

UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

SYSTÈMES DE COMMUNICATION SANS FILS ASSISTÉS PAR L'IA: LA
GÉNÉRALISATION DES DOMAINES PAR APPRENTISSAGE
MÉTA-RENFORCEMENT

MÉMOIRE PRÉSENTÉE
COMME EXIGENCE PARTIELLE DE LA
MAÎTRISE EN GÉNIE ÉLECTRIQUE

PAR
ASMA HMIDI

JUIN 2025

Université du Québec à Trois-Rivières

Service de la bibliothèque

Avertissement

L'auteur de ce mémoire, de cette thèse ou de cet essai a autorisé l'Université du Québec à Trois-Rivières à diffuser, à des fins non lucratives, une copie de son mémoire, de sa thèse ou de son essai.

Cette diffusion n'entraîne pas une renonciation de la part de l'auteur à ses droits de propriété intellectuelle, incluant le droit d'auteur, sur ce mémoire, cette thèse ou cet essai. Notamment, la reproduction ou la publication de la totalité ou d'une partie importante de ce mémoire, de cette thèse et de son essai requiert son autorisation.

UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

MAÎTRISE EN GÉNIE ÉLECTRIQUE (M. Sc. A.)

Direction de recherche :

Prof. Messaoud Ahmed Ouameur

Directeur de recherche

Prof. Daniel Massicotte

Codirecteur de recherche

Jury d'évaluation

(Selon le type de travail de recherche, deux à cinq membres de jury doivent être identifiés ci-dessous)

Prof. Paul Fortier

Évaluateur externe, Université Laval

Prof. François Nougrou

Évaluateur interne, UQTR

Prof. Daniel Massicotte

Codirecteur, UQTR

Remerciements

Je tiens à remercier en premier lieu mes chers parents, Ahmed et Hayet. Sans eux, je n'aurais certainement pas eu la chance de poursuivre de longues études; leur amour m'a permis de devenir la personne que je suis actuellement. Je ne pourrais vous remercier à la hauteur de ce que vous méritez.

Je remercie aussi ma chère sœur Chaima, qui a partagé avec moi tous les moments d'émotions pendant la réalisation de ce travail, elle m'a soutenue avec chaleur et m'a encouragée tout au long de mon parcours.

Je souhaite remercier sincèrement mon directeur de recherche, Professeur Messaoud Ahmed Ouameur, pour son encadrement précieux, sa disponibilité et ses conseils avisés tout au long de ce projet. Son expertise a été essentiel pour mener à bien cette recherche.

Je tiens aussi à exprimer ma reconnaissance envers Mitacs et l'Université du Québec à Trois-Rivières pour m'avoir donner l'opportunité de réaliser ce projet dans un environnement propice à l'apprentissage et à l'innovation.

Finalement, un grand merci à mes amis pour leur soutien moral et leurs discussions stimulantes qui ont enrichi ma réflexion.

Résumé

L'environnement du canal sans fil influence principalement la performance des systèmes de communication sans fil. À la différence des propriétés habituellement stables et prévisibles d'un canal cablé, le canal sans fil est beaucoup plus évolutif et non-prévisible, ce qui complique souvent l'analyse exacte du réseau de communication sans fil. Au cours des dernières années, avec la montée en puissance des prestations de communication mobile et l'apparition des services d'accès à Internet mobile haut débit, il est devenu essentiel d'améliorer les systèmes de communication sans fil. Il est crucial de saisir les canaux sans fil afin de concevoir des procédures de transmission sans fil productives et optimales en matière de fréquence.

La communication sans fil, comparativement à la communication filaire, présente une particularité majeure : elle présente un canal de transmission très défavorable, où le milieu de propagation sans fil est aléatoire et subit des atténuations variables dans le temps et des trajets multiples, ce qui rend difficile l'accomplissement d'une interaction véritable et efficace. C'est la raison pour laquelle plusieurs efforts ont été déployés pour optimiser la couche physique et estimer le canal dans l'ensemble de protocoles de communication. Les recherches récentes ont porté sur l'amélioration de la couche physique et la création d'algorithmes avancés afin d'optimiser l'estimation et l'exploitation du canal sans fil. En introduisant des méthodes telles que l'apprentissage par renforcement (RL) et le Meta-RL, l'intelligence artificielle (IA) a bouleversé ce domaine en permettant une meilleure adaptation aux conditions de propagation dynamiques. Ces techniques offrent des avantages considérables en ce qui concerne l'efficacité, la fiabilité et les performances globales des systèmes.

Dans cette situation, l'usage de bibliothèques open-source telles que Sionna est

essentiel. Sionna propose un cadre performant pour représenter les canaux sans fil, élaborer et évaluer des algorithmes d'apprentissage automatique adaptés aux systèmes de communication. L'objectif de ce projet est d'étudier ces méthodes en évaluant et en comparant des algorithmes classiques et avancés, comme le RL et le Meta-RL, dans différents scénarios. En mettant l'accent sur la simulation et l'analyse des performances, cette approche favorise la création de solutions améliorées pour les systèmes de communication sans fil, ce qui ouvre la voie à une utilisation améliorée des canaux sans fil dans les réseaux de future génération.

Table des matières

Remerciements	iii
Résumé	iv
Table des matières	vi
Liste des tableaux	x
Liste des figures	xi
Liste des symboles	xiii
Chapitre 1 - Introduction	1
1.1 Contexte du projet et problématique	2
1.2 Objectif	4
1.3 Méthodologie	4
1.4 Organisation du mémoire	6
Chapitre 2 - Revue de la littérature	7
2.1 Introduction	7
2.2 Les systèmes de communication sans fil	7
2.2.1 L'évolution des réseaux mobiles	7
2.2.2 Modulations de base en communication numérique	9
2.3 Principales technologies de la 5G et au-delà: les systèmes MIMO-OFDM ..	11
2.4 Canal sans fil	18
2.4.1 Bruit et interférences	23

2.4.1.1	Rapport signal sur bruit: SNR	23
2.4.1.2	Taux d'erreur binaire: BER	24
2.5	Méthodes d'estimation du canal sans fil	24
2.5.1	Méthodes LS	25
2.5.2	Méthode MMSE	25
2.5.3	Méthode basées sur l'interpolation	26
2.5.4	Structure des pilotes	26
2.5.4.1	Mise en place en bloc	27
2.5.4.2	Mise en place en peigne	28
2.5.4.3	Mise en place en treillis	29
2.6	L'intelligence artificielle dans les systèmes de communication	29
2.6.1	Apprentissage automatique pour la couche physique	30
2.6.2	Apprentissage par renforcement (RL)	31
2.6.3	Apprentissage Meta-RL	31
2.6.4	Opportunités et défis	32
2.7	Conclusion	33
Chapitre 3 - Méthodologie		35
3.1	Introduction	35
3.2	Environnement de travail et outils utilisés	35
3.2.1	Langage de programmation	35
3.2.2	Bibliothèques et outils utilisés	36
3.2.3	Environnement de développement	37
3.3	Présentation de l'apprentissage de bout en bout (End-to-End Learning)	37
3.3.1	Principe de fonctionnement	37
3.3.2	Avantages de l'approche	38

3.3.2.1	Fonction de perte et optimisation	39
3.4	Architecture du modèle d'autoencodeur dans Sionna	40
3.5	Algorithmes et méthodes utilisées	44
3.5.1	Modélisation du canal	45
3.5.2	Codage et décodage LDPC	45
3.5.3	Méthodes d'entraînement	46
3.5.4	Résumé de paramètres	56
3.6	Généralisation de domaine avec le Meta-RL	57
3.6.1	Définition de la généralisation de domaine	58
3.6.2	Meta-RL pour la généralisation de domaine	58
3.6.3	Application au canal sans fil	58
3.6.4	Avantages de la généralisation avec le Meta-RL	59
3.6.5	Limites et défis	59
3.7	Conclusion	59
Chapitre 4 - Résultats et analyses		61
4.1	Introduction	61
4.2	Contexte de simulation	61
4.3	Analyse des performances selon le BER	62
4.3.1	BER dans un canal <i>AWGN</i>	62
4.3.2	BER dans un canal Rayleigh	64
4.4	Analyse des performances selon le BLER	66
4.4.1	BLER dans un canal <i>AWGN</i>	66
4.4.1.1	Les performances de l'entraînement conventionnel	67
4.4.1.2	Performances de l'entraînement basé sur le RL	68
4.4.1.3	Performances de l'entraînement Meta-RL	69

4.4.1.4	Comparaison du Meta-RL avec le RL classique	70
4.4.1.5	Interprétation	71
4.4.2	BLER dans un canal <i>Rayleigh</i>	71
4.5	Analyse des constellations apprises dans un canal AWGN	73
4.5.1	Constellation issue de l'entraînement conventionnel	73
4.5.2	Avantages des constellations apprises	74
4.5.3	Limitations	75
4.5.4	Constellation issue de l'entraînement basé sur RL	76
4.5.5	Comparaison du RL avec la méthode conventionnelle	76
4.5.6	Caractéristiques des constellations Meta-RL	78
4.5.7	Comparaison des méthodes en terme de constellation	78
4.6	Analyse des constellations apprises dans un canal Rayleigh	80
4.6.1	Constellation issue de l'entraînement conventionnel	81
4.6.2	Constellation optimisée par apprentissage par renforcement (RL) ..	81
4.6.3	Constellation optimisée par apprentissage par renforcement Meta-RL	82
4.7	Conclusion	83
	Chapitre 5 - Conclusion	85

Liste des tableaux

Tableau 2-1 Exposant de perte de chemin [1]	22
Tableau 2-2 Comparaison entre évanouissement à petite échelle et évanouissement à grande échelle	23
Tableau 2-3 Résumé des méthodes classiques d'estimation de canal	27
Tableau 3-1 Fonctionnalités de Sionna	36
Tableau 3-2 Avantages de l'algorithme Adam [2]	49
Tableau 3-3 Paramètres de l'algorithme Adam utilisés dans le projet	49
Tableau 3-4 Notions de State, Action et Reward dans l'entraînement basé sur le renforcement (RL)	53
Tableau 3-5 Paramètres d'entraînement pour le Meta-RL	55
Tableau 3-6 Résumé des paramètres	56
Tableau 4-1 Avantages de l'entraînement basé sur le RL	69

Liste des figures

Figure 1.1	Exemple courant de propagation radio-mobile.	3
Figure 2.1	L'évolution des réseaux mobiles.	8
Figure 2.2	Modulation ASK.	9
Figure 2.3	Modulation FSK.	10
Figure 2.4	Modulation QPSK.	10
Figure 2.5	Modulation QAM.	11
Figure 2.6	Structure de base des systèmes MIMO.	12
Figure 2.7	Grille de ressource.	14
Figure 2.8	Diagramme du bloc OFDM.	17
Figure 2.9	Architecture de systèmes de communication.	19
Figure 2.10	Classification des canaux d'évanouissement.	21
Figure 2.11	Configuration de type bloc pilote.	28
Figure 2.12	Configuration de type peigne pilote.	28
Figure 2.13	Configuration de type treillis pilote.	29
Figure 3.1	Schéma de principe de l'autoencodeur [3].	40
Figure 3.2	Architecture comparative entre un autoencodeur et une baseline [4].	41
Figure 3.3	Le cadre de RL [5]	54
Figure 3.4	Illustration de la Meta-RL [6].	55
Figure 4.1	Comparaison des performances de BER des algorithmes dans un canal AWGN.	63
Figure 4.2	Comparaison des performances du BER des algorithmes dans un canal du Rayleigh.	65

Figure 4.3 Comparaison des performances des algorithmes dans un canal AWGN.	67
Figure 4.4 Comparaison des performances du BLER des algorithmes dans un canal du Rayleigh.	72
Figure 4.5 Constellation pour l'algorithme conventionnel.	75
Figure 4.6 Constellation pour l'algorithme RL.	77
Figure 4.7 Constellation pour l'algorithme Meta-RL.	79
Figure 4.8 Constellation optimisée par entraînement conventionnel dans un canal Rayleigh.	81
Figure 4.9 Constellation optimisée par RL dans un canal Rayleigh	82
Figure 4.10 Constellation optimisée par Meta-RL dans un canal Rayleigh	83

Liste des symboles

AWGN: Additive White Gaussian Noise

AI: Artificial Intelligence

ASK: Amplitude Shift Keying (Modulation par déplacement d'amplitude)

BER: Bit Error Rate (Taux d'erreur binaire)

BLER: Block Error Rate (Taux d'erreur par bloc)

BCE: Binary Cross Entropy (Entropie de croisement binaire)

CNN: Convolutional Neural Network (Réseau de neurones convolutif)

CP: Cyclic Prefix (Préfixe cyclique)

DL: Deep Learning (Apprentissage profond)

FFT: Fast Fourier Transform (Transformée de Fourier rapide)

FSK: Frequency Shift Keying (Modulation par déplacement de fréquence)

LS: Least Square (Moindres carrés)

LTE: Long Term Evolution (Évolution à long terme)

LLR: Log-Likelihood Ratio (Logarithme du rapport de vraisemblance)

IUT: International Union of Telecommunication (Union Internationale des Télécommunications)

IoT: Internet of Things (Internet des objets)

IDFT: Inverse Discrete Fourier Transform (Transformation de Fourier discrète inverse)

LDPC: Low-Density Parity-Check Codes (Codes à parité de faible densité)

ML: Machine Learning (Apprentissage automatique)

Meta-RL: Meta-Reinforcement Learning (Apprentissage par renforcement mété)

MIMO: Multiple Input Multiple Output (Entrées multiples, sorties multiples)

MMSE: Minimum Mean Square Error (Erreur quadratique moyenne minimale)

OFDM: Orthogonal Frequency Division Multiplexing

PL: Path Loss (Perte de trajet)

PSK: Phase Shift Keying (Modulation par déplacement de phase)

QAM: Quadrature Amplitude Modulation (Modulation en quadrature d'amplitude)

RL: Reinforcement Learning (Apprentissage par renforcement)

RG: Ressource Grid (Grille de ressource)

SISO: Simple Input Simple Output (Entrée simple sortie simple)

SGD: Stochastic Gradient Descent (Descente de gradient stochastique)

SNR: Signal-to-Noise Ratio (Rapport signal sur bruit)

ZF: Zero Forcing (Forçage à zéro)

3GPP: 3rd Generation Partnership Project (Projet de partenariat de la troisième génération)

Chapitre 1 - Introduction

Le progrès technologique de la communication sans fil a profondément modifié la façon dont les informations sont partagées à travers le monde. À la différence des systèmes filaires classiques, où les données sont transmises par des câbles physiques, les systèmes sans fil utilisent des ondes électromagnétiques pour transporter les informations sur de longues distances, souvent sans avoir besoin d'une infrastructure physique complexe [7]. Grâce à cette capacité à transférer des données sans avoir besoin d'un lien physique direct, de nouvelles applications ont vu le jour, telles que la téléphonie mobile, les réseaux de capteurs et l'Internet des objets (IoT) [8].

