait apporter un déploiement plus large de stations Wi-Fi alimentées par l'énergie solaire.

### **3.3.2 Dimensionnement et planification du réseaux Wi-Fi**

Le dimensionnement et la planification des réseaux sans fil représentent des phases critiques dans le processus de mise en place d'un réseau efficace et efficient. En anticipant la consommation électrique globale pour divers scénarios de conception, nous pouvons mieux prévoir et gérer les ressources énergétiques. Les ressources nécessaires à la mise en service du réseau, y compris la bande passante, la fréquence et l'équipement sont soigneusement évaluées pour répondre aux besoins de tous les utilisateurs potentiels du campus.

Le dimensionnement de notre réseau Wi-Fi est basé sur deux critères fondamentaux : la couverture, qui garantit une connectivité uniforme sur l'ensemble du campus, et la capacité, qui assure une vitesse de connexion adéquate pour chaque utilisateur. Pour faciliter ce

processus, nous avons conçu une interface utilisateur intuitive sous MATLAB, un environnement de calcul numérique qui offre une grande flexibilité et puissance pour le dimensionnement et la planification du réseau.

L'optimisation de notre réseau a été réalisée grâce au simulateur de réseau de télécommunications ATOLL [43], un outil reconnu pour sa précision et sa fiabilité. Une fois le dimensionnement du système terminé, nous avons été en mesure d'estimer avec précision la consommation d'énergie du réseau. Cette mesure nous a permis de quantifier l'empreinte carbone du réseau, un indicateur essentiel pour évaluer l'impact environnemental de notre projet. Cela met en évidence notre engagement à minimiser notre impact sur l'environnement tout en fournissant un service de haute qualité.

### 3.3.2.1 Dimensionnement de la couverture du réseau Wi-Fi

La première phase du dimensionnement du système se concentre sur la détermination du nombre de BS nécessaires pour une couverture complète du campus. Cette étape nécessite une estimation précise de la perte maximale de trajet, que nous avons évaluée en suivant la méthodologie décrite dans la référence [44]. Nous avons ensuite calculé le bilan de liaison pour vérifier si le niveau de puissance reçu serait suffisamment fort pour assurer un fonctionnement correct de la liaison, et évaluer la qualité du signal. Il est important de noter que ce paramètre est particulièrement complexe à déterminer car il est intrinsèquement lié aux besoins spécifiques de chaque utilisateur.

Dans l'objectif de fournir une couverture Wi-Fi optimale, les émetteurs Wi-Fi nécessaires ont été installés sur des lampadaires solaires, une stratégie à la fois économique et favorable à l'environnement, contribuant à la réduction des émissions de GES.

Pour déterminer l'affaiblissement sur le trajet ( $PL_{50}$ ) nous avons pris en compte plusieurs modèles de propagation [45]. Le modèle le plus approprié pour notre réseau Wi-Fi s'est avéré être le modèle d'Egli [46]. Ce modèle est spécialement conçu pour calculer l'affaiblissement médian sur un terrain irrégulier, ce qui correspond aux conditions de notre campus.

$$PL_{50} = G_b G_m \left[ \frac{h_b h_m}{d^2} \right]^2 \frac{40^2}{f} P_t \quad (1)$$

où

$PL_{50}$ : pertes de trajet (W)

$G_b$ : gain de l'émetteur de base (dB)

$G_m$ : gain de l'émetteur mobile (dB)

$h_b$ : hauteur de l'antenne de la station de base (m)

$h_m$ : hauteur de l'antenne de la station mobile (m)

$d$ : distance de liaison (m)

$f$ : fréquence (MHz)

$P_t$ : Puissance d'émission (W)

Les composantes de puissance du bilan de liaison liées au côté émetteur sont critiques. Celle-ci est souvent représentée par la puissance isotrope rayonnée effective (EIRP), donnée par :

$$EIRP = P_t - L_c + G_a \quad (2)$$

où

$P_t$ : puissance d'émission (dBm)

$L_c$ : pertes de câble (dB)

$G_a$ : gain de l'antenne de l'émetteur (dBi).

La composante de puissance du bilan de liaison liée au côté récepteur est représentée par la puissance reçue ( $Pr$ ) :

$$Pr(dBm) = EIRP - PL + G_r - L_c \quad (3)$$

où

$PL$ : pertes de trajet (dB)

$G_r$ : gain de l'antenne du récepteur (dBi)

Pour assurer une détection précise du signal transmis, la condition suivante doit impérativement être remplie :

$$Puissance\ reçue > Sensibilité\ du\ récepteur \quad (4)$$

Le dimensionnement de couverture proposée de la BS basée sur le Wi-Fi nous permet de déterminer le nombre de cellules pour optimiser la couverture du signal. Le nombre total de cellules est donné par :

$$Nombre\ de\ cellule = \frac{Superficie\ total}{\pi R} \quad (5)$$

où

$R$  : est la portée de chaque BS.

Le nombre de points d'accès (NPA) pour chaque cellule est déterminé par le rapport suivant :

$$NPA = \frac{BPT}{BPP} \quad (6)$$

où

BPT : bande passante totale

BPP : bande passante offerte par un point d'accès

Le nombre total de points d'accès (NTPA) dans le réseau sera alors :

$$NTPA = NPA.NC \quad (7)$$

où

NPA : nombre de points d'accès par cellule ;

NC: nombre de cellules.

### 3.3.2.2. Dimensionnement de la capacité du réseau Wi-Fi

Il est important d'estimer le nombre d'utilisateurs pouvant être gérés par un seul point d'accès afin de déterminer le nombre de points d'accès dans une zone de couverture.

La détermination du type d'application (données, voix, vidéo) détermine la nature du trafic que le réseau doit transporter. Cela garantit que les performances du réseau répondent aux besoins des utilisateurs.

Pour déterminer la capacité totale du système, il faut déterminer le débit individuel maximal nécessaire pour chaque service offert. Le Tableau 2 fournit des valeurs de bande passante typiques pour les principaux services pris en charge [47].

**Tableau 2** : Bande passante par service utilisé dans cette étude [47]

Service	Bande passante
Navigation sur le Web	19 Mbit /s
Streaming	114 Mbit /s
Conférence vidéo	10 Mbit /s
E-mail	11 Mbit /s
VoIP	11 Mbit /s
Chat / messagerie	08 Mbit /s
Réseaux sociaux	19 Mbit /s
Appel vidéo	11 Mbit /s

Afin de prendre en charge les différents services, nous devons disposer d'une bande passante suffisante au sein du réseau proposé. La bande passante (BBT) est calculé à l'aide de l'équation suivante :

$$BBT = \sum_j n_j t_j c_j \quad (8)$$

où

$n_j$  : nombre d'abonnés desservis par le service  $j$  ;

$c_j$  : bande passante par abonnés pour le service  $j$  ;

$t_j$  : taux de simultanéité pour la catégorie d'abonnés desservie par le service.

### 3.3.2.3 Planification et optimisation du réseau avec ATOLL

Le logiciel ATOLL est utilisé pour la *Planification* et l'optimisation des réseaux Wi-Fi. Il permet d'optimiser la distribution des fréquences dans l'environnement extérieur afin de minimiser les interférences co-canal et de trouver l'emplacement et le nombre optimaux de points d'accès. Les étapes suivantes sont prises en compte lors de la planification d'un réseau sans fil à l'aide du logiciel ATOLL [44] :

- Création d'un nouveau projet en choisissant la technologie sans fil.
- La précision du format des coordonnées géographiques, dans notre cas lié aux coordonnées de l'ENST et de la région d'Alger.
- Importation de cartes de la région concernée avec les caractéristiques du terrain.
- Configuration des paramètres de travail de la bande passante radiofréquence.
- Création d'un nouveau type d'antenne en précisant son gain et son diagramme de rayonnement.
- Création et configuration de sites ou de cellules selon les paramètres GPS du client.
- Ajustement des interférences avec le module *Automatic Frequency Planning* (AFP).
- Optimisation avec le module *Automatic Cell Planning* (ACP).

Le module ACP est critique et permet l'optimisation des réseaux et le calcul automatique des paramètres optimaux en termes de couverture et de qualité du signal. ACP supprime les sites ou secteurs inutiles ou choisit parmi les sites candidats qui peuvent être ajoutés pour améliorer les performances du réseau. Le module ACP peut également contrôler la puissance, l'inclinaison et l'azimut des antennes. Le processus d'optimisation est basé sur une fonction de coût. Le coût diminue lorsque le niveau de couverture et la qualité du signal augmentent. L'algorithme itératif s'ajuste lorsqu'un paramètre de réseau est modifié. Les scénarios obtenus à partir des différents changements sont classés en fonction de la fonction de coût. Lors de

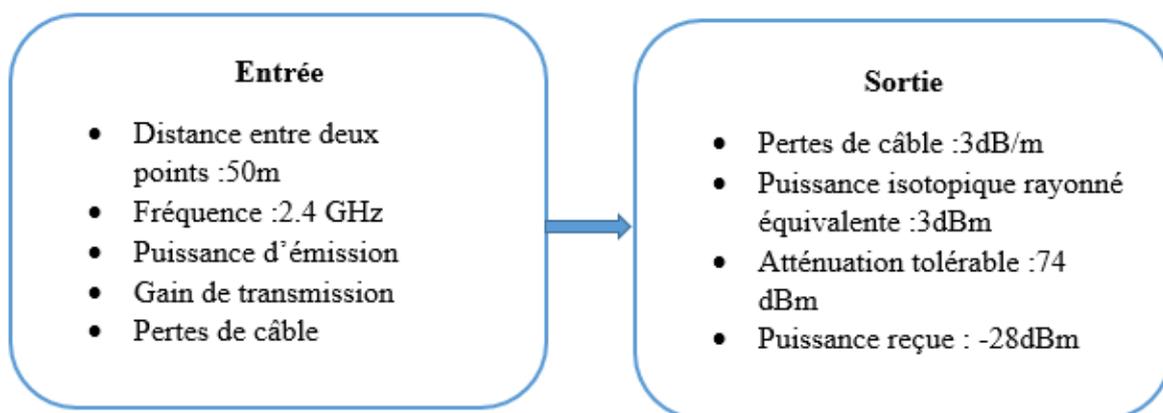
l'utilisation de l'ACP, nous devons spécifier les objectifs et activer uniquement les paramètres que nous souhaitons modifier lors de l'optimisation.

### 3.4 Résultats et discussion

En utilisant la méthodologie décrite ci-dessus, nous fournirons dans un premier temps des résultats liés à l'étude de cas du campus de l'ENST. Ensuite, nous évaluerons le potentiel de réduction des GES. Cette approche sera généralisée à toute la communauté Wi-Fi utilisant l'énergie solaire en remplacement des sources fossiles.

#### 3.4.1 Couverture optimale

Afin d'évaluer le budget radio du réseau Wi-Fi dans le site proposé, un point d'accès avec une consommation de 12 W et une puissance de rayonnement élevée de 27 dBm a été sélectionné. Avant le calcul, pour trouver la couverture optimale, les caractéristiques de l'équipement ont été introduites dans le simulateur, y compris les points d'accès, les antennes et les pertes de câble. La Figure 6 résume les données d'entrée-sortie à l'aide du code MATLAB. Si la puissance reçue (-28 dBm) est supérieure à la sensibilité du récepteur, la connexion est possible.



**Figure 6:** Données d'entrée-sortie de l'interface de la calculatrice MATLAB

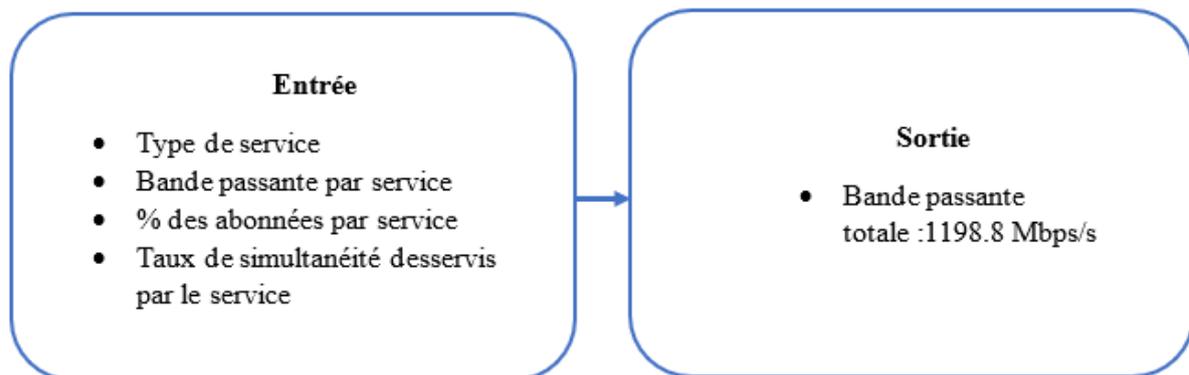
En utilisant le code MATLAB développé pour ce cas d'étude, nous avons estimé qu'au moins cinq points d'accès Wi-Fi pour couvrir l'ensemble du campus sont nécessaires. L'impact de l'utilisation d'un nombre inférieur et supérieur de points d'accès a également été évalué. La Figure 7 fournit le site optimal pour les cinq points d'accès Wi-Fi.



**Figure 7:** Site optimal pour les points d'accès Wi-Fi.

### 3.4.2 Capacité optimale

Dans un premier temps, nous devons calculer la bande passante nécessaire pour satisfaire la demande de ressources réseau sur le campus de l'ENST. Nous avons créé un autre outil en utilisant MATLAB pour cette tâche. La Figure 8 résume les principales données d'entrées et de sorties pour le calcul de la bande passante nécessaire dans le réseau.



**Figure 8:** Entrée-sortie de l'interface MATLAB l'estimation de la bande passante par cellule.

Comme indiqué dans la Figure 8, sur la base des données d'entrée et des informations, nous avons estimé qu'une bande passante totale de 1198,8 Mbp/s pour chaque cellule Wi-Fi est nécessaire.

### 3.4.3 Réseau optimal

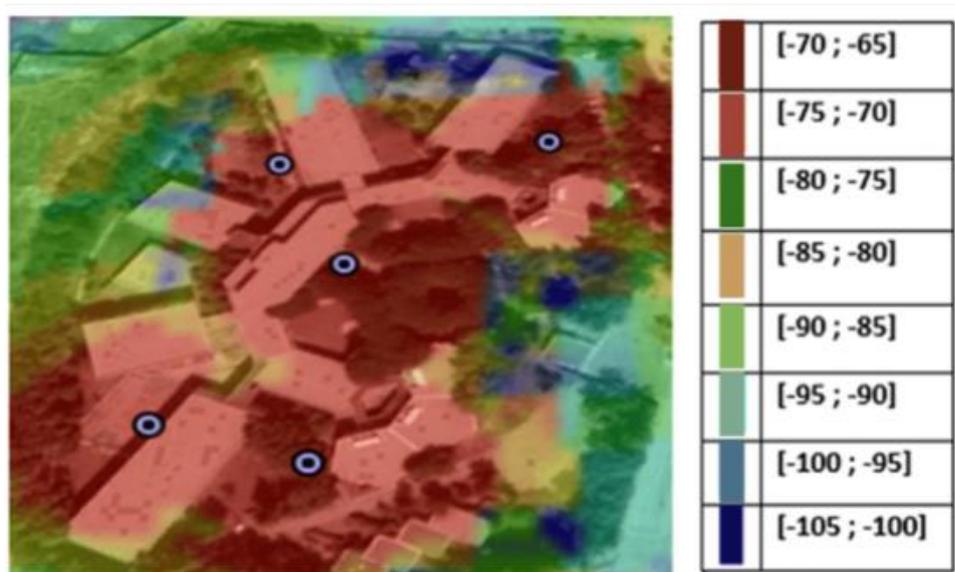
Le campus de l'ENST a été utilisé pour démontrer le cadre proposé. Comme la demande de de l'Internet est importante, la position physique des postes Wi-Fi est critique. Les coordonnées géographiques du campus ENST sont données dans le Tableau 3.

**Tableau 3:** Caractéristiques géographiques du site d'implémentation

Latitude	Longitude	Altitude	Localisation
36.777736	3.258834	14m	Alger, Algérie

Dans un premier temps, nous avons besoin d'optimiser les positions géographiques où les points d'accès Wi-Fi seront installés. Pour cela, nous avons importé une carte du campus ENST de Google Earth dans la plateforme ATOLL. Cela aidera à identifier les emplacements des points d'accès. La propagation du signal, le coût de la location et la disponibilité des sites où les équipements seront installés sont des critères critiques pour choisir les sites des points d'accès. Dans notre cas, les points d'accès Wi-Fi ont été placés à partir des coordonnées du GPS extraites de l'étude d'optimisation de l'éclairage des lampadaires solaires du campus de l'ENST.

Une fois que l'emplacement des points d'accès et leurs positions sur la carte géographique ont été identifiés, la distribution de fréquence pour chaque émetteur sur le réseau et le type d'antenne ont été sélectionnés. Lors du dimensionnement du réseau Wi-Fi précédemment traité, un point d'accès avec des caractéristiques spécifiques telles que la norme de compatibilité Wi-Fi, la puissance d'émission et la fréquence de travail ont été sélectionnés. Par la suite, ces paramètres ont été introduits dans le code du simulateur. Cela aidera à estimer la puissance reçue par un abonné à chaque point. La couverture de signal prévue pour le campus de l'ENST est illustrée à travers la Figure 9. Cela permet d'évaluer si les emplacements choisis des points d'accès sont appropriés.



**Figure 9:** Carte montrant la couverture en puissance du signal (dBm) prévue sur le campus de l'ENST.

Pour évaluer la couverture Wi-Fi, nous avons identifié cinq classes de qualité de niveau de signal :

- Une très bonne couverture correspond à un niveau de signal supérieur à -70 dBm.
- Bonne couverture : correspond aux valeurs de signal comprises entre -75 dBm et -80 dBm.
- Faible couverture : correspond à des valeurs de signal comprises entre -80 dBm et -85 dBm.
- Mauvaise couverture : correspond à des valeurs de signal comprises entre -85 dBm et -90 dBm.
- Une très mauvaise couverture : correspond à un niveau de signal inférieur à -90 dBm.

On peut remarquer que la couverture est presque complète dans la zone sélectionnée et que le niveau du signal varie entre -90 dBm et -70 dBm. Cependant, il existe des zones où le niveau du signal est faible, il y a donc une dégradation de la qualité de la couverture dans ces zones. Cela est dû au fait que le sol présente plusieurs obstacles en direction de ces emplacements, comme c'est le cas pour certaines zones où le niveau du signal est de -105 dBm.

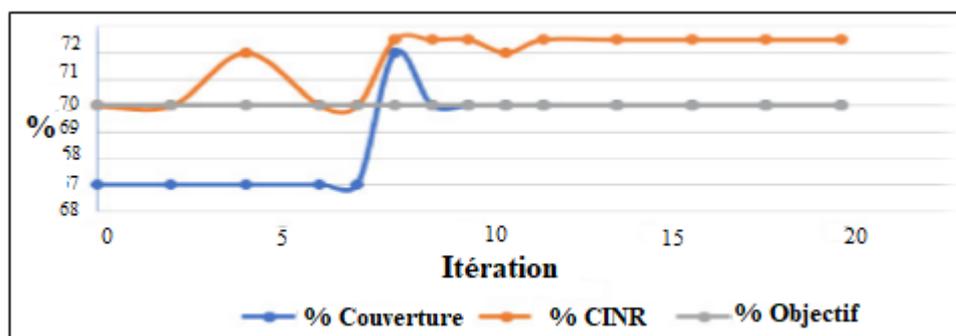
Pour minimiser les interférences dues à l'utilisation de canaux adjacents et à l'utilisation du même canal, le module AFP d'ATOLL a été utilisé. Le module AFP a été utilisé pour calculer automatiquement le coût total, qui est le taux d'interférence dans le réseau implanté.

L'optimisation a été réalisée à l'aide du module ACP, qui permet la conception de réseaux et calcule automatiquement les paramètres optimaux en termes de couverture et de qualité du signal. Dans le Tableau 4, nous pouvons voir les augmentations proposées de la qualité du signal et de la couverture

**Tableau 4 :** Paramètres optimaux avec ACP

L'ordre de changement	Le type de changement	Site	Initiale	Finale	% Amélioration de qualité
1	Puissance	Site 2	27	30	100
2	Azimut	Site 2	0°	340°	100
3	Site désactivé	Site 3	Activé	Désactivé	100
4	Site désactivé	Site 0	Activé	Désactivé	100

D'après le Tableau 4, on remarque qu'il y a quatre modifications : une modification du niveau de puissance d'émission, une modification du niveau d'azimut, et la désactivation des deux sites pour augmenter la qualité de couverture. Après avoir défini les objectifs d'optimisation et d'exécution du module ACP, les résultats suivants ont été obtenus (Figure 10).



