

Optimisation d'un réseau ad hoc de véhicules aériens sans
pilote (UAV) dans un environnement urbain:
Positionnement des UAV à l'aide de l'apprentissage
automatique

par

Assohoun Jean Honorat KOFFI

MÉMOIRE PRÉSENTÉ À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
COMME EXIGENCE PARTIELLE À L'OBTENTION DE LA MAÎTRISE
AVEC MÉMOIRE EN GÉNIE CONCENTRATION :
RÉSEAUX DE TÉLÉCOMMUNICATIONS
M. Sc. A.

MONTRÉAL, LE 22 FÉVRIER 2021

ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
UNIVERSITÉ DU QUÉBEC



Assohoun Jean Honorat KOFFI, 2021



Cette licence [Creative Commons](https://creativecommons.org/licenses/by-nc-nd/4.0/) signifie qu'il est permis de diffuser, d'imprimer ou de sauvegarder sur un autre support une partie ou la totalité de cette œuvre à condition de mentionner l'auteur, que ces utilisations soient faites à des fins non commerciales et que le contenu de l'œuvre n'ait pas été modifié.

PRÉSENTATION DU JURY

CE MÉMOIRE A ÉTÉ ÉVALUÉ

PAR UN JURY COMPOSÉ DE :

M. Michel Kadoch, directeur de mémoire
Département de génie électrique à l'École de technologie supérieure

M. Pierre-Jean Lagacé, président du jury
Département de génie électrique à l'École de technologie supérieure

M. Pascal Giard, membre du jury
Département de génie électrique à l'École de technologie supérieure

IL A FAIT L'OBJET D'UNE SOUTENANCE DEVANT JURY ET PUBLIC

LE 12 FÉVRIER 2021

À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

REMERCIEMENTS

Au terme de ce mémoire, je voudrais du fond du cœur adresser mes remerciements les plus sincères et ma profonde reconnaissance à tous ceux qui, de loin ou de près, ont contribué à la réalisation de mon projet de recherche dans de meilleures conditions.

Je tiens tout d'abord à exprimer toute ma reconnaissance à mon Directeur de recherche, M. Michel Kadoch, pour son soutien, ses encouragements, ses idées et conseils qui ont été très appréciés, m'orientant ainsi tout au long de cette recherche.

Je tiens également à remercier M. Pierre-Jean Lagacé, Président de jury et Professeur au Département de génie électrique à l'École de Technologie Supérieure et M. Pascal Giard, pour avoir accepté d'être membres du jury.

Je suis très reconnaissant envers mes parents, Vanga Koffi et Agnès Koffi ainsi que mes frères et sœurs Verha, Parfait, Junior et Bénédicte pour ce qu'ils ont été pour moi et pour tout ce qu'ils ont fait pour moi, surtout pour leur confiance sans faille en moi. Je voudrais remercier spécialement ma chère petite amie Victoire pour sa présence et son soutien. Merci à la famille au Canada et en Côte d'Ivoire. Je ne trouve tout simplement pas assez de mots pour exprimer ma gratitude et mon amour pour vous.

Enfin j'adresse mes sincères remerciements à tous les professeurs, intervenants et toutes les personnes qui par leurs paroles, leurs écrits, leurs conseils et leurs critiques ont guidé mes réflexions, me permettant de répondre aux questions qui ont contribué à l'élaboration de ce projet.

**Optimisation d'un réseau ad hoc de véhicules aériens sans pilote (UAV) dans un environnement urbain:
Positionnement des UAV à l'aide de l'apprentissage automatique**

Assohoun Jean Honorat KOFFI

RÉSUMÉ

L'apparition récente mais remarquable des véhicules aériens sans pilote (UAV) qui occuperont bientôt la majeure partie de nos systèmes de service constitue la clé de l'expansion des nouvelles technologies de communication et des réseaux sans fil. Ces engins peuvent en effet servir de stations de base volantes permettant d'étendre et/ou d'améliorer la couverture du système de communication mobile terrestre afin de répondre efficacement à la demande de trafic toujours croissante. Cependant, déterminer les meilleures positions pour ces véhicules lors de leur déploiement demeure un réel et grand défi à relever afin d'obtenir d'eux des résultats satisfaisants.

Dans cette étude nous proposons un nouveau schéma de déploiement 3D d'un réseau multi-UAV dans une zone couverte par une station de base (BS) encombrée ou endommagée, intégrant l'apprentissage automatique en vue de maximiser le nombre d'utilisateurs desservis tout en maximisant les bénéfices de l'opérateur.

Premièrement nous proposons un algorithme permettant de déterminer le nombre optimal d'UAV à déployer pour desservir tous les utilisateurs en tenant compte de leurs exigences de service variées. Par la suite nous déterminons les emplacements optimaux de ces véhicules aériens à l'aide d'un algorithme de partitionnement et de positionnement qui intègre les auto-encodeurs afin d'optimiser les emplacements, avant de trouver leur altitude.

La simulation de notre algorithme est réalisée sous MATLAB. Les résultats numériques montrent que notre approche, Deep K-means, proposé peut servir un très grand pourcentage d'utilisateurs en fonction du nombre d'UAV utilisés tout en maximisant le profit de l'opérateur.

Mots-clés : UAV, véhicule aérien sans pilote, réseau multi-UAV, BS, station de base, apprentissage automatique, auto-encodeur, K-Means.

**Optimizing an Ad-Hoc Unmanned Aerial Vehicle (UAV) network in an urban environment:
Positioning UAVs using machine learning**

Assohoun Jean Honorat KOFFI

ABSTRACT

The recent but remarkable emergence of unmanned aerial vehicles (UAVs), which will soon occupy most of our service systems, is key to the expansion of new communication technologies and wireless networks. These machines can be used as flying base stations to extend and/or improve the coverage of the land mobile communication system in order to respond effectively to the ever-increasing demand for traffic. However, determining the best positions for these vehicles during their deployment remains a real and major challenge to achieve satisfactory results from them.

In this study we aim to propose a new 3D deployment scheme of a multi-UAVs network in an area covered by a cluttered or damaged base station (BS), integrating machine learning to maximize the number of users served while maximizing operator benefits.

First, we propose an algorithm to determine the optimal number of UAVs to be deployed to serve all users, considering their varied service requirements. We then determine the optimal locations of these aerial vehicles using a partitioning and positioning algorithm that integrates the auto-encoders to optimize the locations, before finding their altitude.

The simulation of our algorithm is performed under MATLAB. The numerical results show that our proposed Deep K-means approach can serve a very large percentage of users based on the number of UAVs used while maximizing operator profit.

Keywords: UAV, unmanned aerial vehicle, multi-UAV network, BS, base station, machine learning, auto-encoder, K-Means.

TABLE DES MATIÈRES

	Page
INTRODUCTION	1
CHAPITRE 1 REVUE DE LITTÉRATURE.....	5
1.1 Introduction.....	5
1.2 Généralités sur les drones	5
1.2.1 Court rappel historique	5
1.2.2 Évolution des drones.....	7
1.2.3 Quelques perspectives d'utilisation : Applications et services	10
1.3 FANET ou Réseaux ad hoc de Drones	12
1.3.1 Définitions et caractéristiques des réseaux ad hoc multi-drones	12
1.3.2 Protocoles de routage dans les FANET	15
1.3.3 Problèmes dans le processus de communication dans les FANET.....	16
1.4 Enjeux des réseaux ad hoc de drones.....	17
1.5 L'apprentissage automatique dans les FANET.....	18
1.5.1 Généralités sur l'apprentissage automatique	18
1.5.2 Importance de l'apprentissage automatique dans les réseaux multi-UAV	20
1.6 Travaux connexes	21
CHAPITRE 2 MOTIVATIONS, MATÉRIELS ET MÉTHODOLOGIES	25
2.1 Problématique	25
2.2 Objectifs de recherche.....	26
2.3 Méthodologie de recherche et outils	27
CHAPITRE 3 MODÈLE DE SYSTÈME ET FORMULATION DU PROBLÈME	33
3.1 Modèle de canal air-sol.....	34
3.1.1 Le modèle de perte de trajet air-sol.....	34
3.1.2 Le modèle de la probabilité de la ligne de visée.....	36
3.2 Formulation du problème d'optimisation	39
CHAPITRE 4 MÉTHODES D'APPRENTISSAGE AUTOMATIQUE POUR LE POSITIONNEMENT 3D DYNAMIQUE DES UAV	43
4.1 Nombre préliminaire des UAV	43
4.2 Détermination des emplacements 2D des UAV	45
4.2.1 Emplacements 2D envisageables des UAV grâce au k-means standard ..	47
4.2.2 Emplacements 2D des UAV grâce au Deep K-means.....	48
4.2.2.1.1 Réseau d'auto-encodeur à une couche.....	49
4.2.2.1.2 Partitionnement et positionnement basé sur l'auto-encodeur	50
4.3 Analyse d'une offre supplémentaire d'UAV	51
4.4 Recherche de l'altitude pour la couverture optimale.....	52
CHAPITRE 5 RÉSULTATS DES SIMULATIONS ET ANALYSES	55
5.1 Paramètres de simulation	55

5.2	Résultats et analyses	56
5.2.1	Détermination du nombre préliminaire des UAV.....	56
5.2.1.1	Nombre des UAV sans les exigences de service des utilisateurs	57
5.2.1.2	Nombre des UAV en tenant compte des exigences de service utilisateurs.....	59
5.2.2	Optimisation de la fonction de reconstruction.....	60
5.2.3	Positionnement dynamique des UAV à l'aide du Deep K-means	62
5.2.4	Efficacité du Deep K-Means par rapport au K-Means traditionnel.....	65
5.3	Conclusion	67
	CONCLUSION.....	69
	RECOMMANDATIONS	71
	LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES.....	73

LISTE DES TABLEAUX

	Page
Tableau 5.1	Paramètre de simulation.....56
Tableau 5.2	Nombre d'UAV selon le nombre d'utilisateurs sans exigences de service 57

LISTE DES FIGURES

		Page
Figure 1.1	Avion automatique Hewitt-Sperry en 1918	6
Figure 1.2	Unmanned US Navy Grumman F6F – 5K Hellcat drone 1946 © US Navy Naval Aviation News January 1981	7
Figure 1.3	General Atomics MQ-1 Predator 1994.....	8
Figure 1.4	DJI Phantom 4 Pro V2.0.....	9
Figure 1.5	Jual JJRC H8 Mini Drone Eachine H8 Mini Drone RTF RC Quadcopter 2,4Ghz.....	9
Figure 1.6	Sauvetage en mer avec un drone.....	11
Figure 1.7	Drone pulvérisateur agricole 6L – JT6L-606.....	12
Figure 1.8	Architecture de réseau ad hoc d'UAV multicouche.....	14
Figure 1.9	A swarm of drones	14
Figure 1.10	Taxonomie des protocoles de routage pour les réseaux UAV	16
Figure 1.11	Machine Learning, un sous domaine de l'intelligence Artificielle	19
Figure 1.12	Approches du Machine Learning.....	20
Figure 2.1	Neural Network Modelling.....	30
Figure 3.1	Propagation radio des plates-formes basse altitude en milieu urbain	35
Figure 3.2	Pathloss par rapport à la distance entre le drone et un recepteur au sol.....	38
Figure 4.1	Autoencoders Modelling.....	46
Figure 5.1	Profit total potentiel par rapport au nombre d'UAV et d'utilisateurs sans exigences de service.....	58
Figure 5.2	Profit total potentiel par rapport au nombre d'UAV et d'utilisateurs avec les exigences de service	59
Figure 5.3	Influence des itérations sur la fonction de reconstruction	61
Figure 5.4	Positionnement dynamique des UAV avec Deep K-Means à l'itération 1 63	

Figure 5.5	Positionnement dynamique final des UAV avec Deep K-Means.....	64
Figure 5.6	Efficacité de service du Deep K-Means par rapport au K-Means traditionnel	66

LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

BS	Base Station
UAV	Unmanned Aerial Vehicle
FANET	Flying Ad-hoc Network
LoS	Line-Of-Sight
NLoS	Non-Line-Of-Sight
PL	Path Loss
MANET	Mobile ad hoc network
VANET	Vehicular Ad-Hoc Network
ML	Machine Learning
IA	Intelligence Artificielle
FSPL	Free Space PathLoss
UIT	Union internationale des télécommunications
DNN	Deep Neural Network
CL _{<i>j</i>}	Cluster <i>j</i>
SGD	Stochastic Gradient Descent

LISTE DES SYMBOLES ET UNITÉS DE MESURE

dB	Décibel
GHz	Gigahertz
MHz	Mégahertz
km	Kilomètre
δ_{ij}	Variable binaire
RB^{max}	Capacité maximale en ressources d'UAV
x_i	Position d'utilisateur suivant l'axe x
y_i	Position d'utilisateur suivant l'axe y
X_j	Position de l'UAV suivant l'axe X
Y_j	Position de l'UAV suivant l'axe Y
H_j	Position de l'UAV suivant l'axe Z
η^{LoS}	Perte de chemin excessive pour LoS
η^{NLoS}	Perte de chemin excessive pour NLoS
d_{ij}	Distance entre l'utilisateur i et le drone j
f_c	Fréquence de la lumière
c	Vitesse de la lumière
a et b	Constantes basées sur l'environnement système
α_i	Expression des exigences de service de l'utilisateur i
R_j	Rayon de couverture de l'UAV j
P_{ij}	Puissance d'émission de l'UAV j
C^{UAV}	Le coût de service de l'UAV j

XX

C^{power}	Le coût d'une unité de puissance
P	Profit total de l'opérateur
C	Coût de service payé par l'opérateur
G	Gain total de l'opérateur
\hat{N}_D	Estimation du nombre total d'UAV
N_{Dmin}	Limite inférieure du nombre total d'UAV
$[\cdot]$	Désigne la fonction partie entière
N_U	Nombre total d'utilisateurs
u_i	Utilisateur i
$N_U^{non-servi}$	Utilisateurs non servis
$P_{service}$	Prix de service de l'utilisateur
P_j^{max}	Puissance d'émission maximale des drones
$f(x)$	Fonction de reconstruction de l'auto-encodeur
h	Valeur centrale, appelée le code de l'auto-encodeur
N_U^{servi}	Nombre d'utilisateurs couvert
H_j^D	Altitude de l'UAV j
c_j^{t-1}	Ensemble des échantillons appartenant au cluster j après (t-1) itération
$f^t(x_i)$	Fonction de mappage non linéaire à l'itération t

λ	Constante de pesée
θ_{ij}	Angle d'élévation entre l'utilisateur i et le drone j

INTRODUCTION

Les véhicules aériens sans pilote (UAV) ont récemment suscité un intérêt considérable dans le domaine de la recherche et du commerce. D'une utilisation restreinte aux activités militaires, aujourd'hui ces supers engins s'apprêtent à voler dans le ciel au-dessus de nos têtes pour réaliser des tâches jamais imaginées il y a juste quelques années.

Les UAV ont été progressivement adoptés par le public pour être utilisés dans plusieurs domaines d'activité. En fait, déjà plusieurs industries (automobile, médicale, manufacturière, spatiale, commerce, etc.) exigent l'utilisation des drones. La particularité de leur intérêt vient du fait de leur capacité énorme à s'adapter à des environnements dynamiques et à réaliser différents types de tâches dans différents domaines avec de bonnes performances. C'est ainsi que dans le domaine des réseaux et de la télécommunication les chercheurs se sont aperçus de l'opportunité extraordinaire d'améliorer les services offerts de plusieurs manières et même d'en créer d'autres. En effet les infrastructures des réseaux mobiles classiques sont généralement fixées et sont en fait conçues en fonction du flux du trafic selon des prévisions à long terme dans la zone de service qui est basée sur les données de trafic historiques collectées par les fournisseurs de services. En conséquence, ces réseaux sont incapables de servir efficacement lors d'événements imprévus comme une catastrophe naturelle ou un trafic encombré, créant alors une demande de trafic difficile à prévoir. Il appert que des supports supplémentaires et plus efficaces sont nécessaires pour obtenir des connexions sans fil omniprésentes dans le cas de ce type d'événements inattendus (Sun, Wang & S. Wang, 2018).

Des stations de base ou base stations (BS) peuvent être montées sur des véhicules aériens sans pilote (UAV-BS). Ces UAV peuvent aider le réseau cellulaire terrestre dans une variété de scénarios. Par exemple, en cas de défaillance des BS terrestres, les UAV-BS peuvent être rapidement déployés pour répondre à la demande soudaine de services sans fil (Alzenad, El-Keyi, Lagum & Yanikomeroglu, 2017). Ils peuvent être aussi utiles pour étendre un réseau ou même encore déployer le réseau dans une zone retirée non couverte. Ainsi plusieurs possibilités d'utilisation sont à noter et plusieurs aspects de cette technologie à prendre en

considération. Cependant dans la pratique, ce système présente de nombreux défis à relever avant de profiter pleinement de ces avantages. L'un des plus importants et qui fait l'objet de cette étude est le positionnement des UAV dans le réseau lors de leur déploiement afin de mener avec efficacité une mission donnée. En effet dû à leur grande mobilité et leur mouvement souvent très imprévisible, les UAV peuvent entraîner et même multiplier les points de collision imprévisibles à cause d'un manque de contrôle sur leur localisation causant une instabilité dans le réseau, ce qui peut créer des interruptions de communication causant ainsi des pertes de données. En plus du risque de perdre des données souvent même sensibles, le non-contrôle de la position des différents UAV dans le réseau peut occasionner des pertes chez l'opérateur, des retards de communication, etc. Tout cela met en évidence l'importance de s'assurer d'une organisation optimale de ce type de réseau lors de son déploiement.

Notre étude tente de relever ce défi en passant par plusieurs étapes. Dans cette étude nous visons à mettre en place, grâce à des techniques de l'apprentissage automatique, un système de déploiement 3D d'un réseau d'UAV qui permet de maximiser le nombre d'utilisateurs desservis tout en maximisant les gains de l'opérateur. Notre système vise à assurer une meilleure organisation des UAV dans la zone de mission en optimisant leur position au sein du réseau. L'apport de notre étude repose sur un système qui prend en compte différentes densités d'utilisateurs ayant des exigences de service variées.

Pour atteindre nos objectifs de recherche, dans le chapitre 1, nous allons survoler les contours du sujet afin de se placer dans le contexte de notre étude en définissant les différents termes, les avantages et enjeux du système, les principaux problèmes rencontrés ainsi que quelques travaux déjà réalisés et liés à notre étude.

Dans le chapitre 2 nous allons exposer plus en détail les motivations de ce travail de recherche en présentant les grandes lignes de notre démarche pour atteindre les objectifs fixés.

Par la suite dans le chapitre 3 nous allons formuler notre problème et donner des éléments de résolution qui vont nous servir de guide.

La partie suivante, le chapitre 4, va présenter dans les détails notre solution proposée. Elle adoptera une méthodologie qui présentera le travail en quatre grandes étapes afin de faciliter la compréhension de chaque partie.

Enfin le chapitre 5 présente les résultats de simulation ainsi que les analyses avant de conclure cette étude et proposer des recommandations pour des projets futurs.

CHAPITRE 1

REVUE DE LITTÉRATURE

1.1 Introduction

Ce chapitre explore et définit les contours de notre sujet afin de mettre en évidence les éléments nécessaires à sa compréhension et à son élaboration. Dans un premier temps nous allons introduire les drones de façon générale en montrant leur évolution et les différents aspects de leur utilisation. Ensuite nous allons définir les Flying Ad-Hoc Networks (FANET) et mettre en relief les éléments qui les caractérisent et les rendent uniques en leur genre.

Par la suite nous montrerons en quoi l'apprentissage automatique se révèle comme un facteur important dans l'amélioration ou l'optimisation des FANET avant de présenter enfin des études déjà réalisées dans ce domaine et liées à notre sujet en vue de faire ressortir les motivations de notre travail.