À l'intérieur d'un environnement sans fil, diverses interactions entre une station de base (BS) et un récepteur mobile (MS) ont été observées. Il s'agit de la réflexion, de la diffraction et de la diffusion. Lorsque les ondes rencontrent des obstacles de grande taille, comme des immeubles ou des maisons, la réflexion se réalise et les ondes rebondissent dans d'autres directions. On détecte la diffraction lorsque l'onde est perturbée par des objets qui déforment sa trajectoire, tels que des bâtiments ou des montagnes, ce qui entraîne une déviation du signal autour de l'obstacle. De son côté, la diffusion est causée par des objets plus petits et fluctuants, comme des arbres ou des objets dans l'espace urbain, qui dispersent les ondes dans différentes directions. Ces phénomènes combinés influencent la qualité du signal reçu et la performance globale du système de communication sans fil. L'amplitude du signal reçu et les performances du système de communication sans fil sont influencées par ces phénomènes associés comme illustré à la figure 1.1.

Les méthodes de communication sans fil ont connu une évolution continue en ce qui concerne leur capacité, leur fiabilité et leur vitesse. Chaque fois que de nouveaux

réseaux sans fil sont développés, des avancées technologiques ont été utilisées pour relever des défis tels que l’interférence, la gestion du spectre et l’amélioration de la consommation d’énergie. Les systèmes de communication contemporains, tels que les réseaux 4G, 5G et plus encore, intègrent des méthodes de traitement du signal avancées, comme la modulation adaptative, le multiplexage par répartition en fréquence orthogonale (OFDM) et les réseaux MIMO (Multiple-Input Multiple-Output), afin de maximiser l’efficacité du spectre et offrir des débits de données élevés [9, 10]. La technologie de la communication sans fil ne se limite pas à un accomplissement technique, elle joue également un rôle clé dans l’innovation sociale et économique. Grâce aux technologies sans fil, des milliards de dispositifs sont connectés à travers le monde, ce qui facilite l’accès à l’information, la transmission en temps réel et l’automatisation dans différents domaines industriels. Non seulement cela a modifié la façon dont les individus interagissent, mais cela a également permis l’émergence d’applications innovantes, comme les véhicules autonomes, les systèmes de santé connectés et les villes intelligentes [11].

1.1 Contexte du projet et problématique

L’émergence de la 6G impose une amélioration des chaînes de traitement de la couche physique. Cela répond aux exigences croissantes en matière de complexité dans les activités de recherche et de développement. C’est dans ce cadre qu’apparaît Sionna [12], une bibliothèque open-source consacrée à la recherche sur la couche physique de la prochaine génération de systèmes de communication sans fil. Sionna a été développée dans le but de proposer une structure souple et efficace, offrant aux chercheurs et ingénieurs la possibilité de développer, simuler et améliorer les algorithmes de traitement du signal pour des réseaux sans fil de développement récent [13]. Elle permet de mettre en place des concepts avancés de canaux de transmission, des techniques de codage avancées

et des algorithmes de détection, tout en s'intégrant aisément avec des plateformes de calcul contemporaines. Les systèmes de communication classiques sont conçus selon une approche modulaire, où chaque étape de traitement, telle que le codage, la modulation ou l'estimation de canal, est optimisée individuellement. Malgré son efficacité, cette méthode comporte des limites face à la complexité grandissante des réseaux modernes, tels que ceux utilisant MIMO-OFDM. L'utilisation d'autoencodeurs pour l'apprentissage complet (apprentissage de bout en bout) propose une approche innovante en intégrant l'ensemble de la chaîne de communication dans un modèle unifié et personnalisable, optimisé dans son ensemble. L'objectif de ce projet est d'utiliser cette approche en utilisant le cadre Sionna afin de simuler des canaux sans fil réalistes et d'évaluer les performances des autoencodeurs.



Figure 1.1 Exemple courant de propagation radio-mobile.

1.2 Objectif

Le but principal de ce projet est de mettre en évidence le potentiel de l'apprentissage de bout en bout avec des autoencodeurs afin d'améliorer les performances des systèmes de communication sans fil, notamment dans le domaine de MIMO-OFDM. À la différence de la conception traditionnelle qui repose sur des modules séparés. Cette méthode propose d'harmoniser et d'améliorer toute la chaîne de communication, de l'encodage au décodage. Pour cela, les sous-objectifs suivants ont été définis :

- Réduction de la complexité des systèmes : Concevoir une architecture plus simple, sans compromettre la performance globale du système.
- Amélioration du BER : Réduire le BER à travers des approches basées sur l'apprentissage profond.
- Renforcement de la robustesse face aux canaux variables : Garantir la stabilité et la performance des systèmes dans des environnements de canal changeants.
- Utilisation du cadre *Sionna* : Exploiter les capacités de Sionna pour évaluer les performances des modèles implémentés.
- Remplacement des méthodes traditionnelles : Étudier le potentiel des autoencodeurs profonds pour se substituer aux méthodes classiques.

1.3 Méthodologie

La démarche utilisée dans ce projet suit plusieurs étapes essentielles et organisées afin de répondre aux objectifs établis. Tout d'abord, une étude détaillée des concepts essentiels des technologies MIMO-OFDM et des autoencodeurs est réalisée. Grâce à cette recherche, il est possible de saisir les défis actuels des systèmes classiques, tels que les limitations en matière de performances, de complexité algorithmique et d'adaptation aux environnements complexes. Par la suite, le modèle d'autoencodeur est conçu en

utilisant les caractéristiques du cadre Sionna. Ce dispositif offre la possibilité de simuler avec précision les canaux sans fil, incluant les effets d'évanouissement, de bruit et d'interférences, afin d'assurer un environnement réaliste pour l'utilisation du modèle. Trois éléments principaux constituent l'autoencodeur : un encodeur, un canal simulé et un décodeur. L'encodeur convertit les données en une forme qui convient à la transmission, le canal reproduit les conditions de propagation réelles, et le décodeur reconstruit les données d'origine en réduisant au minimum les pertes de données.

Ensuite, le modèle est entraîné à l'aide de méthodes d'apprentissage supervisé, avec des fonctions de perte appropriées comme la réduction du taux d'erreur binaire (BER) ou de l'erreur quadratique moyenne. L'entraînement se déroule sur différents scénarios, tels que des configurations MIMO avec des rapports signal sur bruit (SNR) différents, dans le but d'évaluer sa résistance et son adaptabilité. Après la validation du modèle, ses résultats sont comparés à ceux des méthodes classiques. La comparaison s'appuie sur des indicateurs essentiels, tels que BER, la vitesse de convergence et la capacité à s'ajuster aux fluctuations dynamiques du canal. Les résultats obtenus sont minutieusement examinés afin de repérer les avantages obtenus en ce qui concerne les performances globales et la simplification du processus de communication.

Enfin, les résultats sont présentés à travers des graphiques et des analyses détaillées, ce qui permet de mettre en avant les bénéfices de l'apprentissage de bout en bout par rapport aux méthodes traditionnelles. Ce projet offre aussi des opportunités pour intégrer ces solutions dans les réseaux de communication de nouvelle génération, en exploitant les progrès des technologies d'intelligence artificielle et d'apprentissage automatique.

1.4 Organisation du mémoire

Cet mémoire est organisé en cinq parties distinctes. Le chapitre initial offre une introduction générale au sujet. Dans le deuxième chapitre, une analyse de la littérature est présentée, abordant un état d'art des technologies utilisées dans le projet et les dernières recherches dans ce domaine scientifique. L'accent est mis sur la transmission sans fil de bout en bout basé sur l'autoencodeur dans les systèmes MIMO-OFDM dans le troisième chapitre. La modélisation, la simulation et la comparaison des performances du système avec l'apprentissage profond sous le cadre de Sionna sont abordées dans le quatrième chapitre. Enfin, le chapitre final de ce mémoire termine en résumant les résultats principaux et en proposant des perspectives pour de futurs travaux.

Chapitre 2 - Revue de la littérature

2.1 Introduction

Ce chapitre examine les travaux de la littérature et les apports académiques importants qui ont contribué à l'avancement dans le domaine de la communication sans fil de nouvelle génération. Plus spécifiquement, notre attention est portée sur les recherches menées sur l'utilisation de l'intelligence artificielle (IA) pour améliorer les performances du signal lors de la transmission, en particulier sur les cadres experts tels que Sionna, une librairie source ouverte spécialisée dans les systèmes de communication sans fil, conçue pour simuler et modéliser la couche physique [12]. Dans ce chapitre, nous examinons les dispositifs de communication en utilisant l'apprentissage profond et la démodulation basée sur l'IA, tout en repérant les restrictions des solutions existantes et en justifiant nos décisions de mise en œuvre.

2.2 Les systèmes de communication sans fil

2.2.1 *L'évolution des réseaux mobiles*

Le voyage de la communication sans fil a commencé avec la télégraphie sans fil de Marconi dans le 19ème siècle [14], en évoluant vers des réseaux analogiques 1G pour la communication vocale [15]. La transition vers la numérisation, permettant des services de données et chiffrés, a marqué le début des réseaux 2G [15]. L'ère 3G a introduit divers services de données tels que l'accès à Internet et les appels vidéo [15], tandis que les réseaux 4G/LTE, lancés en 2009, ont révolutionné la transmission de données. Technologiquement et commercialement réussie, la 4G a transformé la société avec l'utilisation des smartphones et les technologies de l'information avancées [15].

Le concept de la 5G est apparu en 2014, mettant l'accent sur la densification

des réseaux, la transmission par ondes millimétriques et l'architecture massive MIMO comme technologies clés [12]. Depuis 2020, les grandes entreprises et les opérateurs ont commencé à construire des réseaux 5G. Les premiers déploiements ont été axés sur les zones urbaines denses, opérant dans le spectre des 2 à 6 GHz [16]. Les technologies MIMO à ondes millimétriques et massives ont été intégrées, tandis que le découpage de réseaux pour des solutions stratégiques a été adopté. L'ère de la 5G a donné la priorité aux services comme le streaming vidéo haute définition, la télévision par protocole Internet et les services de données améliorés. Cependant, certaines technologies de pointe n'ont pas été intégrées en raison des besoins de vérification expérimentale, des coûts élevés, et d'une demande limitée [16]. Afin d'illustrer plus clairement ces progrès, la figure 2.1 illustre comment les réseaux mobiles ont évolué au fil des générations de technologies, depuis les premiers réseaux analogiques jusqu'aux systèmes sans fil de nouvelle génération.

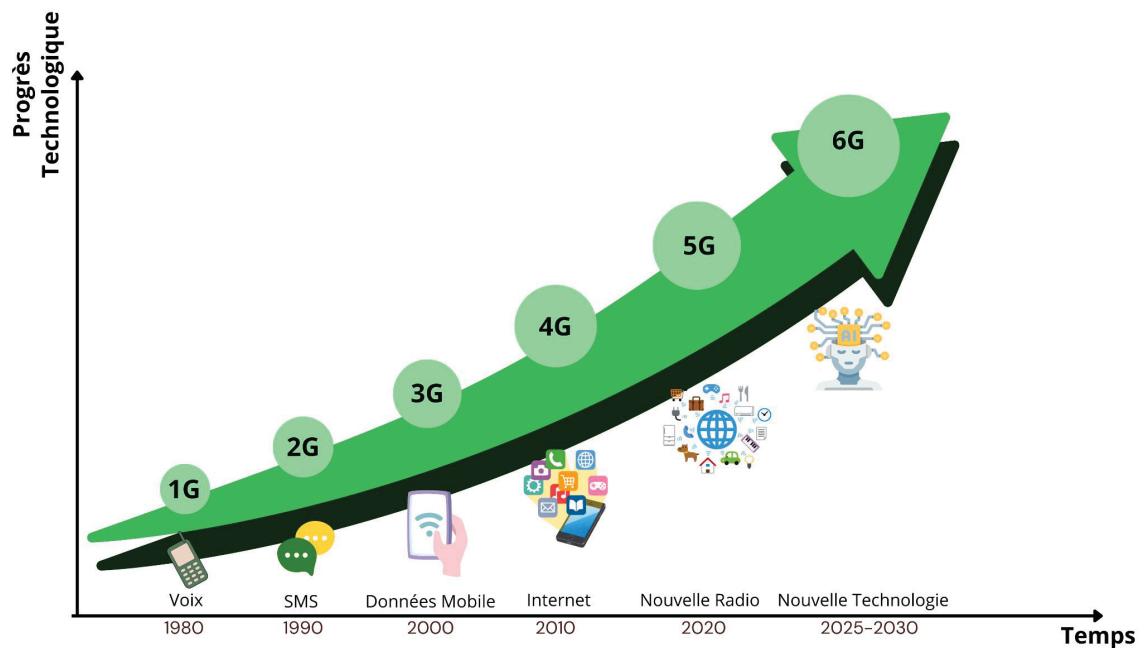


Figure 2.1 L'évolution des réseaux mobiles.

2.2.2 Modulations de base en communication numérique

Dans un système de communication numérique, la modulation est une étape essentielle qui permet de transmettre des données binaires (composées de 0 et de 1) sous forme de signaux analogiques adaptés aux caractéristiques du canal de transmission. Elle consiste à faire varier une ou plusieurs propriétés d'une onde porteuse sinusoïdale — comme l'amplitude, la fréquence ou la phase — en fonction de l'information numérique à transmettre [17].

Parmi les modulations de base les plus couramment utilisées, on trouve la modulation d'amplitude en bande de base (figure 2.2), appelée ASK (Amplitude Shift Keying) qui est une méthode de modulation par déplacement d'amplitude qui change l'amplitude du signal en fonction des données binaires [18].

