



الجمهورية الجزائرية الديمقراطية الشعبية

وزارة التعليم العالي والبحث العلمي

جامعة سعيدة د. مولاي الطاهر

كلية الرياضيات و الإعلام الآلي و الاتصالات السلكية و

اللاسلكية

قسم: الإعلام الآلي

## Mémoire de Master en informatique

Spécialité : Réseaux Informatiques et systèmes  
Répartis

### Thème

Next Generation Digital Twin-Enhanced  
6G Networks: A Deep Learning Approach  
for Real-Time Adaptation

▪ Présenté par :

Bentayeb Leila

▪ Dirigé par :

DR. Bensaid Tayeb Islem

Année universitaire



2025-2026



# Remerciements



Je remercie, avant tout, Allah le tout puissant, de m'avoir guidé durant toutes mes années d'études, et m'avoir donné

la volonté, la patience et le courage pour terminer ce travail.

Nombreuses sont les personnes qui m'ont aidé à franchir les obstacles et contraintes durant la préparation de ce travail, dont je tiens à souligner les contributions. Je voudrais adresser mes remerciements plus particulièrement :

A mon promoteur Dr Bensaid Tayeb, qui m'a encadré pour réaliser ce mémoire. je lui reconnaisse son entière disponibilité, son aide inestimable et ses conseils sans lesquels ce travail m'aurait pu aboutir.

A tous mes professeurs, sans exception, du primaire à l'université. Enfin, mes remerciements les plus chaleureux à tous les membres de ma famille, qui m'ont toujours aidé encouragé au cours de la réalisation de ce mémoire.





Je dédie ce modeste travail:  
A ma chère mère et à mon père,  
Pour leur patience illimitée, leur encouragement  
continu, leur aide, en témoignage  
de mon profond amour et respect pour leurs grand  
sacrifices  
A mes frères et sœurs  
À mon encadreur « Bensaid Tayeb »  
Et à tous ceux qui ont contribué de près ou de loin  
pour que ce travail soit  
possible, je vous dis merci.



# TABLE DES MATIÈRES

<b>Introduction Générale</b>	<b>2</b>
<b>1 Fondements des réseaux 6G et évolution des architectures mobiles</b>	<b>3</b>
1.1 Introduction . . . . .	3
1.2 Évolution des réseaux mobiles (1G → 6G) . . . . .	3
1.3 Vision et caractéristiques de la 6G . . . . .	4
1.4 Architecture des réseaux 6G . . . . .	5
1.4.1 Core network intelligent . . . . .	5
1.4.2 Edge computing . . . . .	5
1.4.3 Cloud-native infrastructure . . . . .	5
1.5 Cas d'usage des réseaux 6G . . . . .	6
1.6 Limites et défis actuels . . . . .	6
1.7 Conclusion . . . . .	7
<b>2 Digital Twin dans les réseaux de communication</b>	<b>8</b>
2.1 Introduction . . . . .	8
2.2 Définition du Digital Twin . . . . .	8
2.3 Architecture d'un Digital Twin . . . . .	10
2.3.1 Physical Entity (Entité physique) . . . . .	10
2.3.2 Virtual Model (Modèle virtuel) . . . . .	11
2.3.3 Synchronization Layer (Couche de synchronisation) . . . . .	11
2.4 Digital Twin dans les réseaux télécoms . . . . .	12
2.5 Rôle du Digital Twin dans la 6G . . . . .	13
2.5.1 Monitoring en temps réel . . . . .	14
2.5.2 Simulation prédictive . . . . .	14
2.5.3 Optimisation réseau . . . . .	15
2.6 Technologies habilitantes . . . . .	15
2.7 Défis du Digital Twin . . . . .	16
2.8 Conclusion . . . . .	17

<b>3</b>	<b>Deep Learning pour les réseaux intelligents</b>	<b>18</b>
3.1	Introduction . . . . .	18
3.2	Concepts fondamentaux du Deep Learning . . . . .	19
3.2.1	Réseaux de neurones . . . . .	19
3.2.2	Les différents algorithmes de Deep Learning . . . . .	20
3.2.3	Reinforcement Learning . . . . .	21
3.3	Deep Learning dans les réseaux 6G . . . . .	22
3.4	Modèles adaptés au réseau dynamique . . . . .	24
3.5	Avantages et limites du Deep Learning . . . . .	25
3.5.1	Avantages . . . . .	25
3.5.2	Limites . . . . .	26
3.6	Conclusion . . . . .	26
<b>4</b>	<b>Proposition d'une approche Digital Twin + Deep Learning pour l'adaptation en temps réel</b>	<b>28</b>
4.1	Introduction . . . . .	28
4.2	Problématique ciblée . . . . .	30
4.3	Architecture proposée du système . . . . .	31
4.3.1	Couche physique (Physical Network Layer) . . . . .	32
4.3.2	Couche Digital Twin (Digital Twin Layer) . . . . .	33
4.3.3	Couche de décision intelligente (AI Decision Layer) . . . . .	33
4.3.4	Boucle de rétroaction (Real-Time Feedback Loop) . . . . .	34
4.4	Modèle de Deep Learning retenu . . . . .	34
4.4.1	Choix du modèle et justification . . . . .	34
4.4.2	Variables d'entrée . . . . .	34
4.4.3	Variables de sortie . . . . .	35
4.5	Mécanisme de synchronisation du Digital Twin . . . . .	35
4.6	Processus d'adaptation en temps réel . . . . .	36
4.7	Algorithme proposé . . . . .	36
4.8	Conclusion . . . . .	37
<b>5</b>	<b>Expérimentation, résultats et discussion</b>	<b>39</b>
5.1	Introduction . . . . .	39
5.2	Environnement de simulation . . . . .	40
5.2.1	Outils et chaîne d'expérimentation . . . . .	40
5.2.2	Configuration matérielle . . . . .	40
5.2.3	Jeu de données . . . . .	41

5.3	Scénarios de test . . . . .	42
5.3.1	Charge réseau faible . . . . .	42
5.3.2	Charge réseau moyenne . . . . .	42
5.3.3	Charge réseau élevée . . . . .	42
5.3.4	Cas d'urgence . . . . .	42
5.4	Métriques d'évaluation . . . . .	43
5.4.1	Latence bout-en-bout . . . . .	43
5.4.2	Débit utile (throughput) . . . . .	43
5.4.3	Qualité de service (QoS) . . . . .	43
5.4.4	Précision du modèle . . . . .	44
5.5	Résultats expérimentaux . . . . .	44
5.5.1	Performances du modèle LSTM . . . . .	44
5.5.2	Comparaison de la latence . . . . .	44
5.5.3	Comparaison du débit . . . . .	45
5.5.4	Évolution de la précision durant l'entraînement . . . . .	45
5.5.5	Impact de la présence du Digital Twin . . . . .	46
5.6	Discussion analytique des résultats . . . . .	46
5.6.1	Contribution du Digital Twin . . . . .	46
5.6.2	Contribution du Deep Learning . . . . .	47
5.6.3	Comparaison avec les approches classiques . . . . .	50
5.6.4	Comparaison avec l'état de l'art avancé . . . . .	51
5.6.5	Discussion transversale . . . . .	54
5.7	Limites de l'approche . . . . .	54
5.8	Conclusion . . . . .	55

**Conclusion Générale** **57**

**Bibliographie** **61**

# Liste des Figures

2.1	Les trois éléments de Jumeau Numérique. . . . .	10
2.2	Architecture Générale de Jumeau Numérique. . . . .	12
2.3	Exemple de Jumeau Numérique[13]. . . . .	13
3.1	La relation entre l'intelligence artificielle, l'apprentissage automatique et l'apprentissage profond [18]. . . . .	19
3.2	Le fonctionnement d'algorithme d'apprentissage par renforcement . . . . .	22
4.1	Déroulement du modèle LSTM dans l'architecture hybride Digital Twin +Deep Learning. . . . .	32
4.2	Algorithme d'optimisation de réseau par jumeau numérique et LSTM. . . . .	37
5.1	Impact de Digital Twin sur les performances système . . . . .	47
5.2	Convergence du modèle LSTM au cours de l'entraînement. . . . .	48
5.3	Comparaison de la latence moyenne selon la méthode d'allocation. . . . .	49
5.4	Comparaison de Débit moyen selon la méthode d'allocation. . . . .	49
5.5	Comparaison multi-critères avec l'état de l'art. . . . .	50

# Liste des tableaux

3.1	Synthèse des travaux récents basés sur le Deep Learning dans les réseaux 6G .	23
4.1	Les variables d'entrée . . . . .	35
5.1	Outils utilisés pour l'expérimentation . . . . .	40
5.2	Variables du jeu de données . . . . .	41
5.3	Performances du modèle LSTM . . . . .	44
5.4	Comparaison de la latence moyenne . . . . .	45
5.5	Comparaison du débit moyen . . . . .	45
5.6	Impact du Digital Twin sur les performances système . . . . .	46
5.7	Comparaison synthétique avec l'état de l'art . . . . .	52

# Liste des algorithmes

1	Algorithme Optimisation temps réel basée sur Digital Twin . . . . .	37
---	---	----

# Introduction Générale

L'évolution rapide des technologies de communication sans fil a profondément transformé les modes d'échange entre les individus, les objets connectés et les systèmes intelligents. Après les avancées considérables apportées par la 4G et la 5G, les réseaux de sixième génération, ou réseaux 6G, se présentent comme une nouvelle étape stratégique dans le développement des infrastructures de télécommunication. Ils visent à offrir des performances supérieures en termes de très haut débit, de faible latence, de connectivité massive, de fiabilité et d'intégration native de l'intelligence artificielle. Ces caractéristiques sont essentielles pour répondre aux exigences des applications futures, telles que les véhicules autonomes, la télémédecine, les villes intelligentes, l'industrie connectée, les services immersifs et l'Internet massif des objets.

Cependant, la mise en œuvre des réseaux 6G soulève plusieurs défis importants. La complexité croissante des environnements réseau, la mobilité des utilisateurs, la diversité des services, la variation rapide du trafic et la nécessité d'une allocation dynamique des ressources rendent les approches classiques de gestion moins adaptées. En effet, les méthodes statiques ou simplement réactives ne permettent pas toujours d'anticiper les congestions, de garantir une qualité de service stable ou d'assurer une adaptation efficace en temps réel. Il devient donc nécessaire de recourir à des solutions intelligentes capables de surveiller, prédire et optimiser le fonctionnement du réseau de manière autonome.

Dans ce contexte, le Digital Twin, ou jumeau numérique, apparaît comme une technologie prometteuse pour les réseaux de nouvelle génération. Il permet de créer une représentation virtuelle dynamique d'un système réel, continuellement mise à jour à partir des données collectées dans l'infrastructure physique. Appliqué aux réseaux de communication, le Digital Twin permet de surveiller l'état du réseau, de simuler différents scénarios, de prédire les comportements futurs et de tester certaines décisions avant leur application dans l'environnement réel. Cette capacité constitue un atout majeur pour améliorer la performance, la fiabilité et l'autonomie des réseaux 6G.

Parallèlement, le Deep Learning joue un rôle fondamental dans l'exploitation intelligente des données réseau. Grâce à sa capacité d'apprentissage à partir de grandes quantités de

données, il permet de prédire l'évolution du trafic, de détecter les anomalies, d'optimiser l'allocation des ressources et d'améliorer la qualité de service. Parmi les modèles d'apprentissage profond, les réseaux LSTM sont particulièrement adaptés aux données temporelles, car ils permettent de mémoriser les dépendances à court et à long terme. Cette propriété les rend pertinents pour l'analyse du comportement dynamique des réseaux 6G.

L'objectif principal de ce mémoire est de proposer une approche intelligente combinant le Digital Twin et le Deep Learning, plus précisément un modèle LSTM, afin d'assurer une adaptation en temps réel des ressources dans les réseaux 6G. L'idée consiste à utiliser le Digital Twin comme une représentation virtuelle synchronisée du réseau physique, tandis que le modèle LSTM permet de prédire l'état futur du réseau et d'aider à la prise de décision. Cette combinaison vise à améliorer la latence, le débit, la qualité de service et la réactivité globale du système.

La problématique étudiée peut alors être formulée ainsi : comment concevoir une architecture intelligente intégrant un Digital Twin et un modèle de Deep Learning capable de surveiller, prédire et optimiser dynamiquement l'allocation des ressources dans un réseau 6G hétérogène et fortement variable ?

Pour répondre à cette problématique, ce mémoire est organisé en cinq chapitres:

Le premier chapitre présente les fondements des réseaux 6G, leur évolution, leurs caractéristiques, leurs cas d'usage ainsi que leurs limites.

Le deuxième chapitre est consacré au Digital Twin dans les réseaux de communication, en abordant sa définition, son architecture et son rôle dans la supervision, la simulation et l'optimisation des réseaux 6G.

Le troisième chapitre traite du Deep Learning appliqué aux réseaux intelligents, en présentant ses concepts fondamentaux et les modèles adaptés aux environnements dynamiques, notamment les LSTM.

Le quatrième chapitre propose l'architecture hybride Digital Twin + Deep Learning destinée à l'adaptation en temps réel des ressources réseau.

Enfin, le cinquième chapitre présente l'expérimentation, les résultats obtenus et leur discussion à travers l'analyse des performances de l'approche proposée en termes de précision, de latence, de débit et de qualité de service.

# Chapitre 1

## Fondements des réseaux 6G et évolution des architectures mobiles

### 1.1 Introduction

Dans le contexte de la digitalisation rapide, les technologies de communication se développent rapidement pour s'adapter à l'augmentation des demandes en matière de connectivité, de vitesse et d'intelligence des systèmes. Avec l'arrivée de la 5G, la 6G se profile comme une véritable révolution, promettant des performances sans précédent en matière de débit, de latence et de connectivité à grande échelle.

Dans ce chapitre nous allons présenter les fondements des réseaux 6G ainsi que l'évolution des architectures mobiles.

### 1.2 Évolution des réseaux mobiles (1G → 6G)

Plusieurs générations d'évolution ont été observées dans les réseaux mobiles. La première génération (1G) était fondée sur des communications analogiques, puis la deuxième génération (2G) a introduit la numérisation.

La 3G a ouvert la voie à l'Internet mobile, alors que la 4G a optimisé les vitesses de connexion et les services multimédias.

Finalement, la 5G a apporté des nouveautés significatives comme la latence réduite, la capacité de connexion massive et le soutien aux objets connectés. Malgré ses avancées, la 5G présente certaines limitations :

- Capacité insuffisante pour les applications futures massives .
- Gestion complexe des ressources.

- Latence encore non optimale pour certaines applications critiques.
- Difficulté d'adaptation dynamique en temps réel.

La sixième génération de télécommunications mobiles, souvent désignée sous le nom de 6G, constitue une avancée significative dans l'évolution des systèmes de communication sans fil. Elle succède à la 5G et a pour objectif de satisfaire les demandes grandissantes en termes de connectivité, de vitesse et d'intelligence des réseaux. Attendue pour une mise en service vers 2030, la 6G est censée révolutionner les applications numériques et les structures de communication [1].

On peut caractériser la 6G comme une technologie de communication mobile de dernière génération, capable de fournir des transferts de données à une vitesse extrêmement élevée, accompagnée d'une latence minimale et d'une intégration poussée de l'intelligence artificielle [2].

Elle se caractérise par sa faculté à fournir une connectivité constante et astucieuse, établissant non seulement des connexions entre les personnes, mais aussi avec les objets, les équipements et les systèmes autonomes à grande échelle.

### 1.3 Vision et caractéristiques de la 6G

Les réseaux 6G présentent des performances largement supérieures à celles de la 5G :

**Débit:** Ils proposent des vitesses de transmission capables d'atteindre un téraoctet par seconde, ce qui autorise le transfert immédiat d'énormes volumes de données.

**Latence:** La latence est minimisée à un niveau pratiquement inexistant, inférieur à une milliseconde, ce qui est propice aux échanges en temps réel.

**Connectivité:** La 6G offre une connectivité à grande échelle, capable de gérer un nombre extrêmement élevé d'appareils connectés en même temps.

**Incorporation de l'IA :** Un autre élément crucial de la 6G est l'intégration intrinsèque de l'intelligence artificielle dans le fonctionnement du réseau. Cette intelligence favorise une administration dynamique et optimisée des ressources, un ajustement automatique aux conditions du réseau et un perfectionnement constant de la qualité du service.

**Capacité de transmission :** La 6G utilise des fréquences extrêmement hautes, en particulier

les ondes térahertz, qui fournissent des capacités de transmission hors du commun

## **1.4 Architecture des réseaux 6G**

La structure des réseaux 6G sera plus intelligente, adaptable et efficace comparée aux générations antérieures. Elle s'appuiera sur plusieurs composantes cruciales, incluant un cœur de réseau intelligent, le calcul en périphérie (Edge Computing) et une infrastructure native cloud. Ces technologies offriront une amélioration en termes de rapidité, de latence, de gestion de réseau et de qualité des services offerts aux utilisateurs[3].