1.2 Généralités sur les drones

1.2.1 Court rappel historique

Les UAV (Unmanned Aerial Vehicle) communément appelés drones en français, sont des aéronefs sans pilote à bord dont le pilotage est automatique ou télécommandé, à usage civil ou au profit des forces armées ou de sécurité. En fonction des capacités recherchées, leur masse varie de quelques grammes à plusieurs tonnes, et leur autonomie peut atteindre jusqu'à plusieurs dizaines d'heures. Déjà au début des années 1920, les premiers engins sans pilote à bord ont été construits et ont volé pour des tests et des missions. Trois décennies plus tard, à l'occasion du conflit coréen et de la guerre du Vietnam dans les années 50, des drones ont été développés par les États-Unis pour réaliser diverses missions allant de la surveillance et de la collecte de renseignements à l'intervention militaire en terrain ennemi (David & Panhaleux, 2015).

Réalisant efficacement les missions qui leur étaient confiées, ces machines ont vite connu un véritable succès. Au fil du temps, connaissant des améliorations et bénéficiant des progrès technologiques réalisés dans les secteurs de l'aéronautique, de la robotique, de l'optronique, de la miniaturisation ou encore de l'informatique et de la transmission de données, ces engins sont devenus de plus en plus fiables et performants, de plus en plus petits et de moins en moins chers. Au cours des dernières années, ceci a permis l'arrivée sur le marché de drones de petite taille (jusqu'à une trentaine de kilogrammes) qui ont favorisé le développement de nombreuses applications et la réalisation de nombreux services que l'on n'imaginait pas il y a seulement une dizaine d'années.

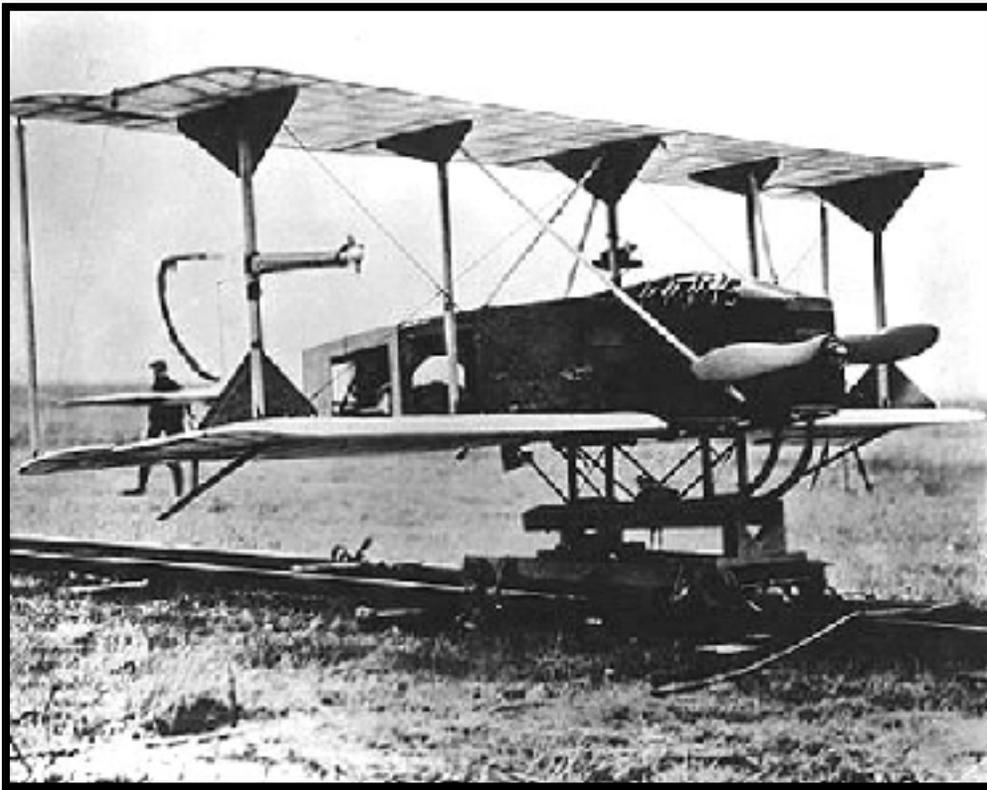


Figure 1.1 Avion automatique Hewitt-Sperry en 1918
Tirée de Studiofly Audiovisuel (2018)
(Consulté au mois de Juin 2020)

1.2.2 Évolution des drones

Les drones étaient des engins qui à la base ne comprenaient que des capteurs, calculateurs et quelques dispositifs leur permettant d'assurer leur vol pour effectuer essentiellement des missions militaires dangereuses où la présence d'un être humain semblait trop risquée ont très vite changé d'aspect. En effet jusqu'aux années 1980, les drones ont été améliorés pour être utilisés par les services de renseignements et d'espionnages, par exemple pour effectuer des missions de reconnaissance en effectuant des prises de vues aériennes.

Ce n'est que dans les années 2000 que les UAV font leur entrée véritable dans le secteur civil. En effet, le progrès technologique et la miniaturisation des systèmes informatiques, les caméras et les batteries dotant ces machines de capacités énormes ont permis de rendre les drones accessibles à plusieurs secteurs d'activités.

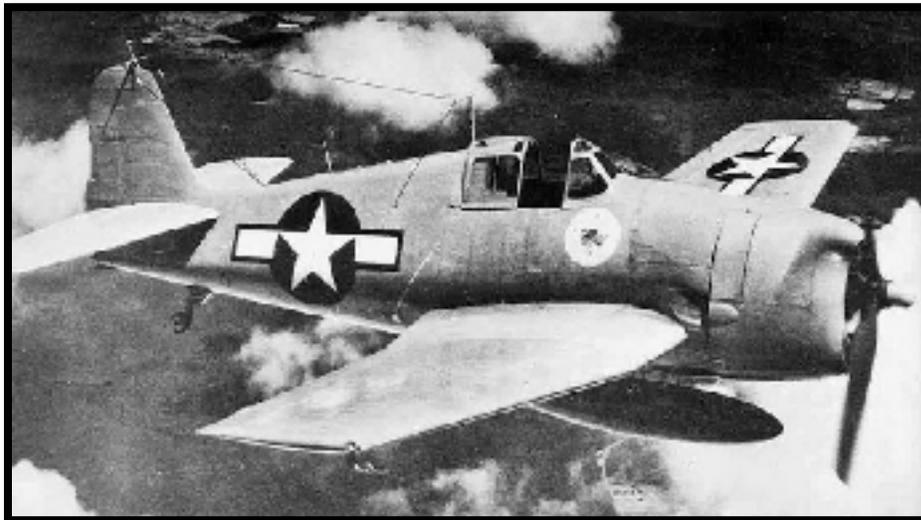


Figure 1.2 Unmanned US Navy Grumman F6F – 5K Hellcat drone 1946 © US Navy Naval Aviation News January 1981
Tirée de Studiofly Audiovisuel (2018)
(Consulté au mois de Juin 2020)



Figure 1.3 General Atomics MQ-1 Predator 1994
Tirée de General Atomics MQ-1 Predator (2020)
(Consulté au mois de Juin 2020)

Les drones modernes peuvent avoir différentes tailles, différents types d'accessoires et de dispositifs afin de leur permettre de réaliser différents types de missions. Dans notre étude, nous nous intéresserons principalement aux mini-drones. « Un mini-drone est équipé d'un ensemble de systèmes micro-électromécaniques qui inclue des microprocesseurs, des adaptateurs radio sans fil et des charges utiles généralement limitées en poids et en taille (car le volume disponible à bord de l'habitacle d'un drone est souvent restreint) » (Maxa, 2017). Cette contrainte peut être un obstacle à la réalisation des missions de longue durée (par exemple, une surveillance aérienne à la suite d'une catastrophe naturelle sur une vaste zone, ou un relais d'une station de base endommagée).



Figure 1.4 DJI Phantom 4 Pro V2.0.
Tirée du site dji.com/ca-fr (2020)
(Consulté au mois de Juin 2020)



Figure 1.5 Jual JJRC H8 Mini Drone Eachine H8 Mini Drone RTF RC Quadcopter 2,4Ghz
Tirée du site tokopedia.com (2020)
(Consulté au mois de Juin 2020)

De ce fait, un moyen alternatif pour contourner cette faille d'autonomie et/ou de performance est le déploiement d'un système multi-drones permettant la mise en œuvre d'un réseau de communication coopératif entre les drones. Un tel système serait capable de réaliser plus efficacement ce qu'un seul drone ne pourrait réaliser ou le ferait difficilement.

1.2.3 Quelques perspectives d'utilisation : Applications et services

La migration très récente et en même temps considérable dans le secteur civil de ces aéronefs sans pilote (drones) leur a permis de très vite conquérir le marché et de se faire une place dans plusieurs secteurs d'activité. Désormais les drones peuvent être utilisés pour réaliser des missions tant militaires que civiles de nature très variée comme, par exemple, la réalisation de prises de vues aériennes, la surveillance d'ouvrages d'art ou d'infrastructures linéaires ou encore d'exploitations agricoles pour en optimiser la gestion, la recherche et le sauvetage, la surveillance des incendies de forêt, la sécurité intérieure, l'estimation du vent, la télédétection, la surveillance du trafic, les livraisons de colis, etc. De façon générale les domaines d'applications et services assistés par drone sont classés en trois domaines : le relais de données, la surveillance et la collecte de données, et la livraison de produits (Vashist & Jain, 2019).

L'utilisation des drones peut être multiple et concerner diverses fonctions. Par exemple, en juin 2017, deux randonneurs ont été portés disparus dans la forêt nationale de Pike au Colorado. Grâce à une équipe utilisant un drone, les randonneurs ont été retrouvés et sauvés alors que plus de vingt-cinq autres volontaires organisés en équipe menaient aussi la recherche (Dukowitz, 2019).

De même par exemple le HELPER, un drone destiné à aider aux procédures de sauvetage en mer est homologué par la DGAC (Direction Générale de l'Aviation Civile) et permet de déposer une bouée auto gonflable à proximité d'une personne en difficulté. Ce drone, grâce à sa vidéo haute qualité, offre une reconnaissance et un contrôle distant de l'état de la victime.

Après plusieurs essais dans la mise en place d'un système automatisé et autonome, Amazon a finalement réussi à livrer de petits paquets à des clients à l'aide de drones. De même, diverses autres entreprises, comme DHL et Dominos, testent également les livraisons de produits à l'aide d'UAV pour réduire les coûts de transport et les temps d'attente (Vashist & Jain, 2019).

Au Maryland des chercheurs de l'Université du Maryland fixent une glacière contenant un rein à un drone DJI M600 Pro en vue d'un vol d'essai. Le rein a volé à des milliers de mètres par le drone sans subir de dommages (Hampson, 2018).

Aujourd'hui des travaux sont menés pour intégrer les UAV dans le contexte des villes intelligentes dont l'objectif ultime est de mieux utiliser les ressources publiques, d'améliorer la qualité des services offerts aux citoyens et de réduire les coûts de fonctionnement des administrations publiques (Qi, Zhu, Mang, Kadoch & Li, 2019).



Figure 1.6 Sauvetage en mer avec un drone
Tirée du site 1001crash.com (Août 2016)
(Consulté au mois de Juin 2020)



Figure 1.7 Drone pulvérisateur agricole 6L – JT6L-606
Tirée du site helsel.eu (2020)
(Consulté au mois de Juin 2020)

Ces quelques exemples démontrent la polyvalence et les capacités des UAV à se rendre utiles pour divers types de services.

1.3 FANET ou Réseaux ad hoc de Drones

1.3.1 Définitions et caractéristiques des réseaux ad hoc multi-drones

Les véhicules aériens sans pilote (UAV) ont gagné en popularité pour divers services et applications dans différents domaines d'activité. Cependant au lieu d'effectuer en mode solitaire les missions, les UAV peuvent être interconnectés entre eux permettant la mise en œuvre d'un réseau de communication coopératif plus efficace pour réaliser les missions. Cette coopération est rendue possible grâce à un algorithme de coordination fiable, qui échange en continu des données de signalisation. Plusieurs types d'architectures de communication peuvent être envisagés pour établir la communication dans un système multi-drones dont celle des réseaux ad hoc mobiles qui est bien adaptée à la gestion d'un ensemble de drones.

Ce système connu sous le nom de FANET ou Flying Ad-hoc Network est un type de réseau sans fil décentralisé ne reposant pas sur une infrastructure préexistante, comme les routeurs dans les réseaux câblés ou des points d'accès dans les réseaux sans fil. Au lieu de cela, chaque nœud, à savoir l'UAV, participe au routage en transférant les données pour d'autres nœuds, de sorte que la détermination des nœuds qui transmettent les données soit effectuée de manière dynamique sur la base de la connectivité réseau et de l'algorithme de routage utilisé (Wireless ad hoc network, 2020). Les FANET peuvent être considérés comme un sous-ensemble du concept bien connu des réseaux ad hoc mobiles MANET ou Mobile Ad-Hoc Networks qui regroupe plusieurs types dont les VANET ou Vehicular Ad-Hoc Network et bien d'autres.

Dans cette grande famille de ce type de réseau, les FANET se distinguent des autres à cause des particularités et des caractéristiques qui leur sont uniques dont l'une des plus distinctives est la fréquence et la rapidité des fluctuations topologiques dues à la grande mobilité des nœuds, les UAV.

Il existe différentes architectures de ce type de réseau multi-UAV. Les figures 1.8 et 1.9 ci-dessous montrent deux architectures de réseaux ad hoc de drones. Les architectures peuvent varier selon le système de contrôle ou de base au sol avec lequel les drones communiquent pendant leur vol.

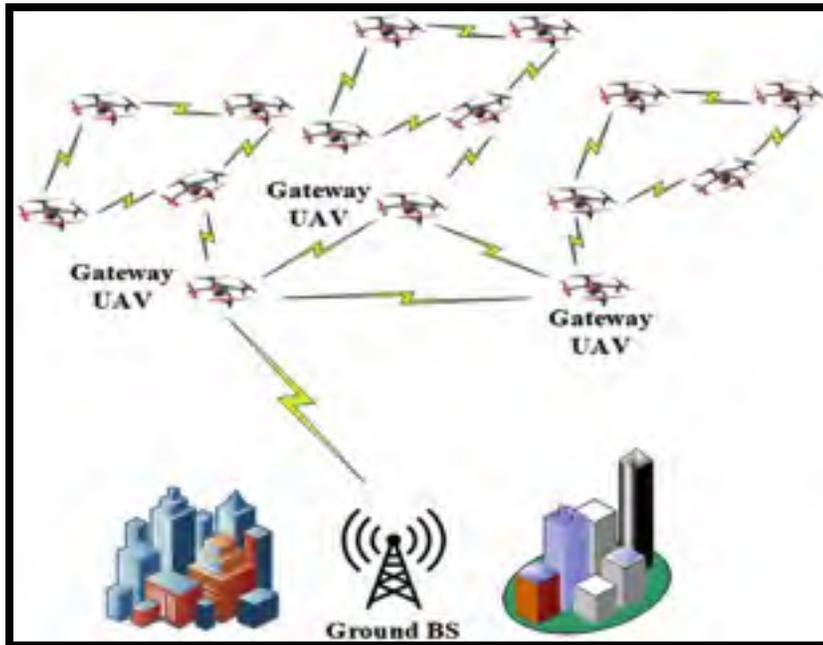


Figure 1.8 Architecture de réseau ad hoc d'UAV multicouche
Tirée de Fadi Al-Turjman & Hadi (2020, p.10)



Figure 1.9 A swarm of drones
Tirée de ynetnews.com (2019)
(Consulté au mois de Juillet 2020)

1.3.2 Protocoles de routage dans les FANET

Dans les réseaux ad hoc multi-drones, la communication entre les différents nœuds du réseau est assurée par des algorithmes et protocoles de communication et de routage. Lors de la conception pour le routage, certaines techniques sont à prendre en compte selon le besoin telles que le **programme de livraison** (routage unicast, broadcast, multicast et géocast), le **routage coopératif** (les nœuds s'entraident pour la transmission d'informations en exploitant le schéma de diffusion), la **découverte du chemin** (utilisé lorsque la position géographique du nœud de destination cible est connue du nœud source), le **chemin unique, les chemins multiples, le routage basé sur le quorum** (utilisé pour développer un service de localisation), le **routage basé sur une grille** (la zone de réseau est divisée en hiérarchies de carrés), le **stockage reporté et expédié** (utilisée lorsqu'une défaillance du réseau provoque une déconnexion du nœud relais suivant) et la **prédiction** (Arafat & Moh, 2019).

Ainsi plusieurs protocoles de routage ont été proposés pour les réseaux d'UAV à travers plusieurs travaux précédents réalisés. Les protocoles de routage UAV sont classés en deux sections différentes: **les protocoles de routage basés sur l'architecture de réseau et sur le transfert de données**. Lesquels sont subdivisées en protocoles de routage basés sur la topologie, la position, la hiérarchie, les déterministes, les stochastiques et les réseaux sociaux comme le montre la figure suivante.

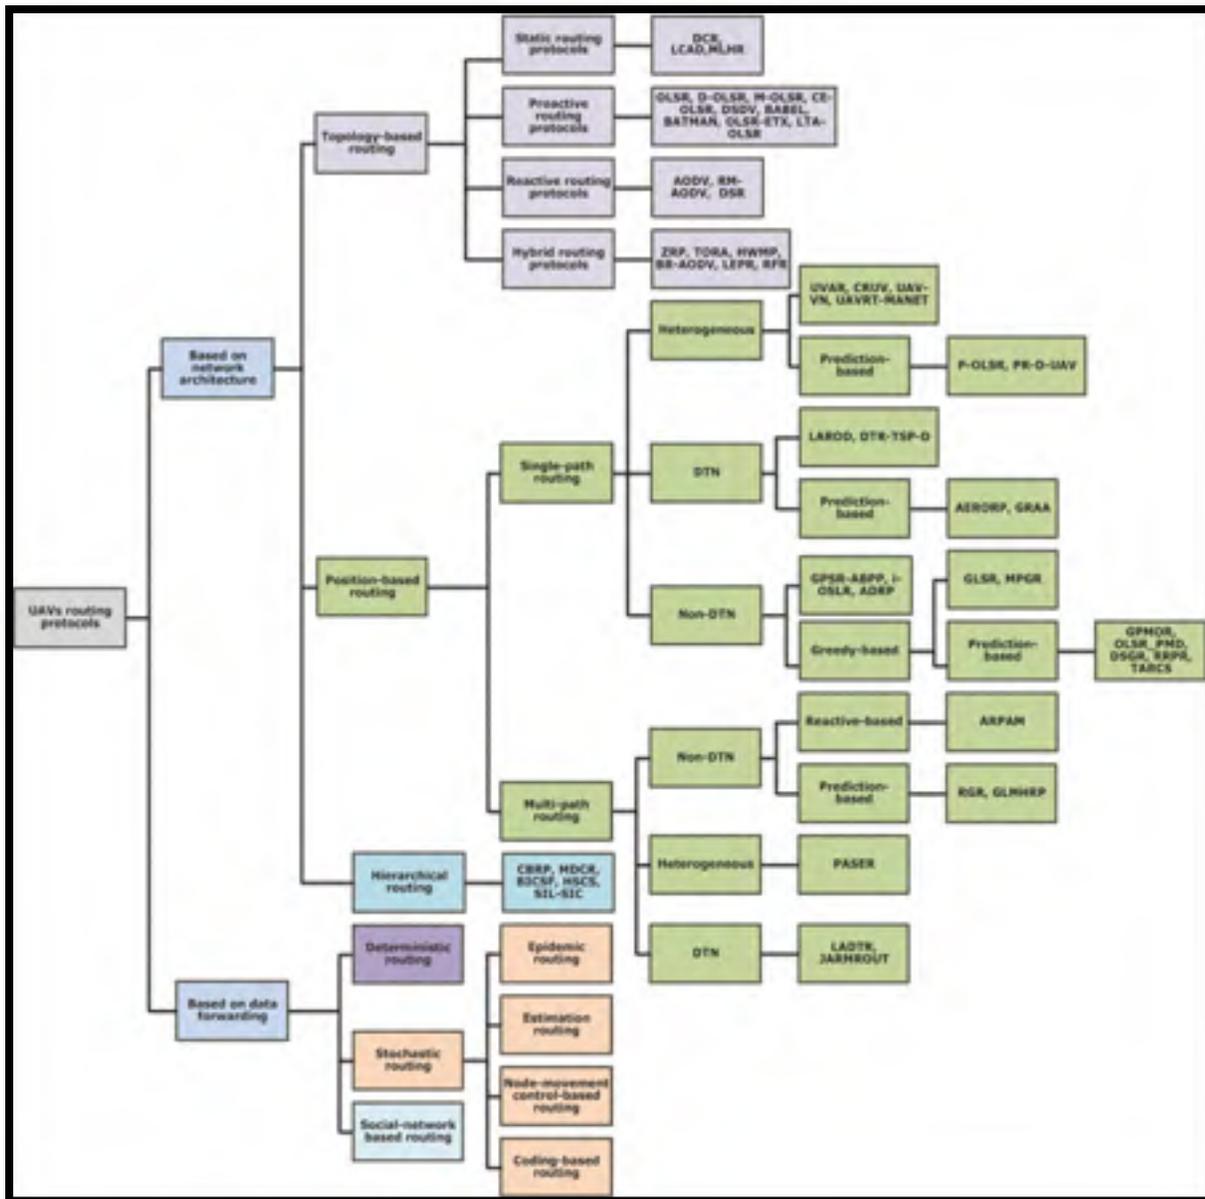


Figure 1.10 Taxonomie des protocoles de routage pour les réseaux UAV
Tirée de Arafat & Moh (2019, p.9)

1.3.3 Problèmes dans le processus de communication dans les FANET

Le comportement dynamique des FANET dû à la grande mobilité des UAV et leur mouvement imprévisible provoquent des changements constants de topologie et des distributions inégales d'UAV dans le réseau. Ces caractéristiques entraînent :

- des points de collision imprévisibles dus au problème de localisation, et des interruptions de communication causant des pertes de données lors d'un déploiement important de drones ou de faible densité respectivement;
- une instabilité et une forte fluctuation des liens de communication entre les UAV;
- des frais généraux de routage et des retards de communication;
- le gaspillage de la bande passante et de l'énergie des UAV;
- la quantité d'énergie limitée permettant pas de faire des vols de longue distance.