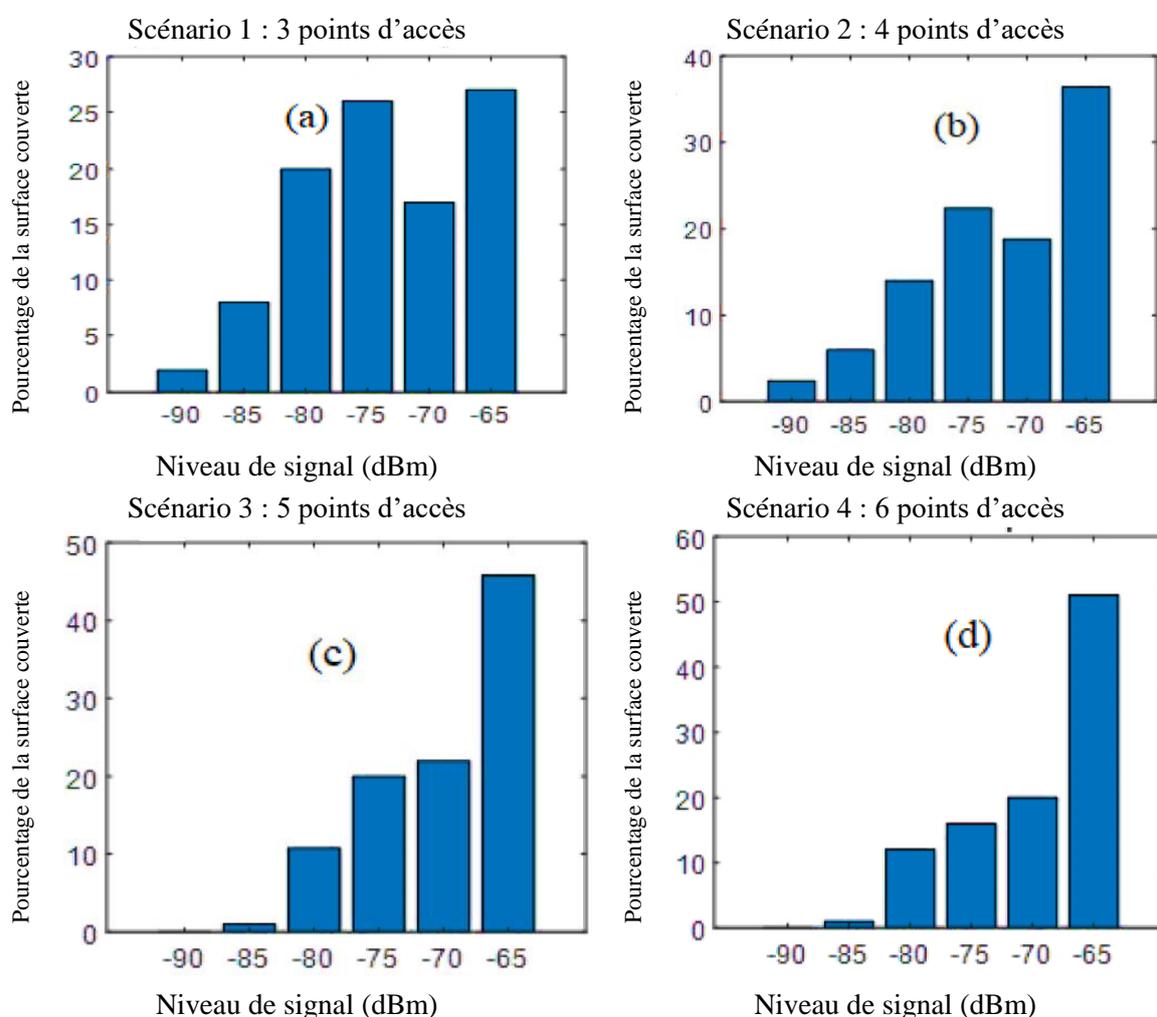
**Figure 10:** Évolution de la couverture et de la qualité du signal en fonction des itérations.

Selon l'emplacement exact des utilisateurs Wi-Fi sur le campus, ils pourraient se connecter à différents points d'accès offrant différents niveaux de qualité de signal. L'émetteur auquel l'abonné peut se connecter est classé par ordre décroissant selon la qualité du signal qu'il a pu obtenir.

### 3.4.4. Analyse du scénario

Le logiciel ATOLL a suggéré qu'un minimum de cinq BS sont nécessaires pour fournir une bonne couverture de service sur tout le campus. Cependant, nous avons voulu évaluer du point de vue de la consommation d'énergie comment le nombre de BS affectera la consommation d'énergie. Ce paramètre n'est pas pris en compte par l'optimiseur de logiciel de réseau Wi-Fi.

Afin de minimiser la consommation d'énergie et donc les émissions de GES, nous avons développé différents scénarios dans lesquels nous avons modifié le nombre de points d'accès. Cela aidera à lier la qualité de la couverture à la consommation d'énergie au sein du réseau Wi-Fi. De toute évidence, la réduction du nombre de points d'accès réduira la demande d'énergie. La Figure 11 résume le pourcentage de la zone totale du campus couverte par différents niveaux de signal pour différents nombres de points d'accès.



**Figure 11:** Histogramme basé sur le pourcentage de zones couvertes par (a) 3, (b) 4, (c) 5 et (d) 6 points d'accès.

Ci-dessous, nous utiliserons CO<sub>2</sub> alors qu'il s'agit en fait de CO<sub>2</sub> -eq, (équivalent CO<sub>2</sub>) représentant l'émission totale de GES. Pour estimer la quantité de CO<sub>2</sub> produite, nous avons utilisé la formule suivante :

$$Q_{CO_2} = E_{ap} * IE * T_{uap} \quad (9)$$

où

$Q_{CO_2}$ : quantité de CO<sub>2</sub> (g);

$E_{ap}$ : consommation électrique à chaque point d'accès (kW) ;

$IE$ : intensité électrique (g/kWh);

$T_{uap}$ : durée d'utilisation du AP (Access point) ;

Les émissions de CO<sub>2</sub> pendant la phase d'utilisation sont estimées pour chacun des quatre scénarios décrits ci-dessous.

#### **3.4.4.1. Scénario 1 (3 points d'accès)**

Avec trois points d'accès, nous avons pu couvrir 27% du campus avec un niveau de signal supérieur à -70dBm, et 43% de la surface est couverte par un niveau de signal compris entre -80 dBm et -70dBm. Ces trois points d'accès consomment 360Wh. Sur la base d'une durée de fonctionnement de 10h, la consommation énergétique d'électricité produite à partir d'énergie fossile (gaz naturel) produit 150g de CO<sub>2</sub>. Ainsi, si nous remplaçons la source d'électricité par l'énergie solaire, nous pouvons réduire la quantité de CO<sub>2</sub> à 19,8g.

#### **3.4.4.2. Scénario 2 (4 points d'accès)**

Dans le deuxième scénario, nous proposons de couvrir le campus avec quatre BS. Nous avons obtenu les résultats présentés sur la Figure 11.b, où 36,4 % de la surface du campus est couverte par un excellent niveau de champ supérieur à -70dBm, et 45% de la surface est couverte par un niveau de signal compris entre -80dBm et -70dBm. Quatre points d'accès sont actifs à une durée de 10h par jour et consomment une quantité d'électricité de 480Wh. Cette consommation d'énergie produit 200,64g de CO<sub>2</sub> si la source de production de l'électricité est basée sur le gaz naturel et 26,4g de CO<sub>2</sub> si la source de production de l'électricité est solaire.

#### **3.4.4.3. Scénario 3 (5 points d'accès)**

Dans ce scénario, nous avons réussi à couvrir 47% de la surface totale avec un niveau de champ supérieur à -70dBm et 39,6% de la surface avec un niveau de signaux compris entre

-80 dBm et -70dBm (Figure 11. c). L'énergie consommée par les cinq points d'accès est égale à 600 Wh pendant une période de fonctionnement de 10 par jour. La quantité de CO<sub>2</sub> résultant de la production d'électricité à partir du gaz naturel est de 250,8g et de 33g si l'électricité est produite à partir de l'énergie solaire.

#### 3.4.4.4. Scénario 4 (6 points d'accès)

Dans ce scénario, nous avons obtenu les résultats de couverture suivants (Figure 11.d) :

- 52% de la zone du campus est couverte par un très bon niveau de signal supérieur à -70 dBm ;
- 36% de la surface est couverte par un bon niveau de signal entre -80 dBm et -70 dBm.

Ces points d'accès sont actifs pendant une durée de 1 h par jour et consomment 720wh. Il en résulte 418g de CO<sub>2</sub> dans le cas où l'électricité est produite à partir du gaz naturel et 39,6g de CO<sub>2</sub> dans le cas où l'électricité est produite à partir de l'énergie solaire. Le Tableau 5 résume les résultats obtenus pour les quatre scénarios.

**Tableau 5:** Les résultats de simulation des quatre scénarios en termes de couverture (%) et de demande d'énergie (E) sont fournis pour différents scénarios et niveaux de signal.

		Plages de niveau de signal (dBm)							
		[-105: 100]	[-100: 95]	[-95: -90]	[-90: -85]	[-85: -80]	[-80: -75]	[-75: -70]	[-70: -65]
Scénario 1-3AP	%	0	0	2	7	21	26	17	27
	E	360 Wh							
Scénario 2-4AP	%	0	0	1	6	14	23	20	36
	E	480 Wh							
Scénario 3-5AP	%	0	0	0	1	11	19	22	47
	E	600 Wh							
Scénario 4-6AP	%	0	0	0	1	11	16	20	52
	E	720 Wh							

### 3.5. Potentiel de réduction des GES suite au déploiement du Wi-Fi solaire

Dans cette section, nous estimons la quantité d'émissions de CO<sub>2</sub> résultant de la consommation d'énergie par le réseau Wi-Fi. Nous comparerons l'empreinte carbone résultante avec la quantité de CO<sub>2</sub> résultante si nous remplaçons la source d'alimentation de ce réseau par une source d'énergie renouvelable. Dans l'étude de cas proposée, la source d'énergie est l'électricité solaire. Le processus d'évaluation de l'impact total est présenté ci-dessous. Pour estimer la quantité de CO<sub>2</sub> nous avons suivi les quatre étapes suivantes :

- Étape 1 : Identifiez la source d'électricité pour l'alimentation du réseau Wi-Fi.

- Étape 2 : Estimer la quantité de CO<sub>2</sub> résultant de la consommation d'électricité produite à partir d'une source d'énergie fossile.
- Étape 3 : Estimer la quantité de réduction de CO<sub>2</sub> si la source d'énergie est remplacée par une source renouvelable pour alimenter ce réseau.
- Étape 4 : Mise à l'échelle et généralisation

On commence par identifier la source d'énergie (la source de production d'électricité), puisque la quantité de CO<sub>2</sub> résultante varie d'une source à l'autre. En 2015, 98,36% de l'électricité produite en Algérie provenait du gaz naturel. L'intensité carbone de l'électricité à base de gaz naturel (GN) était de 418g de CO<sub>2</sub> par kWh. Dans notre cas, nous considérerons le scénario avec cinq points d'accès, qui fonctionne pendant une durée de 10h. Les cinq points d'accès consomment 600Wh, la quantité de CO<sub>2</sub> résultante est donc de 250 g par jour et de 915,42kg par an en utilisant de l'électricité au GN.

L'étape suivante consiste à estimer la quantité de CO<sub>2</sub> si la source d'énergie est remplacée par une source renouvelable pour alimenter ce réseau. L'Algérie est dotée d'un des rayonnements solaires les plus élevés au monde, avec plus de 2500h d'ensoleillement en moyenne par an sur une très grande partie de son territoire. L'énergie reçue quotidiennement sur une surface horizontale de 1 m<sup>2</sup> est d'environ 5kWh, ce qui correspond à 1700kWh/m<sup>2</sup> /an au nord et 2263 kWh/m<sup>2</sup> /an au sud du pays [48]. Si nous remplaçons l'alimentation électrique au GN du réseau Wi-Fi par de l'énergie solaire, les émissions de CO<sub>2</sub> seront réduites de 217g par jour et de 795kg par an.

### **3.6. Prévion de l'atténuation des GES résultant d'un déploiement plus large du Wi-Fi à énergie solaire**

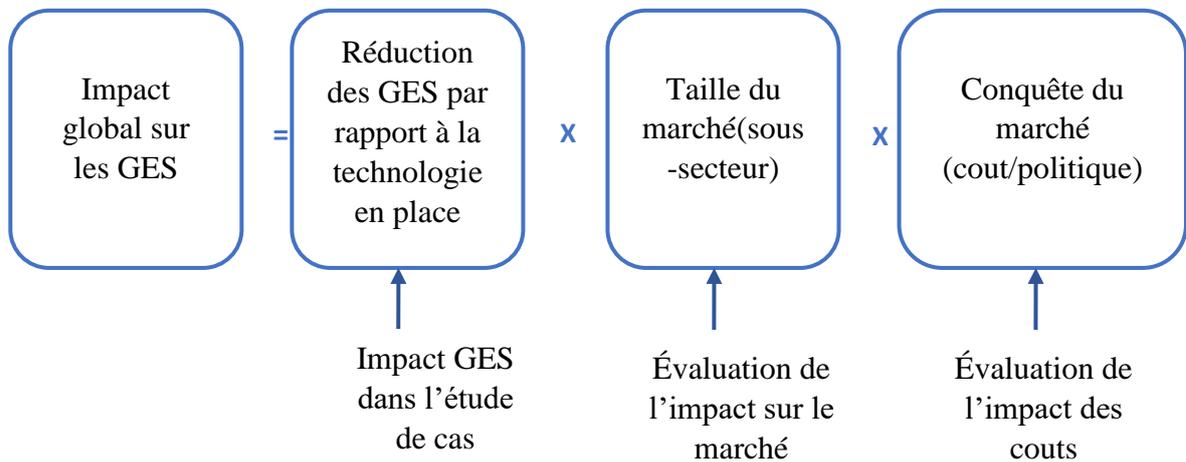
À l'aide des résultats de cette étude de cas, nous avons évalué l'impact d'un déploiement plus large. Nous avons développé une méthodologie de prévision simple pour l'atténuation potentielle des GES si le Wi-Fi à énergie solaire est déployé au niveau pays. À titre d'exemple, nous estimerons le potentiel d'émission de GES si le Wi-Fi à énergie solaire est déployé dans tous les campus universitaires du pays. Pour cela, nous devons quantifier trois paramètres clés:

- Quantité de réduction de GES de la nouvelle technologie par rapport à la technologie en place. Dans ce cas, l'énergie solaire est utilisée à la place de l'énergie fossile pour

générer l'électricité nécessaire pour alimenter le réseau Wi-Fi. Cette estimation doit être effectuée par point d'accès.

- Estimation de la taille globale du marché. Cela pourrait être représenté par le nombre de points d'accès pour couvrir tous les campus universitaires.
- La conquête potentielle du marché de la nouvelle technologie par rapport à la technologie en place. Le coût de déploiement est le principal facteur. D'autres facteurs (par exemple, la complexité du déploiement de la technologie) peuvent également affecter ce paramètre.

La méthodologie globale pour évaluer l'atténuation potentielle des GES lors de l'introduction d'une nouvelle technologie est présentée à la Figure 12.



**Figure 12:** Aperçu de la méthodologie pour les meilleurs technologies disponible (BAT), y compris la sélection et le classement.

Le deuxième paramètre qui est la taille du marché pourrait être obtenu à l'aide de l'équation suivante :

$$Taille\ du\ marché = A \times \left( \frac{S_{Pays}}{S_{ENST}} \right) \quad (10)$$

où  $A$  est le nombre de points d'accès dans l'étude de cas actuelle,  $S_{Pays}$  est le nombre total d'étudiants dans le pays et  $S_{ENST}$  est le nombre d'étudiants dans l'étude de cas actuelle.

Enfin, la capture du marché est probablement le paramètre le plus difficile à estimer. En l'absence d'une quantification détaillée, nous supposons un nombre arbitraire pour ce

paramètre. En supposant une prise de marché de 50%, l'atténuation globale des GES grâce au Wi-Fi à énergie solaire dans les campus universitaires est d'environ 1 089kg par jour et de 397 485kg par an. Même s'il est relativement faible par rapport aux émissions totales de GES dans le secteur des TIC de 720Mt [49] ou en Algérie (170 Mt en 2019) [50], un déploiement plus large du Wi-Fi dans d'autres communautés pourrait offrir des opportunités supplémentaires de réductions de GES. Avec la numérisation croissante dans plusieurs secteurs et l'utilisation plus large du streaming vidéo, nous nous attendons à ce que la réduction potentielle des GES due au déploiement du Wi-Fi solaire augmente considérablement.

Plusieurs facteurs pourraient affecter cette prévision. Nous n'avons pas tenu compte des variations horaires et saisonnières de l'irradiation et de la charge solaires. Un autre facteur critique est lié à l'avantage potentiel d'utiliser la production d'électricité solaire excédentaire pour répondre à la demande à l'intérieur et à l'extérieur du campus. En effet, dans des pays comme l'Algérie, le réseau est sous tension, avec une demande importante d'électricité pendant les journées chaudes surtout durant l'été.

### **3.7 Conclusion**

Dans ce chapitre, nous avons présenté une nouvelle méthode pour lier la consommation d'énergie à la couverture Wi-Fi. Un nouveau cadre d'estimation des émissions de GES a été décrit. On a aussi pu mettre en place une méthodologie de quantification de la réduction potentielle des émissions de GES qui pourrait résulter d'un déploiement Wi-Fi plus large. Ce cadre se compose de trois étapes clés. Tout d'abord, un modèle détaillé a été développé pour quantifier les besoins en énergie pour alimenter un réseau Wi-Fi communautaire au sein d'un campus universitaire. Deuxièmement, nous avons estimé la réduction de GES résultant du changement de combustible entre le solaire et le combustible fossile pour produire l'électricité requise. Enfin, un calcul simplifié a été effectué pour estimer l'atténuation potentielle des GES lorsqu'un déploiement plus large du Wi-Fi communautaire est réalisé au niveau du pays. Cette méthodologie pourrait également être utilisée pour prédire les réductions de GES si d'autres solutions technologiques propres sont déployées.

## Chapitre 4

### Rappel sur l'apprentissage automatique profond

#### 4.1 Introduction

L'apprentissage automatique profond, également connu sous le nom de *deep learning*, est une branche de l'IA qui se concentre sur l'entraînement des machines à apprendre et à effectuer des tâches de manière autonome, en imitant le fonctionnement du cerveau humain.

L'apprentissage profond repose sur des réseaux de neurones artificiels (ANN) profonds, qui sont des modèles mathématiques composés de multiples couches de neurones interconnectés. Chaque couche traite les données d'entrée et transmet les informations à la couche suivante, permettant ainsi une extraction progressive de caractéristiques et de niveaux d'abstraction de plus en plus complexes.

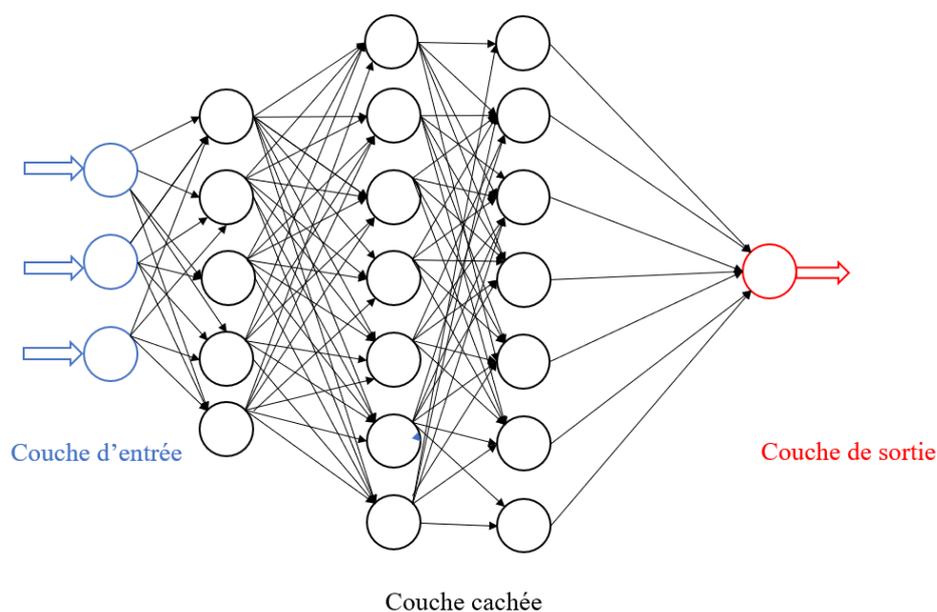
L'apprentissage profond a été révolutionnaire dans de nombreux domaines, tels que la vision par ordinateur, la reconnaissance vocale, la traduction automatique et le traitement du langage naturel et bien d'autres domaines. Les réseaux de neurones profonds (DNN) sont capables d'apprendre des caractéristiques hiérarchiques et de détecter des motifs complexes dans les données de manière profonde et significative, ce qui leur permet d'obtenir des performances remarquables dans de nombreux problèmes d'apprentissage automatique.