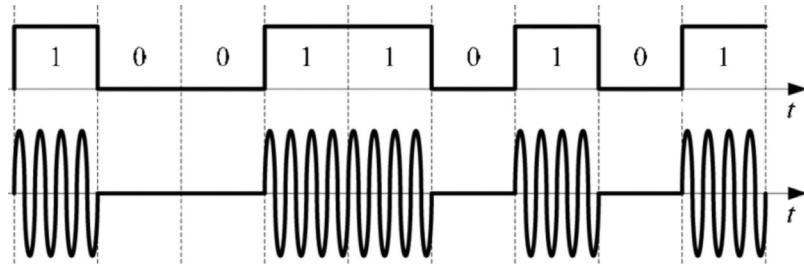


Figure 2.2 Modulation ASK.

Les données sont encodées par la modulation par déplacement de fréquence (Frequency Shift Keying, FSK) en modifiant la fréquence de la porteuse (figure 2.3). Dans ce cas, c'est la fréquence du signal qui varie selon la donnée binaire [19]. Cette méthode est plus robuste que l'ASK face aux interférences, mais elle présente une utilisation plus large de la bande passante.

La troisième modulation de base est la modulation par déplacement de phase (Phase

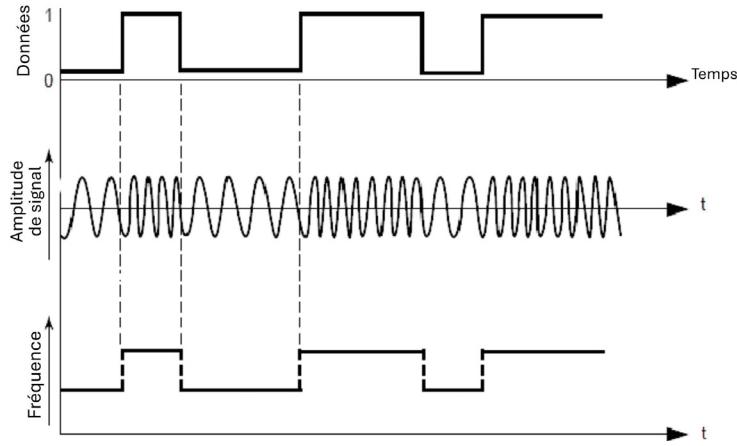


Figure 2.3 Modulation FSK.

Shift Keying, PSK) qui modifie la phase du signal afin de représenter l'information [20]. Par exemple, une phase de 0° peut correspondre au bit 0, et une phase de 180° au bit 1. Elle est plus efficace en termes d'utilisation spectrale et offre une bonne résistance au bruit, mais elle exige une synchronisation précise du signal de phase à la réception.

Le QPSK (Quadrature PSK) est une variante plus avancée qui utilise quatre états de phase pour transmettre deux bits par symbole, ce qui permet d'améliorer l'efficacité spectrale [21] (figure 2.4).

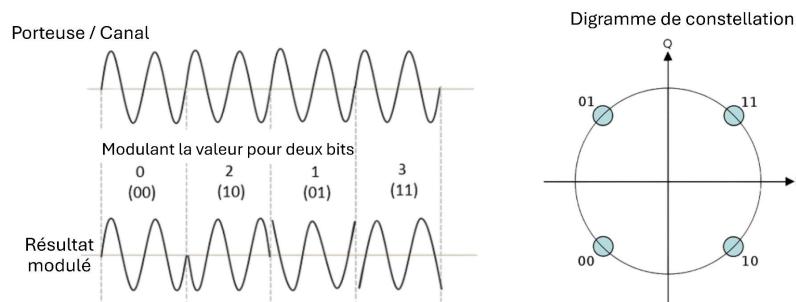


Figure 2.4 Modulation QPSK.

Finalement, la modulation en quadrature d'amplitude (Quadrature Amplitude Modulation, QAM) combine des fluctuations d'amplitude et de phase (figure 2.5), ce qui permet d'obtenir un volume d'information élevé par symbole, fréquemment employée dans les systèmes de communication modernes tels que le Wi-Fi et la 5G [7].

Toutes les formes de modulation sont sélectionnées en fonction des exigences de bande passante, de résistance au bruit et de complexité du système.

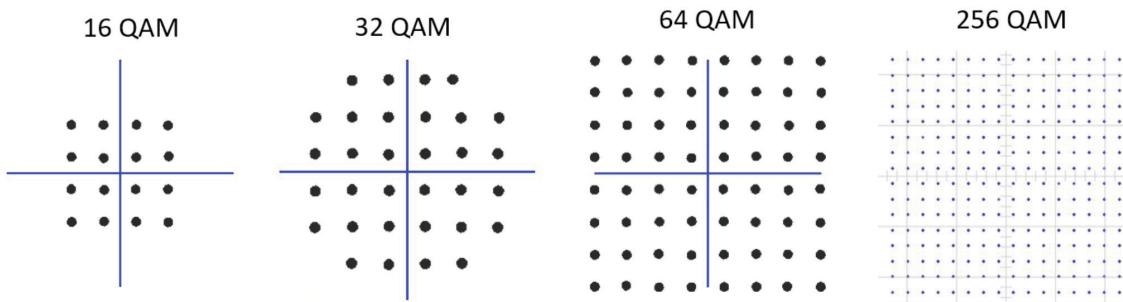


Figure 2.5 Modulation QAM.

2.3 Principales technologies de la 5G et au-delà: les systèmes MIMO-OFDM

MIMO implique l'utilisation de N_k antenne sur un émetteur comme montré dans la figure 2.7. Cette technologie tire parti de la diversité spatiale des canaux sans fil pour améliorer les débits de données, augmenter la capacité et améliorer la stabilité du signal. En transmettant plusieurs flux de données sur différentes antennes, les systèmes MIMO peuvent atteindre des débits de données plus élevés par rapport aux systèmes traditionnels à une seule antenne. Cette technologie exploite les différents trajets générés par la propagation des ondes dans l'environnement, un phénomène qui était jusqu'alors perçu comme une source d'interférences [22]. Le concept fondamental du MIMO est basé sur la variété spatiale, où chaque antenne diffuse un signal distinct. Ces signaux sont regroupés au niveau du récepteur afin de relever les données initiales, ce qui permet d'augmenter le

débit global sans étendre la bande passante [23]. Les caractéristiques de chaque chemin indépendant d'un canal MIMO sont représentées par des gains complexes de chemin. La compilation de tous ces gains complexes sous forme de matrice est présentée par l'équation (2.1). Cette matrice \mathbf{H} , qui caractérise entièrement le canal MIMO, est appelée la matrice de canal. Chaque élément de \mathbf{H} représente le gain d'un chemin indépendant du canal MIMO.

$$\mathbf{H} = \begin{bmatrix} h_{11} & h_{12} & \dots & h_{1N_k} \\ \vdots & h_{22} & & \vdots \\ \vdots & & \ddots & \vdots \\ h_{N_m 1} & \dots & \dots & h_{N_m N_k} \end{bmatrix} \quad (2.1)$$

Les avantages du MIMO sont également liés à sa résistance aux effets d'évanouissement, car la réception simultanée de signaux provenant de différents trajets permet d'améliorer la fiabilité des communications [24].

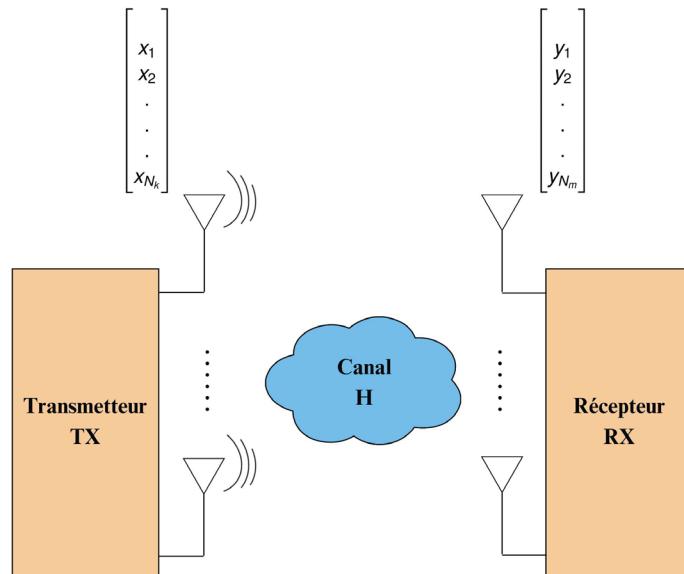


Figure 2.6 Structure de base des systèmes MIMO.

Dans de nombreux systèmes de communication contemporains, l'OFDM est une méthode de modulation qui permet d'améliorer l'efficacité spectrale et de combattre les interférences [25]. Le canal de transmission est divisé en plusieurs sous-porteuses orthogonales par l'OFDM, chacune étant modulée de manière autonome avec un débit limité pour transmettre des données simultanément. Grâce à cette méthode, on peut optimiser l'utilisation du spectre tout en renforçant la résistance des transmissions aux interférences entre les symboles et au fading sélectif en fréquence [26]. Le principal avantage de l'OFDM est de réduire la dispersion des retards dans les canaux multi-trajets, qui est une caractéristique des réseaux sans fil complexes [27]. En distribuant les informations sur différentes sous-porteuses, l'OFDM offre une transmission de données plus efficace et fiable, même dans des situations où les signaux peuvent être réfléchis, réfractés ou dispersés par des obstacles. En outre, l'utilisation de sous-porteuses orthogonales permet à l'OFDM d'éviter les interférences entre les canaux, ce qui permet d'optimiser l'utilisation du spectre disponible. La propriété d'orthogonalité permet aux sous-canaux de se chevaucher en fréquence, éliminant ainsi le besoin de bandes de garde et de filtres coûteux pour séparer les sous-canaux. De plus, l'utilisation de sous-porteuses orthogonales peut être montrée comme équivalente à l'IDFT (Inverse Discrete Fourier Transform) dans le domaine numérique, permettant ainsi d'implémenter les processus de modulation et de démodulation en utilisant l'algorithme FFT (Fast Fourier Transform).

Typiquement, une forme d'onde OFDM comprend des sous-porteuses N_f , chacune portant une partie du signal de données global [28]. Ces sous-porteuses sont organisées en blocs de ressources, qui sont des groupes de sous-porteuses adjacentes comme indiqué dans la figure 2.8. Pour structurer davantage la transmission, les symboles OFDM adjacents sont regroupés en ensembles appelés slots. Ces créneaux, souvent désignés par N_t , aident à organiser le moment de la transmission et de la réception des données.

Chaque emplacement contient un nombre spécifique de symboles OFDM, contribuant à l'efficacité et à la fiabilité globales du système de communication. En visualisant le schéma de transmission dans son ensemble, nous observons une grille temps-fréquence complète connue sous le nom de Resource Grid (RG). Le RG englobe tous les éléments de ressources (ER), qui sont les plus petites unités de transmission de données dans un système OFDM qui est illustré à la figure 2.7. Chaque RE représente une combinaison unique de fréquence et de temps, formant la colonne vertébrale de la transmission des données au sein du système. Le diagramme montré dans la figure 2.8 illustre le diagramme de bloc pour la technique OFDM. L'OFDM est une solution parfaite pour les environnements denses, tels que les zones urbaines, où les interférences et les trajets multiples sont fréquents.

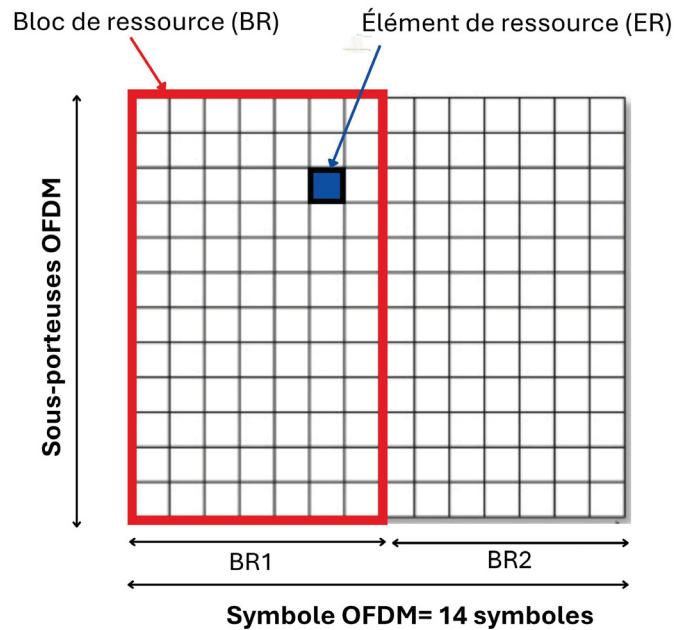


Figure 2.7 Grille de ressource.

On analyse un système MIMO où un récepteur avec N_m antennes reçoit des signaux OFDM transmis par les utilisateurs d'antennes N_k comme montré dans la figure 2.6. N_f

sous-porteuses et N_t symboles OFDM sont utilisés pour envoyer les signaux. La figure 2.6 montre une structure de base du système MIMO où le signal transmis est indiqué par le vecteur transmis $X_{f,t} \in \mathbb{C}^{N_t}$, $X_{f,t}^T = [x_1, x_2, \dots, x_{N_t}]$ et le signal reçu par $Y_{f,t} \in \mathbb{C}^{N_m}$, $Y_{f,t}^T = [y_1, y_2, \dots, y_{N_m}]$, formant une matrice de potentiel de communication qui améliore grandement les capacités de transmission et de réception des données [29]. Le système MIMO a pour objectif d'extraire les informations transmises à partir du signal reçu, même en présence de bruit, d'interférences et de diverses perturbations des canaux. Pour combler le fossé entre la transmission et la réception, on introduit le concept de canal sans fil. Ce canal est mathématiquement représenté par une matrice de canaux étiquetée \mathbf{H} . La matrice de canaux \mathbf{H} englobe les caractéristiques du support sans fil, y compris ses propriétés physiques, les obstacles et les distorsions qui se produisent lorsque le signal passe de l'émetteur vers le récepteur. La compréhension et la caractérisation de ce canal sont d'une importance capitale pour le développement et l'exploitation efficace des systèmes MIMO. Ce processus est décrit par l'équation (2.2) où $n_{f,t}$ désigne le vecteur de bruit additif.

$$Y_{f,t} = \mathbf{H}_{f,t} \times X_{f,t} + n_{f,t} \quad (2.2)$$

Dans l'OFDM, les sous-porteuses sont choisies pour être orthogonales sur une période de T_n secondes, où T_n désigne la période du symbole pour chaque sous-canal. En supposant un taux d'échantillonnage de $f_s = R_{sym} = \frac{1}{T_n}$ où R_{sym} représente le nombre de symboles transmis par seconde, cela équivaut à N échantillons. La condition d'orthogonalité est exprimée mathématiquement comme suit (2.3):

$$\frac{1}{N} \sum_{n=0}^{N-1} e^{j2\pi(f_0/f_s)n} e^{-j2\pi(f_1/f_s)n} = 0 \quad (2.3)$$

où f_0 et f_1 désignent deux fréquences orthogonales et n est l'indice de l'échantillon.