Tout cela ajouté aux incertitudes environnementales, les défaillances des nœuds volants, etc. impactent négativement l'échange fluide de données entre les nœuds. D'autres facteurs tels que les mises à jour de mission ou des capacités inégales entre les nœuds peuvent également entraîner des modifications de la topologie.

Ainsi l'un des principaux problèmes reste la mise en place d'une architecture de déploiement efficace et adaptable du FANET, en fonction des besoins et capable de déterminer les méthodes optimales à appliquer entre les UAV selon une situation donnée. Dans un système de communication basé sur les UAV, la position de l'UAV au sein de son réseau constitue l'un des principaux facteurs affectant la qualité du service offert.

1.4 Enjeux des réseaux ad hoc de drones

Les UAV constituent un potentiel considérable en raison de leurs performances et leur capacité à réaliser efficacement des missions variées et complexes. Les possibilités qu'ils offrent sont encore aujourd'hui loin d'être totalement exploitées et leur emploi suscite toujours un certain nombre de questions auxquelles il convient de trouver des réponses adéquates, questions relatives aussi bien à leur emploi qu'à leur cohabitation avec les autres utilisateurs de l'espace aérien.

Parmi celles-ci, on peut distinguer les questions de nature essentiellement technique : assurer la meilleure sécurité possible des vols, permettre leur insertion dans l'espace aérien, qui est

parfois déjà bien occupé, sans diminuer le niveau de sécurité offert et sans perturber les autres activités aéronautiques, aussi préciser ce qu'on attend des entreprises, des exploitants et les compétences exigées des télépilotes et enfin s'assurer de la disponibilité des fréquences nécessaires à leur exploitation. Par ailleurs il y a aussi des questions de nature sociétale : assurer le respect de la vie privée des personnes survolées, bien identifier les responsabilités associées à leur exploitation, veiller à la disponibilité d'assurances à des niveaux adéquats, bien prendre en compte les risques associés à une utilisation malveillante (David & Panhaleux, 2015). En milieu urbain par exemple, l'emploi des drones doit se faire avec beaucoup d'attention et d'expertise afin d'éviter d'éventuels accidents pouvant causer la destruction du drone ou d'un produit transporté, l'échec d'une mission ou même de blesser une personne circulant dans la zone en dessous du drone.

Cependant comme précédemment exposé, il ne faut pas perdre de vue tous ces avantages qu'ils peuvent offrir. Par exemple pendant un grand évènement temporaire, des UAV peuvent être utilisés comme des stations de base (BS) aériennes permettant d'assurer un relais dans une zone couverte par une station de base au sol congestionnée ou endommagée.

Tout repose en fait sur une question de maîtrise du système, d'organisation, de coordination et de prévoyance.

1.5 L'apprentissage automatique dans les FANET

1.5.1 Généralités sur l'apprentissage automatique

« Le Machine Learning (ML) ou apprentissage automatique en français, est un champ d'études de l'Intelligence Artificielle (IA) qui se fonde sur des approches mathématiques et statistiques pour donner aux ordinateurs la capacité d'apprendre à partir de données » (Apprentissage automatique, 2020), c'est-à-dire d'améliorer leurs performances à résoudre des tâches sans être explicitement programmés pour chacune. L'objectif du Machine Learning est de trouver un modèle qui effectue une approximation de la réalité (le phénomène à l'origine des données), à l'aide de laquelle on peut effectuer des prédictions ou résoudre des problèmes bien plus complexes.



Figure 1.11 Machine Learning, un sous domaine de l'intelligence Artificielle
Tirée de Elodie Faride (Avril 2018)
(Consulté au mois de Juillet 2020)

Les différentes approches de l'apprentissage automatique:

- apprentissage supervisé (Supervised Learning) : Utiliser des exemples (données labélisées) dans des DATASET pour faire apprendre la machine;
- apprentissage non supervisé (Unsupervised Learning) : Utiliser des données non labélisées, on peut procéder par clustering ou associations, permettant de trouver des correspondances, des corrélations entre les données, détecter des anomalies, etc. ;
- apprentissage semi-supervisé (Semi-supervised learning);
- apprentissage par renforcement (Reinforcement learning) : consiste, pour un agent autonome dans un environnement, à apprendre les actions à effectuer, à partir d'expériences, de façon à optimiser une récompense quantitative au cours du temps;
- apprentissage profond (Deep Learning) : ensemble de méthodes d'apprentissage automatique tentant de modéliser avec un haut niveau d'abstraction des données grâce à des architectures articulées de différentes transformations non linéaires.

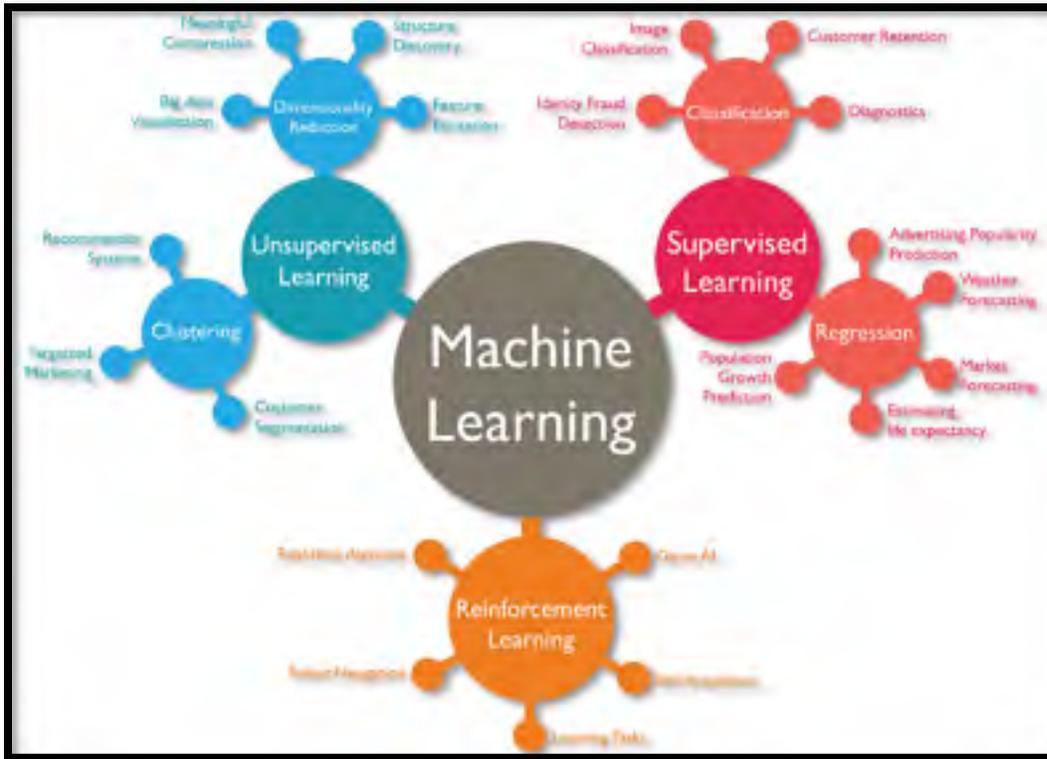


Figure 1.12 Approches du Machine Learning
 Tirée de Abdul Washid (2017, p.12)
 (Consulté au mois de Juillet 2020)

1.5.2 Importance de l'apprentissage automatique dans les réseaux multi-UAV

L'apprentissage automatique permettant entre autres de réaliser des prédictions ou de résoudre des problèmes très complexes pourrait être utilisé comme étant une stratégie importante à considérer dans la mise en œuvre et le déploiement d'un réseau ad hoc multi-UAV, dans lequel les mouvements imprévisibles des nœuds affectent considérablement l'état du réseau.

Dans un article, Park, Kim & Seok ont cherché à déterminer si le succès ou l'échec des transmissions de paquets entre UAV peut être prédit par les méthodes d'apprentissage automatique. Ils ont démontré que l'apprentissage automatique peut prédire avec succès les modèles de transmission dans le réseau de drones (Park et al., 2016).

Dans un contexte où les UAV peuvent être utilisés comme stations de base aérienne (BS) pour l'extension de la couverture, l'amélioration de la transmission, la communication d'urgence, etc. chaque UAV-BS devrait sélectionner le mot de code optimal pour former des faisceaux analogiques directionnels et réaliser ainsi des transmissions simultanées à partir de plusieurs autres BS UAV. Cependant, en raison du grand nombre d'utilisateurs mobiles connectés, les stations de base aériennes ne peuvent pas sélectionner le mot de code dans le livre de codes prédéfini précisément et en temps opportun (Yang et al., 2020). Face à cela des chercheurs ont démontré que l'apprentissage automatique convient pour réduire la complexité de la sélection de mots de code et obtenir une sélection efficace.

L'application de l'apprentissage automatique peut permettre à un drone d'apprendre à maîtriser d'avance un environnement où il devra effectuer une mission, prédire la position future de ses voisins dans le réseau, se comporter intelligemment dans l'environnement en évitant des obstacles, assurer une meilleure organisation en équipe des drones (clustering), etc. Plusieurs travaux à travers la littérature mettent en évidence l'apport indiscutable du Machine Learning dans l'évolution et l'optimisation des réseaux FANET.

1.6 Travaux connexes

Plusieurs études ont porté sur le déploiement efficace d'un réseau multi-UAV, l'application de l'apprentissage automatique dans les réseaux de drones ou alors ces études ont tenté d'apporter des solutions traitant du positionnement des drones dans les FANET.

Dans un article, des chercheurs ont proposé un déploiement 3D d'une seule station de base UAV visant à maximiser le nombre d'utilisateurs couverts avec différentes exigences de qualité de service (Alzenad et al., 2017). Dans un article, Galkin, Kibilda & DaSilva ont proposé un algorithme de partition utilisant la méthode de clustering K-means qui permet de positionner les points d'accès aéroportés autour des emplacements précis des utilisateurs, sélectionner les utilisateurs à décharger des macrocellules puis décharger des utilisateurs compte tenu de la capacité des drones pendant que la macrocellule est encore en service (Galkin et al., 2016).

Dans un article, des chercheurs traitent le problème portant sur la détermination de la position et de la région de service de chaque drone dans le réseau en proposant une méthode efficace pour déployer des UAV en partitionnant la zone en sous-régions afin de minimiser la demande de trafic maximale entre ces sous-régions ainsi qu'une procédure de recherche locale pour relocaliser les drones (Sun, Wang & S. Wang, 2018).

Face à un événement soudain pas supporté par certains dispositifs, des stations de base au sol peuvent être congestionnées ou endommagées. Dans ce contexte des chercheurs proposent une solution visant à desservir les utilisateurs affectés tout en maximisant le profit de l'opérateur en adoptant la méthode des k-means associée à la technique de recherche de modèle afin de trouver les emplacements 3D optimaux des drones (Omran et al., 2020). Considérant l'influence de la position des UAV dans le réseau, des chercheurs proposent un algorithme centralisé pour le positionnement des UAV afin de maximiser le débit d'un réseau de communication multi-UAV (ur Rahman, Kim, Cho & Khan, 2018).

Afin de déployer des drones de manière opportune et flexible, il semble important de prédire a priori les points chauds potentiels et les événements de congestion. C'est dans cette optique que dans un article, des chercheurs proposent une nouvelle approche pour le déploiement prédictif des BS aériens d'UAV afin de fournir un service sans fil à la demande en intégrant des stratégies basées sur le Machine Learning (Zhang et al., 2018).

Dans une étude, Park, Lee & Hong proposent un système pour trouver un emplacement où plusieurs utilisateurs peuvent avoir un débit de service optimal en tenant compte des besoins des utilisateurs dans la communication Multi-UAV (Park et al., 2019). Pour cela ils appliquent un algorithme collaboratif avec la méthode K-means modifié qui peut distribuer des utilisateurs à chaque UAV dans le réseau en résolvant ainsi les problèmes de surcharge de communication. Ils appliquent aussi l'algorithme d'optimisation de politique proximale (PPO) pour définir un emplacement optimal avec un débit maximal.

Dans un article, des auteurs proposent un nouveau cadre pour le déploiement 3D dynamique de véhicules aériens sans pilote (UAV) dans le système de station de base aérienne basé sur les algorithmes d'apprentissage automatique (Zhao et al., 2019). Les auteurs s'appuient sur des techniques basées sur l'apprentissage automatique pour prédire la trajectoire des utilisateurs desservis afin de mettre à jour la position des UAV dans le réseau. Dans un autre article, Zamini & Montazer proposent une méthode basée sur l'auto-encodeur et l'algorithme K-means pour réaliser la division de la scène cellulaire. Ils utilisent tout d'abord le réseau d'auto-encodeur pour effectuer la réduction de dimension des données, ensuite, ils se servent de l'algorithme K-means pour regrouper les données à dimension réduite (Zamini & Montazer, 2018). Une telle approche rend plus efficace le partitionnement que les méthodes traditionnelles.

CHAPITRE 2

MOTIVATIONS, MATÉRIELS ET MÉTHODOLOGIES

2.1 Problématique

A la lumière de tout ce qui précède, nous observons un certain nombre de problème que connaît les FANET, comme par exemple dans le cas d'un déploiement efficace de ce type de réseau en tant que relais face à un évènement soudain qui réduis les capacités ou encombre des stations de base fixe au sol. Lors d'un tel déploiement il est important de déterminer la position des UAV, un facteur qui constitue l'un des principaux éléments affectant la qualité du service offert, aussi recourir des méthodes quasi optimales à appliquer entre les UAV afin d'assurer la communication voulue. Plusieurs travaux déjà réalisés dans ce champ de recherche dont nous avons fait un petit survol dans la partie précédente, s'avèrent encore insuffisants pour faire face au problème de positionnement des différents drones dans le réseau, ce qui met en évidence la complexité de ce système. En effet malgré leurs exploits, les travaux déjà réalisés dans ce domaine proposent d'autres champs de recherche ou de problèmes non encore résolus complètement.

Dans la partie travaux connexes précédente, nous avons présenté quelques réalisations tentant de venir à bout de ce problème. Cependant avant même de penser au positionnement, il semble judicieux de déterminer le nombre optimal de UAV à déployer afin de couvrir entièrement l'espace défini et mener à bien une mission. En effet les UAV s'échangent continuellement des informations pendant le vol afin de maintenir leur connectivité et détecter la position de leur voisin. Plus il y a de drone, plus les message inter-UAV sont nombreux ce qui peut réduire non seulement leur capacité à traiter à temps les informations les plus utiles mais aussi à réduire leur énergie, et cela peut influencer la durée de vie de la mission. Dans une étude des chercheurs ont proposé une méthode pour trouver le nombre minimum ainsi que les positions 3D des drones-BS dans une zone avec différentes densités d'utilisateurs à l'aide d'un algorithme heuristique afin de servir les utilisateurs (Kalantari, Yanikomeroğlu & Yongacoglu, 2016). De même A. Omran et al. dans leur travail ont cherché à déterminer le nombre optimal d'UAV à

déployer pour répondre aux besoins des utilisateurs au sol. D'autre part la distribution des drones de façon à couvrir toute l'espace affectée ne devrait pas être négligée dans la mesure où selon le contexte, il peut y avoir des régions plus denses que d'autres. Une répartition efficace sera l'idéale pour assurer un service équitable. Alzenad et al. dans leur étude ont proposé une méthode de placement 3D efficace de stations de base aériennes qui permet de maximiser le nombre d'utilisateurs couverts en découplant le placement de l'UAV-BS dans la dimension verticale de la dimension horizontale, ce qui simplifie le problème de placement sans aucune perte d'optimalité. Plusieurs autres études ont proposé des solutions visant à distribuer les drones de façon plus optimisée pour un meilleur service, telles que celle des auteurs (Sun et al., 2018) qui étudie comment partitionner la région de manière presque équilibrée, en minimisant la demande maximale de trafic entre les sous-régions. Cela permet en effet de balancer la charge dans l'ensemble du réseau. Des auteurs, (Omran et al., 2020), adoptent la méthode des k-moyennes associée à la technique de recherche de modèle pendant que Zhang et al. proposent d'introduire l'apprentissage automatique dans un cadre basé sur un modèle de mélange gaussien et un algorithme de maximisation des attentes pondérées.

De plus dans un milieu urbain où les risques semblent plus prononcés et avec les utilisateurs pouvant avoir des exigences de services différentes, il convient d'adopter des méthodes et stratégies aussi bien efficaces que flexibles afin de s'adapter aux environnement et situations. De tout cela, nous remarquons que ce champ de recherche demeure encore non entièrement exploité et de ce fait une solution robuste serait de présenter un cadre de déploiement d'un réseau FANET intelligent et adaptable qui intègre des stratégies basées sur l'apprentissage automatique pour fournir un service de qualité.

2.2 Objectifs de recherche

Dans cette étude nous abordons le problème de positionnement des véhicules aériens sans pilote (UAV) dans une zone couverte par une station de base au sol congestionnée ou endommagée (BS) par un évènement soudain dans un milieu urbain. Notre objectif principal est de proposer un schéma de déploiement 3D d'un réseau d'UAV qui aboutit à maximiser le

nombre d'utilisateurs desservis en tenant compte de leurs exigences en termes de qualité de service et de la variation de la densité de ces utilisateurs sur l'ensemble du réseau compte tenu de leur distribution aléatoire tout en maximisant le profit de l'opérateur. En effet d'autres travaux ayant déjà traité le problème n'ont pas considéré le cas où les utilisateurs au sol auraient des besoins ou des exigences de service différents. De même les utilisateurs au sol sont généralement mobile et pendant leur déplacement peuvent sortir de leur couverture.