Dans ce chapitre, nous nous plongeons dans les concepts fondamentaux de l'apprentissage profond. Nous débutons par une exploration détaillée des ANNs, où nous analysons leur fonctionnement et leur architecture. Ensuite, nous étudions les méthodes d'entraînement appliquées aux Réseaux de Neurones Profonds, en mettant l'accent sur l'importance cruciale de la rétropropagation. Les Hyperparamètres en apprentissage automatique sont également examinés, car ils influencent grandement la performance et la généralisation des modèles. Dans la suite du chapitre, nous nous concentrons sur les RNNs, des réseaux adaptés au traitement de données séquentielles et au stockage de l'information contextuelle. De manière spécifique, nous abordons les Réseaux LSTM, une extension puissante des RNNs qui résout certains problèmes liés aux gradients. Enfin, nous traitons des métriques d'évaluation utilisées pour mesurer les performances des modèles de l'intelligence artificielle. Ces indicateurs sont essentiels pour évaluer la performance.

## 4.2 Concepts clés de l'apprentissage profond

L'apprentissage profond, une sous-branche de l'apprentissage automatique, repose sur un certain nombre de concepts clés :

**4.2.1 Les ANNs :** Les ANN sont des systèmes de calcul qui imitent les réseaux neuronaux biologiques, comme ceux que nous avons dans notre cerveau. Ils sont constitués de "neurones" artificiels, qui sont des unités de calcul qui prennent plusieurs entrées, effectuent des opérations mathématiques sur ces entrées et produisent une sortie. Les neurones sont organisés en différentes couches : couche d'entrée, couche de sortie et une ou plusieurs couches cachées.



**Figure 13:** Réseau de neurone artificiels ou ANN

**4.2.2 les DNNs :** Les DNN sont des ANN avec plusieurs couches entre l'entrée et la sortie. Cette "profondeur" permet à l'apprentissage profond de reconnaître des structures plus complexes et de créer des représentations hiérarchiques des données.

**4.2.3 Entraînement d'un réseau DNNs:** L'entraînement d'un réseau de neurones profonds, consiste à ajuster ses poids et biais pour qu'il puisse effectuer une tâche spécifique avec un haut niveau de précision. L'entraînement d'un réseau de neurones profonds implique les étapes suivantes :

**4.2.3.1 Initialisation des poids:** L'initialisation des poids est un aspect crucial de la formation des réseaux de neurones profonds. Une initialisation appropriée peut aider à éviter les problèmes d'explosion ou de disparition de gradient, qui sont des obstacles importants à l'efficacité de l'apprentissage du réseau. Cette initialisation est généralement faite de manière aléatoire, bien qu'il existe plusieurs méthodes pour initialiser les poids d'un réseau de neurones, certaines étant relativement simples et d'autres plus sophistiquées. Ci-dessous les méthodes courantes d'initialisation des poids sont brièvement décrites.

- **Initialisation uniforme :** Cette méthode implique consiste à attribuer un nombre aléatoire minime à chaque poids lors de sa mise en place. Les valeurs sont couramment tirées d'une distribution uniforme, indiquant ainsi que chaque chiffre au sein de l'intervalle défini possède la même chance d'être sélectionné [51]. Les poids  $W$  sont initialisés selon la distribution :

$$W \sim U(a, b) \quad (11)$$

où

$U(a,b)$  est la distribution uniforme dans l'intervalle  $[a,b]$ .

- **Initialisation de Xavier:** Cette méthode, proposée par Xavier Glorot, initialise les poids en fonction de la taille des couches précédente et suivante. Le but est de maintenir la variance des activations et des gradients à travers les différentes couches, facilitant ainsi l'apprentissage. Les poids sont initialisés à partir d'une distribution normale avec une moyenne de zéro et une variance qui dépend de la taille des couches d'entrée et de sortie [52]. Les poids  $W$  sont initialisés selon la distribution :

$$W \sim N\left(0, \sqrt{\frac{2}{n_{in} + n_{out}}}\right) \quad (12)$$

où:

$N(0, \sigma^2)$  est la distribution normale avec une moyenne de 0 et une variance  $\sigma^2$ .

$n_{in}$  est le nombre de neurones en entrée (le nombre d'unités d'entrée).

$n_{out}$  est le nombre de neurones en sortie (le nombre d'unités de sortie).

La raison principale de cette initialisation est d'équilibrer la variance des activations et des gradients à travers les différentes couches, ce qui permet un entraînement plus

stable et plus rapide. Si les poids sont trop petits, les gradients peuvent devenir trop petits à mesure qu'ils se propagent à travers le réseau (le problème du "*vanishing gradient*"). Si les poids sont trop grands, les gradients peuvent devenir trop grands et le réseau peut devenir instable (le problème du "*exploding gradient*"). L'initialisation de Xavier tente de trouver un bon équilibre entre ces deux extrêmes. Pour les fonctions d'activation tanh et sigmoid, l'initialisation de Xavier est souvent une bonne option.

- **Initialisation de He** : Cette méthode est une variante de l'initialisation de Xavier qui a été proposée par Kaiming He et ses collaborateurs. Elle est particulièrement efficace lorsque la fonction d'activation est ReLU (Rectified Linear Unit) ou une de ses variantes. L'initialisation de He est similaire à l'initialisation de Xavier, mais elle utilise une variance différente pour la distribution normale [53]: Les poids  $W$  sont initialisés selon la distribution :

$$W \sim N(0, \sqrt{\frac{2}{n_{in}}}) \quad (13)$$

$N(0, \sigma^2)$  est la distribution normale avec une moyenne de 0 et une variance  $\sigma^2$ .  
 $n_{in}$  est le nombre de neurones en entrée (le nombre d'unités d'entrée).

- **Initialisation de LeCun** : Cette méthode a été proposée par Yann LeCun et est recommandée pour les fonctions d'activation qui sont "centrées" à zéro, comme la fonction d'activation tanh. Elle est similaire à l'initialisation de He, mais utilise une variance différente pour la distribution normale [54] les poids  $W$  sont initialisés selon la distribution :

$$W \sim N(0, \sqrt{\frac{1}{n_{in}}}) \quad (14)$$

$N(0, \sigma^2)$  est la distribution normale avec une moyenne de 0 et une variance  $\sigma^2$ .  
 $n_{in}$  est le nombre de neurones en entrée (le nombre d'unités d'entrée).

**4.2.3.2. Propagation avant (Feedforward):** C'est le processus par lequel un réseau de neurones transforme les entrées en sorties. Il s'agit d'une propagation d'information qui commence par la couche d'entrée du réseau (où les données entrent dans le système) et se termine à la couche de sortie (où nous obtenons le résultat final). Chaque neurone de chaque

couche prend les sorties de tous les neurones de la couche précédente, les multiplie par les poids correspondants, ajoute une constante appelée biais, et applique une fonction d'activation. La sortie de cette fonction est alors l'entrée pour la couche suivante. Mathématiquement, cela se présente comme suit :

$$z = w_1 * x_1 + w_2 * x_2 + \dots + w_n * x_n + b \quad (15)$$

$$a = f(z) \quad (16)$$

où  $w$  est le poids,  $x$  est l'entrée,  $b$  est le biais,  $f$  est la fonction d'activation et  $a$  est la sortie (activation) du neurone [51].

**4.2.3.3. Calcul de l'erreur:** Une fois que nous avons une prédiction, nous devons évaluer à quel point elle est bonne. Pour ce faire, nous calculons une fonction de coût (ou fonction de perte) qui mesure la différence entre la prédiction du réseau et la vraie valeur. Une fonction de coût couramment utilisée est la fonction racine d'erreur quadratique moyenne (*Root Mean Squared Error* ou RMSE) pour les tâches de régression, et la fonction de coût d'entropie croisée pour les tâches de classification. La formule pour calculer le RMSE pour  $n$  exemples est [55] :

$$RMSE = \sqrt{\frac{1}{n} \sum (y_i - \hat{y}_i)^2}, \quad i=1 \text{ à } n \quad (17)$$

où :

$y_i$  est la  $i$ ème valeur réelle.

$\hat{y}_i$  est la  $i$ ème valeur prédite par le modèle.

$n$  est le nombre total d'exemples dans notre ensemble de données.

**4.2.3.4. Rétropropagation (Backpropagation):** C'est l'algorithme central pour l'apprentissage dans les réseaux de neurones. Après avoir effectué une propagation avant et obtenu les prédictions du réseau, on compare ces prédictions aux valeurs réelles pour calculer l'erreur (aussi appelée la fonction de coût ou de perte). Ensuite, l'algorithme de rétropropagation calcule le gradient de cette erreur par rapport à tous les poids du réseau, en utilisant la règle de la chaîne pour la différentiation. Ces gradients indiquent dans quelle mesure chaque poids a contribué à l'erreur. Ensuite, on effectue une étape de descente de gradient, qui ajuste chaque poids dans la direction qui réduit l'erreur. Cela se fait en soustrayant une fraction (le taux d'apprentissage) du gradient du poids. En répétant ce processus pour de nombreux exemples d'entraînement, le réseau apprend à minimiser l'erreur de ses prédictions.

**4.2.3.5. Mise à jour des poids :** Une fois que nous avons le gradient, nous pouvons mettre à jour les paramètres (poids et biais) du modèle afin de minimiser la fonction de coût ou de perte. La descente de gradient est la méthode d'optimisation la plus couramment utilisée, bien qu'il existe plusieurs variantes qui peuvent parfois être plus efficaces.

- **Descente de gradient:** C'est l'algorithme d'optimisation le plus simple et le plus fondamental. À chaque itération ou époque, l'ensemble des données d'apprentissage est utilisé pour calculer le gradient, et les poids sont mis à jour dans la direction opposée au gradient :

$$w(t + 1) = w(t) - \alpha * \nabla L \quad (18)$$

où  $\alpha$  est le taux d'apprentissage, et  $\nabla L$  est le gradient de la fonction de coût. L'inconvénient de la descente de gradient est qu'elle peut être lente et inefficace lorsque les données d'apprentissage sont volumineuses, car chaque mise à jour nécessite de parcourir toutes les données.

- **Descente de gradient stochastique (*Stochastic Gradient Descent, SGD*) :** Pour pallier le problème de la descente de gradient, le SGD met à jour les poids en utilisant un seul exemple d'apprentissage à la fois. Cela rend les mises à jour beaucoup plus rapides, mais aussi plus bruitées, car chaque exemple donne une estimation bruitée du gradient. Cependant, ce bruit peut parfois aider à échapper aux minimums locaux.
- **Descente de gradient stochastique avec momentum (*SGD with momentum*) :** C'est une variante du SGD qui ajoute une composante de "momentum" à la mise à jour des poids. Cette composante est une moyenne mobile du gradient précédent, ce qui permet d'accélérer l'optimisation dans les directions constantes et de réduire les oscillations dans les directions changeantes. Cela est particulièrement utile pour les surfaces de coût qui sont en forme de ravins, où les pentes peuvent varier rapidement. La formule de mise à jour devient :

$$v(t + 1) = \beta * v(t) - \alpha * \nabla L \quad (19)$$

$$w(t + 1) = w(t) + v \quad (20)$$

où  $v$  est le terme de momentum,  $\beta$  est le coefficient de momentum (généralement fixé à 0.9 ou un nombre proche),  $\alpha$  est le taux d'apprentissage et  $\nabla L$  est le gradient de la fonction de coût.

- Adam (*Adaptive Moment Estimation*)** : Adam est une méthode d'optimisation qui combine les idées du SGD avec momentum et du RMSprop (un autre algorithme d'optimisation). Comme le SGD avec momentum, Adam conserve une moyenne mobile du gradient passé. Mais en plus, Adam conserve aussi une moyenne mobile du carré du gradient passé, ce qui permet d'adapter le taux d'apprentissage pour chaque poids individuellement en fonction de l'historique des gradients. L'algorithme Adam utilise des estimateurs adaptatifs du premier moment (moyenne) et du second moment (variance) des gradients. Ces estimateurs sont mis à jour lors de chaque itération du processus d'optimisation. Les étapes de l'algorithme Adam sont :
  - Initialisation des variables : Les variables  $m$  et  $v$  sont initialisées à zéro.  $m$  est l'estimateur du premier moment et  $v$  est l'estimateur du second moment.
  - Calcul des estimateurs du premier et du second moment : Pour chaque itération, les gradients  $\nabla L$  (où  $L$ 'est la fonction de perte) sont calculés. Les estimateurs du premier moment  $m$  et du second moment  $v$  sont mis à jour en utilisant les formules suivantes :

$$m(t) = \beta_1 * m(t + 1) + (1 - \beta_1) * \nabla L \quad (21)$$

$$v(t + 1) = \beta_2 * v(t) + (1 - \beta_2) * (\nabla L)^2 \quad (22)$$

où:  $\beta_1$  et  $\beta_2$  sont des hyperparamètres (généralement fixés à 0.9 et 0.999 respectivement) qui contrôlent la décroissance des estimateurs du premier et du second moment.

- Correction des biais : Les estimateurs du premier et du second moment sont corrigés pour compenser les biais introduits par leur initialisation à zéro et leur nature exponentielle décroissante. Cela est réalisé en utilisant les formules suivantes :

$$m_{hat} = \frac{m}{(1 - \beta_1^t)} \quad (23)$$

$$v_{hat} = \frac{v}{(1 - \beta_2^t)} \quad (24)$$

où  $t$  est le numéro d'itération,  $m_{hat}$  est la moyenne mobile corrigée du gradient,  $v_{hat}$  est la moyenne mobile corrigée du carré du gradient.

- Mise à jour des poids : Les poids sont mis à jour en utilisant les estimateurs corrigés du premier et du second moment. Les mises à jour des poids sont effectuées selon la formule suivante :

$$w(t) = w(t+1) - \alpha * \frac{m_{hat}}{((v_{hat})^2 + \epsilon)} \quad (25)$$

où,  $w$  représente les poids,  $\alpha$  est le taux d'apprentissage, et  $\epsilon$  est un petit nombre ajouté pour éviter une division par zéro.

- **RMSProp (Root Mean Square Propagation)** est un algorithme d'optimisation utilisé dans l'apprentissage profond. Il a été proposé par Geoff Hinton. L'objectif principal de RMSProp est d'adapter le taux d'apprentissage de chaque poids individuellement en fonction de l'historique des gradients. L'algorithme RMSProp utilise une moyenne mobile exponentielle des carrés des gradients passés pour normaliser le gradient actuel. Cela permet de réduire la sensibilité aux gradients incohérents et aux ravins des surfaces de coût. La mise à jour des poids dans RMSProp se fait en utilisant la formule suivante :

$$s(t+1) = \beta * s(t) + (1 - \beta) * (\nabla L)^2 \quad (26)$$

$$w(t+1) = w(t) - * \nabla L \frac{\alpha}{\sqrt{(s)} + \epsilon} \quad (27)$$

où,  $s$  est une estimation de la moyenne mobile des carrés des gradients,  $\beta$  est un hyperparamètre qui contrôle le taux de décroissance de cette moyenne (généralement fixé à 0.9),  $\nabla L$  est le gradient de la fonction de perte par rapport aux poids,  $w$  est le vecteur de poids,  $\alpha$  est le taux d'apprentissage,  $\epsilon$  est un petit nombre ajouté pour éviter la division par zéro.

La formule de mise à jour des poids dans RMSProp normalise le gradient en le divisant par la racine carrée de la moyenne mobile des carrés des gradients précédents. Cela permet de contrôler l'adaptation du taux d'apprentissage pour chaque poids individuellement. RMSProp a l'avantage d'être moins sensible à la sélection initiale du taux d'apprentissage et de s'adapter automatiquement au cours de l'apprentissage. Il est largement utilisé et efficace dans de nombreux problèmes d'apprentissage automatique et d'apprentissage profond.

- **Nadam** (*Nesterov-accelerated Adaptive Moment Estimation*) est un algorithme d'optimisation pour l'apprentissage profond. Il est une extension de l'algorithme Adam (*Adaptive Moment Estimation*) et intègre les idées du moment de Nesterov (*Nesterov momentum*) pour améliorer les performances de convergence. L'algorithme Nadam utilise une combinaison de la méthode de l'estimation adaptative du moment d'Adam et de la méthode du moment de Nesterov. Cela permet à l'algorithme de bénéficier à la fois de l'accélération de la convergence apportée par le moment de Nesterov et de la robustesse face aux gradients bruités et aux problèmes de minima locaux apportée par Adam. La mise à jour des poids dans Nadam est similaire à celle d'Adam, mais avec une adaptation pour tenir compte du moment de Nesterov. Les formules de mise à jour des poids sont les suivantes :

Calcul du moment :

$$m_t = \beta_1 * m_{\{t-1\}} + (1 - \beta_1) * \nabla L \quad (28)$$

Calcul de la correction du moment de Nesterov :

$$m_{t_{hat}} = \frac{m_t}{(1 - \beta_1^t)} \quad (29)$$

Calcul de l'estimation du second moment :

$$v_t = \beta_2 * v_{(t-1)} + (1 - \beta_2) * (\nabla L)^2 \quad (30)$$

Calcul des mises à jour des poids :

$$w(t + 1) = w(t) - \alpha * \left( \frac{m_{t_{hat}}}{(\sqrt{v_t} + \varepsilon)} + \beta_1 * \frac{m_t}{(1 - \beta_1^t)} * \frac{(\nabla L)^2}{(\sqrt{v_t} + \varepsilon)} \right) \quad (31)$$

où  $w$  est le vecteur de poids,  $\alpha$  est le taux d'apprentissage,  $\nabla L$  est le gradient de la fonction de perte,  $\beta_1$  et  $\beta_2$  sont des hyperparamètres pour contrôler le taux de décroissance des moments,  $\varepsilon$  est un petit nombre pour éviter la division par zéro, et  $t$  est le pas de temps actuel [56].

**4.2.3.6. Itération** : Les étapes de propagation avant, de calcul de l'erreur, de rétropropagation et de mise à jour des poids sont répétés un grand nombre de fois, à chaque fois avec une

nouvelle entrée (ou un lot d'entrées) du jeu de données. Cette itération se produit généralement sur plusieurs "époques", où une époque est une passe complète à travers le jeu de données.

**4.2.3.7. Évaluation et ajustement :** Après un certain nombre d'époques, ou lorsque la fonction de coût atteint une valeur acceptable, l'entraînement est arrêté. Le modèle est ensuite évalué sur un jeu de données de test pour s'assurer qu'il peut généraliser à de nouvelles données. Si les performances sur les données de test ne sont pas satisfaisantes, on peut ajuster divers aspects du processus d'entraînement (comme le taux d'apprentissage, le nombre d'époques, la fonction de coût, etc.) et répéter l'entraînement.

**4.3 Hyperparamètres en apprentissage automatique :** sont des variables prédéfinies qui déterminent la structure et le comportement d'un modèle. Contrairement aux paramètres, qui sont appris et ajustés par le modèle au cours de l'apprentissage, les hyperparamètres sont définis à priori et ne sont pas modifiés par le modèle lui-même. Ils peuvent influencer de manière significative les performances d'un modèle, notamment sa capacité à généraliser à partir de nouvelles données. Dans le cadre des réseaux de neurones profonds, qui sont des modèles très expressifs et flexibles, les hyperparamètres comprennent des facteurs tels que :

**4.3.1 Le taux d'apprentissage (*learning rate*) :** détermine l'ampleur des modifications apportées aux poids du modèle à chaque mise à jour pendant l'entraînement. Un taux d'apprentissage trop élevé peut entraîner une convergence instable, tandis qu'un taux trop faible peut ralentir la convergence ou même la bloquer complètement[57] .

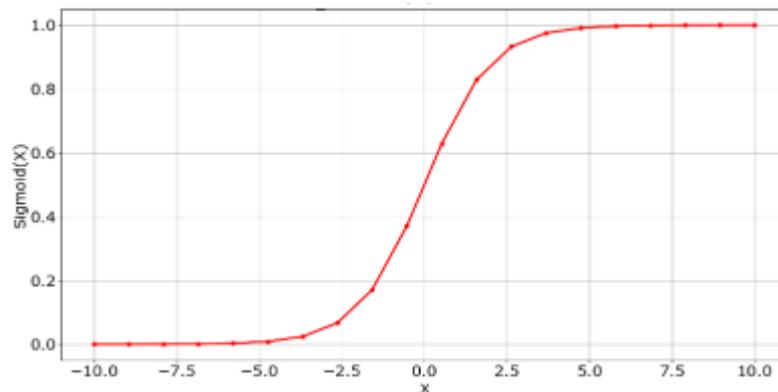
**4.3.2 Le nombre de couches cachées dans le réseau :** est un hyperparamètre crucial qui détermine la "profondeur" du réseau. En gros, chaque couche cachée peut être vue comme une étape de transformation, où le réseau apprend une nouvelle représentation des données d'entrée.