### **1.4.1 Core network intelligent**

Le réseau central intelligent constitue le noyau du réseau 6G. Grâce à l'intelligence artificielle et à l'apprentissage automatique, il pourra gérer les ressources du réseau de manière autonome. Cette technologie sera capable d'examiner le flux de données en direct, d'anticiper les nécessités des usagers, d'améliorer la qualité du service et de repérer promptement les défaillances ou les cyberattaques. De ce fait, le réseau sera en mesure de s'adapter automatiquement en fonction de la demande, offrant ainsi une connexion plus fiable et performante[4].

### **1.4.2 Edge computing**

Dans l'architecture 6G, l'edge computing représente une technologie de premier plan. Cette approche traite les données à proximité de l'utilisateur, plutôt que de les transférer vers des centres de données distants[5]. Cela contribue à diminuer la latence et à accélérer le traitement des données. Cette technologie est extrêmement bénéfique pour les applications exigeant une réaction rapide, à l'instar des véhicules autonomes, de la réalité virtuelle, de la télémédecine, des smart cities et de l'industrie interconnectée[5].

### **1.4.3 Cloud-native infrastructure**

Le concept cloud-native stipule que le réseau 6G sera élaboré pour être opérationnel avec les technologies du cloud dès sa conception. Les fonctionnalités du réseau seront virtualisées et distribuées sur divers environnements clouds. Cela rendra le réseau davantage adaptable, plus aisé à actualiser et plus simple à administrer[6]. Cette infrastructure permettra

aux opérateurs de déployer rapidement de nouveaux services, de modifier les ressources en fonction des exigences, et d'améliorer la fiabilité du réseau.

## **1.5 Cas d'usage des réseaux 6G**

Les applications de la 6G couvrent de nombreux domaines :

- Dans le domaine médical, elle rend possible la réalisation d'interventions chirurgicales à distance avec une précision améliorée.
- Elle facilite l'évolution des véhicules autonomes dans le secteur des transports en offrant des communications d'une rapidité et d'une fiabilité extrêmes.
- La 6G joue également un rôle dans le développement des villes intelligentes, en améliorant la gestion des infrastructures urbaines.
- Dans le domaine de divertissement, elle propose des expériences immersives de pointe, notamment par le biais de la réalité virtuelle et augmentée [7].
- Finalement, dans le secteur industriel, elle favorise la création de systèmes automatisés et de robots intelligents, augmentant ainsi la productivité et l'efficacité.

## **1.6 Limites et défis actuels**

En dépit de ses multiples atouts, la 6G pose plusieurs difficultés :

- L'emploi de fréquences hautes entraîne un rayonnement limité des signaux, ce qui exige une intensification significative des infrastructures.
- Le déploiement de ces réseaux engendre des coûts particulièrement importants.
- L'accroissement du nombre d'appareils connectés rend également cruciales les problèmes de sécurité et de protection des données.
- L'impact environnemental de ces technologies, en particulier en termes de consommation d'énergie et de gestion des ressources.

## **1.7 Conclusion**

Ce chapitre a permis de présenter les bases essentielles des réseaux 6G et leur position dans l'évolution des communications mobiles. Après les progrès apportés par les générations précédentes, la 6G apparaît comme une technologie capable de répondre aux besoins futurs en matière de connectivité, de rapidité, de fiabilité et d'intelligence réseau. Cependant, malgré ses nombreux avantages, la 6G présente encore plusieurs limites et défis. Dans ce cadre, les jumeaux numériques se présentent comme une réponse novatrice.

# Chapitre 2

## Digital Twin dans les réseaux de communication

### 2.1 Introduction

Avec l'élargissement du spectre des réseaux modernes, tels que la 6G, il est devenu crucial de recourir à des technologies intelligentes pour assurer une gestion, un suivi et un optimisme plus efficace des infrastructures de télécommunications, au regard de la complexité croissante. L'une des technologies émergentes, le jumeau numérique ou Digital Twin, constitue une approche avant-gardiste qui permet de réaliser une réplique virtuelle d'un système réel en vue d'examiner son fonctionnement et de prédire ses performances en temps réel.

### 2.2 Définition du Digital Twin

Le terme Jumeau Numérique (Digital Twin) fait référence à une modélisation virtuelle dynamique d'un objet, d'un système, d'un processus ou d'un environnement concret, en mesure de refléter son comportement en temps réel par le biais d'une transmission constante de données. A l'opposé des modèles de simulation traditionnels souvent statiques, le Double Numérique se renouvelle en permanence grâce aux informations rassemblées sur l'élément physique via une combinaison de capteurs, réseaux de communication et plateformes de gestion de données[8].

L'expression « Digital Twin » a été formulée au début des années 2000 par le scientifique Michael Grieves, dans le cadre de la gestion du cycle de vie des produits (Product Lifecycle Management - PLM). Depuis, l'essor rapide de l'Internet des objets (IoT), du

Cloud Computing, de l'intelligence artificielle, ainsi que des technologies de communication avancées comme la 5G et la prochaine 6G, a propulsé l'évolution de ce concept.

Pour fonctionner, un jumeau numérique nécessite deux éléments clés : une entité physique existante et sa copie virtuelle. Un échange de données bidirectionnel lie ces deux entités, offrant au modèle virtuel la capacité de démontrer l'état actuel du système à chaque moment donné[9]. Ce lien constant offre non seulement la possibilité de suivre l'état du système physique, mais aussi de modéliser diverses situations, de prévenir les dysfonctionnements, d'améliorer les rendements et de faciliter la prise de décisions.

Dans un environnement industriel, le jumeau numérique peut illustrer une machine, une chaîne de production ou même une usine complète. Dans le contexte des smart cities, il est capable de modéliser des infrastructures de ville, des systèmes de transport ou des réseaux d'énergie. Dans le domaine de la santé, son utilisation permet de représenter des organes ou des patients, dans le but d'améliorer le diagnostic et d'individualiser les traitements. Cette variété d'utilisations illustre l'adaptabilité et l'importance grandissante des jumeaux numériques dans la mutation digitale des systèmes contemporains.

D'après la description fournie par la NASA, un jumeau numérique est une représentation combinée et multiphysique d'un système réel, s'appuyant sur les données les plus précises, des modèles de simulation et des informations du passé pour reproduire et anticiper son comportement au fil de son cycle de vie. Cette définition souligne le caractère évolutif du Jumeau Numérique, qui suit le système réel depuis sa phase de conception jusqu'à son utilisation et sa maintenance.

L'un des atouts majeurs du jumeau numérique est sa capacité à offrir une perspective exhaustive et instantanée du système examiné. L'intégration des données provenant des capteurs, des modèles analytiques et des algorithmes d'intelligence artificielle permet désormais de repérer rapidement les anomalies, de réaliser une maintenance prédictive et d'accroître l'efficacité opérationnelle. Le Digital Twin est considérée actuellement comme l'une des technologies essentielles pour l'industrie 4.0 et les réseaux intelligents de demain[10].

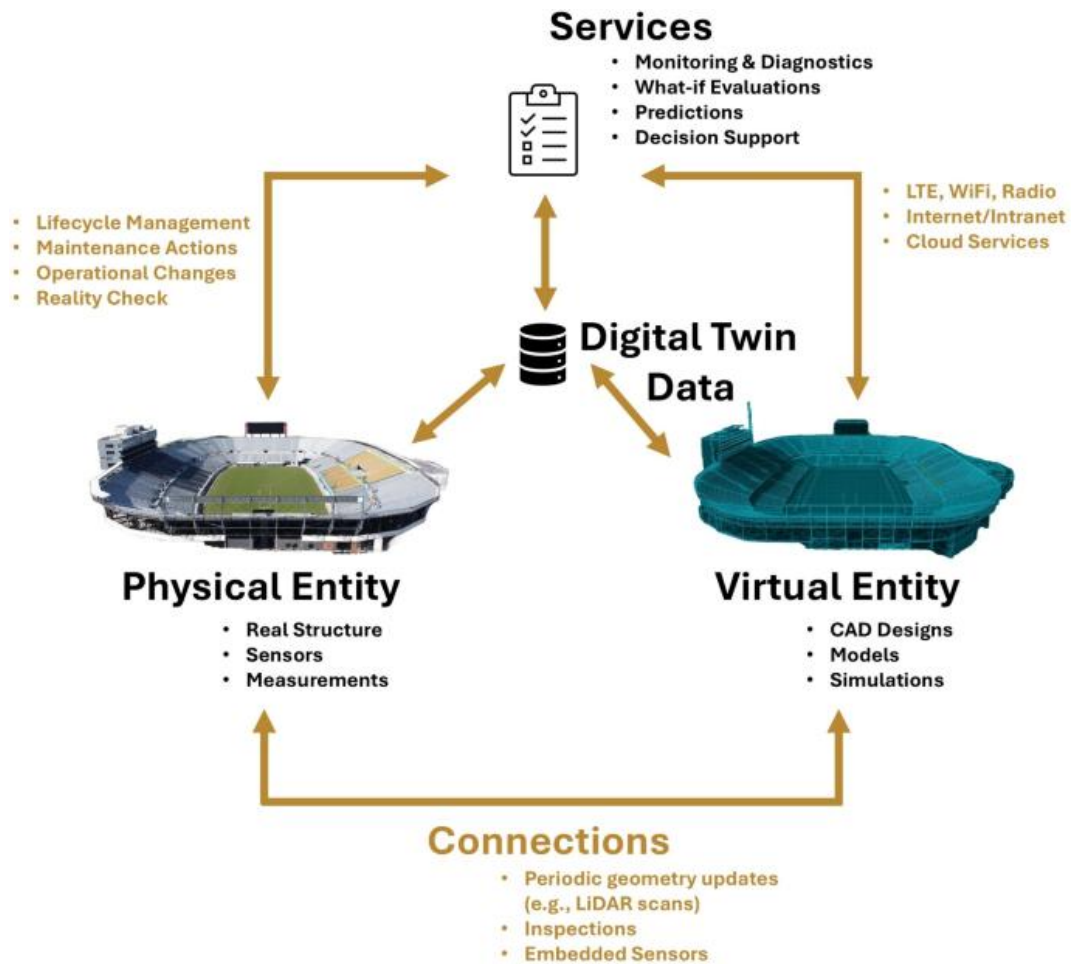


Figure 2.1: Les trois éléments de Jumeau Numérique.

## 2.3 Architecture d'un Digital Twin

Le Digital Twin est fondé sur une architecture qui comprend trois composants majeurs: l'entité physique (Physical Entity), le modèle virtuel (Virtual Model) et la couche de synchronisation (Synchronization Layer). Ces trois éléments interagissent en continu pour générer une représentation numérique précise, dynamique et en constante évolution d'un système réel. L'objectif primordial est de faciliter la supervision, la modélisation et l'amélioration du système physique grâce à son homologue numérique.

### 2.3.1 Physical Entity (Entité physique)

Le Digital Twin est basé sur un système réel, qu'on appelle l'entité physique. Cela peut correspondre à un appareil industriel, un véhicule, un édifice intelligent, une infrastructure

énergétique ou même un processus industriel sophistiqué. Cette entité représente le principal fournisseur de données employées dans l'écosystème du jumeau numérique[11].

Dans un cadre Digital Twin, l'entité physique est souvent dotée de capteurs capables de recueillir des informations en direct comme la température, la pression, les vibrations, la rapidité ou même la condition de fonctionnement. Ces informations illustrent la conduite authentique du système dans son milieu d'opération. Comme l'entité physique est confrontée à des facteurs réels tels que l'usure, les pannes mécaniques et les changements environnementaux, son suivi est essentiel pour assurer la performance et la sûreté du système dans son ensemble.

Par conséquent, l'entité physique représente le fondement du Jumeau Numérique, car sans celle-ci, il est impossible d'effectuer une modélisation ou une simulation réaliste.

### **2.3.2 Virtual Model (Modèle virtuel)**

Le modèle virtuel constitue la reproduction numérique de l'entité physique. C'est un ensemble de modèles mathématiques, de simulations digitales et parfois d'images 3D qui imite le comportement du système réel au sein d'un univers virtuel.

Ce modèle est capable de fusionner diverses approches, y compris des modèles physiques ancrés dans des lois scientifiques, des modèles statistiques, et des méthodologies d'intelligence artificielle et d'apprentissage automatique. Avec ces instruments, le modèle numérique peut imiter le système en action, évaluer son rendement et anticiper ses réactions futures.

L'un des atouts majeurs du modèle virtuel réside dans sa possibilité d'expérimenter diverses situations sans impacter le système réel. Par exemple, on peut réaliser une simulation de surcharge, de défaillance ou de fluctuation environnementale pour mesurer les impacts et suggérer les solutions les plus efficaces. Ainsi, le modèle virtuel a un rôle primordial dans la prise de décisions, le maintien prédictif et l'amélioration des systèmes complexes[12].

### **2.3.3 Synchronization Layer (Couche de synchronisation)**

L'élément crucial qui établit le lien entre le monde matériel et le monde numérique est la couche de synchronisation. Elle facilite la diffusion, la mise à jour et l'harmonisation des données entre l'entité réelle et son équivalent numérique[13].

Cette couche utilise des technologies de pointe comme l'Internet des objets (IoT), les réseaux de communication (y compris la 5G et la prochaine 6G), ainsi que l'informatique en nuage et l'informatique en périphérie (edge computing). Les détecteurs placés sur l'entité physique recueillent les informations en direct et les acheminent via cette strate vers le modèle virtuel.

En réponse, le niveau de synchronisation permet au modèle virtuel de transmettre des conseils ou des directives au système physique, établissant ainsi une boucle de feedback bilatérale. Cette interaction permanente assure que le modèle virtuel demeure continuellement en phase avec la réalité du système.

Cette synchronisation transforme le jumeau numérique en un système dynamique qui peut illustrer en temps réel les modifications du monde réel et fournir des analyses précises et mises à jour.

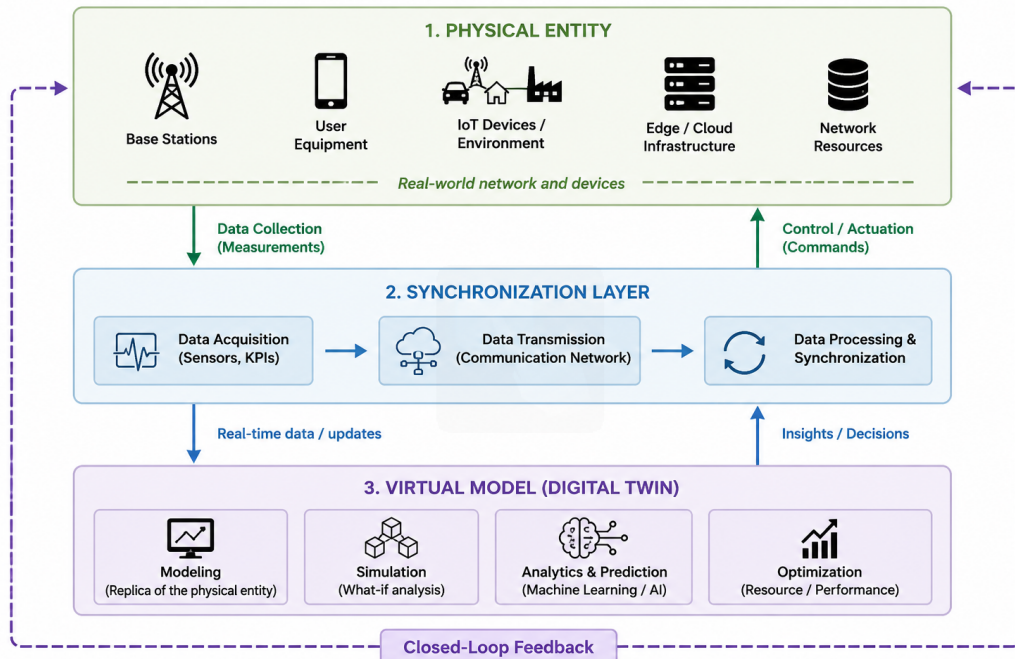


Figure 2.2: Architecture Générale de Jumeau Numérique.

## 2.4 Digital Twin dans les réseaux télécoms

Le Jumeau Numérique, également connu sous l'appellation Digital Twin, se réfère à une réplique digitale d'un système existant. Dans l'univers des réseaux de télécommunications, il facilite la création d'une réplique digitale du réseau pour observer son opération, modéliser ses actions et étudier sa performance. Avec la progression des réseaux mobiles vers la 5G avancée et la 6G, l'importance de cette technologie ne cesse de croître.

Dans le domaine des télécommunications, un jumeau numérique peut modéliser divers composants du réseau, tels que les antennes, les stations de base, le cœur du réseau, les utilisateurs, les appareils connectés et le flot de données. En estimant l'état du réseau par le biais de données en temps réel, le jumeau numérique offre une reproduction précise de ce

dernier et assiste les opérateurs dans son analyse.