Notre solution tirant profit de l'apprentissage automatique pour donner de façon optimale les emplacements actuels des UAV et une mise à jour continue de leur position dans le réseau pourra permettre d'assurer un meilleur déploiement 3D et favoriser une meilleure couverture pour maximiser le nombre d'utilisateurs desservis. Il s'agit pour nous dans un premier temps d'appliquer les bonnes méthodes afin de déterminer le nombre optimal de drones à déployer selon l'ampleur de la situation et le besoin de service avant de chercher à déterminer leurs différentes positions ainsi que les mises à jour de ces positions suivant le déplacement possible des utilisateurs ou l'orientation de la mission.

La principale contribution de cette étude est la proposition d'un nouveau schéma de déploiement 3D d'un réseau multi-UAV dans une zone avec différente densité et exigences variées d'utilisateurs qui intègre l'apprentissage automatique visant à assurer le relais ou étendre la connectivité fournie par une station. Cela en vue de maximiser le nombre d'utilisateurs en tenant compte de leurs exigences de service tout en maximisant les bénéfices de l'opérateur avec une meilleur qualité de service.

2.3 Méthodologie de recherche et outils

Pour atteindre nos objectifs, une démarche méthodologique à la fois analytique, démonstrative et explicative est suivie. Nous considérons que le champ de couverture du réseau est un espace délimité, sain et sans obstacle. En effet dans cette étude nous n'allons pas prendre en considération les multiples aspects et obstacles que présente un milieu urbain.

Dans un premier temps nous allons chercher à déterminer le nombre suffisant de UAV à déployer pour couvrir tous les utilisateurs. Dans cette partie, la première étape consiste à déterminer le nombre minimum d'UAV où toutes les ressources sont utilisées sans rien gaspiller. Ensuite, nous calculons le nombre d'utilisateurs encore non servis et à travers cela, si le besoin de servir les utilisateurs non desservis est remarquable, un UAV supplémentaire est ajouté au système.

Par la suite il s'agira de trouver les emplacements des drones pour une meilleure couverture de la zone. Pour cela le nombre optimal de drone sera déterminé par un algorithme qui prend en considération le nombre des utilisateurs au sol à desservir ainsi que leurs différentes exigences de service pour produire le meilleur profit possible.

En suite pour les positions des UAV dans les différentes régions de la zone de mission, nous proposons d'associer les sous domaines de l'apprentissage automatique, le Deep Learning (Apprentissage profond) et Unsupervised Learning (Apprentissage non supervisé). Essentiellement nous allons utiliser la méthode des K-means (Clustering K-Means) combiné avec le Deep Learning afin d'optimiser le partitionnement et le positionnement. Le clustering K-means fait partie des méthodes de partitionnement du clustering. Le partitionnement de données (ou data clustering en anglais) est une méthode en analyse des données qui vise à diviser un ensemble de données en différents « paquets » homogènes, en ce sens que les données de chaque sous-ensemble partagent des caractéristiques communes, qui correspondent le plus souvent à des critères de proximité (similarité informatique) que l'on définit en introduisant des mesures et classes de distance entre objets (« Partitionnement de données », 2020).

Ainsi les algorithmes ou méthodes de partitionnement sont des techniques de clustering qui subdivisent les ensembles de données en un ensemble de k groupes, où k est le nombre de groupes pré-spécifié. Il existe différents types de méthodes de partitionnement de cluster. Comme mentionné plus haut dans cette étude nous allons recourir au Clustering K-Means.

L'algorithme des K-means détermine la somme des carrés au centre de chaque groupe ou sous-ensemble et la distance des objets de données du groupe en fonction du coût. De plus, le regroupement est effectué en mettant à jour les groupes appartenant à chaque objet de données pour minimiser la valeur de cette fonction (Yu Park et al., 2019).

$$\operatorname{argmin}_S \sum_{i=1}^k \sum_{x_j \in S_i} \|x_j - \mu_i\|^2 \quad (2.1)$$

Avec μ_i le barycentre des points dans S_i . L'équation (2.1) est l'équation cible pour trouver un ensemble S qui minimise la somme des carrés des distances pour chaque groupe.

Par ailleurs la combinaison avec le Deep Learning va permettre d'optimiser le partitionnement. C'est un sous-ensemble du Machine Learning qui présente des capacités extraordinaires à résoudre des problèmes très complexes et à faire des prédictions étonnantes. La volonté de modélisation du fonctionnement d'un neurone biologique en version simplifiée donnant naissance aux neurones artificiels qui sont des modèles mathématiques inspirés de la biologie constitue la brique de base du Deep Learning, d'où sa puissance. Il ne s'agit donc pas de reproduire tout le fonctionnement du neurone biologique, c'est une représentation simplifiée avec différents niveaux d'abstraction, suivant la précision de la modélisation voulue.

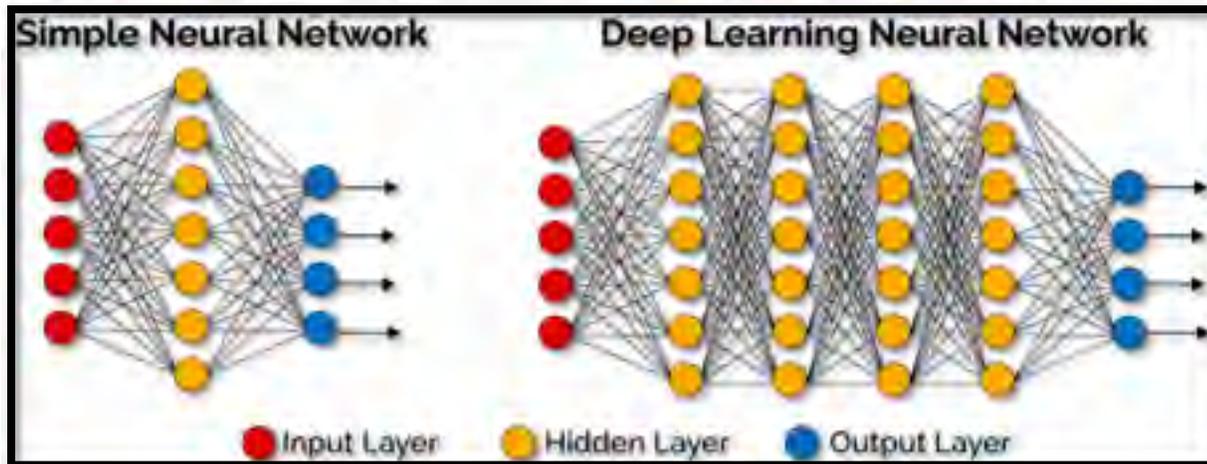


Figure 2.1 Neural Network Modelling
 Tirée de ridhigrg (Juin 2019)
 (Consulté au mois de Septembre 2020)

Dans son fonctionnement l'algorithme du Deep Learning va chercher à optimiser une fonction de perte. C'est-à-dire chercher les paramètres qui minimisent la fonction de perte, d'où dans notre cas optimiser la minimisation de la valeur de la fonction cible de k-means.

De plus l'intégration du Machine Learning pourrait aider à prédire les positions futures des drones pendant le déplacement des utilisateurs afin de maintenir la connectivité et maximiser le taux de transmission. En effet les utilisateurs au sol ne restent pas qu'à la même position. Selon les scénarios du monde réel, les utilisateurs desservis sont dynamiques et l'UAV-BS devrait ajuster sa position pendant que la foule desservie se déplace (Zhao et al., 2019). Dans un travail futur, une approche pourrait être suivie afin de prédire le mouvement des utilisateurs et déterminer le placement dynamique 3D de l'UAV. Cependant dans notre étude nous considérons que les utilisateurs ne s'éloignent pas tellement de leur position initiale et restent couverts par le drone qui leur fourni le service.

Et enfin, nous chercherons à déterminer l'altitude de chaque UAV au sein de chaque cluster. L'altitude de l'UAV lui permet de couvrir un champ convenablement grand afin d'utiliser pleinement ses ressources et permettre aussi qu'ensemble tous les drones déployés couvrent entièrement la zone de mission tout en maintenant la connectivité avec les récepteurs au sol.

L'environnement d'exploitation MATLAB sera utilisé pour les différentes simulations afin mieux analyser les performances de notre système.

CHAPITRE 3

MODÈLE DE SYSTÈME ET FORMULATION DU PROBLÈME

En général chaque drone a une ressource énergétique limitée, un facteur qui influence sérieusement la durée de la mission et qui doit être utilisé efficacement pour les communications et la mobilité. De plus une position donnée pour un drone a une conséquence directe sur sa capacité à servir efficacement l'utilisateur couvert. De ce fait, pendant leur mission, les drones devraient changer intelligemment leurs positions pour répondre aux besoins des utilisateurs et aux exigences du réseaux tout en minimisant la consommation d'énergie. Pour garantir un service aérien optimal sans que les UAV se déplacent en permanence sans but précis, ce qui pourrait gaspiller de l'énergie et compromettre la mission causant des pertes chez l'opérateur de réseaux, celui-ci peut employer des techniques de Machine Learning pour prédire certains états de son réseau afin d'optimiser le déploiement de station de base aérienne dans les zones considérées. Une telle approche ou démarche aura surement tendance à rendre plus efficace la fourniture du service et à maximiser les gains chez le fournisseur.

Notre étude s'appuie sur des techniques de l'apprentissage automatique comme moyen pour déployer des UAV afin qu'ils assurent une meilleure qualité de service, compte tenu de la densité variée des utilisateurs sur l'ensemble du réseau et leurs différentes exigences tout en maximisant les bénéfices de l'opérateur.

Dans notre travail, nous considérons une zone géographique A couverte par une station de base fixe au sol (BS) où le nombre d'utilisateurs dépasse largement sa capacité en raison d'un événement surpeuplé temporaire attirant plusieurs nouveaux utilisateurs ou en raison d'un dysfonctionnement de la BS.

Considérons le nombre total des nouveaux utilisateurs N_U . Les utilisateurs sont répartis de façon aléatoire et inégale ayant des exigences différentes et créant ainsi différents niveaux de

demandes dans la zone. Ils sont désignés par l'ensemble utilisateurs $U = \{u_1, u_2, \dots, u_n\}$ et leurs coordonnées définies par $u_i = (x_i, y_i) \in A$. Les j UAV prévus pour être déployés afin de relayer la BS en desservant les utilisateurs sont similaires en termes de capacité et de consommation d'énergie. Dans notre étude, un utilisateur est affecté à un UAV s'il se trouve dans son champ de couverture et n'est plus desservi par la BS. Nous désignons ainsi par RB^{max} la capacité maximale en ressource que chaque UAV j peut fournir et est égale à $B * w$, où B est la bande passante totale du drone-BS et w l'efficacité spectrale moyenne du système. De plus, les drones sont autorisés à modifier leur altitude et leur position horizontale suivant le déplacement des utilisateurs afin d'améliorer leur service.

3.1 Modèle de canal air-sol

Le canal entre l'UAV et les utilisateurs au sol est appelé canal air-sol. Le modèle de canal air-sol est différent des modèles de canal terrestre. Il est modélisé en considérant les composants de ligne de visée ou line of sight (LoS) en anglais et de sans ligne de vue directe ou non-line of sight (NLoS) ainsi que leurs probabilités d'occurrence séparément. La probabilité de LoS est un facteur important dans la modélisation de la trajectoire air-sol.

3.1.1 Le modèle de perte de trajet air-sol

Étant donné un utilisateur i au sol situé à $(x_i, y_i) \in A$ et un drone j situé à (X_j, Y_j, H_j) , la perte de chemin ou path loss (PL) de la communication descendante de l'UAV j au récepteur i , encore appelée trajet air-sol, en se référant aux auteurs AI-Hourani, Kandeepan et Lardner (2014) sera fonction de la perte de chemin en espace libre entre l'UAV et un utilisateur au sol qu'on notera FSPL (Free Space PathLoss) et une perte de chemin excessive η dans l'environnement urbain sous forme d'ombrage et de diffusion, le tout défini par :

$$PL = FSPL + \eta \quad (3.1)$$

Où FSPL est défini par :

$$FSPL = 20 \log d + 20 \log f + 20 \log \left(\frac{4\pi}{c} \right) \quad (3.2)$$

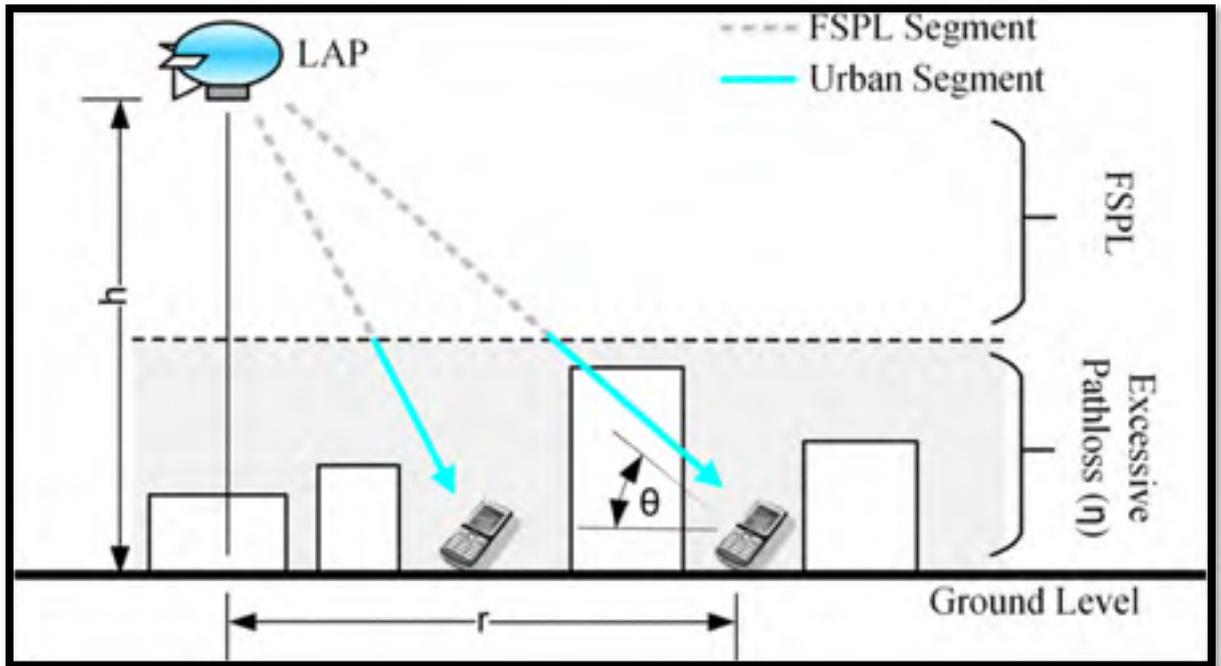


Figure 3.1 Propagation radio des plates-formes basse altitude en milieu urbain
Tirée de Al-Hourani et al. (2014, p.2)

Ainsi la perte de chemin pour LoS et NLoS sera exprimée dans notre cas par (3.2) dans (3.1) :

$$PL_{LoS} = 20 \log \left(\frac{4\pi f_c d_{ij}}{c} \right) + \eta^{LoS} \quad (3.3)$$

$$PL_{NLoS} = 20 \log \left(\frac{4\pi f_c d_{ij}}{c} \right) + \eta^{NLoS} \quad (3.4)$$

Où f_c et c représentent la fréquence du signal (de la porteuse) et la vitesse de la lumière, respectivement, d_{ij} est la distance entre l'utilisateur i et le drone j exprimée par :

$$d_{ij} = \sqrt{(X_j - x_i)^2 + (Y_j - y_i)^2 + (H_j - h_i)^2} \quad (3.5)$$

Avec (X_j, Y_j, H_j) et (x_i, y_i, h_i) les coordonnées respectives de l'UAV j et de l'utilisateur i au sol où on peut considérer $h_i = 0$.

3.1.2 Le modèle de la probabilité de la ligne de visée

L'Union internationale des télécommunications (UIT), dans son document de recommandation (Propagation data and prediction methods for the design of terrestrial broadband millimetric radio access systems, 2003, cité par AI-Hourani et al. (2014), propose une méthode remarquable afin de déterminer la probabilité d'une ligne de service géométrique entre un émetteur terrestre en élévation h_{TX} et un récepteur en élévation h_{RX} en milieu urbain. Cette probabilité dépend de trois paramètres statistiques liés à l'environnement urbain :

- **paramètre α :** Représente le rapport entre la superficie bâtie et la superficie totale du terrain (sans dimension);
- **paramètre β :** Représente le nombre moyen de bâtiments par unité de surface (bâtiments / km²);
- **paramètre γ :** Un paramètre d'échelle qui décrit la distribution des hauteurs des bâtiments selon la fonction de densité de probabilité de Rayleigh:

$$f(H) = (H/\gamma^2) \exp(-H^2/2\gamma^2)$$

Où H est la hauteur du bâtiment en mètres.

Cependant dans le cas particulier d'un UAV, nous pouvons ignorer h_{RX} du fait qu'il est bien inférieur à la hauteur moyenne des bâtiments et à l'altitude de l'UAV. Avec la distance au sol qui devient :

$$r = h/\tan(\theta)$$

Où h est l'altitude du drone, les auteurs AI-Hourani et al. (2014) dans leur étude démontrent que la probabilité d'avoir une connexion *LoS* entre l'utilisateur au sol i et un UAV-BS j peut être donnée par :

$$P(LoS, \theta) = \frac{1}{1 + a \exp(-b(\theta - a))} \quad (3.6)$$

D'où dans notre cas :

$$P_{LoS} = \frac{1}{1 + a \exp\left(-b \left(\frac{180}{\pi} \theta_{ij} - a\right)\right)} \quad (3.7)$$

Avec a et b des constantes basées sur l'environnement système et θ_{ij} l'angle d'élévation entre l'utilisateur et le drone donné par : $\tan^{-1}\left(\frac{h_j}{d_{ij}}\right)$.

L'équation (3.7) montre que la probabilité d'avoir une connexion *LoS* augmente à mesure que l'angle d'élévation augmente, donc si d_{ij} est fixé en augmentant l'altitude du drone, la probabilité de *LoS* augmentera (Kalantari et al., 2016).

La probabilité d'une connexion sans ligne de vue directe est fonction de celle de la ligne de visée et est donnée par :

$$P_{NLoS} = 1 - P_{LoS} \quad (3.8)$$

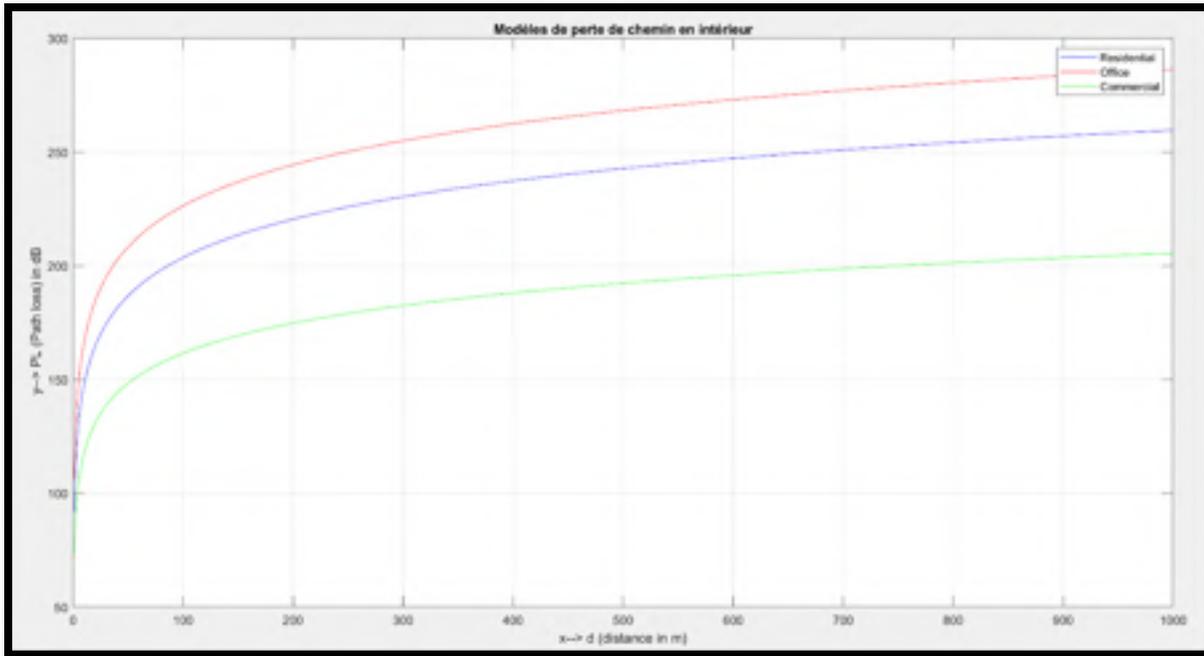


Figure 3.2 Pathloss par rapport à la distance entre le drone et un receptrer au sol
Adaptée de DBR Rawat (2020)
(Consulté au mois de Septembre 2020)

Comme on le voit sur cette Figure 3.2, en augmentant la distance entre un drone-BS et un utilisateur au sol, le pathloss aussi augmente et dépendamment du milieu. En effet le pathloss dépend de la distance entre l'émetteur et le récepteur, mais il dépend aussi de l'altitude du drone-BS, donc après une hauteur spécifique ce facteur domine et à mesure que l'altitude augmente, le pathloss augmentera également.