**4.3.3 Le nombre de neurones par couche cachée :** dans un réseau de neurones, aussi connu sous le nom de la "largeur" du réseau, est un autre hyperparamètre important qui influence la capacité du modèle. Un réseau avec plus de neurones dans ses couches cachées peut avoir une capacité plus grande, c'est-à-dire une plus grande flexibilité pour apprendre des modèles complexes à partir des données d'entraînement.

**4.3.4 La fonction d'activation :** détermine la sortie d'un neurone en fonction de son entrée. Des fonctions d'activation couramment utilisées comprennent le sigmoïde, le tanh, la ReLU et ses variantes.

**4.3.4.1 Fonction d'activation sigmoïde :** Transforme les valeurs d'entrée en une plage entre 0 et 1, ce qui peut être utile pour les problèmes de classification binaire. Cependant, elle peut souffrir de *gradients vanishing* (disparition des gradients) pour les entrées avec de grandes valeurs absolues. La fonction sigmoïde est définie comme suit [58] :

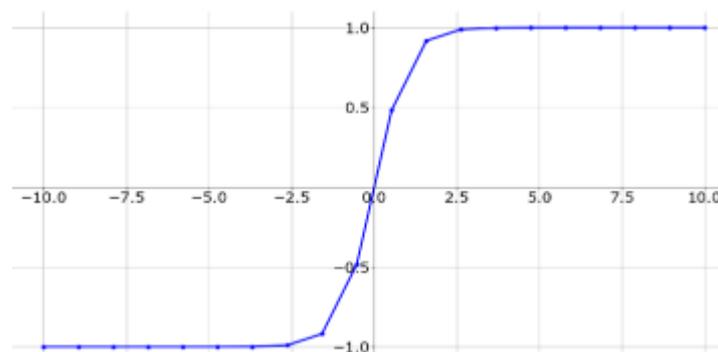
$$\sigma(x) = \frac{1}{(1 + e^{(-x)})} \quad (32)$$



**Figure 14:** Fonction Sigmoïde

**4.3.4.2 La fonction d'activation tangente hyperbolique (tanh),** ou tangente hyperbolique, est une autre fonction d'activation couramment utilisée dans les réseaux de neurones. La fonction tanh transforme les entrées pour qu'elles se situent entre -1 et 1. Elle est définie comme suit [59]:

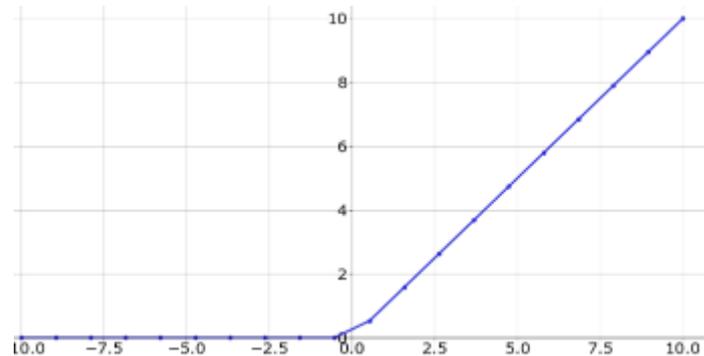
$$\tanh(x) = \frac{(e^{(x)} - e^{(-x)})}{(e^{(x)} + e^{(-x)})} \quad (33)$$



**Figure14:** Fonction tanh

**4.3.4.3 La fonction d'activation Rectified Linear Unit** est une fonction d'activation couramment utilisée dans les réseaux de neurones, en particulier dans les réseaux de neurones convolutifs (CNN). Elle est définie comme[60] :

$$ReLU(x) = \max(0, x) \quad (34)$$



**Figure 15:** Fonction tanh

En d'autres termes, si l'entrée  $x$  est positive, la fonction retourne  $x$ . En revanche, si  $x$  est négative, la fonction retourne 0.

**4.3.5 La taille du lot :** En apprentissage automatique, la taille de lot fait référence au nombre d'échantillons d'apprentissage utilisés dans une seule itération de l'algorithme d'optimisation. Cela signifie que les données d'entraînement sont divisées en lots (ou groupes) de tailles égales, et chaque lot est utilisé pour mettre à jour les poids du modèle. Une taille de lot plus grande peut accélérer le processus d'entraînement, mais nécessite également plus de mémoire, tandis qu'une taille de lot plus petite peut ralentir l'entraînement, mais permet souvent une meilleure généralisation. Le choix d'une taille de lot appropriée dépend du problème spécifique, de la quantité de données disponibles et des ressources informatiques disponibles[61].

**4.3.6 Dropout :** Le "dropout" est une technique de régularisation couramment utilisée en apprentissage automatique, et plus spécifiquement en apprentissage profond. Il s'agit d'une méthode qui vise à prévenir le surapprentissage (*overfitting*) en introduisant du bruit dans le processus d'apprentissage. Le dropout fonctionne en "abandonnant" aléatoirement (en les mettant à zéro) un certain nombre de neurones dans une couche pendant l'entraînement. Cela signifie que ces neurones ne contribuent pas à la propagation en avant (*forward pass*) ni à la rétropropagation (*backward pass*)

du gradient lors d'une itération donnée. La sélection aléatoire des neurones à abandonner est effectuée à chaque itération, ce qui permet d'introduire un mécanisme de régularisation stochastique [62].

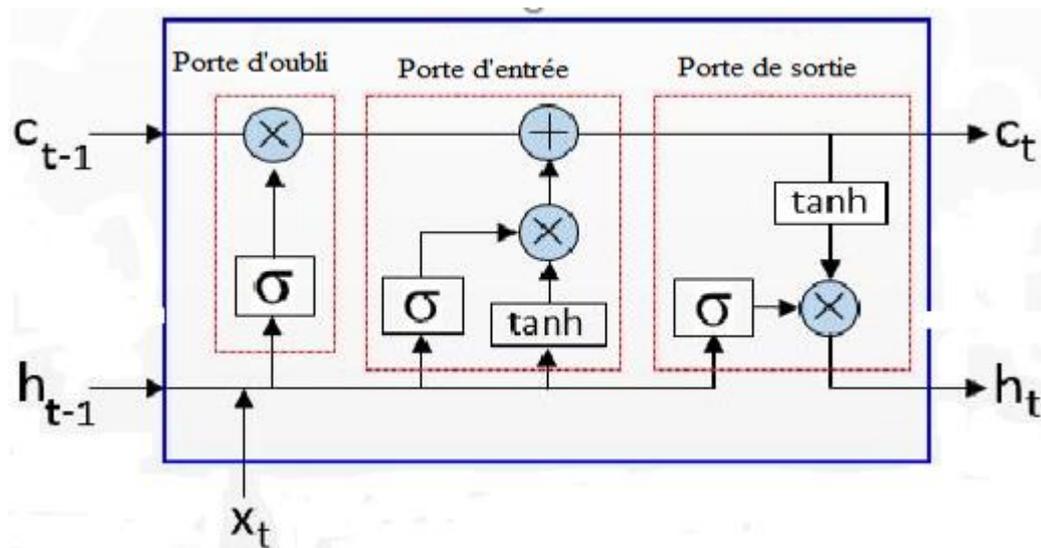
**4.4 Les RNNs** est une classe des ANNs où les connexions entre les nœuds forment un graphe orienté le long d'une séquence temporelle. Cela les distingue des réseaux de neurones feedforward, comme les DNNs ou les CNNs, où les connexions ne forment pas de cycle. La principale caractéristique des RNNs est leur capacité à utiliser leur mémoire interne pour traiter les séquences d'entrées. Cela les rend particulièrement utiles pour traiter des séquences d'informations de longueur variable, comme des séries temporelles ou des phrases dans le traitement du langage naturel.

Un RNN traite une séquence d'entrées en itérant à travers les éléments de la séquence et en maintenant dans ses nœuds cachés un "état" qui contient des informations sur l'historique des éléments précédemment vus. La sortie à un certain temps  $t$  est donc une fonction de l'entrée à ce temps et de l'état à ce temps. Cependant, les RNNs classiques peuvent avoir du mal à apprendre des dépendances à long terme à cause du problème connu sous le nom de "disparition du gradient", où les gradients de la fonction d'erreur se réduisent exponentiellement avec la longueur de la séquence pendant la rétropropagation. Pour surmonter ce problème, des variantes de RNNs ont été proposées, y compris les réseaux de neurones LSTM et les RNNs à mémoire à court terme avec mémoire de grille. Ces variantes introduisent des mécanismes supplémentaires dans l'unité de calcul récurrente pour contrôler le flux et l'actualisation de l'information à travers le temps, ce qui leur permet de maintenir et d'apprendre des dépendances à plus long terme. Les RNNs, et en particulier leurs variantes LSTM et GRU, sont couramment utilisés dans diverses applications, y compris la traduction automatique, la génération de texte, la reconnaissance vocale, la génération de musique, et même dans certains types de modèles génératifs tels que les réseaux de neurones génératifs récurrents[63] .

**4.5 Les LSTM** sont une variante spécifique des réseaux de neurones RNNs, conçus pour pallier le problème de la disparition du gradient dans l'apprentissage des dépendances à long terme. Les LSTM ont été introduits par Sepp Hochreiter et Jürgen Schmidhuber en 1997. Un RNN standard a une couche cachée unique, dont l'activation

à un certain temps est une fonction de l'activation à l'instant précédent et de l'entrée à l'instant actuel. Cependant, dans un LSTM, chaque unité de la couche cachée est remplacée par une structure appelée "cellule de mémoire". La cellule de mémoire est composée de quatre éléments principaux :

1. **État de la cellule:** Il s'agit essentiellement de la "mémoire" de la cellule, qui peut contenir des informations sur les entrées précédentes.
2. **Porte d'entrée :** Ce portail contrôle à quel point les nouvelles informations de l'entrée actuelle sont stockées dans l'état de la cellule.
3. **Porte d'oubli :** Il contrôle la quantité d'information de l'état de la cellule qui doit être oubliée ou retenue.
4. **Porte de sortie :** Il contrôle la quantité d'information dans l'état de la cellule qui doit être utilisée pour calculer la sortie actuelle de la cellule.



**Figure 16:** Cellule LSTM [64].

Ces portes sont en fait des réseaux de neurones feedforward à une seule couche, avec une fonction d'activation sigmoïde pour les portes d'entrée et d'oubli, et généralement une fonction d'activation tanh pour le portail de sortie et l'état de la cellule. En pratique, ces portes permettent à la cellule de mémoire de choisir quand lire, écrire ou oublier ses informations internes, ce qui lui permet d'apprendre à maintenir des dépendances sur de longues périodes de temps, évitant le problème de la disparition du gradient rencontré par les RNNs standards[64].

## 4.6 Métriques d'évaluations de l'efficacité de l'apprentissage automatique

L'évaluation de l'efficacité de l'apprentissage automatique consiste à mesurer les performances et la précision d'un modèle d'apprentissage automatique. Cela permet de déterminer à quel point le modèle est capable de généraliser et de faire des prédictions précises sur de nouvelles données.

**Métrique d'évaluation (RMSE):** Les métriques d'évaluation sont utilisées pour mesurer la performance d'un modèle en fonction de sa capacité à faire des prédictions précises. Ces métriques varient en fonction du type de problème (classification, régression, etc.) et des objectifs spécifiques du modèle. Les modèles de régression sont un type de modèle d'apprentissage automatique et statistique utilisé pour prédire les valeurs d'une variable cible continue. En considérant le réseau LSTM comme un modèle de régression, RMSE est utilisée pour la perte de prédiction [65]. Cependant, le *RMSE* est décrit comme suit :

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (35)$$

Le *RMSE* mesure la racine carrée de la moyenne des carrés des écarts, ce qui quantifie la différence entre les valeurs prédites et les valeurs réelles.  $y_i$  est la valeur réelle,  $\hat{y}_i$  est la valeur prédite et  $N$  représente le nombre total de données de trafic prédites.

## 4.7 Conclusion

En conclusion, ce chapitre donne un rappel sur les concepts clés tels que les réseaux de neurones artificiels, les DNNs et les RNN. Nous avons exploré les différentes architectures de ces réseaux, notamment les DNN, RNN, ainsi que les mécanismes d'entraînement tels que la rétropropagation et la mise à jour des poids. Nous avons également abordé les hyperparamètres et les métriques d'évaluation utilisés pour mesurer les performances des modèles. Dans le prochain chapitre nous allons explorer les algorithmes d'apprentissage automatique appliqués aux réseaux sans fil et d'étudier leur impact sur la consommation énergétique.

## **Chapitre 5**

# **Optimisation et Gestion des Réseaux Sans Fil avec de l'Intelligence Artificielle**

### **5.1 Introduction**

Les réseaux sans fil sont devenus une composante essentielle de notre vie quotidienne, avec une utilisation qui s'étend des communications personnelles aux industries, aux infrastructures critiques et aux services publics. Avec l'augmentation de la demande en termes de capacité, de vitesse et de fiabilité, la gestion et l'optimisation des réseaux sans fil deviennent de plus en plus complexes. L'IA a le potentiel de transformer la manière dont les réseaux sans fil sont gérés et optimisés. En effet, l'IA peut aider à prédire le trafic réseau, à optimiser l'allocation des ressources, à anticiper les pannes de réseau, à améliorer la qualité du service et à renforcer la sécurité. Les RNA, inspirés par le fonctionnement du cerveau humain, sont particulièrement adaptés à ces tâches car ils sont capables d'apprendre à partir de grands ensembles de données et de s'adapter dynamiquement à de nouvelles situations. L'objectif de ce chapitre est d'explorer les algorithmes d'apprentissage automatique appliqués aux réseaux sans fil et d'étudier leur impact sur la consommation énergétique.

### **5.2 Applications de l'apprentissage automatique dans les réseaux sans fil**

L'apprentissage automatique, avec sa capacité à extraire des informations à partir de grands ensembles de données et à prendre des décisions basées sur des patterns, est appliqué à divers aspects des réseaux sans fil pour les optimiser et les rendre plus performants :

#### **5.2.1 Gestion des ressources**

L'une des applications les plus significatives de l'apprentissage automatique dans les réseaux sans fil est la gestion des ressources. La gestion des ressources dans les réseaux sans fil est un aspect essentiel pour assurer des performances optimales, une utilisation efficace du spectre et une économie d'énergie. L'apprentissage automatique offre des solutions prometteuses pour relever ces défis en fournissant des mécanismes d'optimisation intelligents et adaptatifs.

### **5.2.1.1. Gestion du spectre**

L'une des ressources les plus critiques dans les réseaux sans fil est le spectre radioélectrique. Avec l'essor des communications sans fil, le spectre devient de plus en plus encombré, ce qui entraîne une concurrence pour l'accès aux fréquences disponibles. L'apprentissage automatique est utilisé pour prédire la disponibilité du spectre sur différentes fréquences et à différents endroits, permettant aux réseaux sans fil de sélectionner intelligemment les canaux disponibles avec un minimum d'interférences et de collisions. Des techniques telles que les réseaux de neurones, les processus gaussiens et les algorithmes génétiques ont été appliquées pour résoudre ce problème complexe de gestion du spectre [66, 67] .

### **5.2.1.2. Planification de fréquences**

La planification de fréquences consiste à allouer de manière efficace les canaux fréquentiels aux utilisateurs pour éviter les interférences et améliorer la qualité des connexions. L'apprentissage automatique est utilisé pour analyser les modèles d'utilisation du spectre et prédire les moments et les emplacements où certains canaux sont susceptibles d'être plus congestionnés. En utilisant ces prédictions, les réseaux sans fil peuvent ajuster dynamiquement leur planification de fréquences pour une utilisation plus efficace du spectre et une meilleure qualité de service [67].

### **5.2.1.3 Gestion de l'énergie**

Dans les appareils mobiles et les capteurs déployés dans les réseaux sans fil, la gestion de l'énergie est un enjeu crucial. L'apprentissage automatique est utilisé pour optimiser la consommation d'énergie en ajustant les paramètres de transmission et de réception en fonction des conditions du canal et de l'état de la batterie. Par exemple, les algorithmes d'apprentissage automatique peuvent décider quand réduire la puissance de transmission pour économiser de l'énergie tout en maintenant une qualité de signal suffisante. Ces techniques de gestion de l'énergie peuvent prolonger la durée de vie des batteries et améliorer l'efficacité énergétique globale du réseau [68].

## **5.2.2 Prédiction de la mobilité des utilisateurs**

La prédiction de la mobilité des utilisateurs dans les réseaux sans fil est un aspect clé pour améliorer la qualité de service et garantir une expérience transparente pour les utilisateurs en déplacement. L'apprentissage automatique joue un rôle essentiel dans cette tâche en analysant

les modèles de mobilité passés et en utilisant ces informations pour anticiper les futurs déplacements des utilisateurs.

### **5.2.2 1. Analyse des modèles de mobilité**

Les utilisateurs des réseaux sans fil ont souvent des modèles de mobilité prévisibles. Par exemple, dans les réseaux mobiles, les utilisateurs peuvent avoir tendance à se déplacer entre leur domicile, leur lieu de travail et d'autres endroits fréquemment visités. En utilisant des techniques d'apprentissage automatique, telles que les processus markoviens cachés les réseaux de neurones RNN les réseaux sans fil peuvent analyser les traces de mobilité passées des utilisateurs pour identifier et modéliser les schémas de déplacement [69, 70] .

### **5.2.2 2. Prédiction des déplacements futurs**

Une fois que les modèles de mobilité sont identifiés, l'apprentissage automatique est utilisé pour prédire les futurs déplacements des utilisateurs. Les modèles appris sont utilisés pour estimer la probabilité que les utilisateurs se déplacent vers certaines zones géographiques ou points d'accès spécifiques. Ces prédictions peuvent être utilisées par les BS pour préparer les handovers et pour allouer les ressources en fonction des zones probables de déplacement des utilisateurs [71, 72] .

### **5.2.2.3. Optimisation des *handovers***

Les *handovers* sont des opérations sensibles dans les réseaux sans fil, car ils impliquent le transfert de la connexion d'un utilisateur d'une SB à une autre. Si les *handovers* ne sont pas gérés efficacement, cela peut entraîner des interruptions de service et des dégradations de la qualité de la communication. En utilisant les prédictions de mobilité des utilisateurs, les réseaux sans fil peuvent anticiper les *handovers* nécessaires et les planifier de manière proactive pour éviter les retards et les perturbations du service [73] .

### **5.2.3. Sécurité du réseau**

L'apprentissage automatique joue un rôle crucial dans la sécurité des réseaux sans fil en détectant les activités malveillantes et en renforçant la protection contre les attaques potentielles :

### **5.2.3.1. Détection d'anomalies**

L'apprentissage automatique est utilisé pour détecter les activités anormales dans le trafic réseau. En analysant les modèles de trafic et les comportements des utilisateurs, les algorithmes d'apprentissage automatique peuvent apprendre ce qui est considéré comme normal dans le réseau. Lorsqu'une activité inhabituelle est détectée, cela peut indiquer une tentative d'intrusion ou une attaque en cours. Les techniques d'apprentissage automatique telles que les machines à vecteurs de support, les forêts d'arbres décisionnels, ou les réseaux de neurones peuvent être utilisées pour détecter ces anomalies de manière proactive et réagir rapidement pour contrer les menaces [74].

### **5.2.3. 2. Détection des attaques par déni de service**

Les attaques par déni de service (DDoS) sont une menace majeure pour les réseaux sans fil, où un grand nombre de demandes de connexion sont envoyées simultanément pour submerger les ressources du réseau et le rendre indisponible aux utilisateurs légitimes. L'apprentissage automatique est utilisé pour détecter les signes précurseurs d'une attaque DDoS en surveillant les modèles de trafic et en identifiant les schémas de surcharge. Des systèmes de détection d'anomalies basés sur l'apprentissage automatique peuvent être déployés pour alerter les administrateurs du réseau et activer des mécanismes de défense appropriés pour contrer les attaques DDoS [74].

### **5.2.3. 3. Détection des intrusions**

L'apprentissage automatique est utilisé pour détecter les intrusions dans les réseaux sans fil, telles que des tentatives de contournement des mécanismes de sécurité, des attaques par force brute sur les mots de passe ou des attaques d'usurpation d'identité. En analysant en temps réel le trafic réseau et les activités des utilisateurs, les algorithmes d'apprentissage automatique peuvent repérer des activités anormales et initier des procédures d'alerte pour engager des vérifications détaillées. [75].

### **5.2.4 Optimisation du routage**

L'optimisation du routage est un domaine où l'apprentissage automatique peut apporter des améliorations significatives dans les réseaux sans fil. En utilisant des algorithmes d'apprentissage automatique, les réseaux peuvent prendre des décisions plus intelligentes

concernant les itinéraires optimaux pour acheminer les données en fonction de la qualité des liens et de la congestion du trafic.