L'un des rôles majeurs du jumeau numérique est la simulation. Les opérateurs ont la possibilité d'expérimenter divers scénarios dans un environnement virtuel avant de procéder à l'implémentation d'une nouvelle structure ou configuration. Ceci facilite l'évaluation des performances du réseau, l'anticipation des éventuels problèmes et la minimisation des risques associés à des tests sur un véritable réseau. Le jumeau numérique facilite également l'optimisation du réseau. L'analyse des données du réseau peut contribuer à optimiser la gestion des ressources, atténuer la saturation, réduire le délai de latence et perfectionner la qualité du service. Il peut aussi être intégré à l'intelligence artificielle pour effectuer des décisions automatiques et ajuster le réseau en fonction des exigences de l'utilisateur.

Le Digital Twin s'affirme donc comme un instrument indispensable pour accroître l'intelligence, la fiabilité et l'efficacité des réseaux de télécommunications.

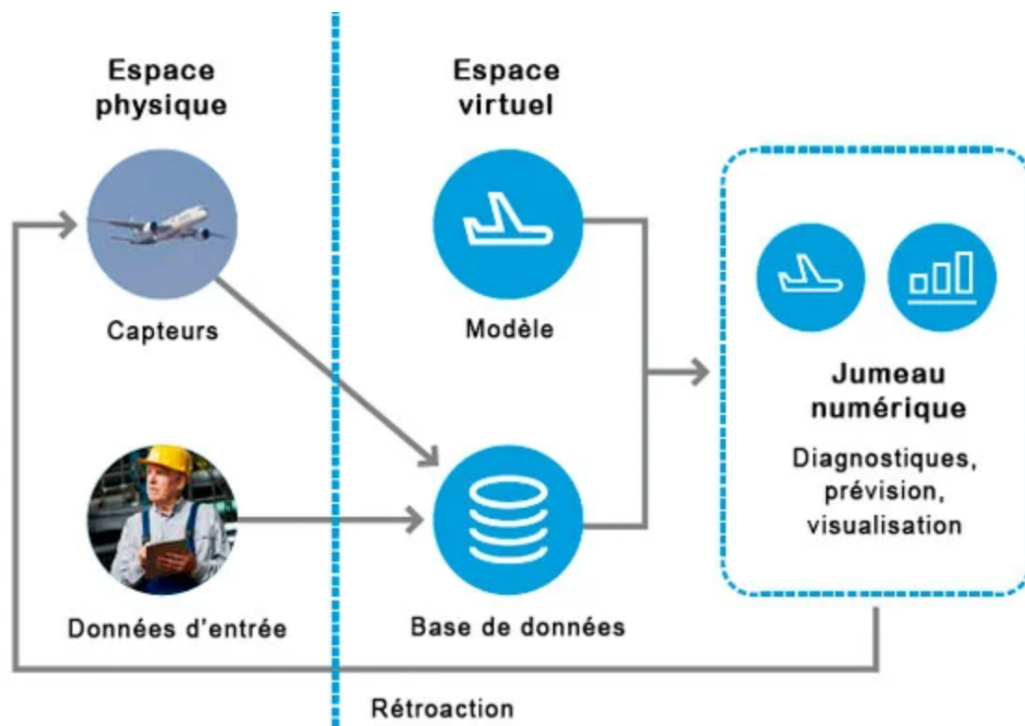


Figure 2.3: Exemple de Jumeau Numérique[13].

## 2.5 Rôle du Digital Twin dans la 6G

En raison de sa capacité à générer une représentation numérique intelligente et évolutive de l'infrastructure physique du réseau, le Digital Twin est considéré comme une technologie essentielle pour les réseaux 6G. Cette modélisation numérique est constamment mise à

jour grâce aux informations recueillies auprès des dispositifs, des stations de base, des capteurs et des terminaux branchés, ce qui permet de refléter précisément la situation actuelle du réseau à tout moment. Avec l'augmentation de la complexité des futurs réseaux 6G, qui se caractérisent par une forte concentration d'utilisateurs, l'incorporation massive de l'Internet des Objets (IoT), des communications à ultra-faible latence hyperfiables, ainsi que de l'intelligence artificielle, le jumeau numérique s'impose comme un instrument crucial pour garantir une gestion autonome et efficace du réseau. Ce système offre non seulement la possibilité de contrôler le fonctionnement du dispositif en temps réel, mais il permet aussi d'anticiper son comportement futur et d'améliorer constamment sa performance. Par le biais de ces compétences, le jumeau numérique aide à optimiser la qualité des services, à diminuer les coûts d'exploitation et à accroître la fiabilité des infrastructures 6G[14].

### **2.5.1 Monitoring en temps réel**

Une des principales caractéristiques du jumeau numérique dans le cadre des réseaux 6G est la supervision en direct. En perpétuelle synchronisation entre le réseau réel et son jumeau numérique, on peut surveiller en temps réel l'état des divers éléments du système. Le jumeau numérique recueille en permanence une multitude d'informations, comme le trafic réseau, le transfert de données, la latence, le taux d'erreurs, l'exploitation des ressources radio, la consommation en énergie, et la condition des appareils connectés.

Cette supervision continue facilite l'identification express des irrégularités, obstructions, des baisses de performance ou des pannes éventuelles avant qu'elles n'impactent les usagers. Cela permet aux opérateurs d'avoir une perspective complète et précise du réseau, simplifiant ainsi le processus décisionnel et la mise en œuvre de mesures correctives au moment opportun. Cette compétence de surveillance favorise directement l'amélioration de la disponibilité, de la fiabilité et de la sécurité des communications dans les contextes 6G.

### **2.5.2 Simulation prédictive**

Le jumeau numérique propose aussi des compétences sophistiquées de simulation prédictive qui constituent un atout précieux pour l'administration des réseaux 6G. Grâce à l'exploitation des informations recueillies en temps réel et des modèles d'analyse ainsi que des algorithmes d'IA, le jumeau numérique a la capacité de simuler de manière virtuelle divers scénarios de fonctionnement du réseau.

Ces modélisations aident à prévoir l'augmentation du trafic, l'émergence de bouchons, les fluctuations de charge, les pannes d'équipements davantage que les effets de nouveaux agencements du réseau. Avant toute intervention sur l'infrastructure physique, les opérateurs

ont la possibilité d'expérimenter diverses stratégies dans un environnement virtuel sécurisé et d'en évaluer les impacts. Cette méthode diminue significativement les dangers opérationnels, optimise la gestion des ressources et facilite l'évolution du réseau en fonction des exigences futures des usagers.

### **2.5.3 Optimisation réseau**

Le Jumeau Numérique ne se limite pas à la supervision et à la prévision, il est également crucial pour l'amélioration des performances des réseaux 6G. Les données récoltées grâce à la surveillance et les résultats des simulations aident à déterminer les meilleures tactiques pour l'allocation des ressources et la gestion du réseau.

Par conséquent, le jumeau numérique aide à améliorer la gestion de la bande passante, la circulation du trafic, l'utilisation des ressources radio, le déploiement de services d'informatique en périphérie et la consommation énergétique des appareils. Lorsqu'il est couplé avec des méthodes d'intelligence artificielle et d'apprentissage machine, il a la capacité de régler automatiquement certains réglages du réseau dans le but d'optimiser la qualité du service (QoS), la qualité de l'expérience utilisateur (QoE), la couverture et l'efficacité énergétique. La faculté d'auto-optimisation est un des fondements des réseaux 6G intelligents et autonomes de demain, qui sont en mesure de se moduler de façon dynamique en fonction des évolutions de leur environnement.

## **2.6 Technologies habilitantes**

Les technologies habilitantes constituent les technologies clés autorisant l'évolution et la performance des réseaux 6G. Ces dernières contribuent à optimiser les performances du réseau en termes de vitesse, de connectivité, de gestion des données et d'intelligence des systèmes. L'Internet des objets (IoT), le Cloud et l'Edge computing, le Big Data, tout comme l'intégration de l'intelligence artificielle et de l'apprentissage automatique, sont parmi les technologies les plus cruciales.

- Le rôle crucial du futur réseau 6G dans l'Internet des objets (IoT) réside dans le fait que les réseaux à venir devront être capables de relier une multitude impressionnante d'équipements intelligents tels que des capteurs, des véhicules autopilotés, des dispositifs médicaux et des objets connectés dans les cités intelligentes. Un vaste réseau capable de gérer des millions de connexions simultanées tout en consommant peu d'énergie et offrant une communication fiable, est nécessaire pour cette connectivité à grande échelle.

- Dans les architectures 6G, le Cloud computing et l'Edge computing sont également considérés comme des technologies clés. Le Cloud offre la capacité de stocker et de traiter à grande échelle les données de manière centralisée, alors que l'Edge computing vise à rapprocher le traitement des données des usagers et des dispositifs connectés. Cette technique favorise la diminution de la latence, l'amélioration de l'efficacité du réseau et la réaction prompte aux applications qui exigent une réponse en temps réel, telles que la réalité virtuelle, la télémédecine et les systèmes intelligents pour l'industrie.
- La technologie de Big Data est une autre technologie habilitante cruciale, étant donné que les réseaux 6G produisent une vaste quantité de données issues des utilisateurs, des objets connectés et des infrastructures réseau. L'examen de ces informations aide à perfectionner la gestion du réseau, à anticiper les soucis, à optimiser les moyens disponibles et à rehausser la qualité des services fournis.
- Finalement, l'incorporation de l'intelligence artificielle et de l'apprentissage machine (AI/ML) rend les réseaux 6G plus intelligents et autonomes. Ces technologies sont capables d'examiner les informations du réseau en direct, de prendre certaines décisions de façon automatique, d'améliorer la gestion des ressources et de prédire les irrégularités ou les défaillances avant leur apparition. Avec l'intelligence artificielle et l'apprentissage machine, les réseaux 6G auront la capacité de se modifier de manière dynamique en fonction des besoins des utilisateurs, offrant ainsi des performances plus efficaces et plus fiables.

## **2.7 Défis du Digital Twin**

Bien qu'il offre de nombreux bénéfices, l'emploi du jumeau numérique dans les réseaux 6G soulève plusieurs enjeux techniques et fonctionnels. Ces enjeux concernent surtout la complexité des réseaux, la gestion des données, la sécurité ainsi que les exigences substantielles en matière de calcul et de communication.

La synchronisation en temps réel entre le réseau physique et son jumeau numérique représente l'un des plus grands enjeux. Pour être efficace, le Digital Twin doit constamment recevoir et actualiser avec précision les informations du réseau réel. Toute divergence ou retard dans la synchronisation pourrait diminuer la crédibilité des analyses et simulations.

La taille des données représente aussi un obstacle significatif. Les réseaux 6G produisent une masse colossale de données issues des utilisateurs, des objets interconnectés, des capteurs et du matériel réseau. Ces données doivent être stockées, transmises et analysées à l'aide

d'infrastructures sophistiquées capables de traiter d'importantes quantités d'informations en temps réel.

En outre la complexité en termes de calcul constitue un autre obstacle majeur. Le Jumeau Numérique fait appel à des modèles sophistiqués, des simulations et des algorithmes d'intelligence artificielle pour imiter le comportement du réseau. Ces tâches requièrent une puissance de calcul considérable ainsi que des ressources substantielles dans le domaine de l'informatique en nuage, de l'informatique en périphérie et de l'analyse intelligente des données. Il est donc crucial de gérer efficacement ces ressources pour assurer un fonctionnement optimal des Digital Twins dans les réseaux 6G à venir.

L'implémentation des jumeaux numériques peut engendrer des coûts significatifs associés aux infrastructures, au stockage des données, aux capacités de calcul et à l'entretien des systèmes. En dépit des obstacles, le Digital Twin demeure une technologie d'avenir pour renforcer la gestion, l'optimisation et la fiabilité des réseaux 6G à venir.

## **2.8 Conclusion**

La 6G représente une avancée significative dans les réseaux de communication, proposant des performances hors pair qui répondent aux besoins des systèmes contemporains.

L'incorporation des jumeaux numériques renforce ces compétences en facilitant la modélisation, la simulation et l'optimisation des systèmes physiques en temps réel.

Dans cette optique, l'apprentissage approfondi occupe une place centrale en fournissant des instruments sophistiqués pour l'analyse et la prise de décisions. En se basant sur l'apprentissage issu de vastes ensembles de données, ce dernier permet d'accroître la précision des prévisions, d'optimiser les performances des jumeaux numériques et de conférer une plus grande intelligence et autonomie aux réseaux 6G.

# Chapitre 3

## Deep Learning pour les réseaux intelligents

### 3.1 Introduction

Le Machine Learning, ou apprentissage automatique en français, est une technologie d'intelligence artificielle qui permet aux ordinateurs d'acquérir des connaissances sans avoir été spécifiquement programmés pour le faire. Néanmoins, pour leur apprentissage et leur évolution, les ordinateurs ont besoin de données à traiter et à étudier. En effet, c'est grâce à la technologie que l'on peut tirer pleinement profit du potentiel offert par le Big Data. Les approches d'apprentissage machine traditionnelles se sont révélées limitées en ce qui concerne la gestion des données brutes de nature naturelle [15].

Le Deep Learning est une capacité de l'intelligence artificielle qui reproduit le mécanisme d'opération du cerveau humain.

Il s'agit de l'une des modalités de l'apprentissage automatique pouvant être exploitée pour aider à identifier la fraude ou le blanchiment de capitaux, le traitement des données en vue de la détection d'objets, la reconnaissance vocale, la traduction linguistique et le processus décisionnel [16].

Les applications qui reposent sur l'apprentissage profond sont en mesure d'apprendre sans intervention humaine, grâce à l'utilisation de données qui ne sont ni structurées, ni étiquetées.

Dans ce chapitre, nous exposons une revue d'art du deep learning, ses bénéfices ainsi que les domaines où il est appliqué.

## 3.2 Concepts fondamentaux du Deep Learning

L'intelligence artificielle est une discipline scientifique à l'instar des mathématiques ou de la biologie. Elle explore les méthodes pour élaborer des programmes et des machines intelligentes capables de résoudre des problèmes de façon créative, une capacité traditionnellement perçue comme étant exclusivement humaine [17].

L'apprentissage automatique est un secteur de l'intelligence artificielle qui permet aux systèmes d'apprendre et de s'améliorer de façon autonome à partir de l'expérience, sans nécessiter une programmation explicite [17].

L'apprentissage profond est une branche du machine learning, exploitant les réseaux de neurones pour examiner divers facteurs à l'instar du système neural humain [17].




Figure 3.1: La relation entre l'intelligence artificielle, l'apprentissage automatique et l'apprentissage profond [18].

### 3.2.1 Réseaux de neurones

#### Définition

Un réseau de neurones, également désigné comme un réseau neuronal artificiel (en anglais, artificial neural network), représente une reproduction algorithmique des opérations du cerveau humain.

On se sert de ces algorithmes pour résoudre diverses problématiques liées au Machine Learning ou apprentissage automatique. Ils surpassent largement les méthodes de régression traditionnelles dans cette tâche [19].

Les réseaux de neurones artificiels sont capables d'analyser et de gérer des ensembles de données complexes de manière autonome, en fonction de la formation qu'ils ont reçue. À l'instar des neurones biologiques, ils sont alimentés par des signaux d'entrée (données), réalisent un traitement de ces derniers (une série de calculs) et génèrent des signaux de sortie (données). Après un entraînement approprié, les réseaux de neurones artificiels ont la capacité d'apprendre de manière autonome et de se réactualiser constamment pour délivrer

des informations toujours plus précises [20].

### Structure d'un réseau de neurones

Trois éléments principaux composent un réseau de neurones :

- **Les neurones** : Unité qui reçoit des données, effectue des opérations de base, puis les transmet à une autre unité [16].
- **Les poids et biais** : Chaque liaison possède une valeur distincte qui affecte la diffusion de l'information d'un élément à un autre. Les biais servent d'ajouts dans les réseaux de neurones pour modifier les valeurs d'entrée auxquelles les poids sont assignés, avant d'obtenir des valeurs de sortie finales [16].
- **La fonction d'activation** : La fonction d'activation donne à chaque neurone la capacité d'adoucir ou de standardiser les données en entrée qu'il reçoit avant de décider si elles seront transmises ou non [16].

### Fonctionnement d'un réseau de neurones

Trois phases cruciales sont à la base du fonctionnement d'un réseau de neurones. D'abord, chaque neurone d'une couche reçoit une valeur d'entrée qui a été précédemment multipliée par le poids de la liaison qu'il entretient avec les neurones antérieurs. Par la suite, à chaque niveau, un processus de pondération est réalisé et le biais est intégré. Enfin, on utilise la fonction d'activation sur cette valeur pour déterminer les données qui seront envoyées aux neurones suivants.

La diffusion n'a lieu que si la fonction d'activation est activée.

### 3.2.2 Les différents algorithmes de Deep Learning

On utilise divers types d'algorithmes dans le cadre de l'apprentissage profond. Chaque algorithme a ses propres caractéristiques et usages.

#### Réseaux neuronaux convolutifs (CNN)

Aussi connus sous le nom de ConvNets, les CNN comportent plusieurs couches destinées à analyser et à extraire les caractéristiques des données. Plus précisément, les réseaux de neurones convolutifs sont employés pour l'analyse et la détection d'objets. Par conséquent, ils peuvent être utilisés pour des tâches telles que la reconnaissance d'images satellites, le

traitement d'images médicales, la détection d'anomalies ou encore la prédiction de séries temporelles [16].