Nous pouvons remarquer aussi que le comportement de la courbe diffère selon le milieu, dû aux réflexions des bâtiments ou autre objet caractérisant le milieu. En l'absence de connaissance du terrain, nous ne pouvons pas déterminer si le lien est en LoS ou en NLoS (Alzenad et al., 2017). Par conséquent, nous considérons la perte de chemin moyenne probabiliste, qui est moyennée sur les conditions LoS et NLoS comme (Omran et al., 2020):

$$PL_{moy}(dB) = 20 \log \left(\frac{4\pi f_c d}{c} \right) + P_{LoS} \eta^{LoS} + P_{NLoS} \eta^{NLoS} \quad (3.9)$$

3.2 Formulation du problème d'optimisation

Dans cette étude l'objectif principal de notre problème est d'assurer une couverture efficace des utilisateurs au sol et de réaliser un profit maximum pour l'opérateur tout en satisfaisant à la fois les contraintes de qualité de service et de capacité. Nous avons adopté pour le cadre de notre problème d'optimisation, celui des auteurs Omran et al. (2020).

Nous définissons le profit $P = G - C$, où G et C représentent le gain total et les coûts, respectivement. Le gain est calculé comme suit:

$$G = \sum_{i=1}^{N_U} \sum_{j=1}^{N_D} P_{service} \alpha_i \delta_{ij}, 1 \leq \forall \alpha < 2 \quad (3.10)$$

Avec $P_{service}$ le prix du service que chaque utilisateur paie, α_i une variable exprimant les exigences de service de l'utilisateur i par rapport au service demandé (elle vaut 1 si l'utilisateur n'a exigé ou ne nécessite aucun service différent ou supplémentaire, dans le cas contraire elle sera supérieure à 1 et inférieure à 2) et δ_{ij} une variable binaire définie comme suit:

$$\delta_{ij} = \begin{cases} 1 & \text{si l'utilisateur } i \text{ est servi par UAV } j \\ 0 & \text{sinon} \end{cases} \quad (3.11)$$

Ou tout simplement:

$$\delta_{ij} = 0 \text{ si } d_{ij} > R_j \text{ sinon } \delta_{ij} = 1 \text{ si } d_{ij} \leq R_j \quad (3.12)$$

Où R_j est le rayon de couverture de l'UAV j .

Le coût C représente les coûts totaux que l'exploitant ou l'opérateur de réseau devra payer pour faire fonctionner les UAV et est calculé comme suit:

$$C = \sum_{i=1}^{N_U} \sum_{j=1}^{N_D} P_{ij} C^{power} \alpha_i \delta_{ij} + \sum_{j=1}^{N_D} C^{UAV} \quad (3.13)$$

Où P_{ij} et C^{UAV} sont la puissance d'émission et le coût de service de l'UAV j , respectivement et avec C^{power} le coût d'une unité de puissance. Par conséquent, l'expression du profit est donnée par :

$$P = \sum_{j=1}^{N_D} \left[\sum_{i=1}^{N_U} [P_{service} \alpha_i \delta_{ij} - P_{ij} C^{power} \alpha_i \delta_{ij}] - C^{UAV} \right] \quad (3.14)$$

$$P = \sum_{j=1}^{N_D} \left[\sum_{i=1}^{N_U} [P_{service} - P_{ij} C^{power}] \alpha_i \delta_{ij} - C^{UAV} \right] \quad (3.15)$$

Dans notre scénario, le problème d'optimisation correspondant est donné par:

$$\max_{N_D, X_j, Y_j, H_j} P \quad (3.16)$$

En prenant en compte :

$$N_D \leq N_D^{max} \quad (3.17)$$

$$\sum_{i=1}^{N_U} \alpha_i \delta_{ij} \leq RB^{max}, \forall j \quad (3.18)$$

$$\sum_{j=1}^{N_D} \delta_{ij} \leq 2, \forall i \quad (3.19)$$

$$\delta_{ij} \in \{0,1\} \quad (3.20)$$

La contrainte en (3.17) indique que le nombre maximum d'UAV disponibles ne doit pas être dépassé.

La contrainte dans (3.18) indique que le nombre d'utilisateurs desservis par un UAV en tenant compte des exigences en termes de service ne peut pas dépasser le nombre disponible de blocs de ressources RB^{max} .

La contrainte en (3.19) indique que un utilisateur peut être couvert par au maximum deux UAV (l'utilisateur peut se trouver dans le champ de couverture de ces deux UAV), cependant il ne peut être desservi que par un et seulement un UAV.

Notre problème est un problème combinatoire dû à la contrainte binaire (3.20). Il s'agit d'un problème de temps polynomial difficile (NP-difficile) non déterministe que nous allons tenter de résoudre en proposant notre algorithme basé sur une combinaison des techniques de Machine Learning.

CHAPITRE 4

MÉTHODES D'APPRENTISSAGE AUTOMATIQUE POUR LE POSITIONNEMENT 3D DYNAMIQUE DES UAV

Trouver les emplacements des UAV-BS, c'est-à-dire les UAV représentant des stations de base aérienne, garantissant que tous ou presque tous les utilisateurs soient servis tout en satisfaisant les contraintes de capacité du système et de qualité de service est un problème très compliqué à résoudre en général. Cela est dû à des multiples aspects du système à considérer dont l'un des plus significatif reste l'instabilité et la forte fluctuation des liens de communication entre les UAV. Ajouter de nouvelles dimensions au problème, qui sont l'altitude des stations de base aériennes d'une part et d'autre part l'adaptation de leur position dans le temps pour maintenir la connectivité ou encore la prédiction de leur position future suivant le déplacement de la cible au sol, rendent le problème encore plus complexe.

Suivant notre problème d'optimisation, à partir de l'équation (3.15), maximiser le profit équivaut à maximiser le nombre d'utilisateurs desservis pour le même nombre d'UAV. Par conséquent, dans notre solution proposée, nous déterminons d'abord le nombre d'UAV sous la base de la répartition et du nombre d'utilisateurs à desservir. Ensuite, nous cherchons à trouver les emplacements de ces drones de façon à couvrir le nombre maximum d'utilisateurs. Il va falloir pour cela déterminer le nombre optimal de cluster selon la répartition des utilisateurs à couvrir avant de chercher la position horizontale qui convient le mieux pour assurer le service. Puis nous déterminons l'altitude de chaque UAV au sein de son cluster. La mise à jour périodique de notre algorithme permettra d'ajuster les positions des UAV afin de maintenir la couverture, ce qui permet de prévenir aussi d'éventuelle congestion ou perte de signal.

4.1 Nombre préliminaire des UAV

Pour résoudre notre problème d'optimisation, nous avons besoin dans un premier temps d'une estimation initiale du nombre de drones-BS pouvant desservir tous les utilisateurs. Ce nombre sera par la suite réévalué selon la situation avant validation. Ainsi dans cette étape, nous visons

à déterminer une estimation \widehat{N}_D du nombre total d'UAV nécessaire pour couvrir sans gaspillage tous les utilisateurs. Le nombre d'UAV doit être estimé en fonction des besoins de couverture et de capacité. Pour cela nous supposons que les utilisateurs sont localisés dans la zone de mission de manière que chaque UAV puisse couvrir exactement sa capacité et fournir de façon optimale son service. Il faut noter que cette estimation \widehat{N}_D présente une limite inférieure $N_{D_{min}}$ qui est le nombre minimum possible à envisager à première vue pour couvrir la zone. De même cette estimation devra respecter la contrainte en (3.17) qui indique qu'elle ne doit pas dépasser le nombre total d'UAV disponible pour la mission.

Nous allons donc exprimer cette limite inférieure d'UAV où tous leurs blocs de ressources seront utilisés, comme (Omran et al., 2020) :

$$N_{D_{min}} = \left\lfloor \frac{N_U}{RB^{max}} \right\rfloor \quad (4.1)$$

Où $\lfloor \cdot \rfloor$ désigne la fonction de plancher. A ce niveau il faut noter que le nombre total d'utilisateur ici est fonction de leurs exigences respectives. C'est-à-dire :

$$N_U = \sum_{i=1}^n u_i * \alpha_i \quad (4.2)$$

Ensuite, nous calculons le nombre d'utilisateurs non servis comme étant:

$$N_U^{non-servi} = N_U - RB^{max} N_{D_{min}} \quad (4.3)$$

Ce nombre initial de UAV n'est pas définitif, en effet si le bénéfice de servir les utilisateurs non desservis est supérieur au coût d'un UAV, c'est-à-dire le profit réalisé sur les utilisateurs restant non desservis est supérieur aux dépenses réalisées pour le service d'un nouvel UAV, un UAV supplémentaire est ajouté et les \widehat{N}_D drones initiaux sont reconsidérés. Par conséquent, l'estimation \widehat{N}_D est mise à jour suivant cette équation :

$$\hat{N}_D = \begin{cases} \hat{N}_D, & \text{si } C^{UAV} > N_U^{non-servi}(P_{service} - P_{ij}^{max} C^{power}), \\ \hat{N}_D + 1, & \text{sinon.} \end{cases} \quad (4.4)$$

Où P_{ij}^{max} est la puissance d'émission maximale des drones. Cette étape sera répétée sur le moment jusqu'à ce que \hat{N}_D reste le même afin de valider le nombre d'UAV nécessaire pour la mission, puis l'opération sera exécutée à des périodes de temps déterminées afin de réévaluer la situation et apprécier la possibilité d'un éventuel UAV supplémentaire.

4.2 Détermination des emplacements 2D des UAV

La zone de couverture d'un UAV portant un BS pouvant être vue comme un disque circulaire, une manière pratique de placer les UAV horizontalement est de considérer le placement du disque circulaire sur le plan horizontal. Il s'agit donc pour nous de centrer de manière optimale la zone de couverture dans un plan 2D de manière à couvrir entièrement et servir le nombre maximal d'utilisateurs possible.

Pour trouver l'emplacement 2D des drones dans une position où leurs services seront vraiment utiles et pleinement exploités, nous proposons d'utiliser la méthode des K-moyennes avec l'apprentissage profond (Deep Learning). En effet les méthodes de clustering traditionnelles comme k-Means reposent entièrement sur les représentations de données originales et peuvent alors être inefficaces lorsque l'on projette les points de données dans un espace de grande dimension. Ainsi les techniques reposant sur des réseaux de neurones profonds ou Deep Neural Network (DNN), qui appliquent des transformations non linéaires successives aux données afin d'obtenir des fonctionnalités de plus en plus de haut niveau s'avèrent très efficaces. Dans notre étude nous allons nous pencher sur un type de réseau de neurone bien adapté aux tâches d'apprentissage non supervisé, les auto-encodeurs. C'est une forme spéciale de réseau de neurones en couches qui permet de construire une nouvelle représentation d'un jeu de données, généralement plus compacte, et présentant moins de descripteurs, ce qui permet de réduire la dimensionnalité du jeu de données assurant une meilleure étude des données.

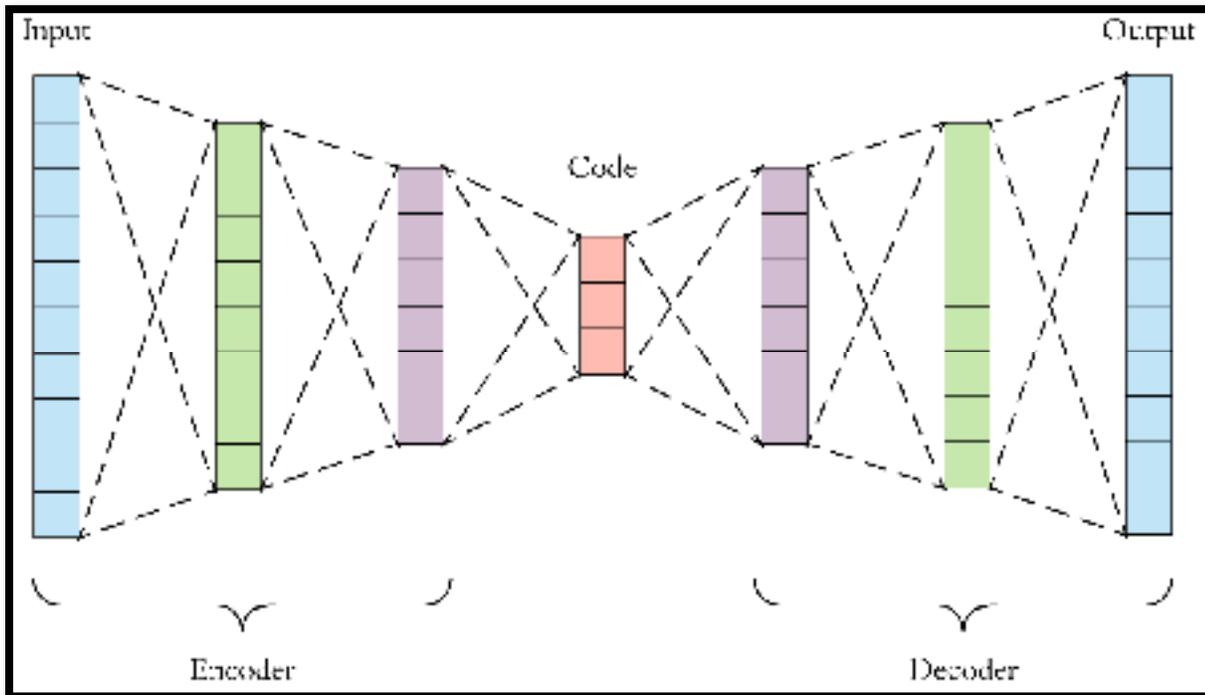


Figure 4.1 Autoencoders Modelling
 Tirée de Imran us Salam (2019)
 (Consulté au mois d' Août 2020)

L'architecture d'un auto-encodeur, comme la montre la figure 4.1, est constituée de deux parties principales qui sont *l'encodeur* et *le décodeur* et d'une partie centrale :

- l'encodeur prend les données en grande dimension et les compresse vers une plus petite dimension;
- le décodeur prend les données en petite dimension et les rétroprojette vers la plus grande dimension et;
- la valeur centrale appelée le code est censée contenir l'information de l'entrée de manière compressée.

Dans sa fonction, l'auto-encoder tente de copier son entrée afin de générer une sortie, qui est aussi proche que possible des données d'entrée en extrayant automatiquement les fonctionnalités essentielles de l'entrée dans la partie encodeur. Il reconstruira par la suite la

sortie en fonction des informations extraites dans la partie décodeur. En effet la partie encodeur se comporte comme la réduction de dimension.

Nous allons donc observer comment nous pourrions utiliser l'encodeur et la couche latente (le code caché) pour la réduction de dimension et effectuer un clustering. À partir de l'auto-encodeur nous pourrions extraire la partie encodeur avec la couche latente uniquement pour faire du clustering et de la visualisation en fonction de la sortie de la couche latente. Ainsi en utilisant K-Means sur la sortie de la couche latente pour le clustering, nous pourrions effectuer un clustering rapide et simple car la couche latente a une faible dimensionnalité (les K-Means ont tendance à être inefficaces avec une dimensionnalité élevée).

4.2.1 Emplacements 2D envisageables des UAV grâce au k-means standard

Dans cette étape nous allons nous servir de la méthode des K-moyennes traditionnelles pour trouver des emplacements envisageables des drones. Cette étape est importante dans le sens qu'elle nous permet rapidement d'avoir une vision claire de notre objectif afin de mieux régler les paramètres qu'il faut pour parfaire la résolution de notre problème. L'avantage des K-means est l'efficacité du regroupement des données non étiquetées en groupes. Dans notre cas son objectif sera de regrouper les \hat{N}_U utilisateurs estimés dans \hat{N}_D Drones.

L'algorithme K-means commence par \hat{N}_D emplacements aléatoires des drones représentant les centroïdes et qui seront les barycentres des futurs clusters. Ensuite, l'algorithme effectue une itération entre (Omran et al., 2020) :

- l'affectation des utilisateurs au cluster et donc à l'UAV le plus proche représentant le barycentre du cluster (i);
- le déplacement des UAV vers le centre de gravité de ses utilisateurs assignés, jusqu'à ce que les emplacements ne soient pas modifiés (ii).

L'affectation en (i) est effectuée entre le i^e utilisateur et le j^e UAV si :

$$\left\| (X_j - x_i)^2 + (Y_j - y_i)^2 \right\| < \left\| (X_k - x_i)^2 + (Y_k - y_i)^2 \right\| \forall k \in \hat{N}_D \quad (4.5)$$

L'utilisateur i est couvert par l'UAV j s'il se trouve plus proche de ce drone que d'un quelconque UAV k par rapport au centre de la zone de couverture.

Le déplacement en (ii) est effectué en déplaçant à chaque itération le drone vers le centre de gravité des utilisateurs qui lui sont affectés. Pour un cluster noté CL_j , les coordonnées de son nouveau centre de gravité sont :

$$(X_j, Y_j) = \left(\frac{1}{N_{U,j}} \sum_{U_i \in CL_j} x_i, \frac{1}{N_{U,j}} \sum_{U_i \in CL_j} y_i \right) \quad (4.6)$$

Avec $N_{u,j}$ le nombre d'utilisateurs dans le cluster CL_j .

Les centroïdes des clusters résultants après l'étape des K-moyennes représentent les emplacements envisageables dans un premier temps pour desservir les utilisateurs. Ces emplacements seront optimisés et réglés dans l'étape suivante qui consiste à minimiser les utilisateurs non desservis grâce aux techniques basées sur les réseaux de neurone en prenant en considération la capacité limitée de chaque drone et les exigences des utilisateurs. Tout cela sans perdre de vue l'objectif de réaliser un profit maximum pour l'opérateur et tout en satisfaisant bien sûr les contraintes de qualité de service et de capacité.

4.2.2 Emplacements 2D des UAV grâce au Deep K-means

Les emplacements 2D optimisés et attendus sont déterminés à l'aide d'une combinaison des K-moyennes et des techniques basées sur les réseaux de neurones profonds, plus spécialement sur les auto-encodeurs qui fournissent une fonction de représentation non linéaire en apprenant de façon itérative avec l'encodeur et le décodeur. Nous allons procéder en deux parties : tout d'abord minimiser l'erreur de reconstruction des données d'entrée et par la suite la distance

entre les données et le centre de leur cluster correspondant dans le nouvel espace. Les centres des différents clusters sont optimisés par une mise à jour de façon itérative.