#### **5.2.4.1. Sélection des itinéraires**

Les réseaux sans fil peuvent être rencontrer à plusieurs itinéraires possibles pour acheminer les données entre une source et une destination. L'apprentissage automatique est utilisé pour évaluer la qualité de chaque itinéraire potentiel en prenant en compte divers facteurs tels que le taux d'erreur du canal, la latence, la bande passante disponible, et la congestion du réseau. Les algorithmes d'apprentissage automatique, tels que les algorithmes de renforcement, peuvent être déployés pour explorer et apprendre progressivement les performances des différentes routes, conduisant à la sélection des itinéraires les plus optimaux pour une communication efficace [76].

#### **5.2.4.2. Routage basé sur les préférences des utilisateurs**

Dans certains cas, les utilisateurs peuvent avoir des préférences spécifiques en matière de routage, telles que la priorité accordée à la latence minimale ou à une haute fiabilité. L'apprentissage automatique est utilisé pour modéliser les préférences individuelles des utilisateurs et personnaliser le routage en fonction de ces préférences. Cela permet d'offrir une meilleure expérience utilisateur et de satisfaire les besoins spécifiques de chaque utilisateur dans le réseau [77].

#### **5.2.4.3. Routage dynamique et adaptatif**

Les conditions du réseau peuvent varier avec le temps, en raison des changements dans la topologie, la qualité des liens, et le trafic. L'apprentissage automatique permet aux réseaux sans fil de s'adapter en temps réel à ces changements en ajustant dynamiquement les itinéraires en fonction des conditions actuelles. Les réseaux peuvent utiliser des algorithmes d'apprentissage automatique, tels que les réseaux LSTM, pour prédire les variations futures du trafic et optimiser le routage en conséquence [78].

#### **5.2.5. Amélioration des performances**

L'apprentissage automatique joue un rôle essentiel dans l'amélioration des performances globales des réseaux sans fil en analysant les données historiques sur les performances du réseau. En utilisant ces informations, les algorithmes d'apprentissage automatique peuvent

identifier les problèmes, prédire les pannes potentielles et optimiser le réseau pour une meilleure efficacité.

#### **5.2.5.1. Détection des goulots d'étranglement**

Les goulots d'étranglement sont des points de congestion dans le réseau où le trafic est bloqué ou ralenti, entraînant une dégradation des performances. L'apprentissage automatique est utilisé pour analyser les données de trafic et identifier les zones où les ressources du réseau sont insuffisantes pour répondre à la demande. En utilisant des techniques telles que l'apprentissage supervisé, les réseaux sans fil peuvent anticiper la formation de goulots d'étranglement et prendre des mesures proactives pour les éviter ou les atténuer, garantissant ainsi un flux de données plus fluide [79].

#### **5.2.5. 2. Prédiction des pannes potentielles**

L'apprentissage automatique est utilisé pour prédire les pannes potentielles dans le réseau avant qu'elles ne se produisent réellement. En analysant les modèles de performance et les comportements du réseau dans le passé, les algorithmes d'apprentissage automatique peuvent identifier les signes avant-coureurs de pannes ou de dysfonctionnements. Ces prédictions permettent aux administrateurs du réseau d'agir de manière proactive en prenant des mesures correctives avant que les problèmes ne deviennent critiques, améliorant ainsi la disponibilité du service et la fiabilité du réseau [80].

#### **5.2.5.3. Optimisation des paramètres du réseau sans fil**

En utilisant l'apprentissage automatique, les réseaux sans fil peuvent optimiser dynamiquement leurs paramètres en fonction des conditions changeantes du réseau et des besoins des utilisateurs. Par exemple, les algorithmes d'apprentissage automatique peuvent ajuster les paramètres de transmission, les seuils de retransmission, ou les taux de modulation en fonction de la qualité des liens et du niveau de bruit. En optimisant ces paramètres, les réseaux sans fil peuvent améliorer leur efficacité énergétique et leur capacité de transmission, ce qui se traduit par des performances globales améliorées [80].

### **5.3 La consommation énergétique des algorithmes d'apprentissage automatique**

L'essor fulgurant du nombre d'algorithmes d'apprentissage automatique est à l'origine d'une exigence énergétique grandissante, qui provient très fréquemment de sources fossiles. Cette

situation entraîne une amplification inéluctable de l'empreinte carbone des réseaux cellulaires, car le secteur énergétique est actuellement coupable d'environ 70 % des émissions de GES [81]. De plus, l'électrification croissante de notre société, engendrée par la numérisation, ne fera qu'accentuer la demande en électricité.

Dans ce contexte, et compte tenu de la croissance exponentielle du déploiement des systèmes basés sur les algorithmes d'apprentissage automatique, on peut prédire qu'une part significative de la production d'électricité sera dédiée au secteur des télécommunications [82]. Par conséquent, l'optimisation des algorithmes d'apprentissage automatique dans l'objectif de réduire davantage la consommation d'énergie s'impose comme une nécessité cruciale et mérite une attention particulière. Cependant, ce facteur est souvent omis par les développeurs des algorithmes d'apprentissage automatique. En effet, durant la phase de développement de ces derniers, les critères de sélection privilégiés sont la précision du modèle et la capacité à générer de nouvelles données. Malheureusement, l'absence d'une méthodologie standard de quantification de la consommation énergétique des algorithmes d'apprentissage automatique entrave la mise en œuvre d'une solution durable pour réduire les émissions de GES dans le secteur de l'information et des télécommunications.

Très peu de recherches ont été menées dans le but d'estimer la quantité d'énergie consommée par les algorithmes d'apprentissage automatique et d'évaluer leurs impacts environnementaux. Néanmoins, ces dernières années, nous observons une augmentation d'études portant sur cette problématique.

L'une des premières études qui a cherché à estimer la consommation énergétique des algorithmes d'apprentissage automatique a été réalisée par Eva et al. [83]. Ils ont introduit un outil logiciel capable d'estimer la consommation d'énergie et ont présenté deux cas d'usage pour optimiser la consommation d'énergie dans le domaine de l'apprentissage automatique.

Lacoste et al.[84] ont fourni le calculateur d'émissions d'apprentissage automatique, qui repose sur l'auto déclaration. Cet outil est capable d'estimer l'empreinte carbone d'un calcul effectué par une unité de traitement graphique, en prenant en compte les types de matériel, le temps d'utilisation, les fournisseurs de cloud et les régions. Cependant, en fonction de la manière dont l'énergie est produite, stockée et distribuée, l'augmentation de la recherche en IA à forte intensité de calcul pourrait entraîner des impacts environnementaux significatifs. L'attention a été attirée pour la première fois sur l'impact environnemental de la recherche en IA par

l'étude fondatrice de Strudel et al. [85], qui a fourni une estimation de haut niveau des coûts financiers et environnementaux.

Lasse Fet al. [86] ont développé l'outil *carbon-tracker* pour suivre et prédire la consommation d'énergie et l'empreinte carbone des algorithmes d'apprentissage automatique durant la phase de formation. De plus, dans la référence [87], les auteurs ont proposé un outil (*neuralPower*) basé sur un cadre prédictif à base de couches pour estimer la consommation d'énergie des CNN. Canziani et al.[88] ont évalué la précision du modèle de classification d'images en fonction de la taille du modèle et des gigaflops requis lors de l'inférence. Ils ont également mesuré la consommation électrique moyenne nécessaire lors de l'inférence sur les GPU en fonction de la taille du lot.

Rodrigues et al. [89] ont proposé *SyNERGY*, un outil de mesure détaillée de l'énergie (c'est-à-dire à des couches spécifiques) et un cadre prédictif pour les DNNs sur des plateformes embarquées. Leur cadre de mesure offre une répartition précise de la consommation d'énergie réelle et des performances à travers toutes les couches des réseaux de neurones.

D'autres travaux d'importance à mentionner incluent ceux de Yang et al.[90] qui ont développé un algorithme de mesure sensible à l'énergie pour les CNN, qui utilise directement la consommation d'énergie d'un CNN pour guider le processus de dimensionnement. Leurs méthodologies d'estimation de l'énergie se basent sur des paramètres extrapolés à partir de mesures réelles.

L'étude menée par Brownlee et al.[91] explore le compromis entre précision et consommation d'énergie dans les modèles d'apprentissage automatique. Ils proposent une approche d'amélioration génétique pour optimiser le compromis précision-énergie, démontrant des résultats prometteurs sur plusieurs ensembles de données de référence.

Le travail de Dai et al.[92] propose une méthode d'adaptation de modèle sensible à la plateforme appelée Chamnet, qui optimise l'architecture du réseau pour s'adapter à la plateforme matérielle spécifique, réduisant la consommation d'énergie et améliorant l'efficacité. Ces auteurs ont obtenu des améliorations significatives en termes de précision et d'efficacité énergétique par rapport à d'autres méthodes de pointe.

Par ailleurs, Brownlee et al. [93] ont également étudié la consommation d'énergie des algorithmes d'apprentissage automatique, proposant une méthode d'optimisation basée sur la

recherche pour la réduction d'énergie des algorithmes omniprésents tels que les k-moyennes, la régression logistique et les arbres de décision. Ils ont démontré que leur approche peut réduire la consommation d'énergie tout en maintenant la précision des modèles.

## **5.4 Conclusion**

En conclusion, l'apprentissage automatique apportent des solutions innovantes pour optimiser les réseaux sans fil. De la gestion des ressources à la prédiction de la mobilité des utilisateurs en passant par l'amélioration des performances et la sécurité du réseau, ces technologies ouvrent de nouvelles perspectives pour des réseaux sans fil plus intelligents, efficaces et sécurisés. Cependant, il est essentiel de poursuivre les efforts pour réduire l'impact énergétique de ces technologies et les rendre plus durables pour un avenir connecté et respectueux de l'environnement.

## Chapitre 6

### **L'impact des hyperparamètres sur la consommation et les performances des algorithmes d'apprentissage automatique pour la prédiction du trafic cellulaire**

#### **6.1 Introduction**

L'évolution récente des TICs a engendré un essor fulgurant des réseaux sans fil. Bien que prometteurs en matière de connectivité, ces avancements ont paradoxalement répercuté des conséquences écologiques néfastes dues à l'utilisation des énergies fossiles et des minerais. Face à ce défi, l'adoption d'algorithmes d'apprentissage automatique pour orchestrer le trafic cellulaire s'est présentée comme une solution pertinente pour modérer la consommation énergétique de ces réseaux. Toutefois, cette médaille a son revers : l'intensité computationnelle croissante requise par ces mêmes algorithmes génère une demande énergétique grandissante, augmentant ainsi leur empreinte carbone.

Il est donc devenu impératif de s'atteler à l'optimisation de ces algorithmes, non seulement pour optimiser leur performance mais aussi pour minimiser leur consommation de ressources naturelles et, en particulier, les énergies fossiles. Dans cette optique, le présent chapitre est dédié à l'étude approfondie de l'influence des hyperparamètres sur la consommation d'énergie et les performances de ces algorithmes, spécifiquement dans le contexte de la prédiction du trafic cellulaire.

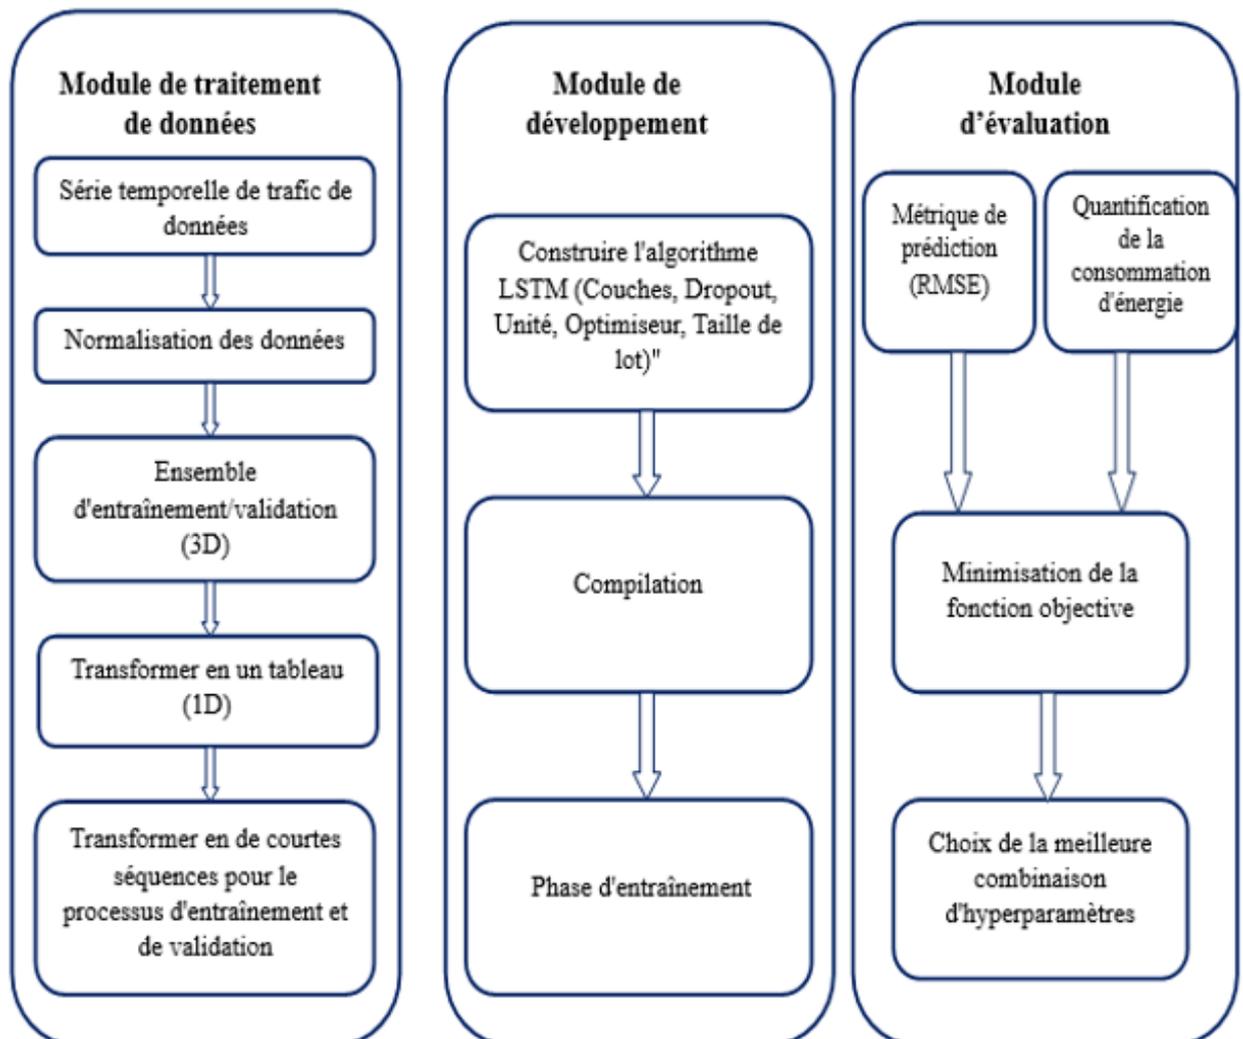
À travers une méthodologie rigoureuse, divers hyperparamètres (le nombre de couches, le nombre de neurones par couche, l'algorithme d'optimisation, la taille de lot, et le taux de dropout) ont été scrutés. Pour chaque combinaison envisageable d'hyperparamètres, un modèle a été formé, et sa consommation énergétique ainsi que ses performances ont été méticuleusement quantifiées et analysées.

L'interrelation entre la consommation énergétique et les hyperparamètres est manifeste, soulignant ainsi l'urgence de choisir judicieusement ces derniers. Il est donc suggéré d'établir un bon compromis entre la réduction de la consommation d'énergie et l'efficacité des algorithmes d'apprentissage automatique.

Ce chapitre se propose de décortiquer cette problématique, de présenter la méthodologie adoptée, et de mettre en lumière les principales découvertes et leurs implications pour le futur des réseaux sans fil.

## 6.2. Étude des Hyperparamètres pour la Prédiction du Trafic Cellulaire

Dans cette section, nous décrivons notre méthode pour étudier l'impact des hyperparamètres sur la consommation d'énergie et l'efficacité des algorithmes d'apprentissage profond dédiés à la prévision du trafic cellulaire. La Figure 17 montre la méthodologie composée de trois phases que nous avons adoptée :



**Figure 17.** Représentation schématique du cadre et de la méthodologie proposés.

## 6.2.1. Module de traitement de données

### 6.2.1.1. Base de données

Les données exploitées dans cette étude proviennent de Kaggle [94]. Ces données proviennent du trafic 4G et couvrent 57 cellules (BS) sur une durée d'environ un an (1 an  $\times$  24 h  $\times$  57 cellules). Les informations incluses dans cette base de données sont :

- Identifiant de la cellule (pour les 57 cellules).
- Date et heure : moment exact de la mesure du trafic.
- Trafic : quantité de trafic spécifique à chaque cellule pour chaque horodatage.

### 6.2.1.2. Normalisation et transformation des données

Les données liées au trafic cellulaire sont intrinsèquement complexes, constituées de signaux ayant des propriétés distinctes. En outre, la distribution de ces données est aléatoire. Afin de réduire l'impact des anomalies dans nos analyses, nous avons utilisé une normalisation min-max. Cette méthode redimensionne les données pour qu'elles se situent entre 0 et 1. Ci-dessous la formule utilisée pour cette fin [95] :

$$X_{normalisée} = \frac{(X - \min(x))}{(\max(x) - \min(x))} \quad (36)$$

où :  $\min(x)$  est le minimum des données et  $\max(x)$  est la valeur maximale du trafic de données.

La prédiction en temps réel du trafic de données nécessite une saisie et un apprentissage continu de ces données. Par conséquent, nous utilisons la notion de fenêtre glissante, qui indique un nombre fixe d'intervalles de temps précédents pour apprendre puis prédire le trafic de données actuel. Enfin, nous divisons les données traitées en deux ensembles : formation et test. Notre ensemble de fonctionnalités doit contenir les valeurs de trafic des dernières 24 heures, tandis que l'étiquette ou la variable dépendante doit être la valeur de trafic à la 25e heure. Afin d'entraîner le modèle LSTM à l'aide d'un ensemble de données d'entraînement, les données doivent être converties dans la forme acceptable pour l'architecture LSTM. Par conséquent, les données doivent être remodelées dans un format tridimensionnel. La première dimension est le nombre d'enregistrements ou de lignes dans l'ensemble de données, qui dans ce cas est 8732.

## 6.2.2. Module de développement

Dans le module que nous proposons, nous nous concentrons uniquement sur les hyperparamètres. Les hyperparamètres sont des configurations externes fournies au modèle,

telles que l'architecture du modèle, la fonction d'activation, etc [96]. Ces hyperparamètres se distinguent des paramètres du modèle tels que les poids et les biais, qui sont quant à eux dérivés durant l'étape d'apprentissage par rétropropagation.

Dans cette étude, nous examinons un ensemble complet d'hyperparamètres clés afin d'évaluer leur impact global. Ces hyperparamètres incluent le nombre de couches, le nombre de neurones par couche, le taux de dropout, et le choix des optimiseurs. L'optimisation de ces hyperparamètres est essentielle pour réduire la consommation d'énergie tout en améliorant l'efficacité de la prédiction. Pour atteindre cet objectif, nous avons utilisé la méthode de recherche par grille.

### 6.2.2.1. Recherche de grille.

La recherche sur grille (RG) est la technique la plus couramment adoptée pour l'optimisation des hyperparamètres [97]. RG se définit comme une méthode d'exploration exhaustive qui teste toutes les combinaisons possibles d'hyperparamètres définis dans une grille. Elle opère en évaluant le produit cartésien d'un ensemble de valeurs prédéterminées par l'utilisateur.

Dans notre travail, le RG a été utilisé pour générer les valeurs d'erreur et la consommation d'énergie en fonction des combinaisons possibles des hyperparamètres. Cela permettra d'exploiter et d'analyser les effets des hyperparamètres sur les performances et la consommation énergétique du modèle. Tout d'abord, nous avons défini la plage de valeurs possibles pour les hyperparamètres ( Tableau 6 ).

Ensuite, nous avons entraîné le modèle pour chaque combinaison à partir de la liste de valeurs prédéfinie. Nous avons généré 12288 combinaisons correspondant à 12 288 entraînements. Le modèle est ensuite évalué sur la base de deux critères : la consommation d'énergie et les performances du modèle à l'aide de l'équation (10). Une fois toutes les combinaisons évaluées, le modèle avec l'ensemble d'hyperparamètres qui a obtenu les meilleures performances et la plus faible consommation d'énergie est considéré comme optimal.