La procédure de OFDM est décrite comme suit: Les bits de message sont convertis par l'émetteur OFDM en une série de symboles PSK (Phase Shift Keying) ou QAM (Quadrature Amplitude Modulation), qui sont ensuite traduits en N flux de données parallèles. La conversion série-parallèle (S/P) de N symboles est effectuée par N sous-porteuses différentes. Chaque sous-porteuse porte un bit d'information (N bits au total) par sa présence ou son absence dans le spectre de sortie. La fréquence de chaque sous-porteuse est choisie pour produire un ensemble orthogonal de signaux, et ces fréquences sont connues à la réception [30]. Les sous-porteuses sont numérotées de 0 à $N-1$, où N indique la taille de la FFT. Un signal OFDM est constitué d'une série de porteuses modulées très rapprochées. Lorsqu'un transporteur est modulé de quelque façon que ce soit: voix, données, etc., les bandes latérales se dilatent des deux côtés. Pour démoduler correctement les données, un récepteur doit être capable de recevoir le signal entier. La modulation OFDM utilise principalement le préfixe cyclique (CP); elle inclut l'opération IFFT et l'insertion d'un préfixe cyclique. Ceci est suivi par l'opération inverse, la démodulation OFDM, qui implique la suppression du préfixe cyclique et l'opération FFT [31] comme montré dans le schéma de principe (figure 2.8) de l'émetteur combinant les éléments du symbole mapping et de la QAM avec l'application de l'IFFT pour produire un signal OFDM.

En règle générale, le type de modulation numérique est déterminé par deux conditions principales. L'une des mesures consiste à restreindre la bande passante nécessaire pour transmettre une information à une vitesse spécifique. La seconde concerne la transmission d'un signal par voie hertzienne ou la transmission dans un canal de communication [32]. La modulation multiniveau d'amplitude et la démodulation cohérente sont employées pour le standard IEEE802.1 qui ne traite pas directement la modulation mais spécifie des protocoles pour la gestion de réseau, notamment le pontage (bridging), la qualité de

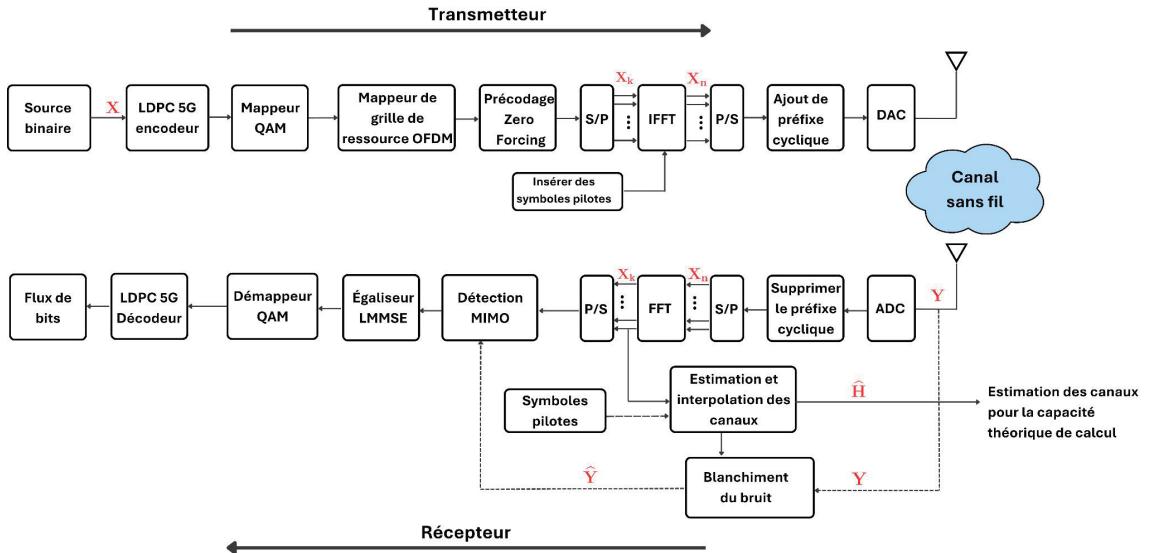


Figure 2.8 Diagramme du bloc OFDM.

service (QoS) et la sécurité dans les réseaux locaux (LAN). L'objectif de la modulation est d'ajuster le signal à envoyer au canal de transmission. L'objectif de cette opération est de modifier un ou plusieurs paramètres d'une onde de transmission. On peut modifier les paramètres suivants : l'amplitude, la fréquence et la phase. Dans les techniques de modulation numérique, les données sont transmises en utilisant un paramètre qui peut prendre deux valeurs différentes. Dans les méthodes de modulation M -aire, les valeurs du paramètre modulé sont M . Cela permet d'associer un mot de n chiffres à un état de modulation, ce qui équivaut à un nombre d'états de $M=2^n$. Le découpage en groupes de n digits du processus binaire issu d'un codeur donne naissance à ces n digits [33] qui sont ensuite mappés sur des symboles QAM. Un symbole QAM correspond à un point dans la constellation complexe (plan IQ) représentant une combinaison unique d'amplitude et de phase, et portant typiquement plusieurs bits d'information. Par exemple, dans une modulation 16-QAM, chaque symbole encode 4 bits, ce qui permet de transmettre efficacement les données binaires sous forme de signaux analogiques exploitables par le canal de transmission.

2.4 Canal sans fil

Le canal sans fil joue un rôle crucial dans tous les systèmes de communication sans fil, car il assure la communication entre l'émetteur et le destinataire. À la différence des réseaux filaires où la transmission est régulée et stable, les canaux sans fil ont des caractéristiques complexes en raison de la propagation des ondes dans l'environnement [7]. En outre, le mouvement relatif entre l'émetteur et le récepteur peut provoquer une variation de fréquence qui rend la réception plus difficile. Dans les dernières années, l'optimisation du système de communication sans fil est devenue essentielle compte tenu de la croissance rapide des services de communication mobile et des nouveaux services d'accès à Internet mobile à large bande. En fait, la compréhension des canaux sans fil jettera les bases du développement d'une technologie de transmission sans fil efficace en termes de performance et de bande passante.

Dans les communications sans fil, la propagation radio désigne le comportement des ondes radio lorsqu'elles sont propagées de l'émetteur au récepteur. Au cours de la propagation, les ondes radio sont principalement affectées par trois modes différents de phénomènes physiques: réflexion, diffraction et diffusion [34]. La réflexion est le phénomène physique qui se produit lorsqu'une onde électromagnétique frappe un objet de très grandes dimensions par rapport à la longueur d'onde, par exemple, la surface de la terre et le bâtiment. Il force la puissance du signal de transmission à être réfléchie vers son origine plutôt que d'être passée tout le long du chemin jusqu'au récepteur. La diffraction désigne divers phénomènes qui se produisent lorsque le trajet radio entre l'émetteur et le récepteur est obstrué par une surface présentant des irrégularités nettes ou de petites ouvertures. Il apparaît comme une flexion des vagues autour des petits obstacles et l'étalement des vagues au-delà de petites ouvertures. Les ondes secondaires

générées par diffraction sont utiles pour établir un chemin entre l'émetteur et le récepteur, même lorsqu'il n'y a pas de ligne de visée. La diffusion est le phénomène physique qui force le rayonnement d'une onde électromagnétique à s'écartez d'un chemin droit par un ou plusieurs obstacles locaux, de petites dimensions par rapport à la longueur d'onde. Les obstacles qui provoquent la dispersion, comme le feuillage, les panneaux de signalisation et les lampadaires, sont appelés les dispersions. En d'autres termes, la propagation d'une onde radio est un processus compliqué et moins prévisible qui est régi par la réflexion, la diffraction et la diffusion, dont l'intensité varie avec différents environnements à différentes instances [35]. La figure 2.9 montre l'architecture générale du système de communication. Cette représentation s'applique à tout type de système de communication que ce soit cablé ou sans fil.

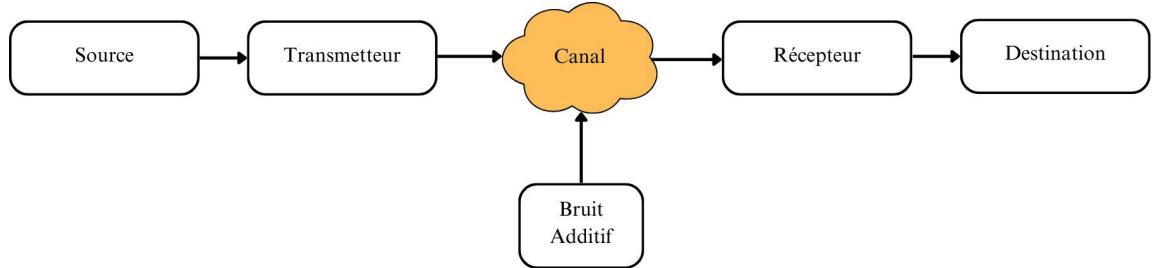


Figure 2.9 Architecture de systèmes de communication.

Le phénomène d'évanouissement (fading) dans le canal de communication sans fil a été initialement modélisé pour les bandes HF (haute fréquence, 3-30 MHz), UHF (ultra HF, 300-3000 GHz) et SHF (super HF, 3-30 GHz) dans les années 1950 et 1960 [21, 36]. Actuellement, les modèles de canaux sans fil les plus populaires ont été établis pour 800 MHz à 2,5 GHz par des mesures étendues de canal sur le terrain [34]. Il s'agit notamment des modèles de canaux standard ITU-R spécialisés pour un système de communication à antenne unique, généralement appelé communication SISO, sur certaines bandes de fréquences. Entre-temps, des modèles de canaux spatiaux pour un

un système de communication multi-antenne, appelé le système MIMO, ont été récemment développé par les diverses activités de recherche et de normalisation telles que IEEE 802, le projet METRA, les projets 3GPP/3GPP2 et WINNER, visant à la transmission sans fil à haute vitesse et au gain de diversité [1]. Le phénomène d'évanouissement peut être classifié en deux types différents: L'évanouissement à grande échelle et l'évanouissement à petite échelle. L'évanouissement ou fading à grande échelle se produit lorsque le mobile se déplace sur une grande distance, par exemple une distance de l'ordre de la taille des cellules. Elle est causée par la perte de signal en fonction de la distance et de l'ombre des grands objets tels que les bâtiments, les terrains intermédiaires et la végétation.

L'ombrage est un processus d'évanouissement lent caractérisé par la variation de la perte médiane du trajet entre l'émetteur et le récepteur à des emplacements fixes. En d'autres termes, l'évanouissement à grande échelle est caractérisé par une perte de trajectoire et un ombrage moyens [37]. D'autre part, l'évanouissement à petite échelle désigne une variation rapide des niveaux de signal due à l'interférence constructive et destructive de plusieurs chemins de signaux (multi-chemins) lorsque la station mobile se déplace sur de courtes distances. Selon l'étendue relative d'un multi-chemin, la sélectivité de fréquence d'un canal est caractérisée (par exemple, par fréquence-sélective ou fréquence plate) pour le fading de petite échelle [38]. En revanche, selon la variation de temps dans un canal due à la vitesse du mobile (caractérisée par le Doppler), l'évanouissement à court terme peut être classée comme soit rapide ou lente [39]. La figure 2.10 classe les types de canaux d'évanouissement.

Dans l'évanouissement à grande échelle, la perte de la trajectoire, qui correspond à la

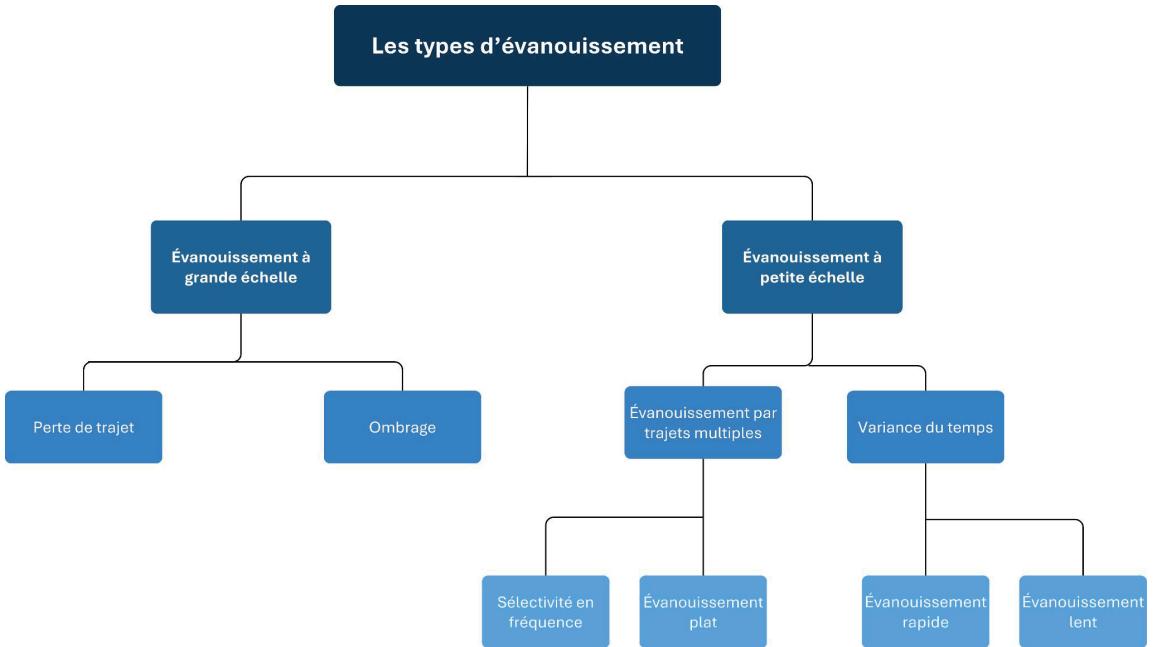


Figure 2.10 Classification des canaux d'évanouissement.

baisse de la puissance du signal avec la distance, est représentée par l'équation (2.4)

$$PL(d) = PL(d_0) + 10n \log_{10} \left(\frac{d}{d_0} \right) + X_\sigma \quad (2.4)$$

où d_0 est une distance de référence, n est l'exposant de perte de chemin, X_σ est une variable aléatoire suivant une distribution normale pour représenter l'ombrage et PL désigne la perte du trajet. Le tableau 2-1 montre la valeur de l'exposant à différents types d'environnements.