Pour notre étude nous allons recourir à une structure d'auto-encodeur profonde au lieu d'avoir une seule couche cachée. En effet lorsque le codeur automatique profond a plus de couches qu'un simple codeur automatique, cela peut conduire à l'apprentissage de modèles plus complexes dans les données et permettre ainsi d'obtenir de meilleurs résultats.

4.2.2.1.1 Réseau d'auto-encodeur à une couche

Il s'agit en fait d'un auto-encodeur avec un encodeur, un décodeur et sa valeur centrale h , appelée le code. Ayant pour base les neurones formels dont l'équation peut être donnée par : $\hat{y} = f((w, x), +b)$, la fonction de représentation cachée de l'auto-encodeur est généralement non linéaire et similaire lors de la compression comme lors de la décompression. Cette fonction peut être donnée par Song, Liu, Huang, Wang & Tan (2013):

$$h = f(x) = \frac{1}{1 + \exp(-(wx + b))} \quad (4.7)$$

Où w et b sont respectivement un coefficient représentant le poids (d'encodage ou décodage) et un biais additionnel, x la donnée à représenter et cette fonction tend à donner une valeur x' , la représentation dans le nouvel espace de la donnée x . Le modèle auto-encodeur vise à apprendre une représentation efficace en minimisant l'erreur de reconstruction. Dans un article les auteurs (Song et al., 2013) ont montré que pour N échantillons d'exemple donnés, les paramètres w et b peuvent être résolus par le problème d'optimisation suivant :

$$\min \left(\frac{1}{N} \sum_{i=1}^N \|x_i - x_i'\|^2 \right) \quad (4.8)$$

En analysant de plus près cette équation, nous nous rendons compte qu'elle aborde exactement le problème cible des K-moyennes d'où un bon compromis pour optimiser le partitionnement de notre zone de mission ainsi que la position de nos différents drones dans la zone.

4.2.2.1.2 Partitionnement et positionnement basé sur l'auto-encodeur

L'auto-encodeur est un modèle puissant pour optimiser une fonction en minimisant l'erreur de reconstruction de la couche de code à la couche de données. L'un des avantages des auto-encodeurs est l'extraction de fonctionnalités utiles et le raffinement de fonctionnalités non utiles, ce qui assure une meilleure performance. L'objectif principal des réseaux à auto-encodeur est la reconstruction des entrées et c'est exactement ce qui nous intéresse, donner une meilleure représentation de nos clusters en tenant compte des exigences des utilisateurs, des capacités des UAV et du souci de qualité de service.

Pour nous servir de l'efficacité et la puissance de l'auto-encodeur pour positionner nos UAV afin de desservir le maximum d'utilisateur, nous allons procéder en deux étapes. Tout d'abord nous allons entraîner notre réseau d'auto-encodeur afin d'obtenir une fonction $f(x_i)$ de reconstruction optimisée avant d'utiliser cette fonction pour exécuter notre algorithme de clustering K-moyennes. Cette démarche accordera une meilleure performance à l'algorithme de clustering K-moyennes. Dans leur article, Song et al. (2013) proposent une nouvelle fonction objective et l'intègrent dans le modèle auto-encodeur comme suit :

$$\min_{w,b} \frac{1}{N} \sum_{i=1}^N \|x_i - x_i'\|^2 - \lambda \cdot \sum_{i=1}^N \|f^t(x_i) - c_i^*\|^2 \quad (4.9)$$

$$c_i^* = \arg \min_{c_j^{t-1}} \|f^t(x_i) - c_j^{t-1}\|^2 \quad (4.10)$$

N est le nombre d'échantillons dans l'ensemble de données, $f^t(x_i)$ est la fonction de mappage non linéaire à l'itération t et c_j^{t-1} le centre du $j^{\text{ème}}$ cluster calculé à l'itération $t-1$. c_i^* est le centre de cluster le plus proche du $i^{\text{ème}}$ échantillon dans la couche de code. Les auteurs utilisent la

descente de gradient stochastique ou Stochastic Gradient Descent en anglais (SGD) pour optimiser les paramètres de l'auto-encodeur.

Cependant pour arriver à cette meilleure performance visée, deux composantes doivent être optimisées : la fonction de représentation $f(\cdot)$ et les centres de cluster c . Pour résoudre ce problème, Song et al. proposent une autre méthode d'optimisation qui optimise d'abord $f(\cdot)$ tout en maintenant c fixe, puis enfin met à jour le centre du cluster :

$$c_j^t = \frac{\sum_{x_i \in c_j^{t-1}} f^t(x_i)}{|c_j^{t-1}|} \quad (4.11)$$

Où c_j^{t-1} est l'ensemble des échantillons appartenant au cluster j après (t-1) itération et $|C_j|$ est le nombre d'échantillons dans ce cluster. L'affectation de l'échantillon calculée dans la dernière itération est utilisée pour mettre à jour les centres de cluster de l'itération courante. Il est important de remarquer que l'affectation de l'échantillon à la première itération C^0 est initialisée aléatoirement.

Sur la base de l'équation (4.6) en sélectionnant efficacement la fonction $f(\cdot)$ et en adaptant l'équation (4.11) à notre problème, pour un cluster noté CL_j , les coordonnées de son nouveau centre de gravité sont :

$$(X_j, Y_j) = \left(\frac{\sum_{U_i \in CL_j^{t-1}} f^t(x_i)}{|N_{U,j}|}, \frac{\sum_{U_i \in CL_j^{t-1}} f^t(y_i)}{|N_{U,j}|} \right) \quad (4.12)$$

4.3 Analyse d'une offre supplémentaire d'UAV

Malgré ces étapes d'optimisation afin de trouver les emplacements définitifs des UAV, nous pouvons constater que certains utilisateurs pourraient ne pas être desservis pour l'une des deux raisons :

- l'utilisateur se trouve dans la couverture d'un UAV qui a une capacité saturée, c'est-à-dire le nombre d'utilisateur dans son cluster valent ses capacités de service, ou;
- l'utilisateur ne se trouve dans aucune des zones de portée d'un UAV.

Par conséquent, nous devons vérifier à nouveau s'il est nécessaire d'ajouter un nouveau drone. Il s'agit de vérifier si cela pourrait augmenter le profit. Le nombre total d'utilisateurs non desservis est indiqué par $N_U^{non-servi}$ et est calculé comme :

$$N_U^{non-servi} = N_U - N_U^{servi} \quad (4.13)$$

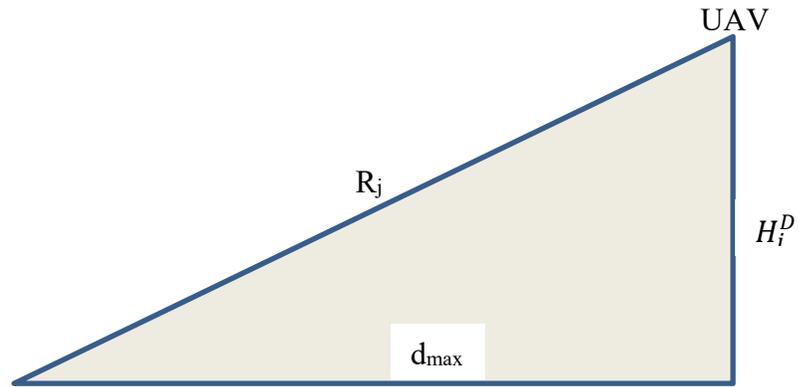
Où N_U^{servi} est le nombre d'utilisateurs couverts. Ensuite \hat{N}_D est à nouveau mis à jour en se basant sur l'équation (4.4). Dans le cas où \hat{N}_D est incrémenté, nous répétons le processus de recherche des nouveaux emplacements 2D en utilisant notre algorithme de partitionnement et positionnement jusqu'à ce qu'il n'y ait plus besoin de drone.

4.4 Recherche de l'altitude pour la couverture optimale

Pour un environnement particulier donné et une altitude h d'UAV donnée, tous les points au sol dans cette zone qui sont situés à une distance R , subissent la même perte de chemin PL . De plus, tous les points situés à distance $r \leq R$ peuvent subir une perte de chemin inférieure à celle subie par les points situés à la distance R (Alzenad et al., 2017). Nous remarquons ainsi l'importance de régler de façon optimale l'altitude de l'UAV afin de maximiser son service.

Ainsi une fois que les emplacements finaux 2D des UAV sont définis, nous déterminons les altitudes en fonction de l'utilisateur le plus éloigné mais inclus dans la zone de couverture de l'UAV avec une distance indiquée par d^{max} . Nous désignons également par R le rayon de couverture de l'UAV correspondant à la puissance d'émission maximale en supposant une antenne omnidirectionnelle. Par conséquent, l'altitude de l'UAV est déterminée par (Omran et al., 2020) :

$$H_j^D = \sqrt{R_j^2 - d_{max}^2} \quad (4.14)$$



Algorithme 4.1 Déploiement 3D dynamique d'UAVs

Algorithm : Déploiement 3D dynamique d'UAV

- 1:
- 2: Entrée: (x_i, y_i, h_i) , a , b , η^{LoS} , η^{NLoS} , Nombre de clusters K , hyper-paramètre λ , Nombre maximum d'itération T ;
- 3: Déterminer l'estimation \hat{N}_D ;
- 4:
- 5: Détermination des positions finales (X_j, Y_j) à l'aide de Deep K-means;
- 6: Fixer t à 1;
- 7:
- 8: Répéter
 - 9: Mettre à jour le réseau de mappage en minimisant l'équation (4.9) avec une descente de gradient stochastique pour un instant;
 - 10: Mettre à jour le centre des clusters c_t via l'équation (4.12);
 - 11: Affecter les utilisateurs aux différents clusters et mettre à jour les affectations suivant l'équation (4.10);
 - 12: $t = t + 1$
 - 13: Jusqu'à $t > T$
 - 14:
 - 15: Si un nouveau UAV est nécessaire
 - 16: Alors $\hat{N}_D = \hat{N}_D + 1$;
 - 17: Aller à 3;
 - 18: Sinon $N_D = \hat{N}_D$;
 - 19: FinSi
 - 20:
 - 21: Déterminer les altitudes H_j en utilisant (4.14);
 - 22:
 - 23: Output: (X_j, Y_j, H_j) , N_D

CHAPITRE 5

RÉSULTATS DES SIMULATIONS ET ANALYSES

Dans cette étude nous avons mis en évidence l'un des principaux problèmes que connaît les FANET et tentons de proposer une solution qui se veut efficace pour venir à bout de ce problème. Il s'agit en fait, lors d'un déploiement d'un réseau multi-UAV la procédure pour déterminer le nombre optimal d'UAV à déployer ainsi que leur meilleure position dans l'espace de mission afin de fournir le meilleur service possible aux utilisateurs. Ainsi dans les parties précédentes, nous avons détaillé la méthodologie et la conception de notre solution proposée qui tire parti de la puissance et l'efficacité des méthodes et techniques du Machine Learning déjà connu comme ayant fait ses preuves dans la résolution de problèmes bien complexes.

Après toutes ces démarches de conception et d'implémentation, nous allons dans ce chapitre présenter les résultats de nos simulations afin de les analyser en vue de mieux apprécier l'efficacité et les performances de notre solution.

Nous rappelons, de ce fait, que dans cette étude nous considérons le champ de couverture de notre réseau dans un espace délimité, sain et sans obstacle et que l'objectif principal visé est de maximiser le profit de l'opérateur tout en assurant pour les utilisateurs un service de qualité ajusté à leur besoin. Nous présentons les résultats de notre simulation sous l'environnement de simulation Matlab/Simulink.

5.1 Paramètres de simulation

Dans notre simulation, nous considérons une zone de forme carrée avec un nombre d'utilisateurs variant entre 180 et 355. Les utilisateurs sont répartis aléatoirement dans la zone selon une distribution normale. On suppose que chaque drone peut admettre 30 utilisateurs sans exigences particulières et donc moins d'utilisateurs si certains ont des exigences de service

différentes de la normale. La zone est supposée être une zone urbaine mais nous ne traiterons pas le cas avec les obstacles.

Tableau 5.1 Paramètre de simulation

Paramètres	Valeurs
Taille de la zone	1 km ²
Nombre de clients N_u	Entre 180 et 355
RB^{\max}	30
P_{service}	9
C^{UAV}	19
C^{power}	2
P_{ij}	4
N_D^{\max}	30
η^{LoS}	1
η^{NLoS}	20
Les constantes a et b	9.61 et 0.16 respectivement
f_c (GHz)	2

5.2 Résultats et analyses

5.2.1 Détermination du nombre préliminaire des UAV

Comme présenté dans notre démarche, nous allons, dans cette première étape de résolution de notre problème, chercher à déterminer le nombre préliminaire suffisant d'UAV à déployer pour couvrir tous les utilisateurs. Sur la base du nombre des utilisateurs et en tenant compte de leurs différentes exigences de service, nous allons adopter le nombre d'UAV qui maximise le profit de l'opérateur.

5.2.1.1 Nombre des UAV sans les exigences de service des utilisateurs

En faisant recours à l'équation (4.1) pour déterminer le nombre préliminaire des UAV à déployer sans tenir compte des exigences des utilisateurs dans un premier temps, nous pouvons obtenir les résultats présentés par le tableau 5.2 suivant :

Tableau 5.2 Nombre d'UAV selon le nombre d'utilisateurs sans exigences de service

N_U	180	205	230	255	280	305	330	355
\hat{N}_D	6	6	7	8	9	10	11	11

Notre objectif principal exprimé en (3.16) est de maximiser le profit P tout en desservant le maximum d'utilisateur possible. De ce fait il serait judicieux dans notre démarche de vérifier par la suite si le nombre d'utilisateurs non desservis ne nécessite pas l'ajout d'un autre UAV qui par la même occasion pourrait augmenter le profit de l'opérateur. Pour cela nous avons développé un petit code sur MATLAB qui prend en compte un certain nombre de paramètre et nous aide à déterminer plus facilement ce nombre selon les situations.

À l'aide de nos paramètres de simulation et de notre algorithme de détermination du nombre optimal d'UAV qui tient compte des contraintes en (4.3) et (4.4) nous pouvons nous assurer du nombre optimal de drone à déployer selon le nombre d'utilisateur suivant la figure ci-dessous.

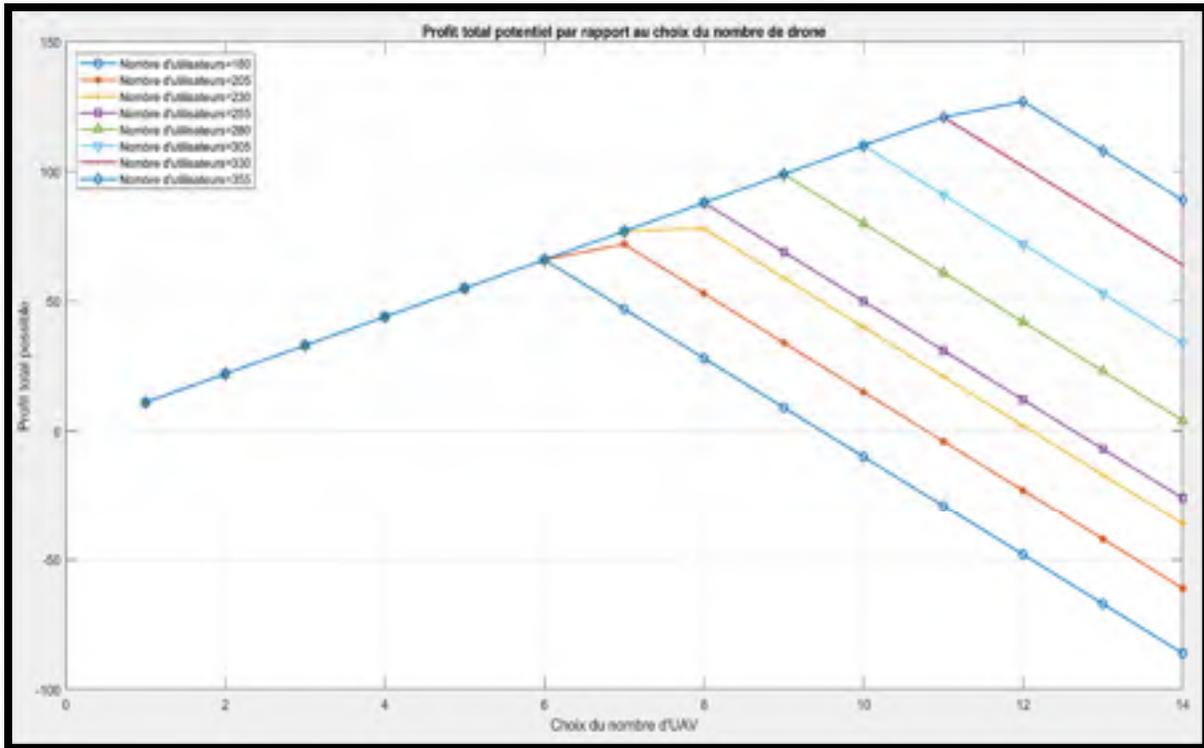


Figure 5.1 Profit total potentiel par rapport au nombre d'UAV et d'utilisateurs sans exigences de service

La Figure 5.1 ci-dessus nous fait remarquer que pour un nombre donné d'utilisateurs, il existe un nombre spécifique de drones qui permet d'obtenir le profit le plus élevé. Par exemple, pendant que dans le tableau des résultats théoriques, pour 205 utilisateurs, le nombre théorique de drone était 6, notre algorithme nous propose 7, une valeur qui d'ailleurs en plus de servir plus d'utilisateur augmente le profit à 72 au lieu de 66 pour 6 drones.

Cela est dû au fait qu'en prenant en compte la capacité d'admission de chaque drone ainsi que nos paramètres pour le calcul du gain et des coûts de service, nous avons introduit une constante qui permet à l'opérateur d'ajouter un drone à l'effectif tout en augmentant son profit si le nombre d'utilisateur à desservir est supérieur au deux-tiers ($2/3$) de la capacité totale ou des ressources disponible de l'UAV (RB^{max}) soit au moins 20 utilisateurs.

5.2.1.2 Nombre des UAV en tenant compte des exigences de service utilisateurs

Maintenant que nous avons pu mesurer l'efficacité de notre algorithme, nous pouvons l'utiliser pour déterminer le nombre optimal d'UAV nécessaire permettant de maximiser le profit tout en maximisant le nombre d'utilisateur desservi et en prenant en compte les exigences variées de chaque utilisateur.

Dans notre simulation nous générons des valeurs aléatoires, à partir d'une distribution normale, comprises dans l'intervalle $[1 ; 2[$, c'est-à-dire la valeur sera égale ou supérieure à 1 et strictement inférieure à 2, exprimant les exigences des différents demandeurs au sol.