**Tableau 6.** Valeurs des hyperparamètres

Hyperparamètres	Valeurs
Optimiseur	[Adam, RMSProp, Nadam]
Taille du lot	[32-512 avec un pas de 32]
Nombre de couches	[1,2,3,4]
Nombre de neurones dans chaque couche	[8-256 avec un pas de 8]
Taux d'abandon	[0,1 .0,2]
Epoque	120
Fonction d'activation	Relu

### 6.2.2.3. L'algorithme d'apprentissage

L'optimisation est réalisée en réentraînant le modèle avec différentes combinaisons d'hyperparamètres (optimiseur, taille de lot, nombre de couches, nombre de neurones par couche) et en évaluant ses performances (consommation d'énergie et précision de la prédiction). Les étapes d'apprentissage du modèle sont répertoriées dans l'algorithme 1.

<b>Algorithme 1 : Algorithme de la méthode proposée</b>	
<b>1</b>	<b>Entrée</b> : données de trafic
<b>2</b>	<b>Résultat</b> : la fonction objective minimisée
<b>3</b>	Préparation des données
<b>4</b>	Fractionner les données (ensemble d'entraînement/ensemble de validation)
<b>5</b>	Définition du scaler min-max
<b>6</b>	Montage avec détartreur min-max
<b>7</b>	Remodeler les données
<b>8</b>	<b>ÉPOQUE</b> : 120
<b>9</b>	Créer le réseau LSTM
<b>dix</b>	<b>Pour</b> les couches de nombres de 1 à 4 <b>faire</b>
<b>11</b>	<b>Pour</b> Optimizer = [Adam, RMSProp, Nadam] <b>faire</b>
<b>12</b>	<b>Pour</b> la taille du lot dans la plage [32, 512, 32] <b>faire</b>
<b>13</b>	<b>Pour</b> Unite dans la gamme [8, 256, 8] <b>faire</b>
<b>14</b>	<b>Pour</b> un abandon dans la plage [0,1, 0,3, 0,1] <b>faire</b>
<b>15</b>	Adapter le réseau LSTM
<b>16</b>	Faire des prédictions avec des ensembles de données d'entraînement et de validation
<b>17</b>	Calculer l'erreur quadratique moyenne et quantifier l'énergie consommée
<b>18</b>	Calculer la fonction objectif
<b>19</b>	<b>Fin</b>
<b>20</b>	<b>Fin</b>
<b>21</b>	<b>Fin</b>
<b>22</b>	<b>Fin</b>
<b>23</b>	<b>Fin</b>
<b>24</b>	Choix des hypermètres dont la fonction objective est minimale

- **Optimiseurs**

Les optimiseurs jouent un rôle crucial dans l'amélioration des performances et de la vitesse d'entraînement. La sélection d'un optimiseur approprié est une tâche non triviale. Le choix de l'optimiseur dépend du problème spécifique et des compromis entre le temps de calcul, la vitesse de convergence et la précision. Dans notre étude, nous avons opté pour les trois

optimiseurs les plus couramment utilisés dans les problèmes de données séquentielles à savoir, Adam, RMSprop et Nadam.

- **Dropout**

La couche de dropout a été ajoutée pour améliorer les performances prédictives du modèle et éviter le surajustement. Dans la couche de dropout, le modèle désactive aléatoirement les neurones d'une couche avec une certaine probabilité. Lorsque la valeur de dropout est ajoutée à une couche, le réseau de neurones ignorera les neurones sélectionnés pendant l'entraînement et le temps d'entraînement sera plus rapide. En général, le taux de dropout peut varier de 0,1 à 0,5. Cependant, il est important de noter que le choix du taux de dropout optimal est généralement un processus d'essais et d'erreurs et peut dépendre de facteurs tels que la complexité du modèle, la quantité de données de formation et la tâche en cours d'exécution. Dans notre cas, nous avons choisi des taux de 0,1 et 0,2 en fonction de la complexité du modèle et de notre base de données. Nous avons pris en compte divers facteurs pour trouver la meilleure valeur de dropout pour notre modèle, y compris les effets de la régularisation sur l'apprentissage et la performance globale du modèle.

- **Taille du lot**

L'un des principaux hyperparamètres à ajuster avant de démarrer le processus de formation est la taille du lot. La taille du lot est un paramètre qui spécifie le nombre d'échantillons d'apprentissage qui seront utilisés lors de l'apprentissage pour effectuer une mise à jour des paramètres du réseau. Pour déterminer l'impact de la taille du lot sur la consommation du modèle, nous avons défini la taille du lot entre 32 et 512 avec un pas de 32, car notre modèle commence à se stabiliser à partir de 512.

- **Couches cachées**

Les couches cachées sont constituées de cellules récurrentes dont les états sont affectés à la fois par les états passés et les entrées actuelles avec des connexions de rétroaction. Les couches récurrentes peuvent être organisées en différentes architectures pour former différents LSTM. Différentes cellules et connexions internes permettent donc aux LSTM d'avoir des capacités différentes. Pour étudier l'impact des couches cachées sur la consommation électrique et les performances du modèle, Nous avons examiné des configurations allant de 1 à 4 couches, car au-delà de 5 couches, le modèle commençait à présenter un sur-ajustement dû à la complexité accrue du réseau par rapport à notre base de données.

- **Nombre d'unités par couche**

Nous avons soigneusement examiné le nombre de neurones par couche pour notre architecture de modèle et avons finalement opté pour des valeurs allant de 8 à 256. Notre décision était basée sur plusieurs facteurs, notamment la taille et la complexité de notre ensemble de données, ainsi que la nature de la tâche. Nous avons constaté qu'au-delà de 256 neurones, le modèle devenait de plus en plus complexe et sujet au sur-ajustement.

### 6.2.3. Module d'évaluation

Le cadre proposé a été évalué à l'aide de différents environnements matériels et logiciels. Le Tableau 7 montre l'équipement utilisé pour évaluer la méthode proposée.

**Tableau 7:** Spécification de l'équipement considéré.

Système d'exploitation	Windows
Unité centrale de traitement (CPU)	Intel(R) Core (TM) i5-1035G1 CPU @ 1.00 GHz 1.19 GH
Mémoire vive (RAM)	8 GB
Langage de programmation	Python

Pour évaluer les performances du modèle proposé, le RMSE a été utilisée pour estimer la précision de la prédiction, Par ailleurs l'outil PyRAPL a été utilisé dans cette étude pour quantifier la consommation d'énergie en fonction de la combinaison des hyperparamètres. À chaque itération de test, le modèle était soumis à un processus d'entraînement sur les données de formation, suivi de prédictions effectuées sur les données de validation, puis enfin, une évaluation du modèle était réalisée.

#### 6.2.3.1. Métriques d'évaluation avec RMSE

Nous avons opté pour la métrique RMSE qui mesure l'erreur moyenne entre les valeurs prédites et les valeurs réelles, en tenant compte de la racine carrée des écarts. Cette métrique est particulièrement utile pour évaluer les performances des modèles de régression avec valeurs aberrantes, car elle pénalise davantage les erreurs importantes. La RMSE est une mesure souvent utilisée pour évaluer la précision de la prédiction obtenue par le modèle.

#### 6.2.3.2. Mesure de la consommation d'énergie

Pour mesurer l'impact des hyperparamètres sur la consommation d'énergie du modèle, il est nécessaire de mesurer la consommation d'énergie de l'algorithme lors de son exécution. Dans Cette expérience nous avons utilisé l'outil PyRAPL, qui offre une interface Python pour la technologie Intel "Running Average Power Limit" (RAPL). Cette technologie RAPL permet

d'estimer la consommation énergétique d'un processeur Intel en fournissant des mesures de la consommation d'énergie de l'ensemble du package de socket CPU [98].

Tous les tests ont été réalisés sur un PC avec un processeur Intel(R) Core(TM) i5, fonctionnant à une vitesse de 1,00 GHz 1,19 GHz, avec 8 Go de RAM et fonctionnant sur le système d'exploitation Windows 10. Le modèle d'apprentissage profond a été implémenté à l'aide de la bibliothèque *Tensorflow* 2.4.1 et du langage de programmation Python. Le modèle complet a été entraîné sur un seul processeur pendant 120 époques, ce qui a pris environ 520 h.

### 6.2.3.3. Minimisation de la fonction objective

Notre problème aborde les compromis impliqués dans un problème d'optimisation à deux objectifs, la minimisation de la consommation d'énergie et l'erreur de prédiction. Pour cela, nous avons défini la fonction objectif ( $OF_{min}$ ) comme suit:

$$OF_{min} = \left[ W_1^2 \left[ \frac{E_c - E_{c,u}}{E_{c,max}} \right]^2 + W_2^2 \left[ \frac{RMSE - RMSE,u}{RMSE,max} \right]^2 \right]^{1/2} \quad (37)$$

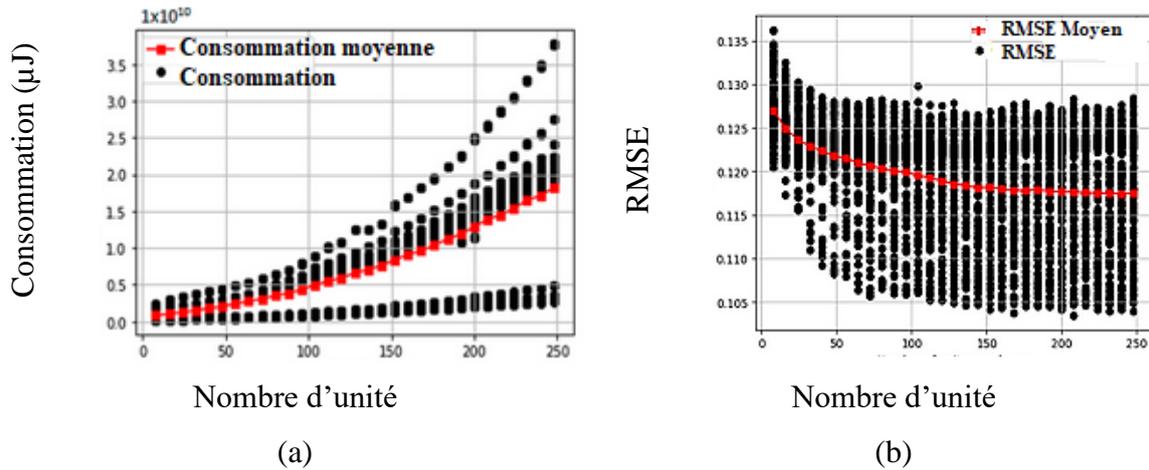
où,  $E_c$  et  $RMSE$  sont respectivement la consommation d'énergie et l'erreur de prédiction. L'indice  $u$  fait référence à la solution utopique, tandis que  $max$  fait référence aux valeurs maximales des fonctions objectifs. Les solutions utopiques pour ce problème peuvent être supposées égales à zéro, où  $W_1$  et  $W_2$  servent de poids à l'échelle et donnent la priorité aux termes.

## 6.3. Résultats et discussion

Dans cette section, les résultats de la simulation et de l'optimisation sont présentés et discutés afin d'évaluer l'impact de chaque hyperparamètre sur la consommation d'énergie et sur les performances du modèle.

### 6.3.1. Impact du nombre d'unités par couche

Pour exploiter l'influence du nombre d'unités par couche sur la consommation d'énergie et les performances du modèle, nous avons défini la plage d'unités entre 8 et 256 avec un pas de 8 et avec un grand espace de recherche de 7022 combinaisons d'hyperparamètres. La Figure 18.a montre l'évolution de l'énergie consommée en microjoules en fonction du nombre d'unités par couche. Chaque point de la Figure 18.a correspond à un ensemble d'hyperparamètres parmi les plages définies dans le Tableau 7. La Figure 18.b présente la dépendance de RMSE au nombre de neurones par couche.



**Figure 18:**(a) Variation de la consommation d'énergie en fonction du nombre d'unités par couche. (b) Variation de RMSE en fonction du nombre d'unités par couche.

Les résultats de la simulation montrent qu'un grand nombre d'unités par couche augmente la consommation d'énergie pour l'apprentissage du modèle. Cependant, l'erreur de prédiction diminue avec l'augmentation du nombre d'unités par couche. Il y a donc un compromis qu'il convient de gérer de manière à ce que la consommation d'énergie soit minimisée, et que la précision des prédictions reste simultanément acceptable.

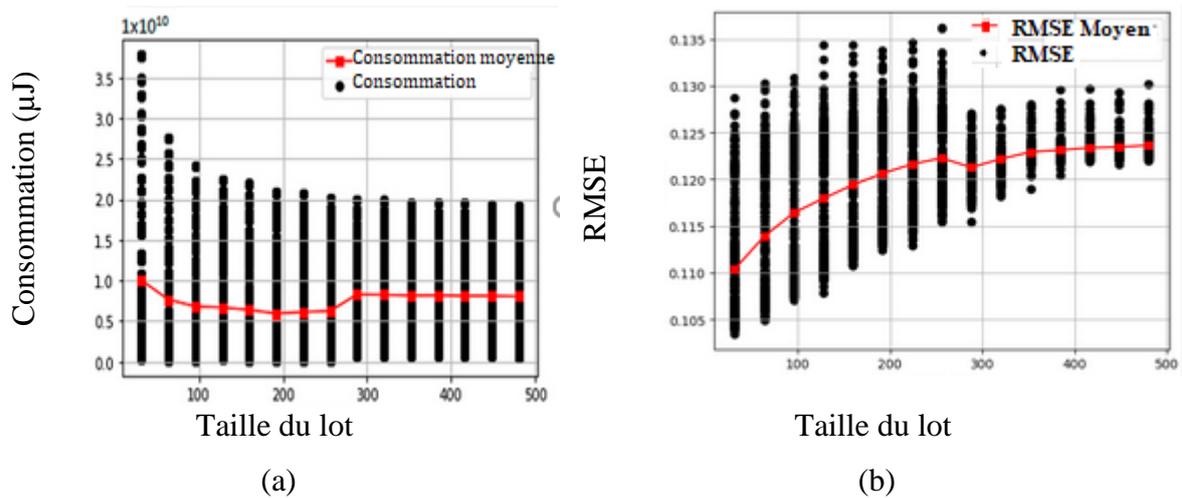
Nous concluons que le nombre d'unités affecte la consommation d'énergie et les performances du modèle. Ainsi, si le but du problème est d'obtenir les meilleures performances, alors un grand nombre d'unités est la solution la plus appropriée. Cependant, si la consommation d'énergie est le facteur principal d'une application, un grand nombre d'unités est défavorable. De plus, augmenter inutilement le nombre d'unités conduit à un problème de sur-ajustement.

### 6.3.2. Impact de la taille du lot

Dans cette section, nous évaluons l'impact de l'un des hyperparamètres les plus importants. L'objectif est de déterminer l'impact de l'hyperparamètre de taille de lot sur la consommation d'énergie et la précision du modèle d'apprentissage profond proposé. Pour obtenir des résultats cohérents, différentes valeurs de taille de lot sont choisies (Tableau 7).

La Figure 19 résume les résultats de simulation liés à l'impact de la taille du lot sur la consommation d'énergie et les performances. Nous pouvons voir sur la Figure 19.a que l'énergie varie avec la valeur de la taille du lot, et la plus grande valeur de l'énergie consommée par le modèle concerne les petites valeurs de la taille du lot. Cela est dû au fait que les petites tailles de lots nécessitent plus de ressources (processeur et logiciel) pour voir toutes les

données et un plus grand nombre d'itérations. La Figure 19.b montre la variation du *RMSE* en fonction de la taille du lot. Dans la Figure 19.b, nous pouvons voir que la taille de lot de 32 donne le meilleur résultat, et les grandes valeurs *RMSE* ont donné par des valeurs de taille de lot inférieures à 250.



**Figure 19:** (a) Variation de la consommation d'énergie en fonction de la taille du lot.  
(b) Variation de RMSE en fonction de la taille du lot.

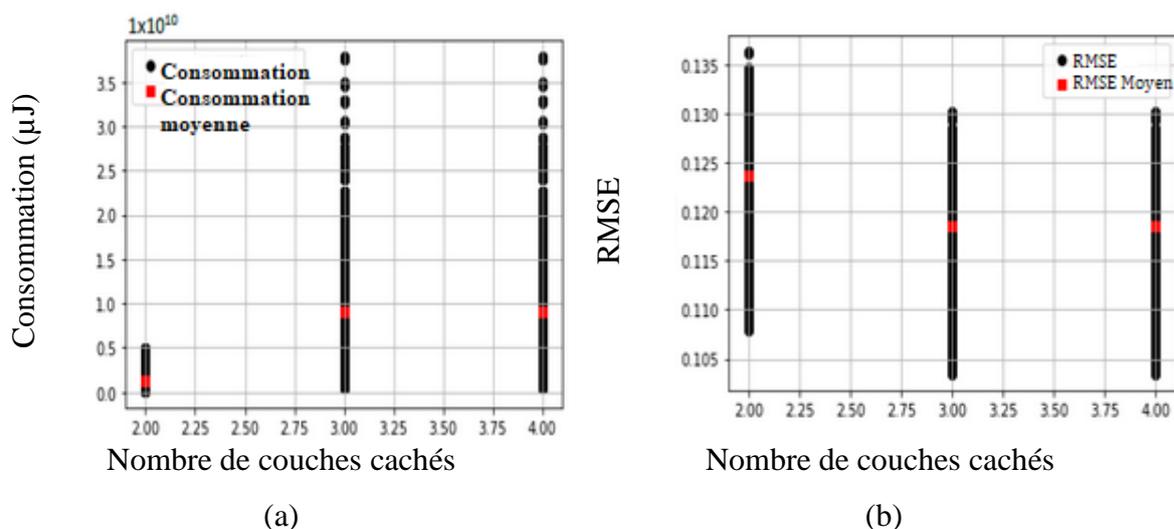
Il ressort de ces simulations que la consommation d'énergie augmente avec la diminution de la taille du lot, alors que les performances s'améliorent avec l'augmentation de la taille du lot. Ces résultats démontrent que l'utilisation d'une grande taille de lot minimise l'énergie mais augmente l'erreur de prédiction du modèle. De ces résultats, nous pouvons conclure que la taille du lot a un impact significatif sur la consommation d'énergie et les performances du modèle. Ainsi, une grande taille de lot doit être utilisée pour réduire la consommation d'énergie et obtenir de bonnes performances du modèle.

### 6.3.3. Impact du nombre de couches

Afin d'étudier l'influence des couches cachées sur la consommation d'énergie et les performances de notre modèle, nous avons varié les valeurs des couches cachées de 2 à 4. La Figure 20. a montre la consommation énergétique du modèle en fonction du nombre de couches cachées. Nous pouvons voir que la consommation d'énergie est la plus faible avec deux couches. Cependant, il n'y a pas de différence entre la consommation d'énergie avec trois et celle avec quatre couches.

Pour analyser l'influence du nombre de couches cachées sur la précision de la prédiction, la variation de *RMSE* en fonction du nombre de couches cachées est montrée. Sur la base des résultats de simulation présentés sur la Figure 20.b on peut voir que l'erreur de prédiction est

faible lorsque le nombre de couches est de trois ou quatre. Cependant, le *RMSE* est élevé lorsque le nombre de couches est de deux.



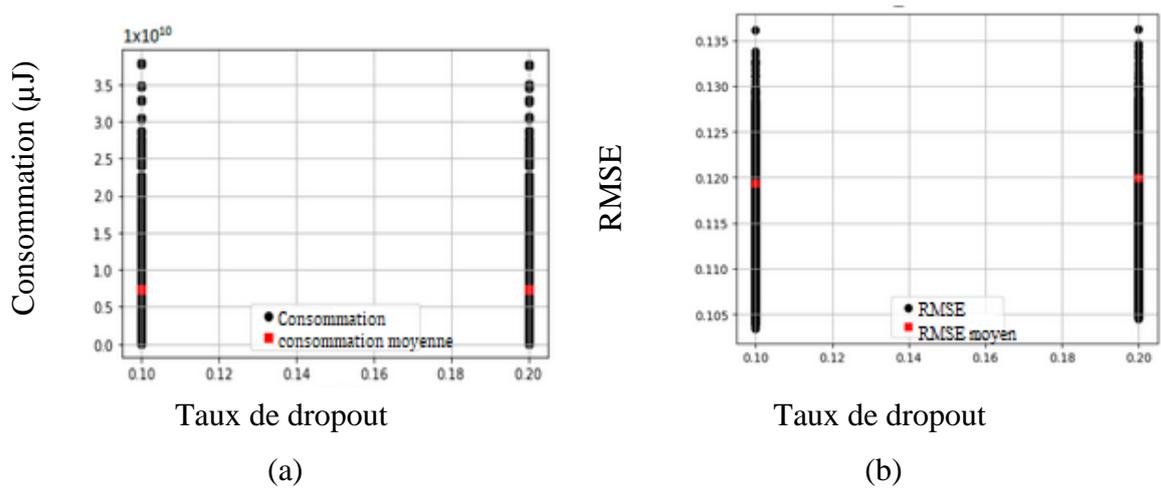
**Figure 20:** (a) Variation de la consommation d'énergie en fonction du nombre de couches cachées. (b) Variation de RMSE en fonction du numéro de couche cachée.