Par contre, l'évanouissement à petite échelle est causée par des fluctuations rapides des niveaux de signal liées à l'interférence constructive et destructive des trajets multiples. La sélectivité en fréquence et la sélectivité temporelle du canal influencent ce phénomène. La largeur de bande de cohérence B_c est responsable de la sélectivité en fréquence, où un canal est considéré comme sélectif en fréquence si $B > B_c$ où B désigne la largeur de bande

Tableau 2-1 Exposant de perte de chemin [1]

Environnement	Exposant de perte de chemin (n)
Espace libre	2
Radio cellulaire en zone urbaine	2.7–3.5
Radio cellulaire urbaine ombragée	3–5
Dans la construction de ligne de visée	1.6–1.8
Obstruction dans le bâtiment	4–6
Entravée dans les usines	2–3

du signal, et plat en fréquence sinon. Le temps de cohérence T_c est associé à la sélectivité temporelle, qui est influencée par la fréquence de Doppler f_D selon $T_c \approx \frac{1}{f_D}$, avec $f_D = \frac{v}{\lambda}$, où v est la vitesse relative entre l'émetteur et le récepteur, et λ est la longueur d'onde. On peut également représenter la décoloration à petite échelle en utilisant le signal reçu, qui est exprimé comme la somme des composantes de multi-trajets dans l'équation (2.5).

$$r(t) = \sum_{i=1}^N a_i e^{j(\omega_i t + \phi_i)} \quad (2.5)$$

où a_i , ω_i , ϕ_i et N représentent respectivement l'amplitude, la fréquence porteuse, la phase aléatoire du i^{eme} trajet et le nombre total de trajets dans un canal à trajets multiples. Les performances des systèmes sans fil sont fortement impactées par ces deux types d'évanouissement, ce qui requiert des techniques avancées pour leur modélisation et leur réduction. En utilisant des modèles tels que celui de Rayleigh pour les environnements riches en trajets multiples ou celui de Rice lorsqu'un chemin direct est dominant, la modélisation permet de représenter mathématiquement ces effets afin de simuler des environnements réalistes. L'estimation de canal, de son côté, a pour objectif de déduire les propriétés du canal en temps réel en utilisant des méthodes comme la méthode des moindres carrés (LS) ou l'erreur quadratique moyenne minimale (MMSE). Ces estimations, fréquemment accompagnées de symboles pilotes, jouent un rôle essentiel

dans des systèmes tels que MIMO-OFDM, où il est essentiel de compenser les effets du canal afin d'assurer des performances fiables. Il convient de souligner que les méthodes utilisées pour évaluer et comparer les différents estimateurs reposent sur les critères MSE et BER. Le premier critère se concentre sur la comparaison entre le canal estimé et le canal réel utilisé, alors que le deuxième critère évalue la qualité de transmission après l'utilisation de chacun des estimateurs. Une simple comparaison entre les types d'évanouissement est décrite dans le tableau 2-2.

Tableau 2-2 Comparaison entre évanouissement à petite échelle et évanouissement à grande échelle

Type de fading	Rayleigh et Rice	évanouissement à grande échelle
Catégorie	évanouissement à petite échelle	évanouissement à grande échelle
Caractéristique	Variations rapides du signal	Changements graduels du signal
Causes	propagation multi-trajet	Distance et obstacles
Exemples de modèles	Rayleigh, Rice	Modèle log-normal, atténuation exponentielle

2.4.1 Bruit et interférences

Le bruit et les interférences constituent deux sources majeures de dégradation du signal dans les systèmes de communication sans fil, affectant directement la qualité de réception et les performances globales du système.

2.4.1.1 Rapport signal sur bruit: SNR

Le rapport signal sur bruit, également connu sous le nom de SNR (Signal-to-Noise Ratio), est une évaluation de la qualité d'un signal en évaluant la puissance du signal utile à celle du bruit défavorable. En général, il est mesuré en décibels (dB) et calculé selon la formule (2.6) suivante :

$$SNR = 10 \cdot \log_{10} \left(\frac{P_{\text{signal}}}{P_{\text{bruit}}} \right) \quad (2.6)$$

où P_{signal} représente la puissance du signal utile et P_{bruit} représente la puissance du bruit. Un signal avec peu de bruit correspond à un SNR élevé, tandis qu'un signal submergé dans le bruit correspond à un SNR faible. Le SNR joue un rôle crucial dans l'évaluation des résultats des systèmes de communication.

2.4.1.2 Taux d'erreur binaire: BER

Le BER (Bit Error Rate) est un indicateur de performance des systèmes de communication qui évalue le nombre d'erreurs de bits reçus par rapport au nombre total de bits transmis sur le canal. Sa formule est décrite par:

$$BER = \frac{N_{\text{erreurs}}}{N_{\text{total}}} \quad (2.7)$$

avec N_{erreurs} représentant le nombre de bits erronés et N_{total} le nombre total de bits transmis ou reçus. Une transmission fiable avec peu d'erreurs est indiquée par un faible BER, tandis qu'un BER élevé témoigne d'une détérioration de la qualité du signal, souvent due au bruit, aux interférences ou aux limitations du canal.

2.5 Méthodes d'estimation du canal sans fil

Il est crucial d'estimer le canal afin de compenser les effets indésirables du canal sans fil, tels que le bruit et les interférences, qui dégradent la qualité de la transmission. Les méthodes traditionnelles reposent généralement sur l'insertion de symboles pilotes ou de signaux d'entraînement dans la trame de transmission, permettant une estimation explicite du canal. Parmi ces approches classiques, on retrouve les méthodes du Least Squares (LS), du Minimum Mean Square Error (MMSE), ainsi que des techniques d'interpolation. Plus récemment, des approches basées sur l'intelligence artificielle ont été introduites pour estimer le canal de manière plus robuste, en exploitant les structures cachées et les

corrélations dans les données reçues, même avec un nombre réduit de symboles pilotes.

2.5.1 Méthodes LS

Les méthodes LS sont parmi les plus simples et les plus fréquemment employées. Elles réduisent au minimum les erreurs du carré entre les sous-porteuses pilotes reçues et celles transmises [40]. La valeur estimée du canal est fournie par l'équation (2.8)

$$\hat{H}_{\text{LS}} = \frac{Y}{X} \quad (2.8)$$

où \hat{H}_{LS} représente la réponse estimée du canal, Y et X désignent respectivement le signal reçu et le signal pilote connu dans le domaine des fréquences.

2.5.2 Méthode MMSE

MMSE est une méthode plus sophistiquée que LS [40]. En tenant compte du bruit et des statistiques du canal, elle réduit l'erreur quadratique moyenne entre l'estimation et la réponse réelle du canal. L'évaluation est effectuée par l'équation (2.9)

$$\hat{H}_{\text{MMSE}} = R_{HY}R_{YY}^{-1}Y \quad (2.9)$$

où:

- R_{HY} est la matrice de corrélation croisée entre le canal et le signal reçu.
- R_{YY} est la matrice d'autocorrélation du signal reçu.
- Y est le vecteur des signaux reçus.

2.5.3 Méthode basées sur l'interpolation

Dans les systèmes où les symboles pilotes ne sont pas insérés sur toutes les sous-porteuses, on utilise souvent des méthodes basées sur l'interpolation pour estimer la réponse du canal. En utilisant les estimations obtenues sur les sous-porteuses pilotes, ces techniques permettent de calculer les valeurs de la réponse du canal pour les sous-porteuses sans pilotes. Parmi ces techniques, la plus facile est l'interpolation linéaire, qui relie les estimations des sous-porteuses voisines par une ligne droite. La relation suivante, équation (2.10) permet d'estimer la réponse du canal à une fréquence intermédiaire f :

$$\hat{H}(f) = H_1 + \frac{(H_2 - H_1)}{(f_2 - f_1)} \cdot (f - f_1) \quad (2.10)$$

où H_1 et H_2 sont les réponses estimées sur les sous-porteuses pilotes situées respectivement aux fréquences f_1 et f_2 . D'autres méthodes, telles que l'interpolation spline ou l'extrapolation polynomiale, sont employées afin d'obtenir une précision accrue, notamment dans les canaux avec des fluctuations fréquentes. Ces techniques traditionnelles sont à l'origine de nombreuses méthodes contemporaines d'estimation du canal, notamment dans les systèmes MIMO-OFDM. Leur sélection est influencée par les limites en termes de complexité, de disponibilité des ressources et des caractéristiques du canal. Le tableau 2-3 présente un résumé des différentes méthodes classiques d'estimation de canal.

2.5.4 Structure des pilotes

Les pilotes sont des porteuses dont l'émetteur et le récepteur sont informés du gain, de la phase et de la position dans la structure OFDM. La sélectivité du canal influence le choix des pilotes dans la trame OFDM [41]. Donc, pour un canal qui est très sélectif en fréquence

Tableau 2-3 Résumé des méthodes classiques d'estimation de canal

Méthode	Avantages	Inconvénients
Least Squares (LS)	<ul style="list-style-type: none"> - Simple à implémenter. - Faible complexité. 	<ul style="list-style-type: none"> - Sensible au bruit. - Performances limitées dans les canaux bruyants.
Minimum Mean Square Error (MMSE)	<ul style="list-style-type: none"> - Réduction optimale du bruit. - Exploite les propriétés statistiques du canal. 	<ul style="list-style-type: none"> - Complexité computationnelle élevée. - Nécessite des connaissances a priori sur le canal.
Interpolation (linéaire, spline, etc.)	<ul style="list-style-type: none"> - Réduit l'utilisation des pilotes. - Efficacité spectrale améliorée. 	<ul style="list-style-type: none"> - Performances limitées dans les canaux très sélectifs. - Moins robuste pour des variations rapides.

mais pas en temps, on optera pour un système de pilotes dans le domaine fréquentiel, où chaque sous-porteuse d'un symbole OFDM spécifique est réservée à l'estimation. Il s'agit du motif employé lorsqu'on prend en compte un canal quasi-statique. Dans le cas d'un canal moyennement sélectif en fréquence, mais très sélectif en temps, on préférera utiliser un arrangement temporel où certaines fréquences sont réservées à l'estimation du canal [42]. Il existe deux dispositions relativement à chaque symbole OFDM : les porteuses pilotes et les porteuses d'information. En fonction de la configuration de la trame OFDM en présence des symboles pilotes, trois configurations distinctes sont prises en compte :

- configuration en bloc
- configuration en peigne
- configuration en treillis

2.5.4.1 *Mise en place en bloc*

La configuration en bloc (figure 2.11) implique l'insertion de pilotes sur toutes les sous-porteuses d'un ou plusieurs symboles OFDM, ce qui est parfait pour les canaux qui varient lentement dans le temps, car elle permet d'obtenir une estimation précise pour des

longues périodes. S_t sur la figure 2.11 désigne la période des symboles pilotes dans le temps.

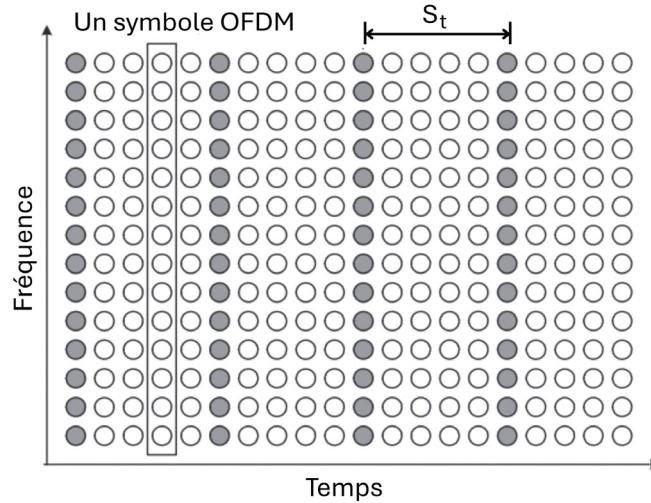


Figure 2.11 Configuration de type bloc pilote.

2.5.4.2 *Mise en place en peigne*

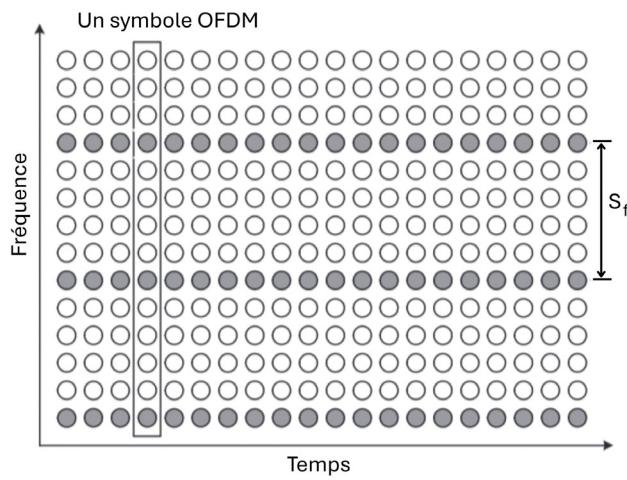


Figure 2.12 Configuration de type peigne pilote.

Les sous-porteuses pilotes sont distribuées à intervalles réguliers sur chaque symbole OFDM grâce à la configuration en peigne (figure 2.12), ce qui permet une estimation

continue adaptée aux canaux sélectifs en fréquence. Dans la figure 2.12, S_f représente la période des tonalités pilotes en fréquence.

2.5.4.3 *Mise en place en treillis*

La configuration en treillis (figure 2.13) combine les deux méthodes précédentes en introduisant des pilotes à la fois dans le temps et la fréquence, ce qui est particulièrement bénéfique pour les canaux qui varient à la fois dans le temps et la fréquence, comme dans les environnements à mobilité élevée.