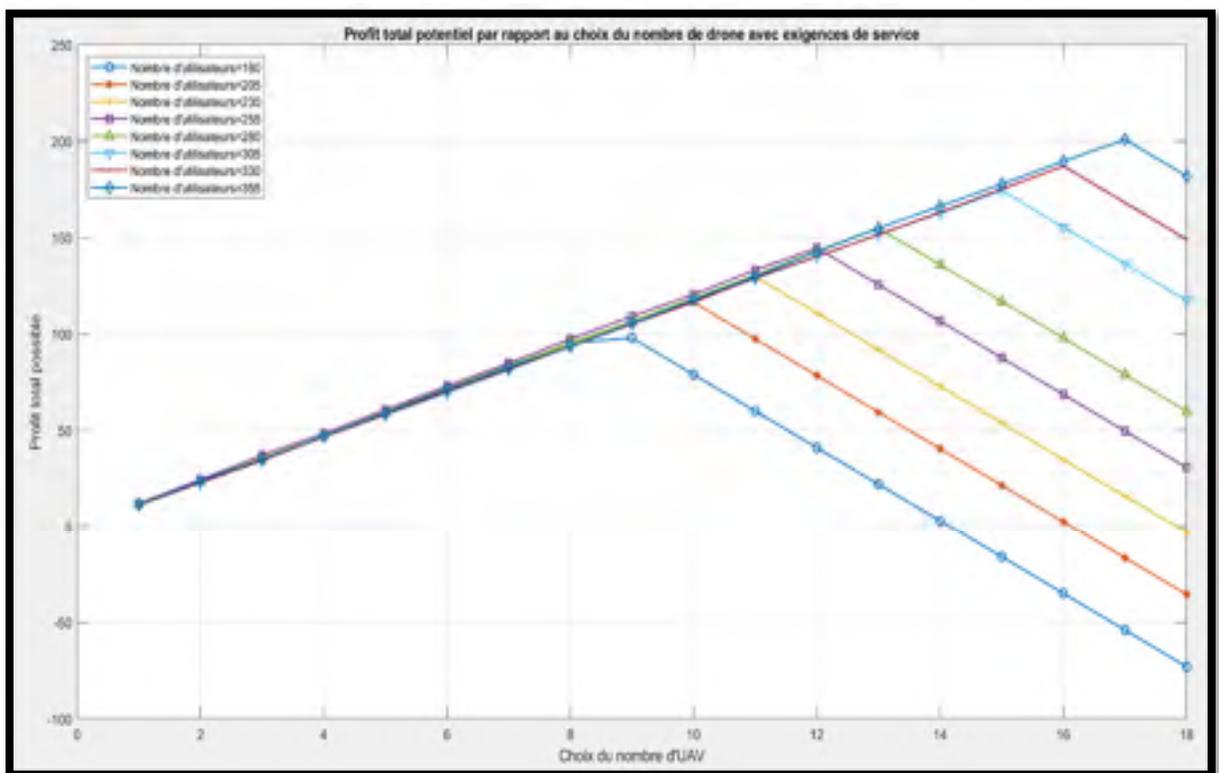


Figure 5.2 Profit total potentiel par rapport au nombre d'UAV et d'utilisateurs avec les exigences de service

La Figure 5.2 ci-dessus nous fait remarquer que pour un nombre donné d'utilisateurs avec des exigences variées de service, il existe un nombre spécifique de drones qui permet d'obtenir le

profit le plus élevé. Pour un même nombre, soit 205 utilisateurs dans le cas précédent, sans tenir compte des exigences, on avait besoin de 7 drones pour produire environ un profit de 72. Ici en desservant les utilisateurs suivant leurs exigences, le système demande plus d'UAV, à savoir 10 comme nombre optimal. Cependant le profit monte à environ 117.

De cette petite analyse nous pouvons remarquer qu'il est bien possible de faire un bon profit en utilisant plusieurs drones et en répondant exactement aux besoins variés des différents clients dans une zone.

5.2.2 Optimisation de la fonction de reconstruction

Dans cette sous-section nous allons faire apprendre notre algorithme d'auto-encodeur afin qu'il soit assez performant pour optimiser le positionnement de nos UAV pour une meilleure couverture. Pour cela nous allons analyser l'influence des itérations sur notre fonction de représentation. En effet pour optimiser la fonction objective de l'auto-encodeur, l'une des premières étapes à réaliser est l'optimisation de la fonction qui minimise l'erreur de reconstruction.

Ainsi dans cette étape et pour la suite de notre étude nous allons adopter comme nombre d'utilisateurs au sol, la valeur 280.

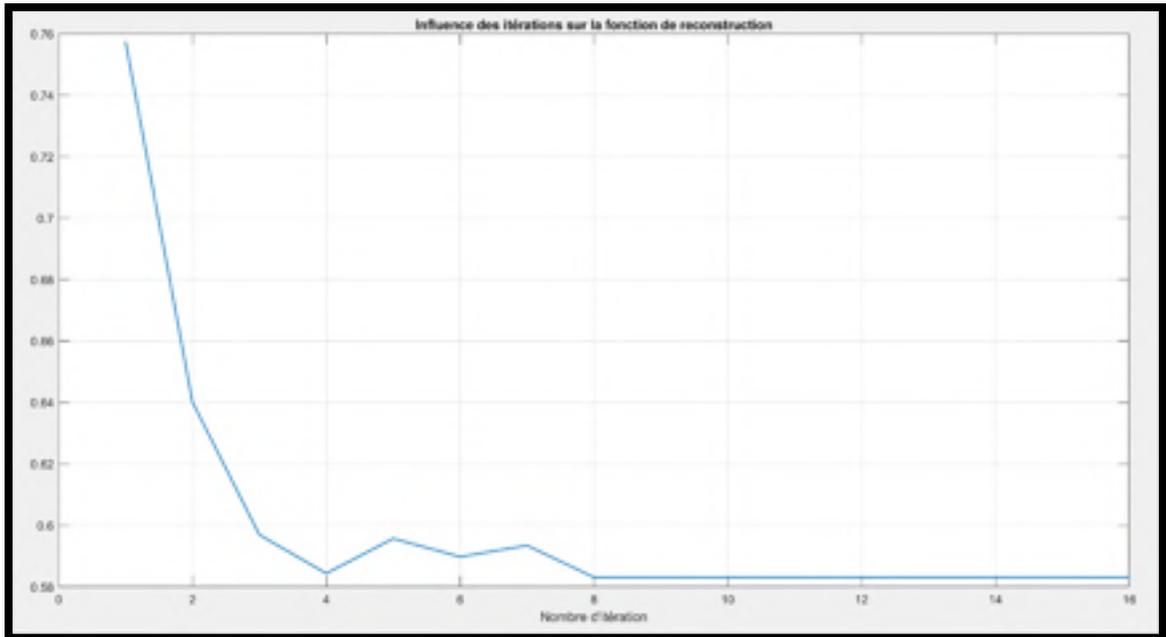


Figure 5.3 Influence des itérations sur la fonction de reconstruction

A travers la figure 5.3 ci-dessus nous pouvons observer la variation de la fonction de reconstruction au fur et à mesure que les itérations augmentent.

Dès la deuxième (2^e) itération, la valeur de la fonction chute considérablement et cette valeur continue de descendre jusqu'à la quatrième (4^e) itération où elle atteint sa valeur minimale exprimant ainsi la performance de notre fonction optimisée et permettant de minimiser l'erreur de reconstruction dans notre fonction d'auto-encodeur.

Cependant c'est jusqu'à partir de l'itération huit (8) que la fonction se stabilise réellement. De ce fait, pour s'assurer de profiter pleinement des performances de notre fonction dans l'optimisation du positionnement de nos UAV pour couvrir efficacement nos 280 utilisateurs, nous allons adopter la valeur dix (10) comme nombre maximum d'itération.

5.2.3 Positionnement dynamique des UAV à l'aide du Deep K-means

Le nombre d'UAV nécessaire à déployer pour couvrir une zone afin de desservir un nombre correspondant d'utilisateurs au sol tout en maximisant le profit de l'opérateur étant connu, nous pouvons par la suite déployer nos stations de base aérienne.

Nous allons de ce fait dans cette partie nous servir de notre algorithme de positionnement basé sur la méthode des K-moyennes profond qui lui-même tire sa puissance des réseaux de neurones profonds. Dans notre simulation réalisée dans une zone de 1km^2 , nous adoptons, pour une meilleure lecture des paramètres et appréciation des résultats, environ 280 utilisateurs repartis de façon aléatoire sur le terrain ayant chacun une exigence particulière en termes de ressource auprès de l'UAV qui assure sa couverture. D'après la Figure 5.2, un tel nombre d'utilisateur requiert 13 UAV pour une couverture optimale et le meilleur profit possible pour l'opérateur en tenant compte bien sûr des exigences de services des utilisateurs.

Nous allons présenter les positions des différents UAV juste au moment de leur déploiement à la première itération et leur position finale donnée par notre algorithme à la fin des itérations (de son exécution).

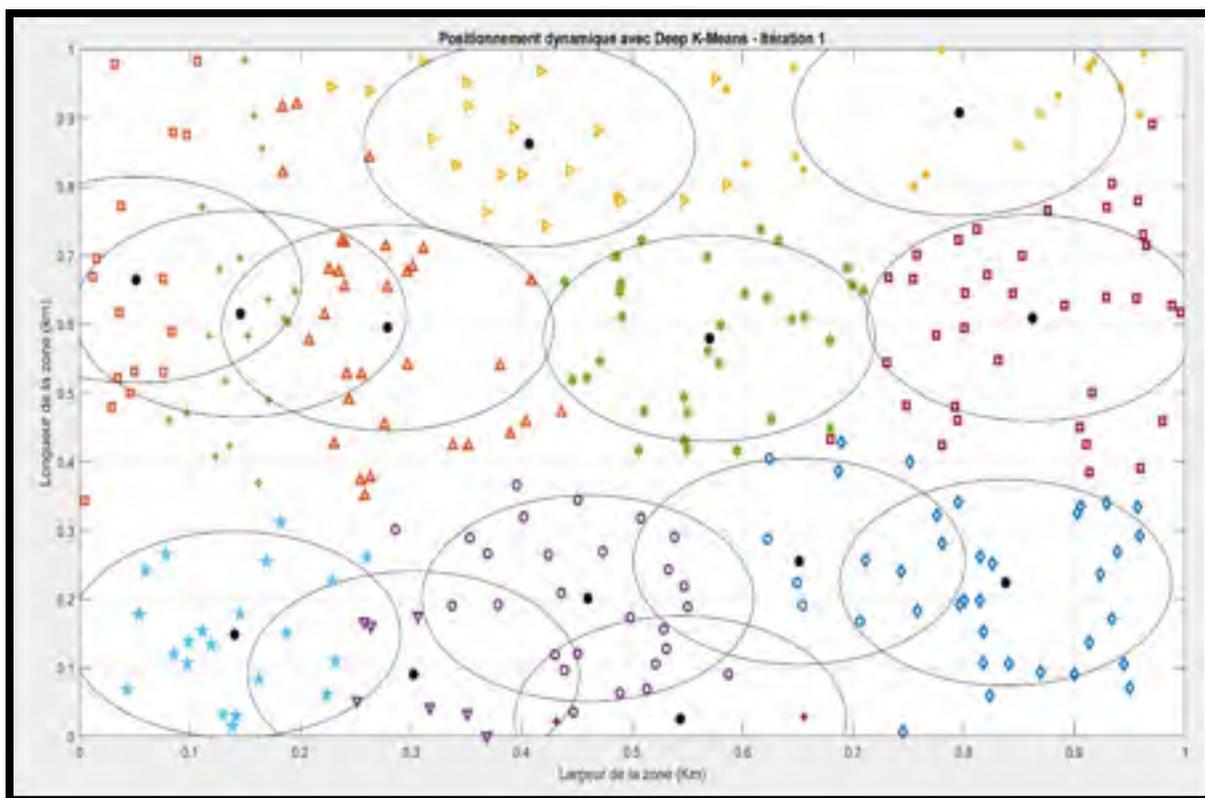


Figure 5.4 Positionnement dynamique des UAV avec Deep K-Means à l'itération 1

La Figure 5.4 ci-dessus nous montre un emplacement aléatoire des drones dans l'environnement de mission lors de leur déploiement, avant l'exécution totale de notre algorithme de positionnement. En effet sans notre méthode proposée, les UAV pourraient rester dans ces positions pour fournir le service. Cependant comme le montre la figure, ces positions ne contribuent en aucun cas à la bonne réalisation de la mission qui est de couvrir tous les utilisateurs en prenant en compte leurs exigences de service tout en maximisant le profit de l'opérateur.

Nous pouvons remarquer facilement qu'il pourrait avoir un gaspillage de ressources au niveau des stations de base aériennes dans certains secteurs et un manque dans d'autres. Pendant que certains UAV semblent être surchargés et ne pourront pas fournir correctement le service, d'autres UAV sont presque sans utilisateurs. Par ailleurs certains utilisateurs sont couverts à la fois par 3 UAV dans certaines parties de la zone pendant que nous observons d'autres sans

couverture et même très loin de l'AV le plus proche. Nous observons une partition non équilibrée de la zone de mission.

Cette observation démontre combien de fois il est plus qu'important que l'algorithme de positionnement soit intelligent afin de calculer les positions optimales suivant la répartition des utilisateurs à couvrir et suivant les capacités des drones.

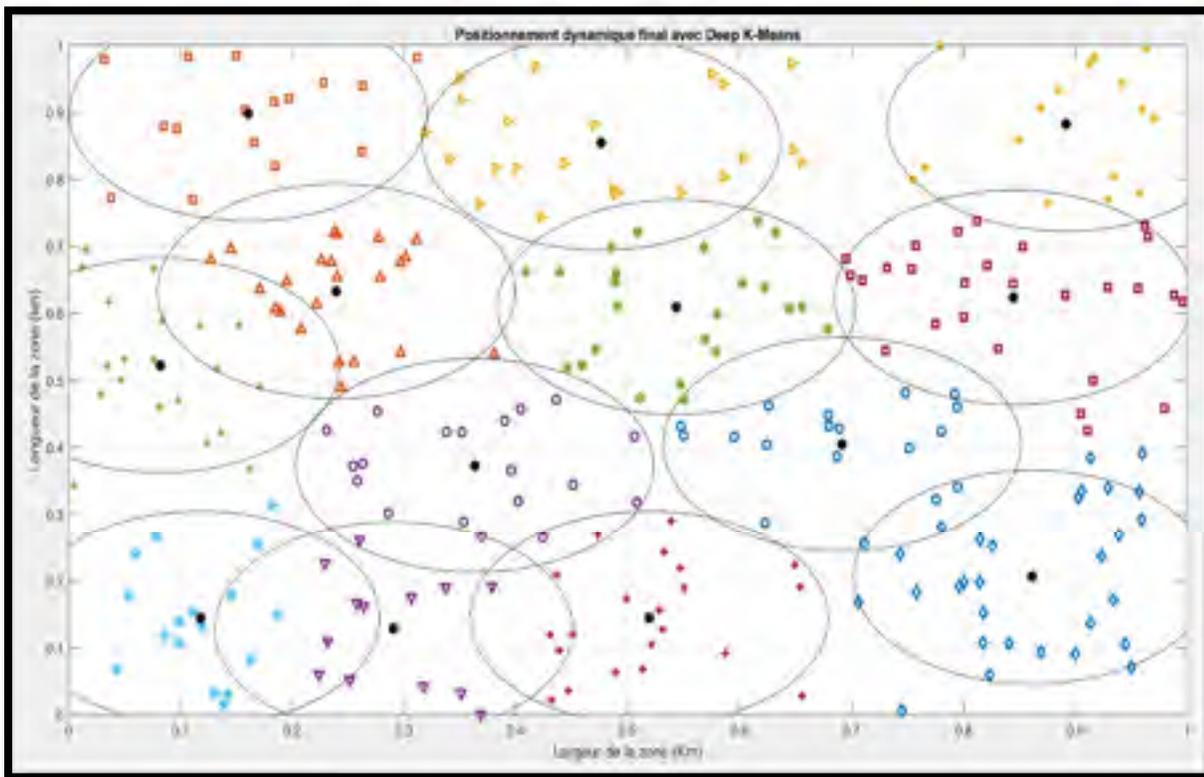


Figure 5.5 Positionnement dynamique final des UAV avec Deep K-Means

La Figure 5.5 montre les emplacements finaux des drones résultant du schéma proposé dans cette étude et la partition correspondante sur la zone. Tout d'abord aucun utilisateur n'est couvert par plus de 2 UAV. Le nombre d'utilisateurs hors du rayon de couverture est minime et d'ailleurs les frontières de partition sont basées sur la théorie que les UAV ayant plusieurs utilisateurs à desservir puisse partager au cas échéant la couverture de certains de leur utilisateur (ceux couverts par deux UAV) afin de pouvoir desservir les autres hors de son rayon

mais qui lui sont effectivement proche. En effet pour y arriver notre algorithme aura à modifier périodiquement la hauteur de l'UAV pour agrandir son champ de couverture. Aussi nous pouvons identifier un aspect de nos contraintes bien respecté qui est qu'aucun UAV ne peut desservir plus de 30 utilisateurs à lui seul.

D'autre part nous montrons que les utilisateurs sont associés aux drones d'une manière garantissant une taille de cellule égale et une qualité de service élevée en raison de l'association avec un drone relativement proche.

Un autre aspect qui aurait été intéressant mais que nous n'avons pas traité dans cette étude est de permettre à l'algorithme de s'exécuter de façon périodique, par exemple chaque minute, afin d'ajuster les positions des UAV dans le cas où les utilisateurs au sol se déplacent afin de prévenir une éventuelle congestion ou une partition déséquilibrée de la zone de mission.

5.2.4 Efficacité du Deep K-Means par rapport au K-Means traditionnel

Comme observé précédemment, notre approche nous assure un meilleur positionnement garantissant une meilleure fourniture de service et de qualité. Notre proposition prend en compte plusieurs aspects dans son exécution qui la rend assez complexe mais en même temps très précis dans ses calculs pour un résultat optimal et très efficace pour une meilleure couverture quel que soit la situation. Qu'en est-il de la méthode traditionnelle de partitionnement k-moyennes?

Dans cette partie nous allons évaluer l'efficacité de notre schéma de positionnement proposé par rapport à celui du K-Means normal. Nous allons observer le pourcentage d'utilisateurs desservis dans plusieurs cas en considérant dans chaque situation un nombre fixe d'UAV disponible qui sera 15 UAV.

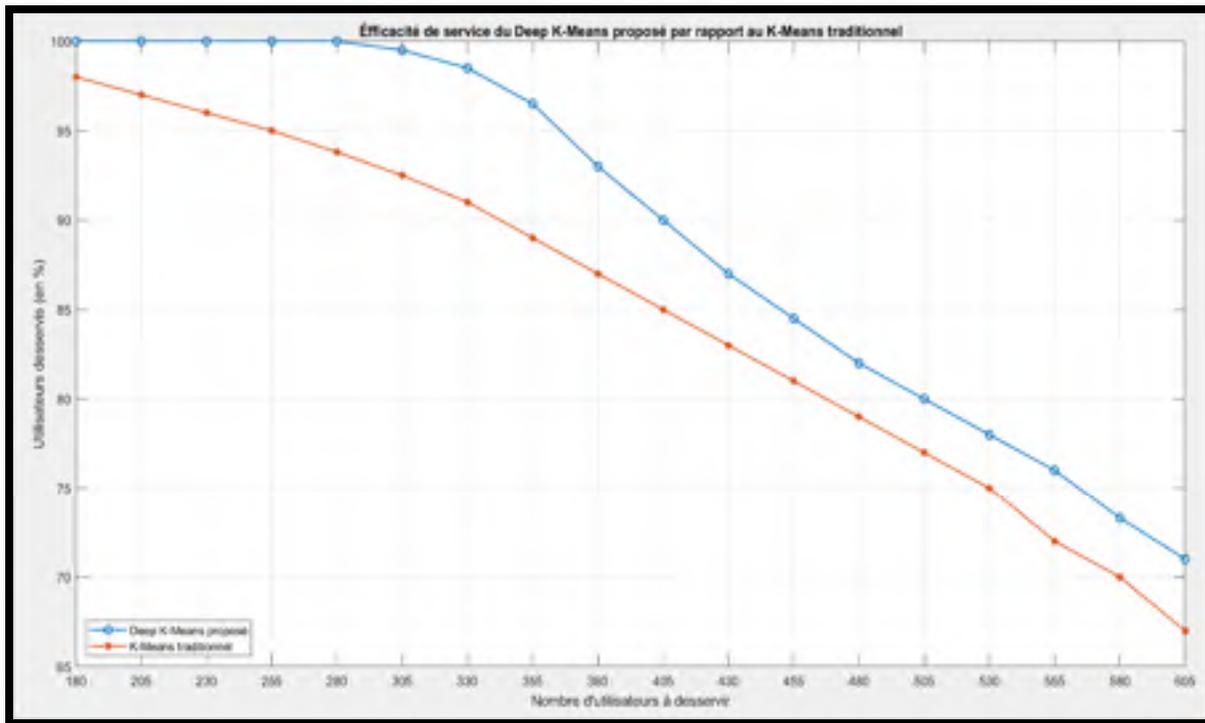


Figure 5.6 Efficacité de service du Deep K-Means par rapport au K-Means traditionnel

La Figure 5.6 ci-dessus montre le pourcentage d'utilisateurs desservis exprimant l'efficacité de service de notre schéma de Deep K-Means proposé par rapport à celui du K-Means. Nous pouvons observer que la méthode proposée surpasse la méthode traditionnelle en servant plus d'utilisateurs pour un même nombre d'UAV égale à 15.