La sélection du nombre de couches cachées dans un réseau de neurones est l'un des problèmes majeurs dans le domaine des réseaux de neurones artificiels. La sélection arbitraire du nombre de couches cachées peut entraîner une consommation d'énergie élevée et une précision du modèle moindre. Si la consommation électrique est le critère le plus important dans une application, un petit nombre de couches cachées est plus adapté. Par contre si la performance du modèle est le facteur le plus important, alors un grand nombre de couches cachées est plus adapté.

### 6.3.4. Impact du taux de dropout

La régularisation des réseaux de neurones est une tâche importante pour la réduction du surapprentissage. Le dropout est une approche de régularisation largement utilisée pour les réseaux de neurones.

Dans cette section, nous analysons l'impact du taux de dropout sur la consommation d'énergie et les performances du modèle. Pour cela, nous avons testé différentes valeurs du taux de dropout présentées dans le Tableau 7. La Figure 21 montre l'évolution de la consommation d'énergie et de l'erreur de prédiction du modèle, respectivement, en fonction de dropout.



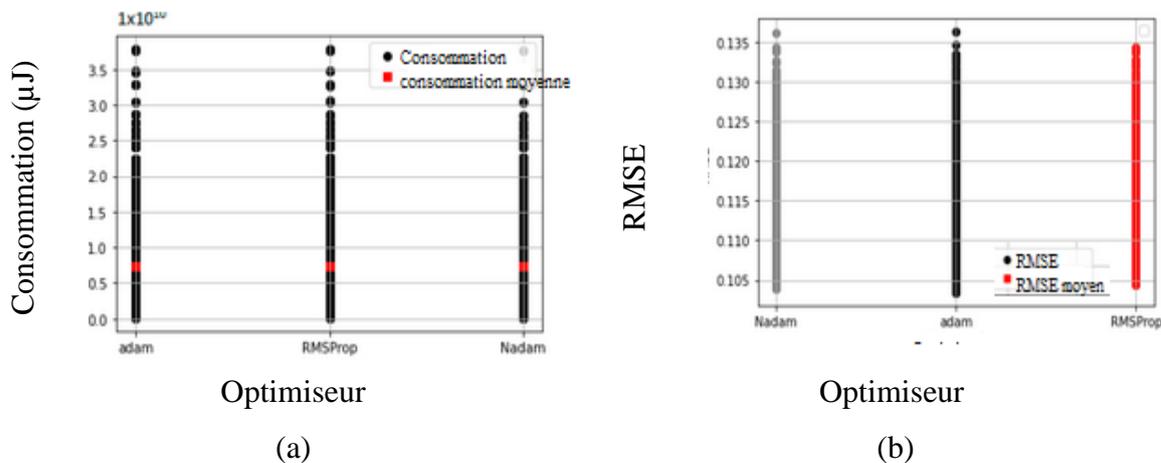
**Figure 21:** (a) Variation de la consommation d'énergie en fonction du taux de dropout.  
 (b) Variation du RMSE en fonction du taux de dropout.

D'après la Figure 21 on peut voir que le taux d'abandon n'a aucun effet sur la consommation d'énergie et l'erreur de prédiction. Sur la base de ces observations, nous concluons que le taux d'abandon n'a aucun effet sur la consommation d'énergie et les performances du modèle. Cependant, le décrochage est plus largement utilisé pour éviter le sur ajustement.

### 6.3.5. Impact du type d'optimiseur

L'optimiseur est un hyperparamètre important pour le réglage du réseau de neurone, mais il n'a pas reçu beaucoup d'attention. Pour illustrer l'impact du type d'optimiseur sur la consommation d'énergie et les performances de notre modèle, nous avons sélectionné trois optimiseurs les plus couramment utilisés dans les problèmes de prédiction : Adam, RMSprop et Nadam.

La Figure 22 montre l'impact du type d'optimiseur sur la consommation d'énergie et la prédiction des erreurs, respectivement.



**Figure 22:** (a) Variation de la consommation d'énergie en fonction du type d'optimiseur.  
 (b) Variation de RMSE en fonction en tant qu'optimiseur de fonction.

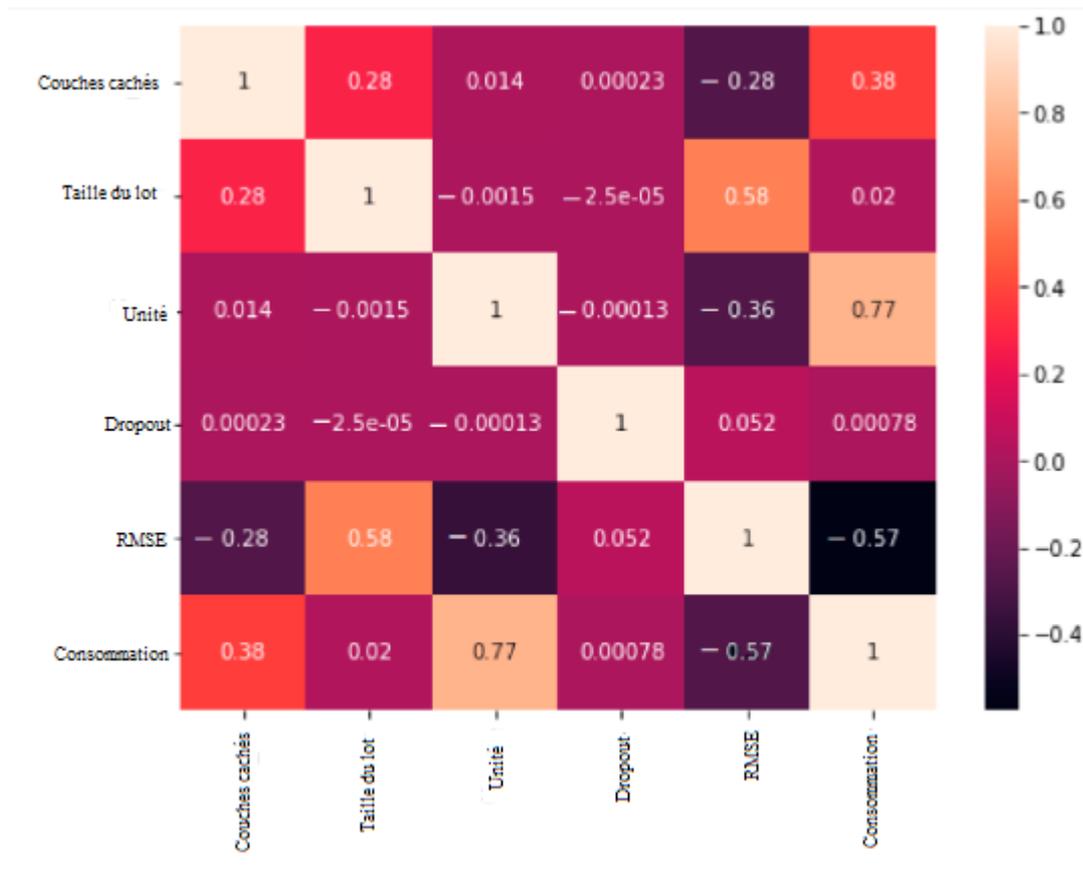
D'après les données présentées dans la Figure 22, nous pouvons voir qu'il n'y a pas de différence de consommation d'énergie entre les différents optimiseurs, mais en termes de performances du modèle, RMSprop affiche des performances supérieures. Adam et RMSprop offrent les mêmes performances.

La sélection d'un algorithme d'optimisation pour le processus d'entraînement a une influence significative sur les résultats de performance. D'après les résultats présentés dans la Figure 22, nous concluons que le type d'optimiseur n'affecte pas la consommation d'énergie du modèle, au contraire il affecte ses performances.

### **6.3.6. Matrice de corrélation**

Pour évaluer l'interdépendance entre les hyperparamètres, la consommation d'énergie et les performances du modèle, nous avons choisi la corrélation de Pearson **qui est** largement utilisée. Cette technique statistique produit un coefficient de corrélation allant de  $-1$  à  $+1$ , représentant la force et la direction d'une relation linéaire entre deux variables. Un coefficient de corrélation de  $+1$  implique une corrélation positive parfaite, où une augmentation d'une variable est associée à une augmentation proportionnelle de l'autre variable. En revanche, un coefficient de corrélation de  $-1$  indique une corrélation négative parfaite, où une augmentation d'une variable correspond à une diminution proportionnelle de l'autre variable. Lorsque le coefficient de corrélation est supérieur à  $0$ , cela indique une corrélation positive, ce qui signifie que lorsque l'une des variables augmente, l'autre tend également à augmenter, bien que la relation ne soit pas nécessairement linéaire.

Ensuite, nous nous sommes concentrés sur l'identification de la meilleure combinaison d'hyperparamètres qui permettrait une faible consommation d'énergie et des performances supérieures. La Figure 23 montre la matrice de corrélation utilisée pour étudier la dépendance entre les différents hyperparamètres, la consommation d'énergie et l'erreur de prédiction du modèle.



**Figure 23:** Matrice de corrélation utilisée pour identifier les principales tendances.

Dans la matrice de corrélation, les coefficients de corrélation de Pearson entre les hyperparamètres, la consommation d'énergie et la RMSE sont indiqués. On peut observer qu'il existe une très forte corrélation de 0,77 entre le nombre d'unités et la consommation d'énergie du modèle, ce qui signifie qu'une augmentation du nombre d'unités par couche augmente la consommation d'énergie. De plus, il existe une dépendance modérée de 0,38 entre le nombre de couches cachées et la consommation d'énergie du modèle, ce qui implique que l'augmentation du nombre de couches augmente modérément l'énergie. On peut également observer qu'il existe une faible corrélation entre le taux d'abandon et l'énergie, indiquant qu'une augmentation du taux d'abandon n'affecte pas l'énergie consommée par le modèle.

Par ailleurs, une corrélation relativement forte de 0,58 est observée entre la taille du lot et l'erreur de prédiction, ce qui signifie qu'une augmentation de la taille du lot augmentera l'erreur. La corrélation entre RMSE et le nombre d'unités par couche est de -0,38, autrement dit une augmentation du nombre de couches réduira l'erreur de prédiction. On peut également observer qu'il existe une corrélation négative modérée de -0,28 entre RMSE et le nombre de couches cachées, indiquant que l'augmentation du nombre de couches cachées réduit

modérément l'erreur. En ce qui concerne le taux d'abandon et le RMSE, il existe une faible corrélation entre les deux paramètres, de sorte que le taux d'abandon n'affecte pas l'erreur de prédiction.

### 6.3.7. Les meilleurs hyperparamètres

Afin de déterminer les hyperparamètres optimaux pour notre modèle, nous avons utilisé l'équation (36) et examiné deux critères principaux : minimiser la consommation d'énergie et garantir une erreur de prédiction acceptable. En faisant varier les valeurs de poids, nous avons pu identifier la combinaison idéale d'hyperparamètres qui a donné la fonction objective la plus faible, comme indiqué dans le Tableau 8.

**Tableau 8:** Résultat de l'optimisation.

Poids	Couches	Taille du lot	Nombre d'unité	Optimiseur	Dropout	OF min
$w_1=0.5$ $w_2=w_1$	3	64	184	RMSprop	0.1	0.3939
$w_1=0.3$ $w_2=0.7$	3	32	72	Nadam	0.1	0.5449
$w_1=0.7$ $w_2=0.3$	3	64	184	Nadam	0.1	0.2401

D'après notre analyse, nous avons constaté que l'attribution d'un même poids de 0,5 à  $w_1$  et  $w_2$  a conduit à une fonction objective minimale égale à 0,3939. Cette combinaison comprenait trois couches cachées, une taille de lot de 64, un nombre d'unités égal à 184, l'utilisation d'un optimiseur RMSprop et un taux d'abandon de 0,1.

Cependant, nous avons également reconnu l'importance de prioriser des critères spécifiques en fonction des objectifs du modèle. Pour mettre l'accent sur la minimisation de la consommation d'énergie, nous avons ajusté les valeurs de poids de  $w_1 = 0,3$  de  $w_2 = 0,7$ , ce qui a conduit à la combinaison optimale d'hyperparamètres constituée de trois couches cachées, une taille de lot de 64, un nombre d'unités égale à 184, l'utilisation d'un optimiseur Nadam, et un taux d'abandon de 0,1.

A l'inverse, pour privilégier la réduction de l'erreur dans la fonction objective, nous avons choisi  $w_1 = 0,7$  et  $w_2 = 0,3$ , ce qui a abouti à la meilleure combinaison d'hyperparamètres pour atteindre la fonction objective minimale, à savoir trois couches cachées, une taille de lot de

32, un nombre d'unités égale à 72, l'utilisation d'un Nadam optimiseur, et un taux d'abandon de 0,1.

Dans l'ensemble, notre approche démontre l'importance d'examiner attentivement les poids relatifs des différents critères lors de l'optimisation des hyperparamètres, afin d'obtenir les résultats souhaités pour le modèle.

## **6.4 Conclusion**

Dans cette étude, un cadre ascendant a été développé et mis en œuvre pour évaluer l'impact des hyperparamètres sur les performances du modèle et sur la consommation d'énergie. L'étude souligne l'importance de sélectionner un ensemble approprié d'hyperparamètres pour optimiser les performances du modèle et minimiser la consommation d'énergie des algorithmes d'apprentissage profond utilisés dans la prédiction du trafic cellulaire. De plus, l'étude a utilisé une approche d'optimisation multi-objectifs pour minimiser simultanément l'erreur et la consommation d'énergie, résultant en une solution de compromis optimale. Nous avons montré qu'un ensemble approprié d'hyperparamètres contribue de manière significative à l'amélioration des performances du modèle et de la consommation d'énergie. La méthode proposée présentée dans cette étude ouvre la voie à l'étude de l'impact des hyperparamètres sur la consommation d'énergie et la prédiction des erreurs dans les modèles d'apprentissage profond.

## Chapitre 7

### Conclusion et perspectives de recherche

#### 7.1 Conclusion

Dans cette thèse, nous avons abordé deux aspects essentiels dans le domaine des réseaux sans fil et de l'Apprentissage automatique: la consommation d'énergie dans les réseaux Wi-Fi communautaires et l'impact des hyperparamètres sur les performances et la consommation énergétique des modèles d'apprentissage profond utilisés dans la prédiction du trafic cellulaire.

Dans le premier volet de notre étude, nous avons proposé une approche novatrice pour évaluer la consommation d'énergie et les émissions de GES associées au déploiement d'un réseau Wi-Fi communautaire sur un campus universitaire. Notre cadre GES a permis de quantifier le potentiel de réduction des émissions de GES résultant du passage à des sources d'énergie plus propres, telles que l'énergie solaire, pour alimenter le réseau Wi-Fi. En appliquant cette méthodologie à un déploiement plus large du Wi-Fi communautaire à l'échelle d'un pays, nous avons pu estimer les bénéfices environnementaux potentiels d'une telle initiative. De plus, cette approche pourrait être étendue pour évaluer l'impact environnemental d'autres solutions technologiques propres.

Dans le deuxième volet de notre recherche, nous avons développé un cadre d'analyse des hyperparamètres pour évaluer l'impact de ces derniers sur les performances des modèles d'apprentissage profond utilisés dans la prédiction du trafic cellulaire. En optimisant simultanément l'erreur quadratique moyenne et la consommation d'énergie, nous avons identifié un ensemble approprié d'hyperparamètres permettant d'atteindre un compromis optimal entre la précision du modèle et l'efficacité énergétique. Cette approche a mis en évidence l'importance cruciale du choix judicieux des hyperparamètres pour améliorer à la fois la précision des modèles et leur efficacité énergétique.

En conclusion, cette thèse a apporté une contribution significative à l'avancement des connaissances dans les domaines des réseaux sans fil, de l'efficacité énergétique et de l'apprentissage automatique. Elle offre des solutions concrètes pour réduire l'empreinte carbone des réseaux sans fil tout en optimisant les performances des modèles, contribuant ainsi à la création d'un avenir durable pour les communications sans fil. Ces résultats sont

d'une importance considérable dans le contexte actuel de préoccupation croissante pour l'environnement et la durabilité.

## 7.2 Perspectives de recherche

Les résultats obtenus dans cette thèse ouvrent la voie à de nouvelles opportunités de recherche dans les domaines des réseaux sans fil et de l'apprentissage automatique. Plusieurs perspectives intéressantes peuvent être envisagées pour approfondir ces travaux :

1. Extension à d'autres types de réseaux sans fil : La méthodologie développée pour évaluer la consommation d'énergie dans les réseaux Wi-Fi communautaires pourrait être étendue à d'autres types de réseaux sans fil, tels que les réseaux cellulaires ou les réseaux IoT (*Internet of Things*). Cela permettrait de mieux comprendre l'impact énergétique global des communications sans fil et d'identifier des stratégies d'optimisation énergétique pour différents scénarios d'utilisation.
2. Intégration de l'IA dans la gestion de l'énergie des réseaux : L'utilisation de l'IA dans la gestion de l'énergie des réseaux sans fil peut être explorée davantage. Des techniques d'apprentissage automatique pourraient être appliquées pour optimiser dynamiquement la consommation d'énergie des équipements réseau en fonction des fluctuations de la demande, des conditions environnementales et des contraintes budgétaires.
3. Exploration de l'optimisation des poids dans les fonctions objectives : Envisager l'utilisation d'autres algorithmes, tels que l'algorithme génétique, pour l'optimisation des poids de la fonction objectif dans les modèles d'apprentissage automatique. Cette approche pourrait offrir une optimisation plus robuste et adaptative des paramètres, essentielle pour gérer les compromis complexes dans les réseaux sans fil.
4. Solutions technologiques propres : Il serait bénéfique de poursuivre la recherche sur les solutions technologiques propres pour alimenter les réseaux sans fil. Cela inclut l'utilisation accrue d'énergies renouvelables, l'amélioration de l'efficacité énergétique des équipements et le développement de nouvelles technologies écoénergétiques.
5. Sécurité et vie privée : L'impact environnemental des réseaux sans fil ne se limite pas seulement à la consommation d'énergie, mais il est également lié à la sécurité et à la vie privée des utilisateurs. Il serait donc intéressant de poursuivre la recherche sur l'optimisation de ces aspects pour garantir un développement durable et responsable des réseaux sans fil.

En mettant en œuvre ces perspectives de recherche, nous pourrions contribuer à la construction d'un avenir durable où les réseaux sans fil joueront un rôle clé dans la connectivité mondiale, tout en minimisant leur empreinte environnementale.

## Références

- [1] Mobility Report d'Ericsson : la croissance mondiale de la 5G dans un contexte de défis macroéconomiques." <https://www.ericsson.com/fr/press-releases/2022/11/ericsson-mobility-report-global-5g-growth-amid-macroeconomic-challenges> (consulté le 22/08/2023).
- [2] Digital report : l'évolution du numérique en 2023 - We Are Social France. (s. d.). We Are Social France. <https://wearesocial.com/fr/blog/2023/01/digital-report-levolution-du-numerique-en-2023/> (Consulté le 22/08/2023).
- [3] Rapport sur les tendances mondiales des réseaux en 2020." <https://www.google.com/search?client=firefox-b&q=Rapport+sur+les+tendances+mondiales+des+r%C3%A9seaux+en+2020+Cisco+https%3A%2F%2Fwww.cisco.com+%E2%80%BA+2019-networking-report> (consulté le 22/08/2023).
- [4] L'Internet est devenu plus abordable et s'est généralisé, mais les plus pauvres à travers le monde restent privées des possibilités offertes par cette technologie." <https://www.itu.int/fr/mediacentre/Pages/PR-2022-11-30-Facts-Figures-2022.aspx> (consulté le 22/08/2023).
- [5] 5G and Its Impact on The Internet of Things." <https://www2.stardust-testing.com/en/5g-and-impact-on-iots> (consulté le 22/08/2023).
- [6] X. You, C. Zhang, X. Tan, S. Jin, and H. Wu, "AI for 5G: Research directions and paradigms," *Science China Information Sciences*, vol. 62, pp. 1-13, 2019.
- [7] M. H. Alsharif, A. H. Kelechi, J. Kim, and J. H. Kim, "Energy efficiency and coverage trade-off in 5G for eco-friendly and sustainable cellular networks," *Symmetry*, vol. 11, no. 3, p. 408, 2019.
- [8] A. S. Andrae and T. Edler, "On global electricity usage of communication technology: trends to 2030," *Challenges*, vol. 6, no. 1, pp. 117-157, 2015.
- [9] "La vie numérique a un lourd bilan carbone." <https://www.sciencepresse.qc.ca/blogue/labo-journalisme-scientifique/2018/03/13/vie-numerique-lourd-bilan-carbone> (consulté le 22/08/2023).
- [10] Y. Liu, S. Bi, Z. Shi, and L. Hanzo, "When machine learning meets big data: A wireless communication perspective," *IEEE Vehicular Technology Magazine*, vol. 15, no. 1, pp. 63-72, 2019.
- [11] J. Ferber, *Multi-Agent System: An Introduction to Distributed Artificial Intelligence* (no. Paper: ISBN 0-201-36048-9). 1999.
- [12] E. Nihl and E. De Bruijckere, "An implementation of a real-time water quality monitoring IoT system with 4G connectivity: Catfish-Data and Sensors," ed, 2021.