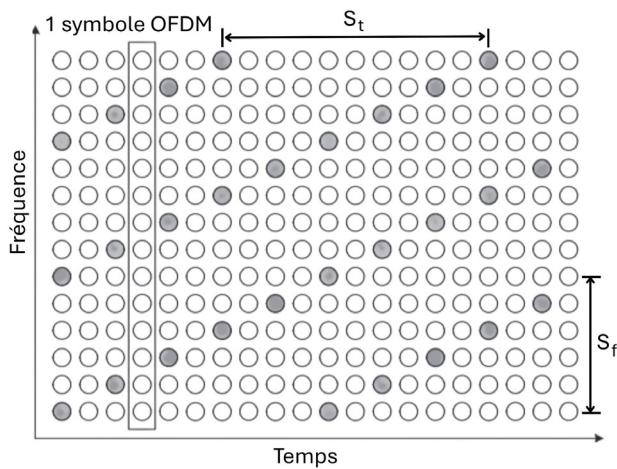


Figure 2.13 Configuration de type treillis pilote.

2.6 L'intelligence artificielle dans les systèmes de communication

L'IA occupe une place de plus en plus importante dans l'amélioration et la mise à jour des systèmes de communication sans fil. Devant la croissance de la complexité des réseaux et les exigences de performances élevées, l'intelligence artificielle propose des solutions novatrices afin d'améliorer l'efficacité, la fiabilité et l'adaptabilité des systèmes de communication. Dans cette partie, nous examinons les principales applications de l'IA, en particulier dans le cadre de la couche physique, et mettons en évidence les progrès

réalisés grâce à des techniques telles que l'apprentissage automatique, l'apprentissage par renforcement (RL) et le Meta-RL. Nous démontrons qu'il est possible d'apprendre des implémentations complètes de l'émetteur et du récepteur pour un modèle de canal donné qui sont optimisées pour une fonction de perte choisie (par exemple, en minimisant le taux d'erreur de bloc (BLER)). Fait intéressant, ces systèmes "savants" peuvent être concurrentiels par rapport à l'état actuel de la technique. L'idée clé ici est de représenter l'émetteur, le canal et le récepteur comme un réseau neuronal profond (NN) qui peut être formé en tant qu'autocodeur. La beauté de cette approche est qu'elle peut même être appliquée à des modèles de canaux et à des fonctions de perte pour lesquelles les solutions optimales sont inconnues.

2.6.1 Apprentissage automatique pour la couche physique

L'apprentissage automatique (ML) offre la possibilité de substituer les méthodes classiques par des algorithmes aptes d'acquérir des connaissances et de s'adapter à des milieux complexes et en constante évolution. Dans la couche physique, ML est employé pour:

- L'estimation de canal: On entraîne des réseaux neuronaux afin d'estimer les caractéristiques du canal avec une plus grande précision par rapport aux méthodes traditionnelles telles que LS ou MMSE.
- La détection de signaux: Il est possible de reconstruire les signaux transmis grâce à des modèles basés sur l'apprentissage supervisé, même dans des environnements bruités ou interférents.
- L'égalisation des canaux: L'approche non linéaire et adaptative des algorithmes ML est particulièrement bénéfique pour les systèmes MIMO-OFDM qui font face à des conditions de propagation complexes.

Le principal bénéfice du ML réside dans sa capacité à tirer des apprentissages directs des données, ce qui diminue la dépendance aux modèles analytiques parfois imprécis dans des environnements réels.

2.6.2 Apprentissage par renforcement (RL)

RL est une évolution significative pour les systèmes adaptatifs, où un agent intelligent acquiert la capacité de prendre des décisions parfaites en interagissant avec son environnement. RL est employé dans les systèmes de communication sans fil pour répondre à plusieurs défis clés [43–45]:

- L’allocation de ressources: Effectuer une optimisation dynamique de l’allocation de spectre, de la gestion de puissance et des schémas d’antennes dans des environnements multi-applications [46].
- L’estimation et la prédiction de canal: En acquérant la capacité de s’ajuster aux évolutions rapides du canal sans fil [47].
- La détection des signaux: En associant actions et récompenses afin de réduire au minimum les erreurs de détection [48].

Le RL s’avère très pratique dans des situations où le système est en constante évolution et où les décisions optimales ne sont pas figées.

2.6.3 Apprentissage Meta-RL

Le Meta-RL est une version du RL qui offre aux agents la possibilité d’acquérir une meilleure compréhension en étendant leurs expériences à divers environnements. À la différence du RL traditionnel, où chaque tâche demande un processus d’apprentissage approfondi, le Meta-RL permet de transférer les connaissances acquises dans un contexte spécifique vers de nouvelles tâches similaires. Dans les systèmes de communication, on

utilise le Meta-RL afin de répondre à:

- L'optimisation des canaux variables: En acquérant la capacité de s'ajuster rapidement à des conditions de canal évolutives [49].
- La gestion multi-scénarios: En ajustant de manière efficace les paramètres du système dans différents contextes [50].
- La réduction du temps d'apprentissage: En accélérant la fusion des solutions dans des réseaux sophistiqués tels que ceux utilisant MIMO-OFDM [51].

2.6.4 *Opportunités et défis*

L'incorporation de l'IA dans les systèmes de communication offre de multiples possibilités d'amélioration des performances globales. Les principaux bénéfices incluent une meilleure optimisation des ressources, une gestion dynamique de l'allocation du spectre et de la puissance, ainsi qu'une diminution des erreurs grâce à des techniques d'apprentissage automatique avancées. En outre, l'intelligence artificielle permet d'améliorer la résistance face aux situations imprévues, telles que les changements soudains du canal ou les milieux bruyants. Toutefois, malgré ces progrès prometteurs, plusieurs obstacles importants demeurent. En premier lieu, la difficulté computationnelle représente un obstacle majeur, car l'apprentissage et la mise en œuvre des modèles d'IA requièrent des ressources considérables en termes de puissance de calcul et de mémoire. Par la suite, il est essentiel de prendre en compte la résistance aux scénarios réels : il est essentiel de vérifier les performances des modèles dans des conditions différentes et dynamiques, afin de garantir leur efficacité dans des environnements concrets. Finalement, il demeure un défi d'exploiter les algorithmes, car ils doivent être intégrés de manière efficace dans des architectures de réseau déjà en place, tout en respectant les contraintes de latence et d'efficacité énergétique.

En résumé, la technologie de l'intelligence artificielle joue un rôle essentiel dans les systèmes de communication sans fil de dernière génération. Elle permet de dépasser les frontières des méthodes classiques et de satisfaire les exigences croissantes en termes de performance et d'adaptabilité, tout en offrant de nouvelles opportunités pour les réseaux à venir.

Récemment, l'intégration de techniques d'apprentissage automatique dans la chaîne de traitement du signal a permis de proposer des architectures apprenantes capables de remplacer certains blocs classiques du transmetteur et du récepteur. Des modèles end-to-end tels que les autoencodeurs ont été explorés pour effectuer conjointement les tâches de modulation, codage, transmission, démodulation et décodage. Ces méthodes visent à optimiser globalement la performance du système en présence de bruit, d'évanouissement et d'interférences, là où les approches traditionnelles traitaient chaque bloc séparément avec des hypothèses souvent simplificatrices. Des études telles que celles de O'Shea et Hoydis (2017), ou de Felix et al. (2018) ont montré le potentiel de telles approches pour simplifier la conception des systèmes tout en améliorant leur efficacité.

2.7 Conclusion

Dans ce chapitre, nous avons examiné en détail les principes des systèmes de communication sans fil, en mettant l'accent sur les difficultés liées à la modélisation et à l'estimation des canaux, ainsi que sur l'essor de l'IA dans ce domaine. Nous nous sommes penchés sur les technologies essentielles comme MIMO-OFDM et abordé les méthodes classiques pour améliorer la couche physique, tout en mettant en évidence leurs limites face aux environnements dynamiques et complexes des réseaux contemporains. L'apparition des méthodes d'apprentissage automatique et de l'apprentissage profond a représenté une avancée majeure, en offrant des solutions capables d'acquérir des

connaissances, de s'adapter et de les généraliser dans différents contextes. Grâce à ces méthodes, il est possible d'améliorer l'efficacité spectrale et la résistance des systèmes, tout en affrontant des défis tels que l'estimation des canaux, la détection de signaux et l'allocation dynamique des ressources.

Chapitre 3 - Méthodologie

3.1 Introduction

Nous exposons dans ce chapitre la méthodologie utilisée pour mener à bien ce projet, qui se base sur l'approche d'apprentissage du bout en bout (end-to-end learning) qui utilise des autoencodeurs pour optimiser les systèmes de communication sans fil, avec une mise en œuvre dans le cadre Sionna. À la différence des méthodes classiques, où chaque élément de la chaîne de communication (encodage, modulation, canal, démodulation et décodage) est optimisé de manière indépendante, l'apprentissage de bout en bout vise une optimisation collective. Dans ce chapitre, une analyse de 3 algorithmes a été faite pour la comparaison des performances: méthode conventionnelle, méthode par renforcement et méthode avec meta-RL. Grâce à l'intelligence artificielle, cette méthode permet de créer des systèmes capables d'acquérir des connaissances directement à partir des données et des caractéristiques du canal, en ajustant de manière dynamique leurs paramètres afin d'optimiser les performances globales.

3.2 Environnement de travail et outils utilisés

Pour ce projet, la réalisation des simulations et la mise en œuvre complète des modèles d'apprentissage ont exigé l'emploi de divers outils logiciels et bibliothèques. Dans cette partie, on expose le cadre de travail, les langages de programmation et les outils techniques utilisés afin d'atteindre les objectifs établis.

3.2.1 *Langage de programmation*

Python a été employé pour toutes les phases de développement et de simulation. Il convient parfaitement aux projets d'apprentissage automatique en raison de sa simplicité, de sa souplesse et de sa vaste communauté scientifique. Il permet d'accéder directement à

des bibliothèques puissantes spécialisées dans le traitement des signaux, l'optimisation et l'apprentissage automatique.

3.2.2 Bibliothèques et outils utilisés

- **Sionna:** L'objectif de la bibliothèque open-source Sionna, conçue pour la recherche en communication sans fil, est décrit dans le tableau 3-1.

Tableau 3-1 Fonctionnalités de Sionna

Caractéristique	Description
Modélisation des canaux	Simulation de canaux réalistes tels que AWGN, Rayleigh, et Rician pour représenter des environnements variés.
Compatibilité TensorFlow	Intégration fluide avec TensorFlow, facilitant l'apprentissage de bout en bout et l'optimisation conjointe.
Différentiabilité	Permet l'entraînement des modèles en exploitant des gradients, indispensable pour les approches basées sur l'IA.
Métriques d'évaluation	Calcul du BER (Bit Error Rate) et de l'erreur quadratique moyenne (MSE) pour mesurer les performances des systèmes.
Flexibilité	Supporte la conception et l'entraînement de systèmes avancés comme les autoencodeurs pour MIMO-OFDM.
Application	Utilisé pour la recherche sur les systèmes de communication sans fil de nouvelle génération, intégrant des algorithmes basés sur l'apprentissage profond.

- **TensorFlow:** Il est utilisé pour créer, entraîner et améliorer les réseaux de neurones.

Sionna est compatible avec TensorFlow, ce qui rend la création des autoencodeurs plus facile et permet d'optimiser ensemble les modules d'encodage, de canal et de décodage.

- **NumPy et Matplotlib:**

1. NumPy a été employé dans le domaine de la manipulation des données numériques, comme la création et la conversion de signaux.
2. Les résultats ont été visualisés à l'aide de Matplotlib, notamment pour

représenter les courbes d'évolution du BER en fonction du SNR.

3.2.3 *Environnement de développement*

On a effectué les simulations dans l'environnement Jupyter Notebook, une plateforme interactive qui permet de créer et d'exécuter du code Python. Cet environnement a été sélectionné afin d'organiser et de documenter le code de manière plus facile, de donner la possibilité de visualiser les résultats en temps réel et de proposer un cadre concret pour associer les explications théoriques aux mises en œuvre techniques.

3.3 Présentation de l'apprentissage de bout en bout (End-to-End Learning)

L'apprentissage de bout en bout, également connu sous le nom d'End-to-End Learning [4], est une méthode innovante dans les systèmes de communication, où toute la chaîne de transmission et de réception est modélisée et optimisée en collaboration avec des réseaux neuronaux [52]. À la différence des systèmes classiques, qui séparent la chaîne en blocs distincts (encodage, modulation, canal, démodulation, décodage), cette méthode cherche à intégrer toutes les étapes dans un modèle unique, différentiable, entraîné pour optimiser les performances globales [53].

3.3.1 *Principe de fonctionnement*

L'apprentissage de bout en bout consiste à utiliser un modèle neuronal pour substituer la chaîne de communication traditionnelle. Il est composé de trois principales composantes:

1. **Encodeur:** L'émetteur dans un système de communication est l'encodeur. Il reçoit des informations brutes, telles que des bits ou des vecteurs symboliques, et les convertit en une représentation appropriée pour la transmission.

- Compression des données: L'utilisation de l'encodeur diminue la répétition des données, tout en préservant les informations essentielles.
 - Modulation implicite: À la différence des systèmes classiques utilisant des modulations explicites (BPSK, QPSK, etc.), l'encodeur apprend directement à partir des données une modulation optimale.
 - Fonctionnement neuronal: En règle générale, l'encodeur est constitué de différentes couches neuronales (denses ou convolutives), comportant des non-linéarités afin de détecter les relations complexes présentes dans les données.
2. **Canal différentiable:** En utilisant des modèles tels que le bruit gaussien (AWGN), le fading multipath (Rayleigh, Rician) ou d'autres effets spécifiques aux environnements sans fil, on simule le canal de manière réaliste. En raison de sa spécificité, ce module offre la possibilité d'apprendre directement les paramètres qui influencent la transmission.
3. **Décodeur:** Le décodeur reconstitue les informations initiales en utilisant le signal bruité reçu. Le but est de réduire au maximum l'erreur entre les informations transmises et les informations reçues.

3.3.2 *Avantages de l'approche*

L'approche intégrée et optimisée de l'apprentissage de bout en bout présente de nombreux avantages importants par rapport aux systèmes de communication classiques. En premier lieu, cette approche offre la possibilité d'optimiser ensemble toutes les étapes de la chaîne de communication, depuis l'encodage jusqu'à la reconstruction des données. Lorsqu'elle entraîne en même temps tout le système afin de réduire la fonction de perte globale, elle assure des performances optimales en tenant compte des interactions entre

les différents modules. Cette méthode se démarque également par sa capacité à s'adapter aux fluctuations dynamiques des conditions du canal, comme les variations du rapport signal-bruit (SNR) ou les environnements où le bruit est élevé. Le modèle acquiert la capacité d'ajuster automatiquement ses paramètres, ce qui renforce sa résistance dans des situations complexes et diversifiées. Enfin, la conception des systèmes est grandement simplifiée grâce à l'apprentissage complet, qui remplace les nombreux blocs indépendants des architectures traditionnelles par un modèle unifié et personnalisable. Ce processus d'intégration permet non seulement de diminuer la complexité des processus de développement, mais elle permet également d'optimiser les performances globales de manière plus fluide et plus efficace.