Jusqu'à 330 utilisateurs à desservir, les performances optimales de notre système sont observées. Lorsque le nombre de ressources disponibles correspond au nombre d'utilisateurs dans le système, comme nous pouvons le remarquer dans le cas de 305 utilisateurs (la Figure 2 recommande 15 UAV pour 305 utilisateurs), non seulement notre système est largement plus efficace que son concurrent mais en plus, il démontre par sa performance comment il est capable d'assurer une meilleure couverture prenant en compte les exigences variées des utilisateurs.

La raison de cette performance est que notre schéma tire parti de la puissance des auto-encodeurs qui peut être utilisé pour améliorer le K-Means; ce qui optimise les emplacements des UAV en fonction de la densité des utilisateurs.

5.3 Conclusion

Les simulations présentées dans ce chapitre ont pour objectif d'évaluer les performances de notre système de déploiement d'un réseau d'UAV, proposé dans cette étude. Le système présente des caractéristiques intéressantes qui le rendent particulier. En effet notre solution propose une démarche simple, à l'aide d'un algorithme, pour obtenir le nombre optimal d'UAV à déployer selon l'ampleur de la mission. Nous pouvons apprécier l'efficacité de cet algorithme en analysant les résultats de simulation présentés à la Figure 5.2 qui présente le nombre optimal d'UAV à prendre en compte pour garantir le meilleur profit tout en assurant la meilleure couverture possible pour les utilisateurs au sol.

De même les Figures 5.5 et 5.6 mettent en évidence l'efficacité de notre solution qui accorde un meilleur profit à l'opérateur et présente des performances satisfaisantes. En effet les simulations nous ont permis d'évaluer et de valider notre système comme étant un nouveau schéma de déploiement d'un réseau multi-UAV permettant de positionner les UAV de façon à maximiser les utilisateurs desservis et par la même occasion maximiser le profit de l'opérateur. Cette contribution s'insère bien dans la grande vague des recherches actuelles en donnant des outils efficaces qui intègrent l'apprentissage automatique en vue de maximiser le nombre d'utilisateurs desservis avec des exigences de service variées tout en maximisant les bénéfices de l'opérateur.

CONCLUSION

Dans cette étude nous avons porté notre attention particulièrement sur l'un des principaux problèmes que connaît les FANET lors de leur déploiement, à savoir le problème de positionnement des UAV dans le réseau, un facteur qui constitue l'un des principaux éléments affectant la qualité du service offert. Ainsi le but principal de cette recherche était de proposer un schéma de déploiement 3D d'UAV qui aboutit à maximiser le nombre d'utilisateurs desservis en tenant compte de leurs exigences en termes de qualité de service, de la variation de la densité des utilisateurs sur l'ensemble du réseau compte tenu de leur distribution aléatoire tout en maximisant le profit de l'opérateur.

Pour atteindre efficacement notre objectif fixé, une approche en trois (3) grandes étapes a été élaborée. Dans un premier temps nous avons déterminé à l'aide d'un algorithme le nombre optimal d'UAV nécessaire pour assurer la meilleure couverture possible pour les utilisateurs. Nous avons d'abord estimé un nombre préliminaire d'UAV qui était en fait le nombre minimal pour couvrir le maximum d'utilisateur possible. Par la suite selon la proportion d'utilisateurs non desservis et dans le souci de maximiser le profit de l'opérateur, ce nombre préliminaire d'UAV était réévalué afin d'intégrer ou non un nouvel UAV à la mission. Par la suite nous avons déterminé les emplacements 2D des UAV à l'aide d'une approche qui à la fois tire, d'une part, sa simplicité de la méthode des k-moyennes et d'autre part sa puissance et son efficacité des auto-encodeurs, une forme spéciale de réseau de neurones en couches bien adapté à notre problème. Enfin la dernière grande étape nous permettait de déterminer l'altitude optimale de l'UAV de façon à maximiser son service.

Ainsi notre approche a été évaluée et validée par des simulations en considérant différentes situations à travers lesquelles les résultats numériques nous ont montré que notre méthode proposée, le Deep K-means, présente une meilleure couverture d'utilisateurs et un profit plus élevé par rapport au fait d'adopter uniquement le clustering k-means traditionnel.

Dans cette recherche nous avons contribué à maximiser le profit de l'opérateur tout en maximisant le nombre d'utilisateurs desservis pendant que ces utilisateurs avaient des exigences de service variées, et cela en employant des techniques d'apprentissage automatique permettant d'optimiser le positionnement des UAV dans le réseau lors d'un déploiement d'un réseau FANET pour une mission.

À l'avenir, des limitations telles que l'efficacité énergétique qui peut influencer la durée de vie de la mission, ainsi que la sécurité dans la communication qui assure la disponibilité, l'intégrité et la confidentialité des données, et qui n'ont pas été prises en compte dans cette recherche pourront servir d'orientation afin de pousser plus loin le champ de vision d'une telle recherche.

RECOMMANDATIONS

Bien que le travail présenté dans cette recherche ait permis d'atteindre notre objectif principal, il est important de souligner que certains aspects auraient pu être améliorés. En effet, l'approche mise en avant dans cette étude reste performante au niveau théorique en simulation malgré les différentes situations utilisées pour la généraliser. Le système a été validé avec succès en simulation, il serait intéressant d'envisager dans des travaux futurs, d'améliorer les capacités du système afin de l'implémenter en pratique.

Par ailleurs dans notre étude, lors du déploiement, les différents clusters étaient représentés par les différents drones prévus pour la mission d'où le nombre de cluster étant égal au nombre d'UAV. Une telle approche non seulement ne favorise pas une meilleure coopération et collaboration entre les drones, mais aussi n'optimise pas la segmentation de la zone. Cela peut aussi impacter la durée de vie du réseau ou de la mission qui est un paramètre important dans les réseaux d'UAV, et qui dépend par exemple de l'arrêt d'un certain nombre de nœuds en raison de l'épuisement énergétique. Il est de ce fait important de favoriser la coopération des nœuds tout en réduisant les interférences de communication et prolonger ainsi la durée de vie du réseau.

Par conséquent il serait judicieux d'adopter un réseau hiérarchique basé sur un mécanisme de clustering où le processus de regroupement prend en compte la sélection de la tête de cluster. Le système en utilisant un protocole de communication et de routage bien adapté pourra non seulement permettre d'optimiser la segmentation de la zone suivant de grands clusters mais aussi minimiser la communication entre les différents UAV, garantissant une bonne durée de vie du réseau par une économie d'énergie et une meilleure coopération et collaboration entre les différents drones.

Par ailleurs, comme mentionné dans la conclusion générale, il serait aussi intéressant de se pencher sur l'aspect sécurité dans la communication inter-UAV et avec la base au sol afin de contrôler les échanges entre les différents nœuds ou entités dans l'ensemble du réseau; aussi

prendre en compte la gestion efficace de l'énergie dans le réseau afin de garantir un service de qualité avec un système robuste qui pourra être généralisé, s'adaptant à diverses situations et divers scénarios.

LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES

- Y. Sun, T. Wang and S. Wang, "Location Optimization for Unmanned Aerial Vehicles Assisted Mobile Networks" 2018 IEEE International Conference on Communications (ICC), Kansas City, MO, 2018, pp. 1-6, doi: 10.1109/ICC.2018.8423028.
- M. Alzenad, A. El-Keyi, F. Lagum and H. Yanikomeroglu, "3-D Placement of an Unmanned Aerial Vehicle Base Station (UAV-BS) for Energy-Efficient Maximal Coverage," in IEEE Wireless Communications Letters, vol. 6, no. 4, pp. 434-437, Aug. 2017, doi: 10.1109/LWC.2017.2700840.
- D. David & J. Panhaleux (2015). Les drones civils, enjeux et perspectives. Rapport n° 008816-01, MINISTÈRE DE L'ÉCOLOGIE, DU DÉVELOPPEMENT DURABLE ET DE L'ÉNERGIE, République Française, ladocumentationfrancaise, France.
- Studiofly Audiovisuel (2018). "Histoire du Drone : Un siècle de recherches et d'élaboration". En ligne <https://www.studiofly.fr/les-drones-un-siecle-de-recherches-et-d-elaboration> (Consulté au mois de Juin 2020)
- General Atomics MQ-1 Predator. (2020). Dans Wikipédia. https://en.wikipedia.org/wiki/General_Atomics_MQ-1_Predator (Consulté au mois de Juin 2020)
- J-A. Maxa (2017). Architecture de communication sécurisée d'une flotte de drones. Thèse de Doctorat, Réseaux et télécommunications [cs.NI]. Université Toulouse 3 Paul Sabatier, 2017. Français. tel-01570242v1
- Phantom 4 Pro V2.0 Intelligence visionnaire, Imagination sublimée. (2020). En ligne <https://www.dji.com/ca-fr/phantom-4-pro-v2> (Consulté au mois de Juin 2020)
- Jjrc H8 Mini Drone Eachine H8 Mini Drone Rtf Rc Quadricoptère 2.4Ghz. (2020). En ligne <https://www.tokopedia.com/rahmaayuningsih/jjrc-h8-mini-drone-eachine-h8-mini-drone-rtf-rc-quadcopter-2-4ghz> (Consulté au mois de Juin 2020)
- S. Vashist and S. Jain, "Location-Aware Network of Drones for Consumer Applications: Supporting Efficient Management Between Multiple Drones," in IEEE Consumer Electronics Magazine, vol. 8, no. 3, pp. 68-73, May 2019, doi: 10.1109/MCE.2019.2892279.

- Zacc Dukowitz (2019). Les drones en recherche et sauvetage. En ligne <https://uavcoach.com/search-and-rescue-drones/>
(Consulté au mois de Juin 2020)
- M. Hampson (2018). Maryland Test Confirms Drones Can Safely Deliver Human Organs. Article en ligne <https://spectrum.ieee.org/the-human-os/robotics/drones/test-run-confirms-that-drones-can-safely-deliver-organs-for-transplant>
(Consulté au mois de Juin 2020)
- F. Qi, X. Zhu, G. Mang, M. Kadoch and W. Li, "UAV Network and IoT in the Sky for Future Smart Cities," in IEEE Network, vol. 33, no. 2, pp. 96-101, March/April 2019, doi: 10.1109/MNET.2019.1800250.
- 1001crash.com. (Août 2016). "La menace des drones sur la sécurité de l'aviation civile". En ligne <https://www.1001crash.com/index-page-drone-lg-1.html>
(Consulté au mois de Juin 2020)
- DRONE PULVÉRISATEUR AGRICOLE 6L – JT6L-606 (2020). En ligne <https://helsel.eu/produit/drone-pulverisateur-agricole-6l-jt6l-606/>
(Consulté au mois de Juin 2020)
- Wireless ad hoc network. (2020, 18 Juillet). En ligne https://en.wikipedia.org/wiki/Wireless_ad_hoc_network
(Consulté au mois de Juillet 2020)
- Fadi AL-Turjman & Hadi Zahmatkesh (2020). A Comprehensive Review on the Use of AI in UAV Communications: Enabling Technologies, Applications, and Challenges. Part of the Unmanned System Technologies book series (UST), Unmanned Aerial Vehicles in Smart Cities pp 1-26
- M. Y. Arafat and S. Moh, "Routing Protocols for Unmanned Aerial Vehicle Networks: A Survey," in IEEE Access, vol. 7, pp. 99694-99720, 2019, doi: 10.1109/ACCESS.2019.2930813.
- O. S. Oubbati, M. Atiquzzaman, P. Lorenz, M. H. Tareque and M. S. Hossain, "Routing in Flying Ad Hoc Networks: Survey, Constraints, and Future Challenge Perspectives," in IEEE Access, vol. 7, pp. 81057-81105, 2019, doi:10.1109/ACCESS.2019.2923840.
- Apprentissage Machine. (s.d.). En ligne <https://www.hisour.com/fr/machine-learning-42773/>
(Consulté au mois de Juillet 2020)

- Abdul Washid. (2017). Big data and machine learning for businesses. En ligne <https://www.slideshare.net/awahid/big-data-and-machine-learning-for-businesses>
- J. Park, Y. Kim & J. Seok, "Prediction of information propagation in a drone network by using machine learning," 2016 International Conference on Information and Communication Technology Convergence (ICTC), Jeju, 2016, pp. 147-149, doi: 10.1109/ICTC.2016.7763456.
- Y. Yang, Z. Gao, Y. Zhang, Q. Yan and D. He, "Codeword Selection for Concurrent Transmissions in UAV Networks: A Machine Learning Approach," in IEEE Access, vol. 8, pp. 26583-26590, 2020, doi: 10.1109/ACCESS.2020.2968533
- M. Alzenad, A. El-Keyi, F. Lagum & H. Yanikomeroglu, "3-D Placement of an Unmanned Aerial Vehicle Base Station (UAV-BS) for Energy-Efficient Maximal Coverage," in IEEE Wireless Communications Letters, vol. 6, no. 4, pp. 434-437, Aug. 2017, doi: 10.1109/LWC.2017.2700840.
- B. Galkin, J. Kibilda & L. A. DaSilva, "Deployment of UAV-mounted access points according to spatial user locations in two-tier cellular networks," 2016 Wireless Days (WD), Toulouse, 2016, pp. 1-6, doi: 10.1109/WD.2016.7461487.
- A. Omran, L. Sboui, M. Kadoch, Z. Chang, J. Lu & R. Liu, "3D Deployment of Multiple UAVs for Emergent On-Demand Offloading," 2020 International Wireless Communications and Mobile Computing (IWCMC), Limassol, Cyprus, 2020, pp. 692-696, doi: 10.1109/IWCMC48107.2020.9148252.
- S. ur Rahman, G. Kim, Y. Cho & A. Khan, "Positioning of UAVs for throughput maximization in software-defined disaster area UAV communication networks," in Journal of Communications and Networks, vol. 20, no. 5, pp. 452-463, Oct. 2018, doi: 10.1109/JCN.2018.000070.
- Q. Zhang, M. Mozaffari, W. Saad, M. Bennis & M. Debbah, "Machine Learning for Predictive On-Demand Deployment of Uavs for Wireless Communications," 2018 IEEE Global Communications Conference (GLOBECOM), Abu Dhabi, United Arab Emirates, 2018, pp. 1-6, doi: 10.1109/GLOCOM.2018.8647209.
- Y. M. Park, M. Lee & C. S. Hong, "Multi-UAVs Collaboration System based on Machine Learning for Throughput Maximization," 2019 20th Asia-Pacific Network Operations and Management Symposium (APNOMS), Matsue, Japan, 2019, pp. 1-4, doi: 10.23919/APNOMS.2019.8892962.

- P. Zhao, X. Liu, Y. Liu, Y. Chen & K. K. Chai, "Machine Learning for Position Prediction and Determination in Aerial Base Station System," ICC 2019 - 2019 IEEE International Conference on Communications (ICC), Shanghai, China, 2019, pp. 1-6, doi: 10.1109/ICC.2019.8761117.
- M. Zamini & G. Montazer, "Credit Card Fraud Detection using autoencoder based clustering," 2018 9th International Symposium on Telecommunications (IST), Tehran, Iran, 2018, pp. 486-491, doi: 10.1109/ISTEL.2018.8661129.
- E. Kalantari, H. Yanikomeroğlu & A. Yongacoglu, "On the Number and 3D Placement of Drone Base Stations in Wireless Cellular Networks," 2016 IEEE 84th Vehicular Technology Conference (VTC-Fall), Montreal, QC, 2016, pp. 1-6, doi: 10.1109/VTCFall.2016.7881122.
- P. CAZIN, Histoire des drones. Encyclopædia Universalis. Article de <https://www.universalis.fr/encyclopedie/drones/2-histoire-des-drones/> (Consulté au mois de Juin 2020)
- Partitionnement de données. (2020, 19 juillet). Dans Wikipédia. En ligne https://fr.wikipedia.org/wiki/Partitionnement_de_donn%C3%A9es (Consulté au mois de Juillet 2020)
- Ridhigrg. (2019). Clear your basics of Neural Networks in Machine Learning. En ligne <https://www.houseofbots.com/news-detail/12150-1-clear-your-basics-of-neural-networks-in-machine-learning> (Consulté au mois de Septembre 2020)
- A. Al-Hourani, S. Kandeepan & S. Lardner, "Optimal LAP Altitude for Maximum Coverage," in IEEE Wireless Communications Letters, vol. 3, no. 6, pp. 569-572, Dec. 2014, doi: 10.1109/LWC.2014.2342736.
- Imran us Salam. (2019). Autoencoders — Guide and Code in TensorFlow 2.0. En ligne <https://medium.com/red-buffer/autoencoders-guide-and-code-in-tensorflow-2-0-a4101571ce56> (Consulté au mois d’Août 2020)
- Song C., Liu F., Huang Y., Wang L., Tan T. (2013) Auto-encoder Based Data Clustering. In: Ruiz-Shulcloper J., Sanniti di Baja G. (eds) Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications. CIARP 2013. Lecture Notes in Computer Science, vol 8258. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-41822-8_15

- Artem Oppermann. (2019). What is Deep Learning and How does it work? En ligne <https://towardsdatascience.com/what-is-deep-learning-and-how-does-it-work-2ce44bb692ac>
(Consulté au mois d’Août 2020)
- Junru Wu, Yue Wang, Zhenyu Wu, Zhangyang Wang, Ashok Veeraraghavan & Yingyan Lin. (2018) Deep k-Means: Re-Training and Parameter Sharing with Harder Cluster Assignments for Compressing Deep Convolutions. Proceedings of the 35th International Conference on Machine Learning, Stockholm, Sweden, PMLR 80, 2018.
- X. Liu, Y. Liu, Y. Chen, L. Wang and Z. Lu, "Machine Learning Aided Trajectory Design and Power Control of Multi-UAV," 2019 IEEE Global Communications Conference (GLOBECOM), Waikoloa, HI, USA, 2019, pp. 1-6, doi: 10.1109/GLOBECOM38437.2019.9014216.
- D. Romero and G. Leus, "Non-Cooperative Aerial Base Station Placement via Stochastic Optimization," 2019 15th International Conference on Mobile Ad-Hoc and Sensor Networks (MSN), Shenzhen, China, 2019, pp. 131-136, doi: 10.1109/MSN48538.2019.00036.
- K. Xiao, J. Zhao, Y. He and S. Yu, "Trajectory Prediction of UAV in Smart City using Recurrent Neural Networks," ICC 2019 - 2019 IEEE International Conference on Communications (ICC), Shanghai, China, 2019, pp. 1-6, doi: 10.1109/ICC.2019.8761110.
- J. Zeng, J. Wang, L. Guo, G. Fan, K. Zhang and G. Gui, "Cell Scene Division and Visualization Based on Autoencoder and K-Means Algorithm," in IEEE Access, vol. 7, pp. 165217-165225, 2019, doi: 10.1109/ACCESS.2019.2953184.
- Elodie Faride. (Apr 2018) #Episode1 — Le vendredi c’est : AI. en ligne <https://medium.com/@LZigaDigital/episode1-le-vendredi-cest-ai-9eada2c4a6dc>
(Consulté au mois de Juillet 2020)
- DBR Rawat (2020). Path Loss. En ligne <https://www.mathworks.com/matlabcentral/fileexchange/14016-path-loss>
(Consulté au mois de Septembre 2020)