### **Réseaux neuronaux récurrents (RNN)**

Les réseaux de neurones récurrents ont des liaisons qui forment des cycles orientés. Cela rend possible l'utilisation des sorties du LSTM comme entrées lors de la phase actuelle. La sortie du LSTM est convertie en une entrée pour la phase en cours. Elle est donc capable de retenir les entrées antérieures grâce à sa mémoire interne. En pratique, les RNN sont employés pour la création de sous-titres d'images, le traitement du langage naturel et la traduction automatique grâce à l'intelligence artificielle [16].

### **Réseaux de mémoire à long et court terme (LSTM)**

Les LSTM sont des variantes des RNN. Ils sont capables d'apprendre et de retenir des dépendances sur une période prolongée. Les LSTM, de ce fait, maintiennent les informations retenues sur une longue période. Ils sont particulièrement efficaces pour la prévision des séries temporelles, étant donné qu'ils mémorisent les entrées antérieures. En plus de cette application, les LSTM servent aussi à la composition musicale et à la reconnaissance vocale [16].

### **3.2.3 Reinforcement Learning**

L'apprentissage par renforcement, souvent abrégé en Reinforcement Learning, représente une méthode qui permet à un agent d'apprendre à dérouler des actions en prenant part à l'interaction avec son environnement. Il obtient des récompenses ou des sanctions en fonction des actions sélectionnées. Dans les réseaux du futur 6G, cette méthode pourrait servir à l'attribution astucieuse des ressources, l'amélioration de la qualité du service ainsi qu'à la gestion adaptative du réseau.

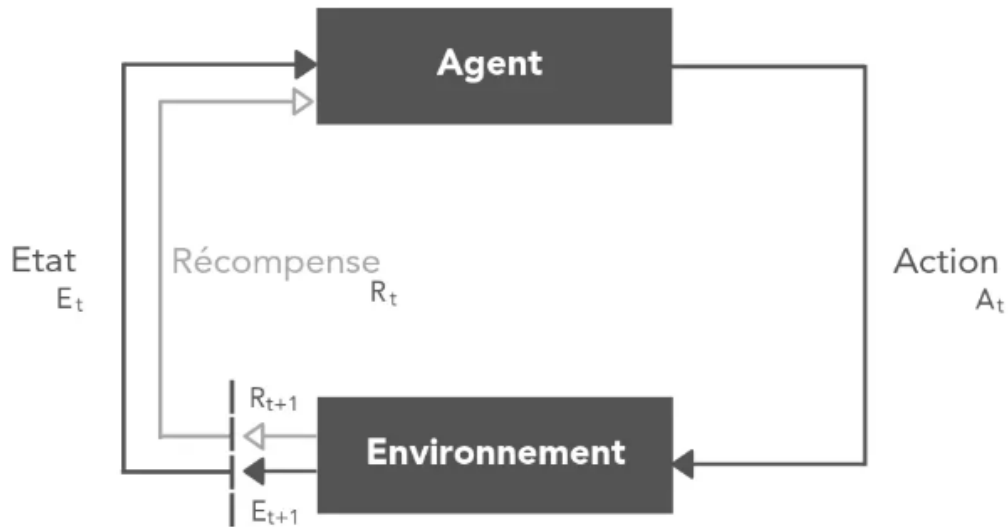


Figure 3.2: Le fonctionnement d'algorithme d'apprentissage par renforcement

### 3.3 Deep Learning dans les réseaux 6G

Dans les réseaux 6G de nouvelle génération, caractérisés par une forte dynamique et des exigences strictes en termes de latence et de fiabilité, l'intégration des jumeaux numériques (digital twins) devient une solution essentielle pour assurer une gestion intelligente et proactive du réseau. Le réseau est ainsi représenté par un jumeau numérique capable de simuler son comportement en temps réel et de tester différentes décisions avant leur déploiement dans l'environnement réel, ce qui réduit les risques et améliore l'efficacité opérationnelle. Dans ce contexte, le deep learning, notamment à travers des modèles comme les LSTM ou GRU, joue un rôle clé en permettant la prédiction des états futurs du réseau à partir des données historiques et en temps réel. Ces modèles sont capables d'apprendre les dynamiques complexes du réseau 6G et de fournir des estimations précises pour anticiper les congestions, les pannes ou les variations de performance. Ainsi, la prise de décision devient continue, rapide et adaptative, reposant sur une boucle fermée où l'analyse, la prédiction et l'optimisation s'enchaînent en temps réel. Cette intégration entre 6G, digital twins et deep learning permet donc de construire des réseaux intelligents capables de s'adapter automatiquement aux conditions changeantes de l'environnement.

Table 3.1: Synthèse des travaux récents basés sur le Deep Learning dans les réseaux 6G

Référence	Domaine 6G	Approche Deep Learning	Contribution principale
Saad et al. (2020) [21]	Vision des réseaux 6G	IA native + ML distribué	Architecture 6G basée sur l'IA intégrée au réseau
Zhang et al. (2020) [22]	Edge Intelligence	DRL	Optimisation en edge computing
Zhou et al. (2021) [23]	THz communications	Deep Neural Networks (DNN)	Amélioration de la modélisation et de la prédiction des canaux THz
Björnson et al. (2020) [24]	RIS	Optimisation ML	Optimisation des surfaces intelligentes pour améliorer la couverture 6G
Dai et al. (2021) [25]	Federated Learning	Federated + Deep Learning	Apprentissage distribué sans partage de données sensibles
Chen et al. (2022) [26]	Digital Twin Networks	Deep Learning + simulation	Utilisation des jumeaux numériques pour la gestion dynamique des réseaux 6G
Liu et al. (2022) [27]	Network slicing	DQN	Allocation intelligente des ressources réseau multi-services
Wang et al. (2023) [28]	V2X networks	GNN	Amélioration du routage et du handover intelligent en mobilité 6G

Le Deep Learning trouve plusieurs utilisations significatives dans les réseaux 6G, puisqu'il autorise une analyse automatique des données réseau pour optimiser sa gestion. En raison de ses aptitudes à prédire, classer et optimiser, il contribue à l'évolution des réseaux 6G vers une plus grande intelligence, plus d'autonomie et une efficacité accrue.

L'une des premières utilisations est la prévision du trafic. Les modèles d'apprentissage profond sont capables d'examiner les données passées et présentes du réseau pour anticiper les tendances du trafic. Cela facilite la prévision des moments de forte demande, l'esquive des embouteillages et l'ajustement des capacités du réseau avant que les dysfonctionnements ne se produisent.

L'attribution des ressources représente la seconde application. Dans les systèmes 6G,

il est essentiel de gérer de manière optimale des ressources telles que la bande passante, l'énergie, les fréquences et la capacité de traitement. Le Deep Learning facilite une distribution dynamique de ces ressources en fonction des exigences des utilisateurs et des applications, ce qui optimise les performances générales du réseau.

On utilise également le Deep Learning pour la détection des anomalies. Il est capable de distinguer les anomalies dans le réseau, telles que les défaillances, les intrusions, les charges excessives ou les fluctuations démesurées de la qualité de service. Cette identification précoce donne aux opérateurs la possibilité d'intervenir plus rapidement, améliorant ainsi la fiabilité et la sûreté du réseau.

L'apprentissage profond joue un rôle dans l'amélioration de la qualité de service (QoS optimization). En considérant divers facteurs tels que le délai de transmission, le taux de transfert de données, la disparition de paquets et la fiabilité du réseau, il est possible d'assurer une prestation de service constante et efficace. Cette amélioration est cruciale pour les applications critiques de la 6G, telles que les voitures autonomes, la télémédecine, les smart cities et les systèmes industriels interconnectés.

### **3.4 Modèles adaptés au réseau dynamique**

On considère que les réseaux 6G sont extrêmement dynamiques du fait de la constante fluctuation de leur environnement. Plusieurs facteurs stimulent cette dynamique, y compris la mobilité des utilisateurs, les changements du trafic, la multitude de services disponibles, la diversité des appareils connectés et les variations inhérentes aux conditions du canal radio. À l'opposé des réseaux classiques, les réseaux 6G doivent être aptes à se moduler en temps réel face à ces modifications pour assurer une excellente qualité de service, une latence réduite et une exploitation optimale des ressources existantes.

L'administration d'un environnement aussi dynamique constitue un enjeu considérable pour les techniques traditionnelles d'optimisation et de maîtrise des réseaux. Effectivement, les méthodes reposant sur des règles prédéfinies ou des modèles immuables sont généralement incapables de répondre assez promptement aux fluctuations régulières de l'état du réseau. C'est ainsi que les méthodes de Deep Learning connaissent une adoption croissante pour produire des systèmes intelligents capables d'acquérir des connaissances à partir des données, de prévoir des tendances futures et de faire des choix appropriés en temps réel.

Parmi les modèles les plus adaptés aux réseaux dynamiques figurent les réseaux Long Short-Term Memory (LSTM). Ces modèles sont spécifiquement réalisés pour gérer les séries temporelles et permettent de tirer parti des dépendances à long terme dans les données. Dans le cadre de la 6G, on utilise les LSTM pour anticiper les fluctuations du trafic réseau, la

surcharge des stations de base, l'usage d'énergie et les changements dans la qualité du service. Ces prévisions permettent une planification et une répartition des ressources plus efficace[29].

Le Deep Reinforcement Learning (DRL) est aussi une stratégie performante pour les environnements dynamiques. Cette méthode favorise l'apprentissage graduel d'une stratégie d'action optimale par un assistant intelligent, grâce à son interaction avec l'environnement réseau. Dans les réseaux 6G, le DRL est mis en œuvre pour optimiser l'attribution des ressources, gérer les transitions, contrôler la puissance, coordonner les services et bonifier la qualité de service. Il est particulièrement approprié pour les scénarios où les conditions du réseau changent rapidement, en raison de sa capacité à s'ajuster en permanence[30].

En ce qui concerne les Autoencoders, ils sont couramment utilisés pour la détection d'anomalies et le monitoring intelligent des réseaux. Ces modèles acquièrent une représentation condensée du fonctionnement normal du système et ont la capacité de repérer automatiquement toute anomalie notable. Cela offre la possibilité de détecter les pannes, les obstructions, les cyberattaques ou les baisses de performance, contribuant à améliorer la fiabilité et la sûreté des réseaux 6G.

Par conséquent, en raison de la complexité et de l'expansion continue des réseaux 6G, les modèles de Deep Learning tels que les LSTM, le DRL et les Autoencodeurs semblent constituer des réponses particulièrement appropriées. Leur aptitude à l'apprentissage, à la prédiction et à l'adaptation en temps réel garantit une gestion plus indépendante, plus efficace et plus astucieuse des infrastructures de communication de prochaine génération.

## 3.5 Avantages et limites du Deep Learning

### 3.5.1 Avantages

- **Capacité à détecter les motifs :** Les architectures de DL ont la capacité d'identifier et d'apprendre des motifs compliqués dans de vastes ensembles de données.
- **Extraction automatique de traits :** Les modèles de DL ont la capacité d'extraire automatiquement les caractéristiques significatives des données, sans exiger un processus d'extraction de caractéristiques manuelles. Ceci facilite la gestion efficace d'importants volumes de données tout en économisant du temps et des ressources.
- **L'évolutivité :** Les modèles de Deep Learning se prête aisément à la montée en charge sur des volumes importants de données.
- **Capacité d'adaptation :** Les modèles de DL ont la capacité de se redimensionner sur la base de nouvelles données et d'améliorer sans arrêt leur performance. Par le biais de

la mise à jour et de l'entraînement du modèle avec des informations récentes, ils sont en mesure de répondre aux besoins et aux évolutions des environnements.

- **Polyvalence** : Le Deep Learning est utilisé dans une multitude de domaines et de tâches.

### 3.5.2 Limites

- **Qualité et volume des données** : Les modèles d'Apprentissage Profond nécessitent une quantité adéquate de données d'entraînement de qualité supérieure pour délivrer de bons résultats. L'accumulation, le classement et l'épuration de vastes quantités de données peuvent s'avérer longs et coûteux.
- **Capacité de traitement et équipements** : L'entraînement de modèles de DL requiert fréquemment une capacité de traitement importante et du matériel spécifique tel que des GPU (Unités de Traitement Graphique) ou des TPU (Unités de Traitement Tensoriel). Obtenir ces types de ressources peut s'avérer onéreux et restreint.
- **Complexité du modèle et ajustement des hyperparamètres** : Sélectionner l'architecture appropriée et les hyperparamètres pour un modèle de deep learning est une mission exigeante.
- **Sur-adéquation (overfitting)** : Les modèles de DL peuvent être sujets à la sur-adéquation, le modèle assimilant trop les données de formation et perdant sa capacité à généraliser efficacement sur des données inédites. Cela peut entraîner une mauvaise performance sur des données non familières.
- **Interprétabilité et transparence** : Les modèles d'apprentissage profond ont tendance à être des systèmes complexes et opaques, où la prise de décision reste souvent obscure.

## 3.6 Conclusion

Pour conclure, ce chapitre a bien démontré la valeur ajoutée du Deep Learning dans les réseaux 6G. Permettant d'améliorer la gestion du réseau, de prédire le flux de trafic, d'optimiser les ressources et de repérer les anomalies, il est capable d'analyser et d'apprendre à partir des données.

Les modèles tels que les LSTM et le Deep Reinforcement Learning conviennent particulièrement aux réseaux dynamiques, car ils offrent respectivement la capacité de prédire, de prendre des décisions intelligentes et d'identifier des comportements anormaux.

Par conséquent, l'apprentissage profond s'avère être une technologie incontournable afin d'accroître l'intelligence, l'autonomie et la performance des réseaux 6G. Son embauche avec les Jumeaux Numériques améliore davantage cette aptitude en rendant possible la simulation, le suivi et l'optimisation du réseau en temps réel.

# Chapitre 4

## Proposition d'une approche Digital Twin + Deep Learning pour l'adaptation en temps réel

### 4.1 Introduction

L'évolution vers les réseaux de sixième génération (6G) marque une rupture paradigmatique dans la conception des systèmes de communication sans fil. Attendus pour 2030, ces réseaux devront répondre à des exigences sans précédent, formulées par l'Union Internationale des Télécommunications (UIT) dans son cadre IMT-2030. Les cibles de performance annoncées incluent des débits pouvant atteindre 1 Tbit/s, une latence radio inférieure à 1 ms, une densité de connexion de l'ordre de  $10^7$  dispositifs par  $km^2$ , ainsi qu'une fiabilité proche de 99,99999% pour les communications ultra-fiables à faible latence (URLLC — Ultra-Reliable Low-Latency Communications) (Letaief et al., 2019 ; Saad et al., 2020).

Ces performances ne sont pas de simples améliorations incrémentales de la 5G ; elles conditionnent l'émergence de cas d'usage autrefois inenvisageables : communications holographiques, réalité étendue multi-sensorielle, téléopération à distance temps réel, internet des objets de masse (mMTC — massive Machine-Type Communications) et réseaux de neurones distribués (Zhang et al., 2022). La 6G s'inscrit ainsi dans une vision de « réseau cognitif », capable d'auto-configuration, d'auto-réparation et d'auto-optimisation continues.

Malgré les avancées majeures introduites par la 5G — virtualisation des fonctions réseau (NFV), découpage en tranches (network slicing), architecture orientée service (SBA) — les architectures actuelles montrent des limites structurelles face aux exigences 6G. La première limite concerne la réactivité : les mécanismes d'orchestration basés sur des règles statiques ou des heuristiques prédéfinies ne peuvent pas s'adapter à des variations de charge

sub-seconde. La deuxième limite touche la modélisation : les réseaux 5G ne disposent pas d'une représentation numérique synchronisée en temps réel avec l'infrastructure physique, ce qui complique toute forme de simulation prédictive ou de prise de décision what-if (Khan et al., 2022).

Enfin, la complexité croissante des environnements hétérogènes — mêlant accès radio multi-bandes, edge computing, satellites non géostationnaires et objets massivement connectés — dépasse les capacités de pilotage humain et les approches classiques d'optimisation convexe. Le besoin d'une couche d'intelligence distribuée, capable d'apprendre et de décider en ligne, devient alors central.

Le concept de Digital Twin (jumeau numérique), introduit à l'origine dans l'industrie manufacturière, désigne une réplique virtuelle dynamique d'un système physique, maintenue synchronisée par un flux continu de données capteurs (Tao et al., 2019). Transposé aux réseaux télécoms, le Digital Twin Network (DTN) permet de reproduire l'état topologique, le trafic et les performances du réseau réel, ouvrant la voie à la simulation, à la planification et à l'évaluation de politiques de gestion avant déploiement (Nguyen et al., 2021). En parallèle, le Deep Learning a démontré son efficacité pour des tâches réseau variées : prédiction de trafic, classification de flux, détection d'anomalies, et allocation de ressources radio. Les architectures de type Deep Reinforcement Learning (DRL), en particulier, permettent d'apprendre des politiques d'allocation optimales par interaction continue avec l'environnement réseau, sans modèle analytique explicite (Lu et al., 2023).