3.3.2.1 Fonction de perte et optimisation

Une fonction de perte est utilisée pour évaluer la qualité de la reconstruction des données dans l'apprentissage de bout en bout. On utilise fréquemment des mesures telles que l'erreur quadratique moyenne (MSE) ou le taux d'erreur binaire (BER):

$$\mathcal{L} = \text{MSE}(x, \hat{x}) \quad \text{ou} \quad \mathcal{L} = \text{BER}(x, \hat{x}) \quad (3.1)$$

où x représente les données originales et \hat{x} les données reconstruites. L'objectif principal est de minimiser cette fonction de perte en ajustant les paramètres des réseaux neuronaux constituant l'encodeur et le décodeur, tout en prenant en compte les distorsions introduites par le canal. Grâce à cet ajustement, l'apprentissage de bout en bout garantit une optimisation conjointe de toutes les étapes du système, ce qui permet d'améliorer à la fois la robustesse et la précision de la transmission dans des environnements variés.

3.4 Architecture du modèle d'autoencodeur dans Sionna

Un autoencodeur est structuré autour de deux groupes de couches neuronales. Le premier groupe constitue l'encodeur, qui manipule les données d'entrée afin de créer de nouvelles représentations (codes). Le second groupe, connu sous le nom de décodeur, s'efforce de reconstituer les données à partir de ce code [54]. La figure 3.1 illustre l'organisation générale d'un autoencodeur symétrique.

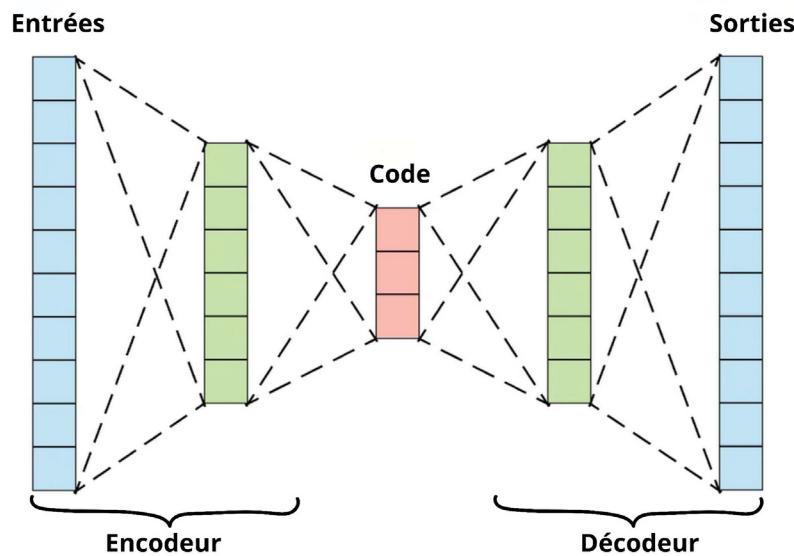


Figure 3.1 Schéma de principe de l'autoencodeur [3].

Dans ce projet, l'architecture de l'autoencodeur est basée sur une intégration totale dans le cadre Sionna. La chaîne de communication complète est simulée par cet autoencodeur, comprenant l'encodage, la transmission via un canal simulé et le décodage. Les divers éléments de cette architecture sont reliés de manière variée, ce qui permet une optimisation collective à travers tout le système. L'architecture globale est montrée à la figure 3.2.

La mise en œuvre d'un système de communication de bout en bout avec un autocodeur implique l'utilisation d'une architecture de réseau neuronal composée d'un codeur et d'un

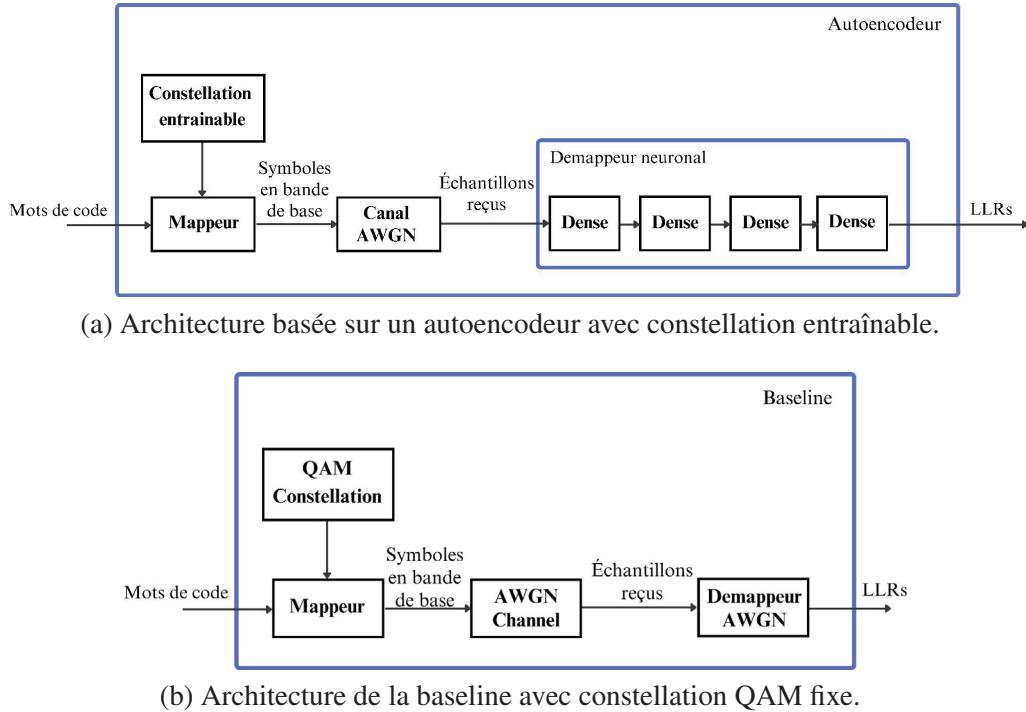


Figure 3.2 Architecture comparative entre un autoencodeur et une baseline [4].

décodeur. La figure 3.2 présente une comparaison entre deux architectures de transmission dans un système de communication sans fil. La figure (a) illustre une architecture basée sur un autoencodeur, tandis que la figure (b) correspond à une architecture de référence traditionnelle, appelée baseline. Dans la figure (a), l'architecture repose sur un autoencodeur dans lequel la constellation est optimisée (entraînable) et le démappeur est remplacé par un réseau neuronal constitué de couches denses. Le flux de données débute par les mots de code binaires, mappés en symboles complexes via un mappeur optimisé, puis transmis à travers un canal AWGN. Les échantillons reçus sont traités par un démappeur neuronal constitué de couches denses, produisant directement les LLRs pour la détection. Cette architecture optimise conjointement la constellation et le démappeur par apprentissage profond, améliorant les performances dans des environnements complexes. En revanche, la figure (b) représente l'architecture classique (baseline), où les mots de

code sont d'abord modulés via une constellation QAM fixe. Le signal suit ensuite le même chemin à travers le canal AWGN, mais au lieu d'un démappeur neuronal, un démappeur conventionnel dédié au bruit blanc est utilisé pour générer les LLRs. Cette méthode repose sur des modules prédéfinis et non optimisés, ce qui limite son adaptabilité à des conditions de canal variables ou inconnues.

L'autoencodeur, en tant que type d'apprentissage non supervisé, est formé pour compresser les données d'entrée dans une représentation à faible dimension (codage) et ensuite reconstruire l'entrée originale à partir de ce codage. Ce processus de compression et de reconstruction est la base de l'apprentissage de bout en bout dans les systèmes de communication. En utilisant une cible d'erreur moyenne au carré (MSE) et une méthode de gradient stochastique (SGD) pour identifier les poids de réseau qui fournissent une régression efficace, les autoencodeurs minimisent la perte de reconstruction sur une séquence de représentations. La figure 3.2 illustre le système mis en œuvre par rapport à une base de référence qui est un modèle de référence simple utilisé pour la comparaison.

Dans ce travail, le démappeur neuronal représenté à la figure 3.2(a) se compose de quatre couches denses avec l'activation ReLU. Le démappeur reçoit l'échantillon reçu $y \in \mathbb{C}$ et la densité spectrale de puissance du bruit N_0 à l'échelle \log_{10} pour gérer divers ordres de grandeur du SNR. Étant donné que le réseau neuronal ne peut traiter que des entrées de valeur réelle, ces valeurs sont saisies sous forme d'un vecteur tridimensionnel $[R(y), I(y), \log_{10}(N_0)]$ où $R(y)$ et $I(y)$ désignent respectivement la partie réelle et imaginaire de y . Le démappeur neuronal, également appelé récepteur, estime les valeurs du rapport de vraisemblance logarithmique (LLR: Log Likelihood Ratio) pour les bits transmis cartographiés à un point de constellation afin de démapper les symboles complexes reçus.

Pour le i^{eme} bit, la LLR est calculée en utilisant:

$$\begin{aligned} LLR(i) &= \ln \left(\frac{\Pr(b_i = 1 | y, \mathbf{p})}{\Pr(b_i = 0 | y, \mathbf{p})} \right) \\ &= \ln \left(\frac{\sum_{c \in \mathcal{C}_{i,1}} \Pr(c | \mathbf{p}) \exp \left(-\frac{1}{N_o} |y - c|^2 \right)}{\sum_{c \in \mathcal{C}_{i,0}} \Pr(c | \mathbf{p}) \exp \left(-\frac{1}{N_o} |y - c|^2 \right)} \right) \end{aligned} \quad (3.2)$$

On utilise l'expression suivante pour déterminer la valeur de N_o :

$$N_o = \left(\frac{E_b}{N_o} \frac{rM}{E_s} \right)^{-1} \quad (3.3)$$

où les points de la constellation pour lesquels le i^{eme} bit est égal à 1 et 0 sont indiqués par $\mathcal{C}_{i,1}$ et $\mathcal{C}_{i,0}$ respectivement. $\mathbf{p} = [p_0, \dots, p_{K-1}]$ est un vecteur de probabilités a priori associé à chacun des K bits, représentant la croyance que chaque bit soit égal à 1. Il est défini comme le vecteur des LLR qui agit comme connaissance préalable sur les bits K qui sont mappés à un point de constellation. Lorsqu'aucune information préalable n'est disponible, ce vecteur est initialisé à zéro, c'est-à-dire $\mathbf{p} = 0$. $r \in (0, 1]$ est le taux du codage, E_b est l'énergie par bit d'information, N_o est la densité spectrale de puissance du bruit, M est le nombre moyen de bits codés pour chaque symbole de constellation et $E_s=1$ est l'énergie moyenne par constellation par symbole. La probabilité antérieure sur le symbole de constellation c est $\Pr(c | \mathbf{p})$.

$$\Pr(c | \mathbf{p}) = \prod_{k=0}^{K-1} \text{sigmoid}(p_k \ell(c)_k) \quad (3.4)$$

où $\ell(c)_k$ est le bit $k^{i\text{ème}}$ de c , où 0 est restauré à -1.

Dans notre système de communication proposé, nous adoptons une approche nouvelle en effectuant un entraînement conjoint du côté de l'émetteur et en optimisant

simultanément la géométrie de la constellation et le marquage des bits. La géométrie de la constellation, qui représente l'arrangement des symboles cruciaux pour une transmission efficace des données, est affinée avec l'attribution de valeurs binaires à ces symboles (étiquetage de bits). Cette double optimisation vise à améliorer l'efficacité globale du processus de communication. Du côté récepteur, nous implementons un démappeur sophistiqué basé sur les réseaux de neurones qui calcule les rapports log-vraisemblance (LLR) pour les bits transmis en fonction des échantillons reçus. Le décodeur est entraîné pour réduire l'erreur de reconstruction, tandis que les LLR fournissent une estimation probabiliste des bits transmis. Pour simuler davantage les impacts des canaux pendant la transmission, une couche additionnelle de bruit blanc gaussien (AWGN) a été ajoutée, ce qui renforce la résistance du codeur automatique au bruit. Le système utilise l'encodage et le décodage LDPC (Low-Density Parity-Check) pour améliorer considérablement les performances. LDPC fournit des capacités de correction d'erreur robustes, garantissant que l'encodeur automatique fonctionne efficacement même dans des situations bruyantes. Le réseau neuronal est entraîné pour optimiser le calcul des LLR et fournir une approche discriminante et adaptative pour décoder l'information transmise. Notre système de communication à encodeur automatique est comparé aux méthodes établies, en particulier la modulation d'amplitude en quadrature (QAM) avec étiquetage Gray et un démappage optimal du bruit blanc gaussien additif (AWGN).

3.5 Algorithmes et méthodes utilisées

Cette section décrit les principaux algorithmes et méthodes employés dans le cadre de notre système de communication, en détaillant les étapes de codage, de modélisation du canal ainsi que les techniques d'apprentissage automatique intégrées pour optimiser la performance globale.

3.5.1 Modélisation du canal

On simule le canal de communication en utilisant un modèle différentiable qui intègre un canal AWGN et un canal avec Rayleigh:

- Bruit gaussien additif: Ce modèle est employé afin de reproduire l'impact du bruit aléatoire sur les signaux lors de leur transmission.
- Variations du SNR: Les simulations permettent d'évaluer les performances du système sur une plage de SNR allant de 4 dB à 8 dB, avec une augmentation de 0.5 dB. Cette plage a été choisie de manière stratégique, car elle correspond à la zone où les performances des modulations classiques, telles que la 16-QAM ou la 64-QAM, commencent à devenir intéressantes et comparables [4]. De plus, cela permet de ne pas alourdir inutilement le temps de simulation.

Il est crucial d'avoir ce canal différentiable, c'est-à-dire un canal modélisé par des opérations mathématiques continues et dérivables, afin de rétropropager les gradients à travers lui, ce qui permet d'améliorer les paramètres de l'ensemble de la chaîne.