- [13] B. Vidyapeeth, "Comparative study between the generations of mobile communication 2G, 3G & 4G," *International Journal on Recent and Innovation Trends in Computing and Communication*, vol. 1, no. 4, pp. 327-331, 2013.
- [14] R. Sood and A. Garg, "Digital society from 1G to 5G: a comparative study," *International Journal of Application or Innovation in Engineering & Management (IJAEM)*, vol. 3, no. 2, pp. 186-193, 2014.
- [15] D. K. Sucheta, "A comparative study of 1G, 2G, 3G AND 4G." *J. Ing. Calculer. Appl. Sci* 2.4 (2013) : 55-63.
- [16] M. Attaran, "The impact of 5G on the evolution of intelligent automation and industry digitization," *Journal of ambient intelligence and humanized computing*, vol. 14, no. 5, pp. 5977-5993, 2023.
- [17] V. Garg, *Wireless communications & networking*. Elsevier, 2010.
- [18]"Aspects pertinents de la quatrième génération de réseau mobile sans fil "  
<https://www.rapport-gratuit.com/aspects-pertinents-de-la-quatrieme-generation-de-reseau-mobile-sans-fil/> (consulté le 22/08/ 2023).
- [19] B. Feng et al., "HetNet: A flexible architecture for heterogeneous satellite-terrestrial networks," *IEEE network*, vol. 31, no. 6, pp. 86-92, 2017.
- [20] J. Jeong et al., "High-efficiency WCDMA envelope tracking base-station amplifier implemented with GaAs HVHBTs," *IEEE journal of solid-state circuits*, vol. 44, no. 10, pp. 2629-2639, 2009.
- [21] O. Arnold, F. Richter, G. Fettweis, and O. Blume, "Power consumption modeling of different base station types in heterogeneous cellular networks," in *2010 Future Network & Mobile Summit*, 2010: IEEE, pp. 1-8.
- [22] C. Qiu, Y. Zhang, Z. Feng, P. Zhang, and S. Cui, "Spatio-temporal wireless traffic prediction with recurrent neural network," *IEEE Wireless Communications Letters*, vol. 7, no. 4, pp. 554-557, 2018.
- [23] D. Palani and M. Arulraj, "Energy Efficient Solutions for Green Cellular Networks—a Survey," vol. 9, pp. 1-16.
- [24] J. Wu, Y. Bao, G. Miao, S. Zhou, and Z. Niu, "Base-station sleeping control and power matching for energy–delay tradeoffs with bursty traffic," *IEEE Transactions on Vehicular Technology*, vol. 65, no. 5, pp. 3657-3675, 2015.
- [25] M. A. Marsan, L. Chiaraviglio, D. Ciullo, and M. Meo, "On the effectiveness of single and multiple base station sleep modes in cellular networks," *Computer Networks*, vol. 57, no. 17, pp. 3276-3290, 2013.
- [26] Y. S. Soh, T. Q. Quek, M. Kountouris, and H. Shin, "Energy efficient heterogeneous cellular networks," *IEEE Journal on selected areas in communications*, vol. 31, no. 5, pp. 840-850, 2013.

- [27] H. Tabassum, U. Siddique, E. Hossain, and M. J. Hossain, "Downlink performance of cellular systems with base station sleeping, user association, and scheduling," *IEEE Transactions on Wireless Communications*, vol. 13, no. 10, pp. 5752-5767, 2014.
- [28] C. Han et al., "Green radio: radio techniques to enable energy-efficient wireless networks," *IEEE communications magazine*, vol. 49, no. 6, pp. 46-54, 2011.
- [29] S. Cui, A. J. Goldsmith, and A. Bahai, "Energy-efficiency of MIMO and cooperative MIMO techniques in sensor networks," *IEEE Journal on selected areas in communications*, vol. 22, no. 6, pp. 1089-1098, 2004.
- [30] M. Li, P. Li, X. Huang, Y. Fang, and S. Glisic, "Energy consumption optimization for multihop cognitive cellular networks," *IEEE Transactions on Mobile Computing*, vol. 14, no. 2, pp. 358-372, 2014.
- [31] Y. Chen, S. Zhang, S. Xu, and G. Y. Li, "Fundamental trade-offs on green wireless networks," *IEEE Communications Magazine*, vol. 49, no. 6, pp. 30-37, 2011.
- [32] G. He, S. Zhang, Y. Chen, and S. Xu, "Fundamental tradeoffs and evaluation methodology for future green wireless networks," in *2012 1st IEEE International Conference on Communications in China Workshops (ICCC)*, 2012: IEEE, pp. 74-78.
- [33] H. ElSawy, E. Hossain, and M. Haenggi, "Stochastic geometry for modeling, analysis, and design of multi-tier and cognitive cellular wireless networks: A survey," *IEEE Communications surveys & tutorials*, vol. 15, no. 3, pp. 996-1019, 2013.
- [34] A. R. Ekti, M. Z. Shakir, E. Serpedin, and K. A. Qaraqe, "Downlink power consumption of HetNets based on the probabilistic traffic model of mobile users," in *2013 IEEE 24th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC)*, 2013: IEEE, pp. 2797-2802.
- [35] A. Mukherjee, S. Bhattacharjee, S. Pal, and D. De, "Femtocell based green power consumption methods for mobile network," *Computer Networks*, vol. 57, no. 1, pp. 162-178, 2013.
- [36] W. Guo and T. O'Farrell, "Green cellular network: Deployment solutions, sensitivity and tradeoffs," in *2011 Wireless Advanced*, 2011: IEEE, pp. 42-47.
- [37] H. Claussen, I. Ashraf, and L. T. Ho, "Dynamic idle mode procedures for femtocells," *Bell Labs Technical Journal*, vol. 15, no. 2, pp. 95-116, 2010.
- [38] W. Li, W. Zheng, Y. Xie, and X. Wen, "Clustering based power saving algorithm for self-organized sleep mode in femtocell networks," in *The 15th International Symposium on Wireless Personal Multimedia Communications*, 2012: IEEE, pp. 379-383.
- [39] I. H. Rowlands, P. Parker, and D. Scott, "Consumer perceptions of "green power"," *Journal of consumer marketing*, vol. 19, no. 2, pp. 112-129, 2002.
- [40] Y.-K. Chia, S. Sun, and R. Zhang, "Energy cooperation in cellular networks with renewable powered base stations," *IEEE Transactions on Wireless Communications*, vol. 13, no. 12, pp. 6996-7010, 2014.

- [41] Y. Chan, "China's Huawei to supply solar-powered base stations to Bangladesh," *Business Green*, London, UK, Aug, 2009.
- [42] C. Okoye, "Airtel base stations to be solar powered," *Daily Times Nigeria*, Lagos, Nigeria, Dec, 2011.
- [43] Fourche. Disponible en ligne : <https://www.forsk.com/atoll-wi-fi> (consulté le 22/08/2023).
- [44] "A Complete Wireless Network Planning & Optimisation Toolset for Mobile Operators ." <https://www.forsk.com/> (consulté le 22/08/2023).
- [45] T. S. Rappaport, *Wireless communications: Principles and practice*, 2/E. Pearson Education India, 2010.
- [46] J. S. Seybold, *Introduction to RF propagation*. John wiley & sons, 2005.
- [47] Gérez les points d'accès WiFi depuis le cloud." <https://success.tanaza.com/s/access-point-selector> (consulté le 22/08/2023).
- [48] A. B. Stambouli, "Algerian renewable energy assessment: The challenge of sustainability," *Energy Policy*, vol. 39, no. 8, pp. 4507-4519, 2011.
- [49] C. Cunliff. "Beyond the Energy Techlash: The Real Climate Impacts of Information Technology." <https://itif.org/publications/2020/07/06/beyond-energy-techlash-real-climate-impacts-information-technology/> (consulté le 22/08/2023).
- [50] "Algérie - Émission de CO2 (kt)." <https://knoema.fr/atlas/Alg%C3%A9rie/%C3%89mission-de-CO2-kt> (consulté le 22/08/2023).
- [51] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*. MIT press, 2016.
- [52] X. Glorot and Y. Bengio, "Understanding the difficulty of training deep feedforward neural networks," in *Proceedings of the thirteenth international conference on artificial intelligence and statistics, 2010: JMLR Workshop and Conference Proceedings*, pp. 249-256.
- [53] K. He, X. Zhang, S. Ren, and J. Sun, "Delving deep into rectifiers: Surpassing human-level performance on imagenet classification," in *Proceedings of the IEEE international conference on computer vision*, 2015, pp. 1026-1034.
- [54] S. Maheshkar. "A Gentle Introduction To Weight Initialization for Neural Networks." <https://wandb.ai/sauravmaheshkar/initialization/reports/A-Gentle-Introduction-To-Weight-Initialization-for-Neural-Networks--Vmlldzo2ODExMTg> (accessed 22/08, 2023).
- [55] R. T. Trevor Hastie, Jerome H. Friedman, Springer, Ed. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2009.
- [56] T. Dozat, "Incorporating nesterov momentum into adam. 2016," ed, 2016.
- [57] M. D. Zeiler, "Adadelta: an adaptive learning rate method," arXiv preprint arXiv:1212.5701, 2012.

- [58] S. Narayan, "The generalized sigmoid activation function: Competitive supervised learning," *Information sciences*, vol. 99, no. 1-2, pp. 69-82, 1997.
- [59] M. M. Lau and K. H. Lim, "Review of adaptive activation function in deep neural network," in *2018 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES)*, 2018: IEEE, pp. 686-690.
- [60] A. F. Agarap, "Deep learning using rectified linear units (relu)," *arXiv preprint arXiv:1803.08375*, 2018.
- [61] S. L. Smith, P.-J. Kindermans, C. Ying, and Q. V. Le, "Don't decay the learning rate, increase the batch size," *arXiv preprint arXiv:1711.00489*, 2017.
- [62] P. Baldi and P. J. Sadowski, "Understanding dropout," *Advances in neural information processing systems*, vol. 26, 2013.
- [63] H. Salehinejad, S. Sankar, J. Barfett, E. Colak, and S. Valaee, "Recent advances in recurrent neural networks," *arXiv preprint arXiv:1801.01078*, 2017.
- [64] Y. Yu, X. Si, C. Hu, and J. Zhang, "A review of recurrent neural networks: LSTM cells and network architectures," *Neural computation*, vol. 31, no. 7, pp. 1235-1270, 2019.
- [65] A. Botchkarev, "Performance metrics (error measures) in machine learning regression, forecasting and prognostics: Properties and typology," *arXiv preprint arXiv:1809.03006*, 2018.
- [66] K. Bagadi, T. Abrao, and F. Benedetto, "A Novel Machine Learning Approach for Intelligent Spectrum Management in Cognitive Radio Networks," *IEEE Networking Letters*, 2023.
- [67] Y.-C. Liang, *Dynamic spectrum management: from cognitive radio to blockchain and artificial intelligence*. Springer Nature, 2020.
- [68] Y. Zhang, C. Kang, T. Ma, Y. Teng, and D. Guo, "Power allocation in multi-cell networks using deep reinforcement learning," in *2018 IEEE 88th Vehicular Technology Conference (VTC-Fall)*, 2018: IEEE, pp. 1-6.
- [69] H. Si, Y. Wang, J. Yuan, and X. Shan, "Mobility prediction in cellular network using hidden markov model," in *2010 7th IEEE consumer communications and networking conference*, 2010: IEEE, pp. 1-5.
- [70] H. Gebrie, H. Farooq, and A. Imran, "What machine learning predictor performs best for mobility prediction in cellular networks?," in *2019 IEEE International Conference on Communications Workshops (ICC Workshops)*, 2019: IEEE, pp. 1-6.
- [71] M. Yan, S. Li, C. A. Chan, Y. Shen, and Y. Yu, "Mobility prediction using a weighted Markov model based on mobile user classification," *Sensors*, vol. 21, no. 5, p. 1740, 2021.
- [72] M. L. A. Morel, I. Saffar, K. D. Singh, and C. Viho, "Multi-task deep learning based environment and mobility detection for user behavior modeling," in *2019 International Symposium on Modeling and Optimization in Mobile, Ad Hoc, and Wireless Networks (WiOPT)*, 2019: IEEE, pp. 1-7.

- [73] M. S. Mollet et al., "A survey of machine learning applications to handover management in 5G and beyond," *IEEE Access*, vol. 9, pp. 45770-45802, 2021.
- [74] S. Eltanbouly, M. Bashendy, N. AlNaimi, Z. Chkirbene, and A. Erbad, "Machine learning techniques for network anomaly detection: A survey," in *2020 IEEE International Conference on Informatics, IoT, and Enabling Technologies (ICIoT)*, 2020: IEEE, pp. 156-162.
- [75] B. Riyaz and S. Ganapathy, "A deep learning approach for effective intrusion detection in wireless networks using CNN," *Soft Computing*, vol. 24, pp. 17265-17278, 2020.
- [76] Y. Saleem, K.-L. A. Yau, H. Mohamad, N. Ramli, M. H. Rehmani, and Q. Ni, "Clustering and reinforcement-learning-based routing for cognitive radio networks," *IEEE Wireless Communications*, vol. 24, no. 4, pp. 146-151, 2017.
- [77] N. Meghanathan, "Location prediction based routing protocol for mobile ad hoc networks," in *IEEE GLOBECOM 2008-2008 IEEE global telecommunications conference*, 2008: IEEE, pp. 1-5.
- [78] R. Dudukovich and C. Papachristou, "Delay tolerant network routing as a machine learning classification problem," in *2018 NASA/ESA Conference on Adaptive Hardware and Systems (AHS)*, 2018: IEEE, pp. 96-103.
- [79] W. Jiang, "Cellular traffic prediction with machine learning: A survey," *Expert Systems with Applications*, vol. 201, p. 117163, 2022.
- [80] C. Zhang, P. Patras, and H. Haddadi, "Deep learning in mobile and wireless networking: A survey," *IEEE Communications surveys & tutorials*, vol. 21, no. 3, pp. 2224-2287, 2019.
- [81] "Global Emissions. Center for Climate and Energy Solutions." <https://www.c2es.org/content/international-emissions> (consulté le 22/08/2023)
- [82] "Digitalisation and Energy." <https://www.iea.org/reports/digitalisation-and-energy> (consulté le 22/08/2023).
- [83] E. García-Martín, C. F. Rodrigues, G. Riley, and H. Grahn, "Estimation of energy consumption in machine learning," *Journal of Parallel and Distributed Computing*, vol. 134, pp. 75-88, 2019.
- [84] A. Lacoste, A. Luccioni, V. Schmidt, and T. Dandres, "Quantifying the carbon emissions of machine learning," *arXiv preprint arXiv:1910.09700*, 2019.
- [85] E. Strubell, A. Ganesh, and A. McCallum, "Energy and policy considerations for deep learning in NLP," *arXiv preprint arXiv:1906.02243*, 2019.
- [86] L. F. W. Anthony, B. Kanding, and R. Selvan, "Carbontracker: Tracking and predicting the carbon footprint of training deep learning models," *arXiv preprint arXiv:2007.03051*, 2020.
- [87] D. Stamoulis, E. Cai, D.-C. Juan, and D. Marculescu, "Hyperpower: Power-and memory-constrained hyper-parameter optimization for neural networks," in *2018 Design, Automation & Test in Europe Conference & Exhibition (DATE)*, 2018: IEEE, pp. 19-24.
- [88] A. Canziani, A. Paszke, and E. Culurciello, "An analysis of deep neural network models for practical applications," *arXiv preprint arXiv:1605.07678*, 2016.

- [89] C. F. Rodrigues, G. Riley, and M. Luján, "SyNERGY: An energy measurement and prediction framework for Convolutional Neural Networks on Jetson TX1," in Proceedings of the international conference on parallel and distributed processing techniques and applications (PDPTA), 2018: The Steering Committee of The World Congress in Computer Science, Computer ..., pp. 375-382.
- [90] T.-J. Yang, Y.-H. Chen, and V. Sze, "Designing energy-efficient convolutional neural networks using energy-aware pruning," in Proceedings of the IEEE conference on computer vision and pattern recognition, 2017, pp. 5687-5695.
- [91] A. E. Brownlee, J. Adair, S. O. Haraldsson, and J. Jabbo, "Exploring the accuracy–energy trade-off in machine learning," in 2021 IEEE/ACM International Workshop on Genetic Improvement (GI), 2021: IEEE, pp. 11-18.
- [92] X. Dai et al., "Chamnet: Towards efficient network design through platform-aware model adaptation," in Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019, pp. 11398-11407.
- [93] A. E. I. Brownlee, N. Burles, and J. Swan, "Search-based energy optimization of some ubiquitous algorithms," IEEE Transactions on Emerging Topics in Computational Intelligence, vol. 1, no. 3, pp. 188-201, 2017.
- [94] Predict Traffic of LTE Network. <https://kaggle.com/naebolo/predict-traffic-of-lte-network>. (consulté le 22/08/2023)
- [95] D. Borkin, A. Némethová, G. Michal'čonok, and K. Maiorov, "Impact of data normalization on classification model accuracy," Research Papers Faculty of Materials Science and Technology Slovak University of Technology, vol. 27, no. 45, pp. 79-84, 2019.
- [96] S. A. Khadem, F. Bensebaa, and N. Pelletier, "Optimized feed-forward neural networks to address CO2-equivalent emissions data gaps–Application to emissions prediction for unit processes of fuel life cycle inventories for Canadian provinces," Journal of Cleaner Production, vol. 332, p. 130053, 2022.
- [97] D. M. Belete and M. D. Huchaiah, "Grid search in hyperparameter optimization of machine learning models for prediction of HIV/AIDS test results," International Journal of Computers and Applications, vol. 44, no. 9, pp. 875-886, 2022.
- [98] "Pyrapl, PyPI." <https://pypi.org/project/pyRAPL/> (consulté le 22/08, 2023).

## **Contributions de la thèse**

**Article 1:** *Methodology for Quantitative Assessment of Greenhouse Gas Emissions Reduction of Solar-Powered Wi-Fi.* Samah Temim, Farid Bensebaa, Larbi Talbi, MPDI-Electronics, vol. 10, no 2829, pp. 1-16, Nov. 2021.

**Abstract:** in this paper, a modeling framework to quantify the reduction of potential greenhouse gas (GHG) emissions when using solar-powered Wi-Fi as an internet access point is developed and tested. This framework includes newly developed MATLAB code and the use of the ATOLL tool for energy consumption and network optimization, respectively. A practical case study is described with scenarios enabling different signal coverage on a university campus. These scenarios are based on technical requirements, including number of access points, budget link, and access duration. Four hundred tons of GHG can be reduced each year if solar Wi-Fi is deployed in solar campuses, which represents  $5.5 \times 10^{-5}$  percent of the total GHG produced by the telecommunications sector. A direct relationship between the number of access points and coverage signal quality on the one hand and energy consumption on the other hand is established. We use this case study to forecast the potential GHG mitigation if a wider deployment of the community Wi-Fi is achieved. This methodology could also be used to estimate GHG reductions when other wireless technologies are deployed.

**Article 2:** *Analysis and Multiobjective Optimization of a Machine Learning Algorithm for Wireless Telecommunication,* Samah Temim, Larbi Talbi, Farid Bensebaa, MDPI – Telecom, Vol. 4, Issue 2, pp. 219-235, April 2023.

**Abstract:** there has been a fast deployment of wireless networks in recent years, which has been accompanied by significant impacts on the environment. Among the solutions that have been proven to be effective in reducing the energy consumption of wireless networks is the use of machine learning algorithms in cell traffic management. However, despite promising results, it should be noted that the computations required by machine learning algorithms have increased at an exponential rate. Massive computing has a surprisingly large carbon footprint, which could affect its real-world deployment. Thus, additional attention needs to be paid to the design and parameterization of these algorithms applied in order to reduce the energy consumption of wireless networks. In this article, we analyze the impact of hyperparameters on the energy consumption and performance of machine learning algorithms used for cell traffic prediction. For each hyperparameter (number of layers, number of neurons per layer, optimizer algorithm, batch size, and dropout) we identified a set of feasible values. Then, for each combination of hyperparameters, we trained our model and analyzed energy consumption and the resulting performance. The results from this study reveal a great correlation between hyperparameters and energy consumption, confirming the paramount importance of selecting optimal hyperparameters. A trade-off between the minimization of energy consumption and the maximization of machine learning performance is suggested.

Cet article a été sélectionné pour figurer en couverture du journal Telecom de MDPI, Telecom, Vol. 4, Numéro 2, pp. 219-235, juin 2023. Cette distinction témoigne de la qualité et de la portée de notre recherche dans le domaine des télécommunications sans fil où l'impact de l'apprentissage automatique sur la consommation énergétique est significatif.