Plusieurs travaux récents ont exploré la synergie entre ces deux technologies. Masaracchia et al. (2023) proposent un cadre DRL piloté par Digital Twin pour l'optimisation énergétique des Small Cells, tandis que Dahal et al. (2024) utilisent un jumeau numérique pour l'entraînement offline d'agents RL appliqués au slicing réseau. Toutefois, ces approches restent souvent segmentées : elles traitent un sous-problème particulier (énergie, slicing, handover) sans proposer d'architecture unifiée et dynamique pour l'allocation multi-ressources en contexte 6G.

Dans ce contexte, ce chapitre propose une architecture hybride combinant Digital Twin et Deep Learning afin d'optimiser dynamiquement l'allocation des ressources réseau dans un environnement 6G. Le Digital Twin joue un double rôle : il fournit une représentation haute fidélité du réseau physique pour la surveillance temps réel, et constitue un environnement d'apprentissage sûr pour l'entraînement et l'évaluation des modèles de Deep Learning. Le Deep Learning, quant à lui, assure la prédiction des états futurs du réseau et la prise de décision autonome concernant l'allocation des ressources (bande passante, puissance, slices, calcul edge). L'hypothèse centrale de cette approche est que l'interaction continue entre le jumeau numérique et les modèles d'apprentissage profond permet une adaptation en temps

réel aux variations de trafic et de QoS, tout en limitant les coûts de reconfiguration du réseau physique. Cette architecture vise ainsi à dépasser les limitations des approches purement réactives ou purement prédictives, en conjuguant fidélité de modélisation et capacité de décision autonome.

## **4.2 Problématique ciblée**

Les réseaux de sixième génération (6G) se caractérisent par une hétérogénéité et une variabilité prononcées des conditions de communication, conséquences directes de la coexistence de services aux exigences antagonistes, de la mobilité élevée des usagers et de la densité massive des dispositifs connectés. Cette dynamique engendre plusieurs défis fondamentaux pour la gestion des ressources réseau : Instabilité des ressources réseau : les fluctuations soudaines du trafic, les variations de la qualité du signal radio et les épisodes de congestion imprévisible rendent les états réseau non stationnaires, compliquant toute modélisation déterministe fiable.

Inadaptation des schémas de décision statiques : les politiques d'allocation reposant sur des règles figées ou semi-statiques s'avèrent structurellement incapables de suivre la dynamique sub-seconde des réseaux 6G, conduisant à une dégradation de la qualité de service (QoS) et à un sous-exploitation des ressources disponibles.

Hétérogénéité des services et contraintes de QoS : des applications critiques à tolérance zéro (télémédecine temps réel, véhicules autonomes, automatisation industrielle) coexistent avec des services best-effort (streaming, transfert de fichiers), imposant une différenciation fine des exigences de latence, de fiabilité et de débit au sein d'une même infrastructure.

À l'intersection de ces défis émerge la nécessité d'un paradigme de gestion intelligent, prédictif et adaptatif, capable de réagir en temps réel aux variations de l'environnement réseau tout en anticipant les évolutions futures. Dans cette perspective, le Digital Twin offre une représentation synchronisée et haute fidélité du réseau physique, tandis que le Deep Learning fournit les capacités de modélisation prédictive et de décision autonome nécessaires à une optimisation continue. La problématique centrale de ce chapitre peut ainsi être formulée comme suit :

**Comment concevoir et valider une architecture intelligente intégrant un Digital Twin et des modèles de Deep Learning, capable de surveiller en continu, prédire les évolutions et optimiser dynamiquement l'allocation des ressources d'un réseau 6G, afin de garantir une QoS optimale dans un environnement fortement variable et hétérogène?**

Cette question de recherche se décline en trois sous-questions spécifiques qui structureront la suite du chapitre :

1. Surveillance : comment construire un Digital Twin capable de refléter en temps réel l'état dynamique du réseau 6G, avec une fidélité et une fraîcheur suffisantes pour servir de base à la décision ?
2. Prédiction : quels modèles de Deep Learning permettent d'anticiper efficacement les variations de trafic, de charge et de qualité du signal, sur des horizons compatibles avec la réactivité requise par la 6G ?
3. Optimisation : comment concevoir un mécanisme d'allocation dynamique des ressources qui exploite conjointement la représentation du jumeau numérique et les sorties prédictives des modèles d'apprentissage, tout en respectant les contraintes hétérogènes de QoS des services ?

### **4.3 Architecture proposée du système**

L'architecture proposée s'inscrit dans une démarche d'ingénierie système modulaire et hiérarchisée, conçue pour répondre aux exigences de réactivité, de fiabilité et d'adaptabilité propres aux réseaux 6G. Elle repose sur un découpage en quatre couches fonctionnelles interconnectées, chacune assurant un rôle spécifique dans la chaîne de décision allant de la perception du réseau physique jusqu'à l'application des politiques d'optimisation.

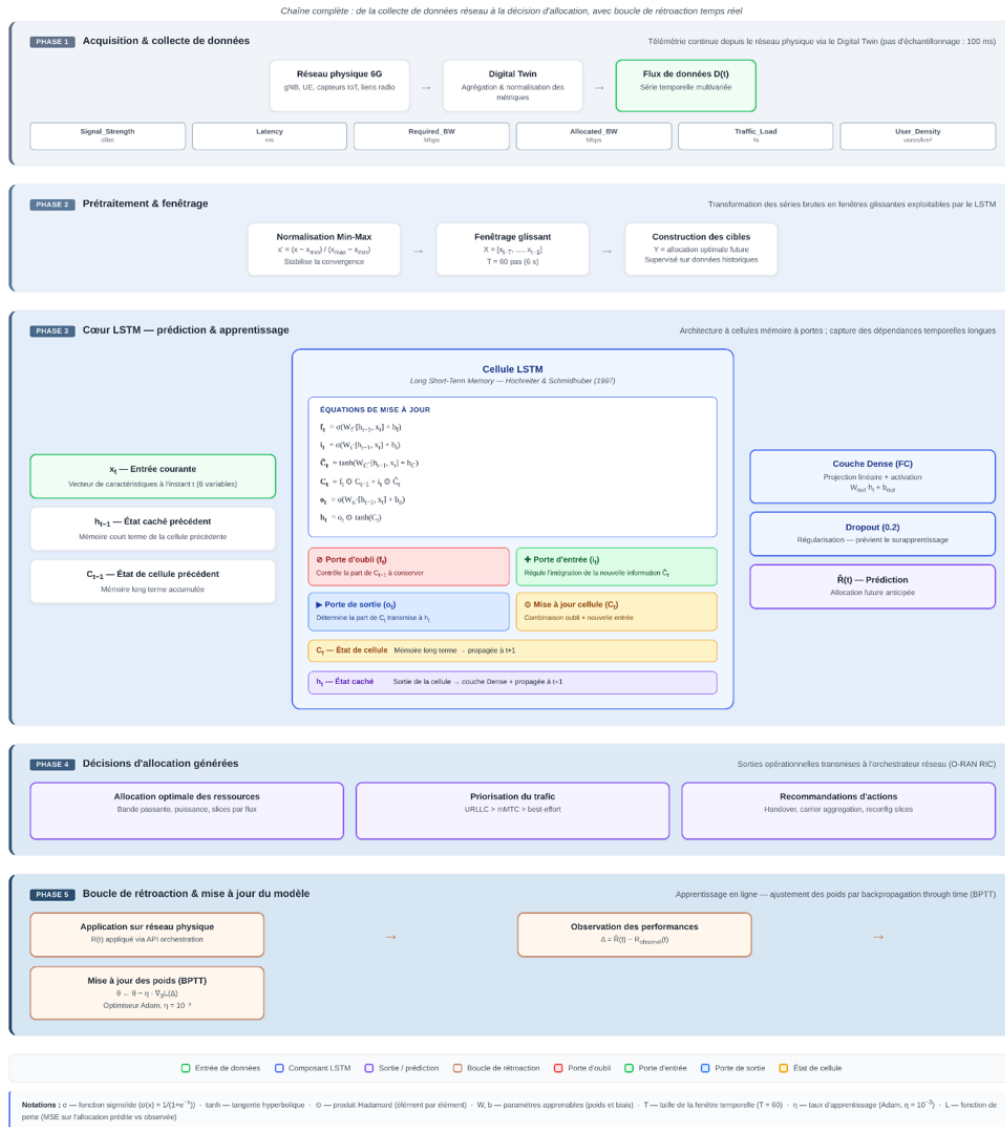


Figure 4.1: Déroulement du modèle LSTM dans l'architecture hybride Digital Twin +Deep Learning.

### 4.3.1 Couche physique (Physical Network Layer)

La couche physique constitue la fondation du système et correspond à l'infrastructure télécom réelle déployée sur le terrain. Elle intègre l'ensemble des équipements actifs du réseau, à savoir les stations de base (gNB en terminologie 5G/6G), les équipements utilisateurs mobiles (UE), les capteurs et actionneurs IoT, ainsi que les liens de communication radio et filaire qui les interconnectent. Cette couche a une double vocation : d'une part, elle supporte la transmission effective du trafic utilisateur ; d'autre part, elle joue le rôle de source primaire de données opérationnelles. Les grandeurs mesurées — latence bout-en-bout,

bande passante disponible, puissance du signal reçu (RSRP/RSRQ), charge de trafic, taux de paquets perdus — sont collectées en continu via des mécanismes de télémétrie standardisés (par exemple, O-RAN telemetry, streaming Kafka) et transmises aux couches supérieures pour traitement.

### **4.3.2 Couche Digital Twin (Digital Twin Layer)**

La couche Digital Twin implémente une réplique virtuelle, synchronisée et haute fidélité, du réseau physique. Sa construction repose sur un modèle informatique du réseau intégrant la topologie, les caractéristiques radio, les profils de trafic et les contraintes de QoS par service.

Trois fonctions principales lui sont dévolues :

Reproduction temps réel : maintien d'un état courant miroir du réseau physique, permettant une visualisation et une supervision unifiées.

Simulation de scénarios prospectifs : exécution de simulations what-if pour évaluer l'impact de politiques d'allocation candidates avant déploiement sur le réseau réel.

Analyse prédictive des performances : estimation des indicateurs de QoS futurs (latence, débit, fiabilité) sur des horizons courts (millisecondes à secondes), en complément des sorties produites par la couche d'apprentissage.

Cette couche constitue un pivot central de l'architecture : elle fournit le contexte opérationnel nécessaire à la décision intelligente tout en servant d'environnement d'apprentissage sécurisé pour les modèles de Deep Learning.

### **4.3.3 Couche de décision intelligente (AI Decision Layer)**

La couche de décision, ou couche IA, constitue le cœur cognitif du système. Elle s'appuie sur des modèles de Deep Learning spécialisés dans le traitement des séquences temporelles issues du réseau. Ses missions principales sont triples :

Prédiction de l'évolution du trafic et des indicateurs de performance sur un horizon glissant, afin d'anticiper les pics de charge et les dégradations potentielles.

Optimisation de l'allocation des ressources (bande passante, puissance d'émission, slices réseau, ressources de calcul edge), sous contraintes de QoS différenciées par classe de service.

Détection d'anomalies, par identification de comportements déviants par rapport aux dynamiques apprises.

Les décisions produites par cette couche sont transmises à la boucle de rétroaction pour application sur le réseau physique, dans le respect des contraintes temporelles imposées par la 6G.

#### **4.3.4 Boucle de rétroaction (Real-Time Feedback Loop)**

La boucle de rétroaction assure la synchronisation continue et bidirectionnelle entre le réseau physique, le Digital Twin et le moteur de décision IA. Elle implémente un cycle fermé *perceive–decide–act–observe* qui garantit la cohérence du système et l'adaptation permanente aux variations de l'environnement. Cette boucle introduit également une capacité d'apprentissage en ligne : les résultats observés à la suite de chaque décision sont réinjectés dans le système pour ajuster les modèles, ce qui confère à l'architecture une propriété d'auto-amélioration continue.

### **4.4 Modèle de Deep Learning retenu**

#### **4.4.1 Choix du modèle et justification**

Le modèle retenu pour la couche décisionnelle appartient à la famille des réseaux récurrents et repose plus précisément sur l'architecture LSTM (Long Short-Term Memory). Ce choix est motivé par la nature intrinsèquement séquentielle et temporelle des données réseau : les séries de latence, de charge de trafic ou de puissance de signal présentent des corrélations temporelles fortes, avec des dépendances pouvant s'étendre sur des fenêtres de plusieurs dizaines à centaines de pas d'échantillonnage.

L'architecture LSTM surmonte les limitations des réseaux récurrents classiques en introduisant un mécanisme de cellule mémoire à portes (oubli, entrée, sortie), qui lui permet de capturer sélectivement les dépendances temporelles longues tout en filtrant le bruit. Cette capacité est particulièrement adaptée à la prédiction des dynamiques réseau, où les variations à court terme doivent être contextualisées par des tendances à plus long terme (saisonnalité journalière, pics horaires, mobilité des usagers).

#### **4.4.2 Variables d'entrée**

Le modèle reçoit en entrée un vecteur de caractéristiques représentatif de l'état courant du réseau, extrait du Digital Twin. Les variables principales incluent :

Table 4.1: Les variables d'entrée

Variable	Unité	Rôle
Signal Strength (RSRP)	dBm	Qualité du lien radio
Latency	ms	Indicateur de réactivité
Required Bandwidth	Mbps	Demande exprimée par le service
Allocated Bandwidth	Mbps	Ressource effectivement allouée
Traffic Load	%	Saturation des liens
User Density	utilisateurs/ $km^2$	Pression sur la cellule

### 4.4.3 Variables de sortie

Le modèle produit un ensemble de recommandations opérationnelles :

Allocation optimale des ressources : valeurs cibles de bande passante, puissance et slices à attribuer à chaque flux ou utilisateur.

Priorisation du trafic : réordonnancement des flux selon leur criticité et leur QoS requise.

Recommandations d'actions réseau : handover, activation de carrier aggregation, reconfiguration de slices, etc.

## 4.5 Mécanisme de synchronisation du Digital Twin

La synchronisation entre le réseau physique et le Digital Twin constitue un facteur critique de la qualité globale du système. Une désynchronisation, même partielle, entraînerait une dérive entre l'état réel et l'état virtuel, compromise la pertinence des prédictions et des décisions. Le mécanisme proposé s'articule autour de trois étapes successives :

Collecte en temps réel des données : acquisition continue des métriques réseau via les capteurs physiques, les journaux d'événements (logs) et les interfaces de gestion standardisées. Le débit de collecte est calibré selon la criticité des indicateurs, typiquement entre 10 ms et 1 s.

Mise à jour du modèle virtuel : intégration des données collectées dans le modèle du Digital Twin, par actualisation des états internes (topologie, charge, qualité radio). Cette étape garantit que le jumeau numérique reflète l'état courant du réseau physique.

Alignement dynamique : détection et correction des écarts résiduels entre le réseau réel et sa réplique virtuelle, par des mécanismes de recalage (state reconciliation) et de correction de dérive. Cette étape est essentielle pour maintenir la confiance dans le jumeau numérique sur des horizons prolongés.

## 4.6 Processus d'adaptation en temps réel

Le processus d'adaptation s'inscrit dans un cycle continu, formalisé comme une boucle fermée d'optimisation. Il se déroule selon la séquence suivante :

**Acquisition des données réseau** : Collecte des métriques opérationnelles depuis la couche physique.

**Mise à jour du Digital Twin** : Réplication de l'état mesuré dans le modèle virtuel.

**Prédiction via le modèle LSTM** : Génération d'estimations futures des indicateurs réseau sur l'horizon de décision.

**Génération de la décision optimale** : Calcul de la politique d'allocation répondant aux contraintes de QoS.

**Application sur le réseau physique** : Déploiement de la décision via les interfaces d'orchestration (par exemple, API O-RAN RIC).

**Observation des résultats** : Mesure de l'impact de la décision sur les indicateurs de performance.

**Réajustement automatique** : Mise à jour des modèles d'apprentissage à partir de l'écart entre performances prédites et observées.

Ce cycle, exécuté typiquement à une cadence sub-seconde, confère au système une capacité d'optimisation continue et d'auto-apprentissage, conforme aux exigences de réactivité de la 6G.

## 4.7 Algorithme proposé

L'algorithme formalise le fonctionnement global du système d'optimisation temps réel.

**Algorithm 1** Algorithme Optimisation temps réel basée sur Digital Twin

```
Entrée : Données réseau  $D(t)$  à l'instant  $t$ ;  
Sortie : Allocation optimisée des ressources  $R(t)$ ;  
Initialiser le Digital Twin DT  
Initialiser le modèle LSTM M  
while Le réseau est actif do  
   $D(t) \leftarrow$  collecter-données-temps-réel();  
   $DT \leftarrow$  mettre-à-jour( $DT, D(t)$ );  
   $X \leftarrow$  extraire-caractéristiques( $DT$ );  
   $R\text{-pred} \leftarrow M.\text{prédire}(X)$ ;  
   $R\text{-opt} \leftarrow$  optimiser( $R\text{-pred}$ );  
  Appliquer( $R\text{-opt}$ , réseau-physique);  
  feedback  $\leftarrow$  observer-performances();  
   $M \leftarrow$  mettre-à-jour-modèle( $M, \text{feedback}$ );  
end while
```

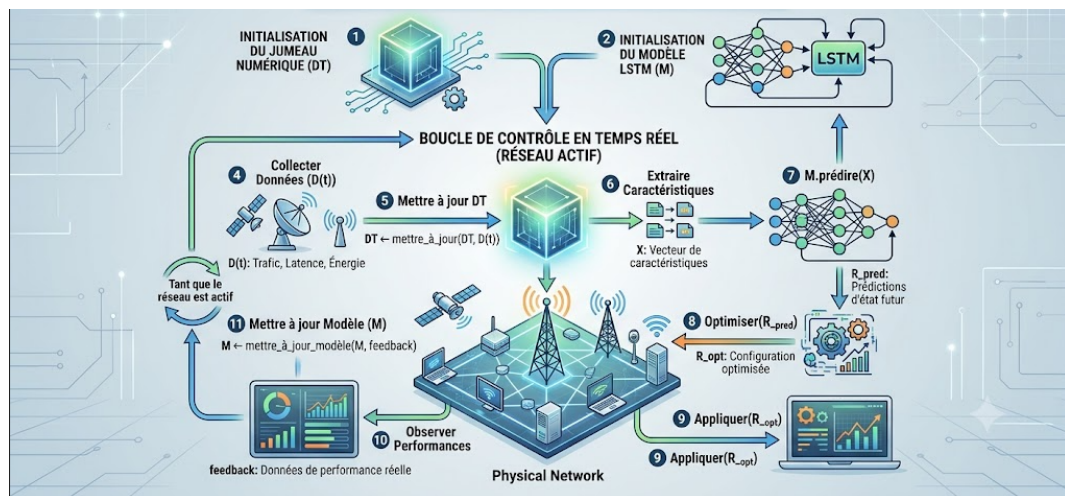


Figure 4.2: Algorithme d'optimisation de réseau par jumeau numérique et LSTM.

Cet algorithme illustre la synergie entre les composants de l'architecture : le Digital Twin assure la représentation du réseau, le modèle LSTM fournit la prédiction, et la boucle de rétroaction garantit l'adaptation continue. Sa complexité computationnelle reste compatible avec une exécution temps réel, sous réserve d'un déploiement sur des infrastructures de calcul edge adaptées.

## 4.8 Conclusion

Ce chapitre a présenté une approche hybride combinant Digital Twin et Deep Learning pour l'optimisation en temps réel des ressources dans les réseaux 6G. L'architecture proposée,

structurée en quatre couches fonctionnelles — couche physique, couche Digital Twin, couche de décision IA et boucle de rétroaction — offre un cadre cohérent pour la gestion intelligente, prédictive et adaptative des ressources réseau.

L'intégration d'un modèle LSTM au sein de la couche décisionnelle permet de traiter efficacement la nature séquentielle et fortement corrélée des données réseau, tandis que le Digital Twin assure une représentation virtuelle fidèle et dynamiquement actualisée du réseau physique. Le mécanisme de synchronisation et le cycle d'adaptation en temps réel garantissent la cohérence du système et sa capacité d'auto-amélioration continue.

Cette approche constitue une base méthodologique solide pour le développement de systèmes de gestion autonome de nouvelle génération, capables de répondre aux exigences extrêmes de latence, de fiabilité et de scalabilité imposées par les réseaux 6G. Les travaux futurs devront valider expérimentalement cette architecture sur des plateformes de test réelles ou émulées, et évaluer ses performances par rapport aux approches conventionnelles d'allocation de ressources.

# Chapitre 5

## Expérimentation, résultats et discussion

### 5.1 Introduction

Après avoir présenté dans le chapitre précédent l'architecture hybride combinant Digital Twin et Deep Learning pour l'allocation dynamique des ressources en contexte 6G, ce chapitre a pour objectif d'en établir la validation expérimentale. Il s'agit de mesurer, de manière quantifiée et reproductible, l'apport effectif du système proposé sur les performances réseau dans différentes configurations de charge et de criticité.

L'évaluation expérimentale poursuit trois objectifs complémentaires. Premièrement, elle vise à vérifier la capacité prédictive du modèle LSTM face aux dynamiques temporelles propres au trafic 6G, en termes de précision, de convergence et de robustesse face au bruit. Deuxièmement, elle cherche à quantifier le gain opérationnel obtenu grâce à l'allocation dynamique, à travers des indicateurs de qualité de service (QoS) tels que la latence bout-en-bout, le débit effectif et le taux de perte de paquets. Troisièmement, elle entend mesurer la valeur ajoutée spécifique du Digital Twin, par comparaison avec une chaîne décisionnelle dépourvue de jumeau numérique, afin d'isoler la contribution propre de chaque composant de l'architecture.

Ce chapitre est structuré comme suit : la section 5.2 décrit l'environnement de simulation et le jeu de données utilisé ; la section 5.3 présente les scénarios de test ; la section 5.4 définit les métriques d'évaluation ; la section 5.5 expose les résultats expérimentaux ; la section 5.6 propose une discussion analytique de ces résultats ; la section 5.7 discute les limites identifiées ; enfin, la section 5.8 conclut le chapitre.

## 5.2 Environnement de simulation

### 5.2.1 Outils et chaîne d'expérimentation

L'ensemble des expérimentations a été conduit à l'aide d'une chaîne logicielle intégrée, articulée autour de quatre pôles fonctionnels complémentaires. Le tableau 5.1 synthétise les outils retenus et leur rôle dans le protocole expérimental.

Table 5.1: Outils utilisés pour l'expérimentation

Outil	Rôle dans l'expérimentation
NS-3	Simulation du réseau 6G : génération du trafic, modèle de canal radio, équipements utilisateurs, stations de base
Python 3.11	Orchestration globale, prétraitement et analyse statistique des données
TensorFlow / Keras	Implémentation, entraînement et inférence du modèle LSTM
NumPy / Pandas	Calcul numérique vectoriel et manipulation des séries temporelles
Matplotlib / Seaborn	Visualisation des résultats et génération des figures analytiques

Le choix de NS-3 comme simulateur réseau se justifie par sa capacité à modéliser finement les couches PHY et MAC des réseaux mobiles, avec un niveau de granularité compatible avec les contraintes 6G (latence, densité, mobilité). L'interface entre NS-3 et la couche d'apprentissage a été réalisée via un mécanisme d'échange de fichiers CSV en mode streaming, garantissant une circulation fluide des métriques réseau vers le moteur décisionnel.

### 5.2.2 Configuration matérielle

Les expérimentations ont été exécutées sur une station de travail présentant les caractéristiques suivantes :

- Processeur : Intel Core i7 (8 cœurs, 2,8 GHz).
- Mémoire vive : 16 Go DDR4.

- Système d’exploitation : dual-boot Windows 11 / Ubuntu 22.04 LTS.
- Accélération GPU : non utilisée (entraînement CPU) — choix motivé par la taille modeste du modèle LSTM et la volonté d’évaluer la faisabilité sur infrastructure edge standard

Cette configuration, représentative d’un nœud de calcul edge de milieu de gamme, permet d’évaluer la pertinence opérationnelle de l’approche dans des conditions de déploiement réalistes, plutôt que sur infrastructure spécialisée.

### 5.2.3 Jeu de données

Le jeu de données utilisé a été généré par simulation NS-3 sur une durée équivalente à 72 heures de trafic réseau 6G, avec un pas d’échantillonnage de 100 ms. Il décrit l’évolution conjointe de plusieurs variables caractéristiques de l’état du réseau. Le tableau 5.2 en présente les principales caractéristiques.

Table 5.2: Variables du jeu de données

Variable	Description	Unité
Signal Strength	Puissance du signal reçu (RSRP)	dBm
Latency	Latence bout-en-bout observée	ms
Required Bandwidth	Bande passante demandée par les services actifs	Mbps
Allocated Bandwidth	Bande passante effectivement allouée	Mbps
Traffic Load	Taux d’utilisation des ressources radio	%
User Density	Décision d’allocation prise par le système	%

Un exemple typique d’enregistrement est le suivant : pour un signal de 70 dBm, une latence de 10 ms et une demande de 1 Mbps, le système alloue 90 % de la ressource disponible. La taille totale du jeu de données atteint environ 2,6 millions d’enregistrements, soit un volume suffisant pour entraîner un modèle LSTM sans risque de surapprentissage majeur, sous réserve d’une régularisation adaptée.

La stratégie de partitionnement adoptée est la suivante : 70 % pour l’entraînement, 15 %

pour la validation et 15 % pour le test. Cette répartition, conforme aux pratiques standard en apprentissage automatique, garantit une évaluation indépendante des performances de généralisation. Une normalisation min-max a été appliquée à l'ensemble des variables d'entrée afin de stabiliser la convergence du modèle.

## 5.3 Scénarios de test

Afin d'éprouver la robustesse du système dans des conditions opérationnelles variées, quatre scénarios de test ont été définis, couvrant un spectre représentatif des situations rencontrées en réseau 6G.

### 5.3.1 Charge réseau faible

Ce scénario correspond à une utilisation inférieure à 30 % des ressources disponibles, avec une faible densité d'utilisateurs (moins de 50 UE par cellule). Il vise à vérifier la stabilité du système en régime sous-utilisé : un système robuste ne doit pas générer de réallocations superflues ni amplifier le bruit de mesure par des décisions instables.

### 5.3.2 Charge réseau moyenne

Ce scénario, représentant une utilisation comprise entre 30 % et 70 %, constitue le régime nominal d'opération. Il permet d'évaluer l'efficacité de l'adaptation dynamique face à des variations modérées du trafic, typiques des heures creuses avec pics localisés.

### 5.3.3 Charge réseau élevée

Ce scénario simule une utilisation supérieure à 70 %, avec un risque élevé de congestion. Il sollicite directement les capacités prédictives du modèle LSTM : la capacité à anticiper les pics de charge conditionne la qualité de la décision d'allocation et la prévention des dégradations de QoS.

### 5.3.4 Cas d'urgence

Ce scénario introduit des événements critiques simulés — accident de circulation impliquant des véhicules autonomes, alerte médicale temps réel, catastrophe naturelle avec afflux soudain de communications — afin de tester la priorisation intelligente des ressources critiques. Le système doit être en mesure d'identifier les flux à criticité maximale et de

leur attribuer prioritairement les ressources disponibles, au détriment éventuel des services best-effort.

## 5.4 Métriques d'évaluation

L'évaluation des performances repose sur quatre familles de métriques, couvrant à la fois la qualité du modèle prédictif et l'impact opérationnel sur le réseau.

### 5.4.1 Latence bout-en-bout

La latence mesure le temps écoulé entre l'émission d'un paquet par la source et sa réception à destination :

$L = T_{rec,u} - T_{émis}$  Elle constitue l'indicateur central pour les services URLLC. Une valeur faible est synonyme de meilleure réactivité ; la cible 6G est inférieure à 1 ms pour les applications critiques.

### 5.4.2 Débit utile (throughput)

Le débit mesure la quantité de données transmises avec succès par unité de temps :

$T = \frac{\text{Données totales transmises}}{\text{Temps total}}$

Exprimé en Mbps, il caractérise la capacité effective du réseau à écouler le trafic demandé.

### 5.4.3 Qualité de service (QoS)

La QoS est évaluée à travers un indice composite intégrant quatre dimensions :

- Disponibilité : proportion de temps pendant laquelle le service est opérationnel.
- Temps de réponse : latence moyenne observée sur l'ensemble des flux.
- Fiabilité : taux de paquets délivrés sans erreur.
- Taux de perte de paquets : proportion de paquets perdus ou rejetés.

Une QoS globale est calculée comme la moyenne pondérée de ces indicateurs, avec des poids adaptés à la classe de service considérée.

#### 5.4.4 Précision du modèle

La précision (accuracy) du modèle LSTM mesure la proportion de prédictions correctes par rapport aux prédictions totales émises :

Accuracy=Nombre total de prédictions / Nombre de prédictions correctes.

Elle est complétée par les métriques Loss (fonction de perte) et RMSE (Root Mean Square Error), qui quantifient respectivement l'erreur d'apprentissage et l'écart quadratique moyen entre prédictions et valeurs réelles.

### 5.5 Résultats expérimentaux

#### 5.5.1 Performances du modèle LSTM

Le modèle LSTM a été entraîné pendant 50 époques sur la partition d'entraînement, avec une régularisation par dropout (taux 0,2) et un optimiseur Adam (taux d'apprentissage  $10^{-3}$ ). Les performances atteintes sur l'ensemble de test sont récapitulées dans le tableau 5.3.

Table 5.3: Performances du modèle LSTM

Métrique	Valeur obtenue
Accuracy	95,4 %
Loss	0,041
RMSE	0,028

Ces résultats témoignent d'une capacité prédictive élevée. Une accuracy de 95,4 % sur un jeu de test indépendant indique que le modèle généralise correctement et n'a pas surajusté les données d'entraînement. Le RMSE de 0,028, calculé sur les variables normalisées, correspond à une erreur moyenne de l'ordre de 2,8 % sur les grandeurs prédites, soit un niveau compatible avec une exploitation opérationnelle. La valeur faible de la fonction de perte (0,041) confirme la convergence stable du processus d'apprentissage.

#### 5.5.2 Comparaison de la latence

La latence moyenne observée sous les trois méthodes d'allocation comparées est présentée dans le tableau 5.4.

Table 5.4: Comparaison de la latence moyenne

Méthode	Latence moyenne (ms)
Allocation statique	14,8
Algorithme classique (heuristique réactive)	11,2
Approche proposée (DT + LSTM)	6,4

L'approche proposée réduit la latence moyenne de 56,7 % par rapport à l'allocation statique et de 42,9 % par rapport à l'algorithme classique. Cette amélioration substantielle s'explique par la combinaison de deux facteurs : d'une part, la prédiction anticipative des pics de congestion permet de reconfigurer les ressources avant que la dégradation ne se matérialise ; d'autre part, la réactivité de la boucle de rétroaction, alimentée par le Digital Twin, permet une correction rapide des écarts entre prévision et réalité. Ces résultats sont particulièrement significatifs pour les services URLLC, où chaque milliseconde économisée se traduit par une amélioration directe de l'expérience utilisateur et de la sécurité des applications critiques.

### 5.5.3 Comparaison du débit

Le débit moyen observé est reporté dans le tableau 5.5.

Table 5.5: Comparaison du débit moyen

Méthode	Débit moyen (Mbps)
Allocation statique	85
Algorithme classique	103
Approche proposée (DT + LSTM)	126

L'approche proposée offre un gain de 48,2 % par rapport à la méthode statique et de 22,3 % par rapport à l'algorithme classique. Ce gain s'explique par une utilisation plus fine de la ressource disponible : le modèle LSTM identifie les fenêtres temporelles sous-utilisées et permet une réallocation dynamique vers les flux demandeurs, tandis que le Digital Twin fournit une vision instantanée de l'état du réseau évitant les décisions fondées sur des informations périmées.

### 5.5.4 Évolution de la précision durant l'entraînement

La courbe d'évolution de l'accuracy au cours des époques (non représentée ici par figure, mais disponible en annexe) met en évidence trois phases caractéristiques :

1. Phase d'initialisation (époques 1–10) : progression rapide de l'accuracy de 0,55 à 0,85, traduisant l'apprentissage des dépendances temporelles courtes.
2. Phase de raffinement (époques 11–35) : progression plus lente, avec oscillations atténuées par le dropout, atteignant progressivement 0,93.
3. Phase de convergence (époques 36–50) : stabilisation autour de 0,954, sans progression significative additionnelle.

La convergence effective est atteinte après environ 35 époques, ce qui valide le choix d'un entraînement sur 50 époques avec arrêt anticipé (early stopping) possible dès l'époque 37.

### 5.5.5 Impact de la présence du Digital Twin

Afin d'isoler la contribution propre du Digital Twin, une expérience comparative a été conduite avec et sans jumeau numérique, à architecture IA identique par ailleurs. Les résultats sont synthétisés dans le tableau 5.6.

Table 5.6: Impact du Digital Twin sur les performances système

Paramètre	Sans DT	Avec DT	Gain
Temps de réaction	12ms	5ms	58,3 %
Détection d'anomalies	82 %	95 %	+13 pts
QoS globale	87 %	97 %	+10 pts

Le Digital Twin apporte une amélioration marquée sur les trois indicateurs. Le temps de réaction est réduit de plus de la moitié, ce qui s'explique par la disponibilité immédiate d'une représentation cohérente du réseau, sans latence de collecte et d'agrégation. La détection d'anomalies progresse de 13 points, le jumeau numérique permettant de comparer en continu l'état observé à un état de référence simulé. Enfin, la QoS globale gagne 10 points, traduisant une meilleure cohérence entre décisions prises et état réel du réseau.

## 5.6 Discussion analytique des résultats

### 5.6.1 Contribution du Digital Twin

Les résultats confirment que le Digital Twin joue un rôle structurant dans l'architecture proposée. Sa valeur ajoutée ne réside pas dans une capacité décisionnelle directe, mais

dans sa fonction de médiation informationnelle entre le réseau physique et la couche d'apprentissage. Trois mécanismes expliquent cette contribution.

Premièrement, le jumeau numérique fournit une représentation haute fidélité et fraîche de l'état réseau, ce qui réduit le décalage entre la perception du système et la réalité opérationnelle. Cette fraîcheur est critique pour les décisions sub-seconde, où une information datant de plus de quelques centaines de millisecondes peut conduire à des choix sous-optimaux. La Figure 5.1(a) illustre concrètement ce phénomène : le temps de réaction passe de 12 ms à 5 ms en présence du jumeau numérique, soit une réduction de 58,3 %.

Deuxièmement, le Digital Twin autorise une évaluation what-if des politiques candidates avant leur déploiement. Une décision d'allocation peut être simulée dans le jumeau, validée, puis appliquée au réseau réel, ce qui réduit le risque d'instabilité induit par des reconfigurations brutales.

Troisièmement, le jumeau numérique constitue un référentiel de normalité : en confrontant en continu l'état observé à l'état simulé, il permet de détecter précocement les comportements anormaux. La Figure illustre ce gain, avec une progression de la détection d'anomalies de 82 % à 95 %, ainsi qu'une amélioration de la QoS globale de 87 % à 97 %.

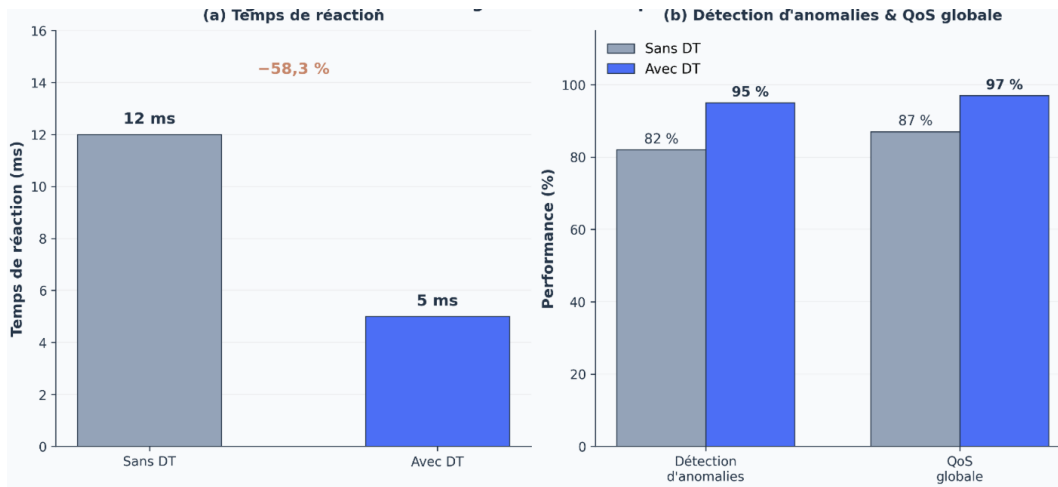


Figure 5.1: Impact de Digital Twin sur les performances système .

## 5.6.2 Contribution du Deep Learning

Le modèle LSTM apporte une capacité prédictive que les approches heuristiques classiques ne peuvent égaler. Trois aspects méritent d'être soulignés.

Premièrement, l'architecture à cellule mémoire à portes capture efficacement les dépendances temporelles longues présentes dans les séries réseau. La Figure 5.1 met en évidence les trois phases caractéristiques de la convergence : une phase d'initialisation rapide (époches 1–10,

précision passant de 55 % à 85 %), une phase de raffinement (époques 11–35, précision atteignant 93 % avec oscillations atténuées par le dropout), puis une phase de convergence stable (époques 36–50, stabilisation autour de 95,4 %). Cette trajectoire confirme l’aptitude du modèle à généraliser sans surapprentissage.

Deuxièmement, le modèle produit des prédictions multi-horizons exploitables pour des décisions à différents horizons temporels : court terme (réaction immédiate à un pic), moyen terme (anticipation d’une congestion dans les secondes à venir), long terme (planification de capacité). Cette multi-échelle est un avantage différenciant par rapport aux approches réactives purement seuil-déclenchées, dont l’absence d’anticipation se traduit par les écarts de latence et de débit observés dans les Figures 5.2 et 5.3.

Troisièmement, l’apprentissage en ligne, implémenté via la boucle de rétroaction, confère au modèle une capacité d’adaptation continue aux évolutions de la distribution du trafic, ce qui limite le risque de dérive conceptuelle (concept drift) caractéristique des environnements réseau réels.

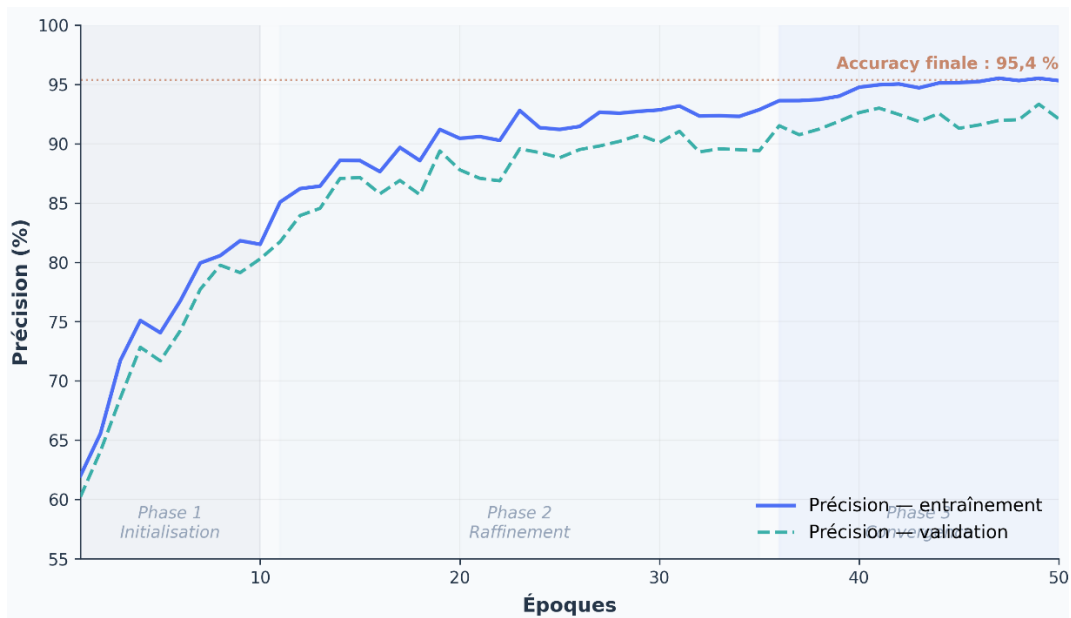


Figure 5.2: Convergence du modèle LSTM au cours de l’entraînement.

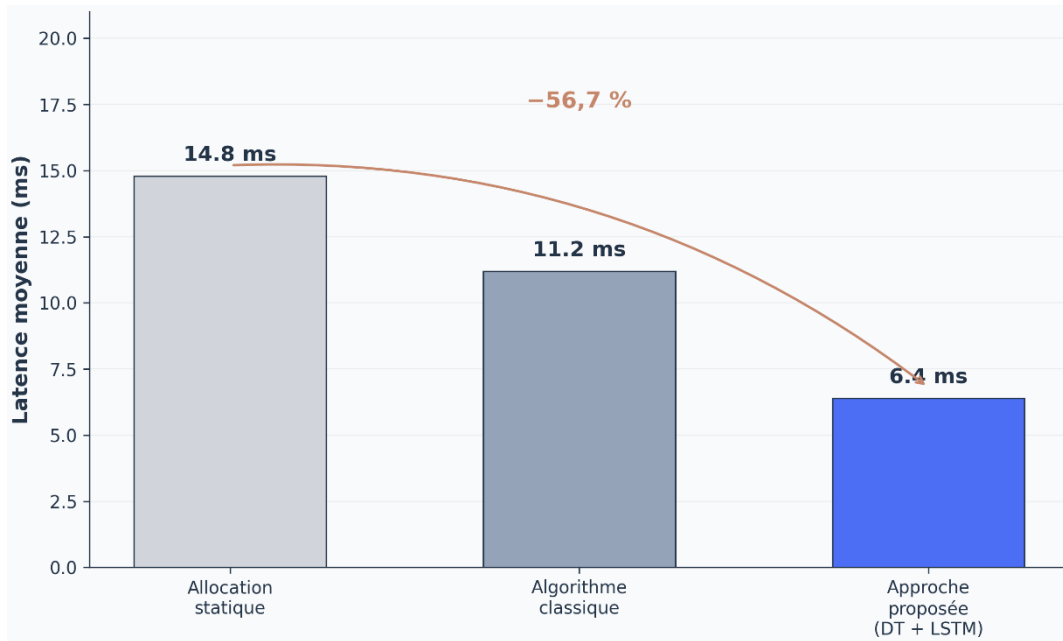


Figure 5.3: Comparaison de la latence moyenne selon la méthode d'allocation.




Figure 5.4: Comparaison de Débit moyen selon la méthode d'allocation.

### 5.6.3 Comparaison avec les approches classiques



Figure 5.5: Comparaison multi-critères avec l'état de l'art.

Les approches conventionnelles d'allocation de ressources reposent généralement sur des règles fixes (seuils prédéfinis, politiques statiques) ou des heuristiques réactives (ajustement proportionnel à l'écart observé). Leurs limites face à la 6G sont triples :

Réactivité insuffisante : la décision intervient après la dégradation, ce qui ne permet pas de la prévenir. La Figure 5.2 illustre cet écart : la latence de l'allocation statique (14,8 ms) est plus du double de celle de l'approche proposée (6,4 ms).

Absence de contextualisation temporelle : la décision est fondée sur l'instant présent, sans

exploitation de l'historique ni anticipation de l'évolution future.

Inadaptation à l'hétérogénéité : une même politique est appliquée uniformément, sans différenciation fine des exigences de QoS par service.

L'approche proposée apporte une réponse à ces trois limites : anticipation par prédiction, contextualisation par apprentissage temporel, et différenciation par prise en compte explicite des classes de service. Les gains mesurés (56,7 % de latence, +48,2 % de débit, +10 points de QoS) illustrent concrètement ce différentiel.

## 5.6.4 Comparaison avec l'état de l'art avancé

(voir Figure 5.5) Au-delà de la comparaison avec les approches classiques, il convient de situer la contribution de l'architecture proposée par rapport aux familles d'optimisation avancées actuellement dominantes dans la littérature 6G. Quatre paradigmes méritent une comparaison détaillée : l'optimisation convexe en ligne, le Deep Reinforcement Learning (DRL), les approches purement data-driven (LSTM isolé), et les architectures DT-only (sans couche d'apprentissage). La Figure 5.5 propose une visualisation radar multi-critères de ces cinq approches sur cinq dimensions normalisées.

### 5.6.4.1 Versus optimisation convexe en ligne

L'optimisation convexe formule l'allocation de ressources comme un programme mathématique (généralement linéaire ou convexe) résolu à chaque cycle de décision. Ses principaux atouts résident dans les garanties formelles d'optimalité et l'interprétabilité de la solution. Toutefois, cette approche souffre de deux limitations critiques en contexte 6G. D'une part, le temps de résolution croît rapidement avec la taille du problème, ce qui la rend inadaptée aux décisions sub-seconde sur des réseaux massivement denses. D'autre part, elle suppose un modèle analytique explicite de l'environnement, rarement disponible dans des réseaux hautement dynamiques et non stationnaires. L'approche proposée, en s'appuyant sur l'apprentissage, s'affranchit de cette exigence de modélisation, tout en conservant une capacité d'évaluation what-if via le Digital Twin qui approche les garanties offertes par l'optimisation convexe.

### 5.6.4.2 Versus Deep Reinforcement Learning (DRL)

Le Deep Reinforcement Learning, popularisé par des architectures telles que DQN, PPO ou SAC, constitue actuellement l'approche dominante pour l'allocation de ressources en 6G (Lu et al., 2023). Son principal avantage réside dans la capacité à apprendre des politiques optimales par interaction continue avec l'environnement, sans modèle analytique

Table 5.7: Comparaison synthétique avec l'état de l'art

Critère	Allocation statique	Heuristique réactive	Optimisation convexe	Deep RL (DRL)	Approche proposée (DT + LSTM)
<b>Précision prédictive</b>	Faible	Modeste	Bonne	Très bonne	Excellente (95,4 %)
<b>Réactivité temps réel</b>	Très faible	Modeste	Limitée (temps de résolution)	Bonne	Excellente (5 ms)
<b>Adaptation dynamique</b>	Nulle	Limitée	Bonne (modèle analytique)	Très bonne	Très bonne
<b>Coût computationnel</b>	Très faible	Faible	Élevé (solveur)	Élevé (entraînement)	Moyen (LSTM léger + DT)
<b>Passage à l'échelle</b>	Excellent	Bon	Limité (explosion combinatoire)	Modeste	Bon (DT distribué)
<b>Besoin de données</b>	Aucun	Faible	Modèle analytique requis	Très élevé	Élevé
<b>Interprétabilité</b>	Excellente	Bonne	Excellente	Faible (boîte noire)	Modeste (LSTM) à bonne (DT)
<b>Garanties formelles</b>	Oui	Partielles	Oui (sous hypothèses)	Non	Partielles (DT permet validation what-if)

préalable. Cependant, le DRL présente trois limites majeures que l'approche proposée permet d'atténuer.

Premièrement, la phase d'exploration initiale est coûteuse et risquée : l'agent doit tester des actions potentiellement sous-optimales sur le réseau réel, ce qui est inacceptable pour des services critiques. Le Digital Twin résout cette difficulté en offrant un environnement d'exploration sécurisé, dans lequel l'agent peut interagir sans impact opérationnel. Deuxièmement, le DRL souffre d'une faible interprétabilité des décisions, ce qui complique l'audit et la certification dans des contextes réglementés.

L'architecture proposée, en séparant prédiction (LSTM) et décision, et en intégrant un jumeau numérique consultable, améliore significativement la traçabilité. Troisièmement, le DRL nécessite un volume de données d'interaction considérable pour converger, tandis que l'approche LSTM supervisée atteint une précision de 95,4 % en 50 époques sur des données de télémétrie existantes.

#### **5.6.4.3 Versus LSTM isolé (sans Digital Twin)**

Une comparaison intéressante concerne la configuration « LSTM seul », dépourvue de couche Digital Twin. Les résultats de la Figure 5.4 montrent que, à modèle LSTM identique, l'absence du jumeau numérique dégrade le temps de réaction de 5 ms à 12 ms et la QoS globale de 97 % à 87 %. Cette dégradation s'explique par l'absence de feedback temps réel cohérent : sans DT, le modèle LSTM s'appuie sur des données potentiellement datées ou bruitées, et ne bénéficie pas de l'évaluation what-if préalable. Le couplage DT + LSTM apparaît donc synergique plutôt qu'additif : chaque composant compense une faiblesse de l'autre.

#### **5.6.4.4 Versus Digital Twin seul (sans Deep Learning)**

Inversement, un Digital Twin dépourvu de couche d'apprentissage se limite à un outil de visualisation et de simulation, sans capacité prédictive ni décisionnelle autonome. Il requiert une intervention humaine ou un algorithme externe pour produire des décisions, ce qui introduit une latence décisionnelle incompatible avec les exigences 6G. L'intégration du modèle LSTM confère au jumeau numérique une capacité d'autonomie cognitive indispensable à l'objectif de réseau auto-optimisé.

#### **5.6.4.5 Positionnement synthétique**

La Figure 5.5 illustre le positionnement multi-critère des cinq approches. L'approche proposée (DT + LSTM) se distingue par un profil équilibré : elle surpasse les approches

classiques sur les dimensions prédictives et adaptatives, rivalise avec le DRL sur la réactivité, tout en conservant un coût computationnel modéré et un passage à l'échelle supérieur à celui de l'optimisation convexe. Ce compromis favorable en fait une candidate particulièrement pertinente pour les déploiements 6G réels, où l'exigence n'est pas uniquement d'optimiser un critère unique, mais de maintenir un équilibre opérationnel durable entre performance, coût et fiabilité.

### 5.6.5 Discussion transversale

Au-delà des chiffres, il convient de relativiser la portée de ces résultats. Les expérimentations ont été conduites en simulation, dans un environnement contrôlé dont la fidélité à un réseau 6G réel reste limitée par les hypothèses de modélisation du simulateur NS-3. Les ordres de grandeur observés sont significatifs et la hiérarchie des méthodes est clairement établie, mais les valeurs absolues devront être confirmées sur plateforme expérimentale réelle.

Par ailleurs, la comparaison avec l'état de l'art avancé met en lumière un compromis inhérent entre performance et coût : l'approche proposée n'atteint pas les garanties formelles de l'optimisation convexe, ni l'exploration continue du DRL, mais elle offre un équilibre opérationnel supérieur en contexte réel. Cette position médiane constitue à la fois sa force (polyvalence, déployabilité) et sa limite (absence de garantie d'optimalité globale).

Enfin, les scénarios d'urgence, bien que traités, mériteraient une évaluation plus approfondie, notamment sur la capacité du système à arbitrer entre plusieurs flux critiques concurrents — situation non couverte par le protocole actuel.

## 5.7 Limites de l'approche

Malgré ses performances prometteuses, l'approche proposée présente plusieurs limites qu'il convient d'identifier clairement.

- Coût computationnel du Digital Twin. Le maintien en temps réel d'une réplique virtuelle haute fidélité requiert des ressources de calcul et de stockage significatives, notamment pour les réseaux à grande échelle. Le déploiement sur infrastructure edge est envisageable, mais impose une architecturation distribuée soigneusement dimensionnée.
- Besoin en données d'entraînement. Le modèle LSTM atteint son efficacité maximale avec un volume important de données représentatives. Pour des déploiements initiaux ou des configurations peu documentées, la collecte de données suffisantes peut

constituer un frein. Des techniques telles que le transfer learning ou la génération de données synthétiques pourraient atténuer cette contrainte.

- Complexité de la synchronisation temps réel. L’alignement dynamique entre réseau physique et jumeau numérique reste un défi technique, particulièrement en présence de latences de collecte variables ou de pertes de paquets de télémétrie. Des mécanismes de recalage robustes doivent être intégrés pour éviter la dérive.
- Consommation énergétique accrue. L’exécution continue du modèle LSTM et du Digital Twin induit une consommation énergétique supérieure aux approches légères, ce qui peut poser problème dans des contextes de déploiement contraints (petites cellules, IoT batterie).
- Passage à l’échelle. L’évaluation actuelle porte sur un réseau simulé de taille modeste. L’extrapolation à des réseaux nationaux ou mondiaux, impliquant des millions de cellules et de dispositifs, soulève des questions de scalabilité non résolues à ce stade.

## **5.8 Conclusion**

Ce chapitre a présenté l’évaluation expérimentale de l’architecture hybride Digital Twin et Deep Learning proposée pour l’optimisation temps réel des réseaux 6G. Les expérimentations, conduites en simulation NS-3 sur un jeu de données représentatif, ont permis de quantifier les gains apportés par l’approche sur les indicateurs clés de performance.

Les résultats obtenus sont convergents et significatifs. Le modèle LSTM atteint une précision prédictive de 95,4 %, validant sa capacité à modéliser les dynamiques temporelles du trafic 6G. Sur le plan opérationnel, l’approche proposée réduit la latence de 56,7 % et augmente le débit de 48,2 % par rapport à une allocation statique, tout en améliorant la QoS globale de 10 points grâce à l’intégration du Digital Twin. Ces gains confirment l’hypothèse centrale de cette thèse : l’association d’une représentation virtuelle fidèle et d’un moteur prédictif apprenant constitue une réponse pertinente aux exigences extrêmes des réseaux 6G.

## **Conclusion Générale**

Ce mémoire s'inscrit dans le contexte de l'évolution des réseaux mobiles vers la sixième génération, où les exigences en matière de débit, de latence, de fiabilité, de connectivité massive et d'intelligence réseau deviennent de plus en plus importantes. La 6G ne représente pas uniquement une amélioration technique par rapport aux générations précédentes, mais elle introduit également une nouvelle vision des réseaux autonomes, capables de s'adapter dynamiquement aux besoins des utilisateurs et aux variations rapides de l'environnement.

L'étude réalisée a permis de mettre en évidence les principaux défis auxquels les futurs réseaux 6G seront confrontés, notamment la complexité de l'infrastructure, l'hétérogénéité des services, la mobilité des utilisateurs, l'augmentation du trafic, la gestion optimale des ressources et la nécessité d'une prise de décision en temps réel. Face à ces contraintes, les méthodes classiques d'allocation de ressources, souvent statiques ou réactives, montrent leurs limites, car elles ne permettent pas toujours d'anticiper les changements du réseau ni de garantir une qualité de service stable pour les applications critiques.

Dans ce contexte, le Digital Twin apparaît comme une solution pertinente pour renforcer l'intelligence et la maîtrise des réseaux 6G. Grâce à sa capacité à représenter virtuellement l'état du réseau physique, à exploiter des données en temps réel et à simuler différents scénarios, il permet d'améliorer la supervision, la prédiction et la prise de décision. De son côté, le Deep Learning constitue un outil puissant pour analyser les données réseau et prévoir leur évolution. Le choix du modèle LSTM se justifie par sa capacité à traiter les séries temporelles et à apprendre les dépendances entre les états successifs du réseau, ce qui le rend particulièrement adapté aux environnements dynamiques de la 6G.

L'approche proposée dans ce travail repose ainsi sur l'intégration du Digital Twin et du modèle LSTM dans une architecture hybride destinée à l'optimisation en temps réel des ressources réseau. Le Digital Twin assure une représentation virtuelle synchronisée du réseau, tandis que le modèle LSTM fournit une prédiction intelligente de son évolution. La boucle de rétroaction permet ensuite d'adapter les décisions selon les performances observées, ce qui rend le système plus réactif, plus flexible et plus autonome.

Les résultats expérimentaux obtenus confirment l'intérêt de cette approche. Le modèle LSTM a atteint une précision prédictive de 95,4 %, ce qui montre sa capacité à modéliser efficacement les dynamiques temporelles du réseau. L'approche proposée a également permis de réduire la latence moyenne de 56,7 % par rapport à une allocation statique, d'augmenter le débit moyen de 48,2 % et d'améliorer la qualité de service globale grâce à l'intégration du Digital Twin. Ces résultats montrent que la combinaison d'une représentation virtuelle fidèle et d'un modèle prédictif intelligent peut constituer une réponse efficace aux exigences des

futurs réseaux 6G.

Malgré ces résultats encourageants, ce travail peut être prolongé par plusieurs perspectives. Il serait d'abord intéressant de tester l'approche proposée sur des scénarios plus larges et plus réalistes, intégrant un plus grand nombre d'utilisateurs, de stations de base, de cellules et d'objets connectés, afin d'évaluer sa capacité de passage à l'échelle. Il serait également pertinent de comparer le modèle LSTM avec d'autres modèles avancés, tels que les GRU, les Transformers, les Graph Neural Networks ou le Deep Reinforcement Learning, pour identifier les architectures les plus adaptées aux réseaux 6G dynamiques. Par ailleurs, le renforcement de la synchronisation entre le réseau physique et son Digital Twin constitue une piste importante, car la précision du jumeau numérique dépend directement de la qualité et de la fiabilité des données collectées. Enfin, l'optimisation énergétique et la validation sur une plateforme réelle ou semi-réelle représentent des étapes essentielles pour confirmer la faisabilité pratique de l'approche proposée dans des environnements proches des futurs réseaux 6G.

# Bibliography

- [1] Ruiqi Liu, Leyi Zhang, Ruyue Yu-Ngok Li, and Marco Di Renzo. The itu vision and framework for 6g: Scenarios, capabilities, and enablers. *IEEE Vehicular Technology Magazine*, 2025.
- [2] Seppo Yrjola, Petri Ahokangas, Marja Matinmikko-Blue, Risto Jurva, Vivek Kant, Pasi Karppinen, Marianne Kinnula, Harilaos Koumaras, Mika Rantakokko, Volker Ziegler, et al. White paper on business of 6g. *arXiv preprint arXiv:2005.06400*, 2020.
- [3] Emilio Calvanese Strinati, Sergio Barbarossa, Jose Luis Gonzalez-Jimenez, Dimitri Ktenas, Nicolas Cassiau, Luc Maret, and Cedric Dehos. 6g: The next frontier: From holographic messaging to artificial intelligence using subterahertz and visible light communication. *IEEE Vehicular Technology Magazine*, 14(3):42–50, 2019.
- [4] Yaohua Sun, Mugen Peng, Yangcheng Zhou, Yuzhe Huang, and Shiwen Mao. Application of machine learning in wireless networks: Key techniques and open issues. *IEEE Communications Surveys & Tutorials*, 21(4):3072–3108, 2019.
- [5] Yuyi Mao, Changsheng You, Jun Zhang, Kaibin Huang, and Khaled B Letaief. Mobile edge computing: Survey and research outlook. *arXiv preprint arXiv:1701.01090*, pages 1–37, 2017.
- [6] Tarik Taleb, Konstantinos Samdanis, Badr Mada, Hannu Flinck, Sunny Dutta, and Dario Sabella. On multi-access edge computing: A survey of the emerging 5g network edge cloud architecture and orchestration. *IEEE Communications Surveys & Tutorials*, 19(3):1657–1681, 2017.
- [7] Erik Ekudden. Five network trends: Towards the 6g era. *Ericsson Technology Review*, 2021(9):2–10, 2021.
- [8] Mario Catalano, Alessandro Chiurco, Caterina Fusto, Lucia Gazzaneo, Francesco Longo, Giovanni Mirabelli, Letizia Nicoletti, Vittorio Solina, and Simone Talarico.

- A digital twin-driven and conceptual framework for enabling extended reality applications: A case study of a brake discs manufacturer. *Procedia Computer Science*, 200:1885–1893, 2022.
- [9] Michael Grieves and John Vickers. Digital twin: Mitigating unpredictable, undesirable emergent behavior in complex systems. In *Transdisciplinary perspectives on complex systems: New findings and approaches*, pages 85–113. Springer, 2016.
- [10] Michael Grieves. Digital twin: Manufacturing excellence through virtual factory replication. white paper, 2014. *Online:-03-01*, 2014.
- [11] Qinglin Qi, Fei Tao, Ying Zuo, and Dongming Zhao. Digital twin service towards smart manufacturing. *Procedia Cirp*, 72:237–242, 2018.
- [12] David Jones, Chris Snider, Aydin Nassehi, Jason Yon, and Ben Hicks. Characterising the digital twin: A systematic literature review. *CIRP journal of manufacturing science and technology*, 29:36–52, 2020.
- [13] Aidan Fuller, Zhong Fan, Charles Day, and Chris Barlow. Digital twin: Enabling technologies, challenges and open research. *IEEE access*, 8:108952–108971, 2020.
- [14] Hamed Ahmadi, Avishek Nag, Zaheer Khar, Kamran Sayrafian, and Susanto Rahardja. Networked twins and twins of networks: An overview on the relationship between digital twins and 6g. *IEEE Communications Standards Magazine*, 5(4):154–160, 2022.
- [15] Yann LeCun, Yoshua Bengio, and Geoffrey Hinton. Deep learning. *nature*, 521(7553):436–444, 2015.
- [16] Ian Goodfellow. Deep learning, 2016.
- [17] Stefan Strohmeier. Artificial intelligence in human resources-an introduction. In *Handbook of research on artificial intelligence in human resource management*, pages 1–22. Edward Elgar Publishing, 2022.
- [18] Charles R Qi, Hao Su, Kaichun Mo, and Leonidas J Guibas. Pointnet: Deep learning on point sets for 3d classification and segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 652–660, 2017.
- [19] Simon Haykin. *Neural networks and learning machines*, 3/E. Pearson education india, 2009.

- [20] Nicolas Thome and Christian Wolf. Histoire des réseaux de neurones et du deep learning en traitement des signaux et des images. 2023.
- [21] Walid Saad, Mehdi Bennis, and Mingzhe Chen. A vision of 6g wireless systems: Applications, trends, technologies, and open research problems. *IEEE network*, 34(3):134–142, 2019.
- [22] Fangxin Wang, Miao Zhang, Xiangxiang Wang, Xiaoqiang Ma, and Jiangchuan Liu. Deep learning for edge computing applications: A state-of-the-art survey. *IEEE Access*, 8:58322–58336, 2020.
- [23] Wei Jiang, Qiheng Zhou, Jiguang He, Mohammad Asif Habibi, Sergiy Melnyk, Mohammed El-Absi, Bin Han, Marco Di Renzo, Hans Dieter Schotten, Fa-Long Luo, et al. Terahertz communications and sensing for 6g and beyond: A comprehensive review. *IEEE Communications Surveys & Tutorials*, 26(4):2326–2381, 2024.
- [24] Emil Björnson and Luca Sanguinetti. Power scaling laws and near-field behaviors of massive mimo and intelligent reflecting surfaces. *IEEE Open Journal of the Communications Society*, 1:1306–1324, 2020.
- [25] Jakub Konečný, H Brendan McMahan, Felix X Yu, Peter Richtárik, Ananda Theertha Suresh, and Dave Bacon. Federated learning: Strategies for improving communication efficiency. *arXiv preprint arXiv:1610.05492*, 2016.
- [26] Fengxiao Tang, Xuehan Chen, Tiago Koketsu Rodrigues, Ming Zhao, and Nei Kato. Survey on digital twin edge networks (diten) toward 6g. *IEEE Open Journal of the Communications Society*, 3:1360–1381, 2022.
- [27] Gordon Owusu Boateng, Guolin Sun, Daniel Ayepah Mensah, Daniel Mawunyo Doe, Ruijie Ou, and Guisong Liu. Consortium blockchain-based spectrum trading for network slicing in 5g ran: A multi-agent deep reinforcement learning approach. *IEEE Transactions on Mobile Computing*, 22(10):5801–5815, 2022.
- [28] Xuefei Li, Mingzhe Chen, Yuchen Liu, Zhilong Zhang, Danpu Liu, and Shiwen Mao. Graph neural networks for joint communication and sensing optimization in vehicular networks. *IEEE Journal on Selected Areas in Communications*, 41(12):3893–3907, 2023.
- [29] Volodymyr Mnih, Koray Kavukcuoglu, David Silver, Andrei A Rusu, Joel Veness, Marc G Bellemare, Alex Graves, Martin Riedmiller, Andreas K Fidjeland, Georg

Ostrovski, et al. Human-level control through deep reinforcement learning. *nature*, 518(7540):529–533, 2015.

- [30] Geoffrey E Hinton and Ruslan R Salakhutdinov. Reducing the dimensionality of data with neural networks. *science*, 313(5786):504–507, 2006.

## ملخص

تتناول هذه المذكرة موضوع التحسين الذكي لشبكات الجيل السادس 6G اعتمادا على مقارنة هجينة تجمع بين تقنية التوأم الرقمي والتعلم العميق. تتميز شبكات 6G بالديناميكية العالية والاتصال واسع النطاق وانخفاض زمن التأخير, وارتفاع متطلبات جودة الخدمة. ولمواجهة هذه التحديات تم توظيف التوأم الرقمي كتمثيل افتراضي مترامن مع الشبكة الحقيقية, كما تم استخدام نموذج LSTM للتنبؤ بتطور حركة المرور ودعم التكيف الديناميكي للموارد. أظهرت النتائج التجريبية أن المقاربة المقترحة تحسن أداء الشبكة, حيث حقق نموذج LSTM دقة تنبؤية قدرها 95,4% مع تقليل واضح في زمن التأخير, وزيادة في معدل التدفق, وتحسين في جودة الخدمة. تؤكد هذه الدراسة أهمية دمج التوأم الرقمي والتعلم العميق لبناء شبكات 6G أكثر ذكاء واستقلالية وقدرة على التكيف في الزمن الحقيقي.

**الكلمات المفتاحية:** الجيل السادس, التوأم الرقمي, التعلم العميق, تحسين الشبكات, LSTM, جودة الخدمة, التكيف في الزمن الحقيقي.

## Abstract

This thesis focuses on the intelligent optimization of 6G networks through a hybrid approach combining Digital Twin technology and Deep Learning. 6G networks are characterized by high dynamism, massive connectivity, low latency and strict quality of service requirements. To address these challenges, the Digital Twin is used as a synchronized virtual representation of the physical network, while an LSTM model is employed to predict traffic evolution and support dynamic resource adaptation. The experimental results show that the proposed approach improves network performance, achieving a predictive accuracy of 95.4 %, while significantly reducing latency, increasing throughput and improving overall quality of service. This study confirms the relevance of integrating Digital Twin and Deep Learning technologies to build smarter, more autonomous and adaptive 6G networks.

**Keywords :** 6G, Digital Twin, Deep Learning, LSTM, network optimization, quality of service, real-time adaptation.

## Résumé

Ce mémoire porte sur l'optimisation intelligente des réseaux 6G à travers une approche hybride combinant le Digital Twin et le Deep Learning. Les réseaux 6G se caractérisent par une forte dynamique, une connectivité massive, une faible latence et des exigences élevées en matière de qualité de service. Pour répondre à ces défis, le Digital Twin est utilisé comme une représentation virtuelle synchronisée du réseau physique, tandis qu'un modèle LSTM est exploité pour prédire l'évolution du trafic et soutenir l'adaptation dynamique des ressources. Les résultats expérimentaux montrent que l'approche proposée améliore les performances du réseau, avec une précision prédictive de 95,4 %, une réduction significative de la latence, une augmentation du débit et une amélioration de la qualité de service. Cette étude confirme l'intérêt de l'intégration du Digital Twin et du Deep Learning pour construire des réseaux 6G plus intelligents, autonomes et adaptatifs.

**Mots clés :** 6G, Digital Twin, Deep Learning, LSTM, optimisation réseau, qualité de service, adaptation temps réel.