3.5.2 Codage et décodage LDPC

Afin de garantir une transmission plus fiable, le système intègre un codage LDPC. Les bits d'entrée sont initialement codés à l'aide d'un code LDPC 5G NR (Nouvelle Radio) standardisé, qui est implémenté via les modules LDPC5GEncoder et LDPC5GDecoder de Sionna, de 1500 bits avec un taux de codage de 0,5. Le décodeur LDPC reconstruit les données initiales après la modulation et la transmission en réduisant au minimum les erreurs introduites par le canal.

3.5.3 Méthodes d'entraînement

Il y a trois approches principales pour entraîner l'autoencodeur, chacune adaptée à des situations particulières:

1. Entraînement conventionnel

L'optimisation des paramètres est utilisée dans cette méthode en utilisant l'algorithme Adam (Adaptive Moment Estimation), un optimiseur basé sur la descente de gradient. La Binary Cross-Entropy (BCE) est la fonction de perte utilisée pour évaluer la disparité entre les bits d'entrée et les bits reconstruits [2].

Elle est définie comme suit:

$$\mathcal{L}_{\text{BCE}} = -\frac{1}{N} \sum_{i=1}^N [x_i \log(\hat{x}_i) + (1 - x_i) \log(1 - \hat{x}_i)] \quad (3.5)$$

où N est le nombre total de bits, x_i représente le bit original (0 ou 1) et \hat{x}_i est la probabilité prédictive (valeur comprise entre 0 et 1). Cette fonction pénalise les écarts entre les valeurs cibles et les prédictions, et elle est particulièrement adaptée aux problèmes de classification binaire. L'entraînement se déroule sur 10 000 itérations, avec une taille de batch de 32 échantillons, chacun représentant une séquence de bits codés et modulés. La méthode d'optimisation Adam est couramment employée dans les modèles d'apprentissage profond. C'est une version sophistiquée de la Descente de Gradient Stochastique (SGD), qui combine les bénéfices de deux techniques principales : Adagrad et RMSProp. Les taux d'apprentissage des paramètres du modèle sont adaptés de manière dynamique à Adam en fonction des moments d'ordre 1 (moyennes) et d'ordre 2 (variances) des gradients.

La **SGD** consiste à mettre à jour les paramètres du modèle θ afin de minimiser

une fonction de perte (\mathcal{L}). À chaque itération t , les gradients sont calculés sur un mini-lot de données, et les paramètres sont mis à jour comme suit:

$$\theta_{t+1} = \theta_t - \eta \nabla \mathcal{L}(\theta_t) \quad (3.6)$$

où :

- θ désigne l'ensemble des paramètres ajustables du modèle lors de l'entraînement (les poids des connexions entre les neurones, les biais).
- η est le *taux d'apprentissage*.
- $\nabla \mathcal{L}(\theta_t)$ est le gradient de la fonction de perte par rapport aux paramètres.

Malgré son efficacité, la SGD présente des limitations telles que des oscillations importantes et une convergence lente. En ajustant les taux d'apprentissage pour chaque paramètre en fonction de l'historique des gradients, Adam surmonte les désavantages de la SGD standard. Cela favorise une synchronisation plus stable et plus rapide, notamment dans des environnements de paramètres complexes.

En utilisant des moyennes mobiles exponentielles des gradients et des gradients au carré, Adam met à jour les paramètres. Voici les principales étapes [2]:

- (a) **Initialisation** : Les paramètres du modèle sont initialisés ($\theta_0 \neq 0$), ainsi que les moments $m_0 = 0$ (moyenne des gradients) et $v_0 = 0$ (moyenne des gradients au carré).
- (b) **Calcul des gradients** : Le gradient de la fonction de perte est calculé :

$$g_t = \nabla \mathcal{L}(\theta_t)$$

(c) **Mise à jour des moments :**

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (\text{moyenne des gradients})$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (\text{moyenne des gradients au carré})$$

où dans la suite, nous avons fixé $\beta_1 = 0.9$ et $\beta_2 = 0.999$ sont des coefficients d'exponentiation.

(d) **Correction des biais :** Les moments biaisés sont corrigés pour obtenir :

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}, \quad \hat{v}_t = \frac{v_t}{1 - \beta_2^t}$$

(e) **Mise à jour des paramètres :** Les paramètres sont ajustés comme suit :

$$\theta_{t+1} = \theta_t - \eta \frac{\hat{m}_t}{\varepsilon + \sqrt{\hat{v}_t}}$$

où nous avons imposé $\varepsilon = 10^{-8}$ est un petit terme pour éviter les divisions par zéro.

Le tableau 3-2 et le tableau 3-3 résument les avantages de l'algorithme Adam ainsi que les paramètres utilisés qui ont été choisis conformément aux recommandations des auteurs de l'algorithme [2]. L'utilisation de l'algorithme Adam dans ce projet a été efficace pour optimiser les paramètres de l'autoencodeur. Il est parfait pour les modèles complexes tels que ceux impliquant des systèmes de communication sans fil en raison de sa capacité à s'adapter dynamiquement aux gradients. Sa solidité et sa rapidité de convergence ont joué un rôle important dans l'amélioration des performances du système dans différents environnements de canal.

La méthode traditionnelle d'entraînement offre une fondation solide pour évaluer les

Tableau 3-2 Avantages de l'algorithme Adam [2]

Avantage	Description
Adaptation dynamique	Adam ajuste automatiquement le taux d'apprentissage pour chaque paramètre en fonction des gradients calculés, ce qui améliore la stabilité de l'optimisation.
Robustesse	Il est particulièrement efficace dans des environnements bruyants ou avec des gradients clairsemés, garantissant une convergence dans des conditions difficiles.
Convergence rapide	En combinant les forces des algorithmes Adagrad et RMSProp, Adam offre une convergence plus rapide dans les espaces paramétriques complexes.
Efficacité computationnelle	L'algorithme maintient une faible empreinte mémoire tout en calculant des moyennes mobiles exponentielles des gradients, ce qui le rend adapté à des modèles de grande taille.

Tableau 3-3 Paramètres de l'algorithme Adam utilisés dans le projet

Paramètre	Valeur
Taux d'apprentissage (η)	0.001
Coefficient du premier moment (β_1)	0.9
Coefficient du second moment (β_2)	0.999
Terme de régularisation (ϵ)	10^{-8}
Nombre d'itérations	10,000

performances initiales du système. Toutefois, cette approche présente un manque de souplesse pour s'ajuster aux changements dynamiques des conditions de canal.

L'entraînement conventionnel repose sur une approche supervisée classique. Le processus commence par la génération de données binaires à l'aide de la fonction `BinarySource()`, suivie de leur encodage via le module `LDPC5GEncoder()` selon les spécifications 5G. Ces bits codés sont ensuite mappés sur des symboles complexes grâce à la fonction `Mapper()`, avant d'être transmis à travers un canal bruité modélisé par `AWGN()` ou `RayleighBlockFading()` selon les cas. Les symboles reçus sont ensuite démappés par `Demapper()` puis décodés à

l'aide du `LDPC5GDecoder()` pour reconstituer les bits estimés. La qualité de la reconstruction est évaluée par la fonction de perte `loss_fn()` — souvent une *Binary Cross-Entropy* — et les gradients sont calculés automatiquement avec l'outil `tf.GradientTape()`. Enfin, les paramètres du modèle sont mis à jour à l'aide de l'optimiseur `tf.keras.optimizers.Adam()`, via l'appel à `optimizer.apply_gradients()`.

Algorithm 1 Entraînement conventionnel

Entrées: Données X , taux d'apprentissage η , nombre d'époques E , plage de SNR $[\text{Eb}/\text{No}_{\min}, \text{Eb}/\text{No}_{\max}]$, taille de lot B

Sorties: Encodeur et décodeur entraînés, métriques de performance (BLER, BER)

- 1: Initialiser les poids de l'encodeur et du décodeur
 - 2: Définir la fonction de perte
 - 3: **for** chaque époque e de 1 à E **do**
 - 4: **for** chaque lot b dans X **do**
 - 5: **Émetteur (Encodage)** : $z = \text{Encoder}(b)$
 - 6: **Simulation du canal**: $z_{\text{bruité}} = z + \text{AWGN}(\text{SNR})$
 - 7: **Récepteur (Décodage)** : $\hat{b} = \text{Decoder}(z_{\text{bruité}})$
 - 8: **Calcul de la perte** : $L = \text{Loss}(b, \hat{b})$
 - 9: Mettre à jour les poids de l'encodeur et du décodeur pour minimiser L
 - 10: Évaluer le modèle sur l'ensemble de validation
 - 11: **Retourner**: Encodeur et décodeur entraînés, métriques de performance (BLER, BER)
-

L'algorithme 1 décrit les étapes clés de l'entraînement conventionnel de l'autoencodeur. Il commence par l'initialisation des poids de l'encodeur et du décodeur, suivie de l'encodage des données d'entrée, de la simulation du canal

bruité (AWGN), puis du décodage. À chaque itération, la fonction de perte est calculée entre les bits transmis et les bits reconstruits, puis utilisée pour mettre à jour les paramètres du réseau via rétropropagation. À la fin de chaque époque, les performances sont évaluées à l'aide des métriques BER et BLER.

2. Entraînement Basé sur le Renforcement RL

On utilise l'apprentissage par renforcement afin d'améliorer la résistance du système face aux variations des conditions des canaux sans fil. Cette méthode, à la différence de l'entraînement supervisé, ne fait pas appel directement à des paires d'entrée-sortie comme signal d'apprentissage. Elle optimise plutôt une politique en fonction d'une récompense qui évalue la qualité de la transmission. L'algorithme2 implémente un entraînement basé sur l'apprentissage par renforcement (RL), où le modèle apprend à optimiser ses décisions (la génération des symboles transmis) en réponse à un signal de récompense. Le processus commence par la génération des bits sources à l'aide de la fonction `BinarySource()`, suivie d'un encodage LDPC par `LDPC5GEncoder()`. Les données codées sont ensuite mappées sur des symboles complexes via la fonction `Mapper()`. Ces symboles sont transmis à travers un canal bruité simulé avec `AWGN()` ou `RayleighBlockFading()`, et les échantillons reçus sont démappés avec `Demapper()`. Contrairement à l'entraînement supervisé, ici une fonction de récompense personnalisée, définie dans `reward_fn()`, est utilisée pour guider l'apprentissage en fonction des performances obtenues (BLER ou BER). Les gradients sont calculés avec `tf.GradientTape()`, et les paramètres du modèle sont mis à jour à l'aide de `optimizer.apply_gradients()`, comme dans l'entraînement supervisé. Cette approche permet d'optimiser le comportement du système sans connaissance explicite du canal, en maximisant une récompense définie selon les objectifs du système. L'ensemble du processus d'entraînement basé

sur le renforcement, incluant la simulation du canal, le calcul de récompense et la mise à jour de la politique, est présenté dans l'algorithme 2.

Algorithm 2 Entraînement basé sur le RL

Entrée: Données d'entraînement X , taux d'apprentissage η , nombre d'époques E , plage de SNR $[E_b/N_{0_{\min}}, E_b/N_{0_{\max}}]$, taille de lot B , fonction de récompense R , facteur d'actualisation γ

Sortie: Encodeur et décodeur entraînés, métriques de performance (BLER, BER)

Initialiser les poids de l'encodeur et du décodeur

- 2: Définir la fonction de perte (ex. : Binary Cross-Entropy, BCE) et la fonction de récompense R
- 3: Définir le facteur d'actualisation γ
- 4: **for** chaque époque e de 1 à E **do**
- for** chaque lot b dans X **do**
- Transmetteur (Encodage):** $z = \text{Encoder}(b)$
- Simulation du canal:** $z_{\text{bruité}} = z + \text{AWGN}(\text{SNR})$
- Récepteur (Décodage):** $\hat{b} = \text{Decoder}(z_{\text{bruité}})$
- Calcul de la récompense:** $R = f(b, \hat{b})$ (basé sur BER ou BLER)
- Calcul de la perte:** $L = \text{BCE}(b, \hat{b})$
- Mise à jour de la politique:** Mettre à jour les poids avec $\nabla_{\theta} [R + \gamma L]$
- 12: Évaluer le modèle sur l'ensemble de validation et calculer BLER/BER

Retour: Encodeur et décodeur entraînés, métriques de performance (BLER, BER)

- Processus d'entraînement:
 - Formation alternée (Alternating Training): L'encodeur et le décodeur sont successivement entraînés. Grâce à cette alternance, les deux modules sont assurés de s'adapter mutuellement aux perturbations du canal. Cette étape est réalisée sur 7,000 itérations.
 - Ajustement final (Fine-Tuning): Une autre étape de réglage est effectuée afin d'optimiser exclusivement les paramètres du décodeur. Cette étape dure 3000 itérations.
- Récompense et perturbations: Le BER est utilisé pour déterminer une récompense, avec une sanction pour les erreurs élevées. Les symboles sont

équipés de petites perturbations (variance: 0,01) afin de reproduire des conditions réalistes et favoriser la résistance. La représentation de RL est montrée à la figure 3.3.

Les concepts fondamentaux de l'apprentissage par renforcement, notamment l'état, l'action et la récompense, sont définis dans le tableau 3-4, afin de clarifier leur rôle dans le processus d'entraînement. La figure 3.3 illustre le cadre général

Tableau 3-4 Notions de State, Action et Reward dans l'entraînement basé sur le renforcement (RL)

Concept	Description
State (État)	Représente les symboles reçus après la transmission à travers le canal bruité, encapsulant les conditions actuelles du canal (par exemple, bruit, fading).
Action (Action)	Décisions prises par l'encodeur pour ajuster les constellations de symboles ou par le décodeur pour reconstruire les bits transmis en minimisant les erreurs.
Reward (Récompense)	Mesure la qualité des actions prises. Elle est inversement proportionnelle au taux d'erreur (BER ou BLER), favorisant les actions qui améliorent les performances du système.

de l'apprentissage par renforcement utilisé dans ce projet. L'agent représente ici le système de communication, incluant l'encodeur, le décodeur et la politique d'apprentissage. L'environnement correspond au canal de transmission.

L'algorithme d'apprentissage adapte la politique de l'agent en fonction des récompenses obtenues, calculées selon la qualité de la transmission (BER ou BLER). Ce processus est décrit de manière détaillée dans l'algorithme 2 qui montre l'enchaînement des étapes d'entraînement en lien avec les éléments du cadre de RL.

3. Meta-Reinforcement Learning (Meta-RL)

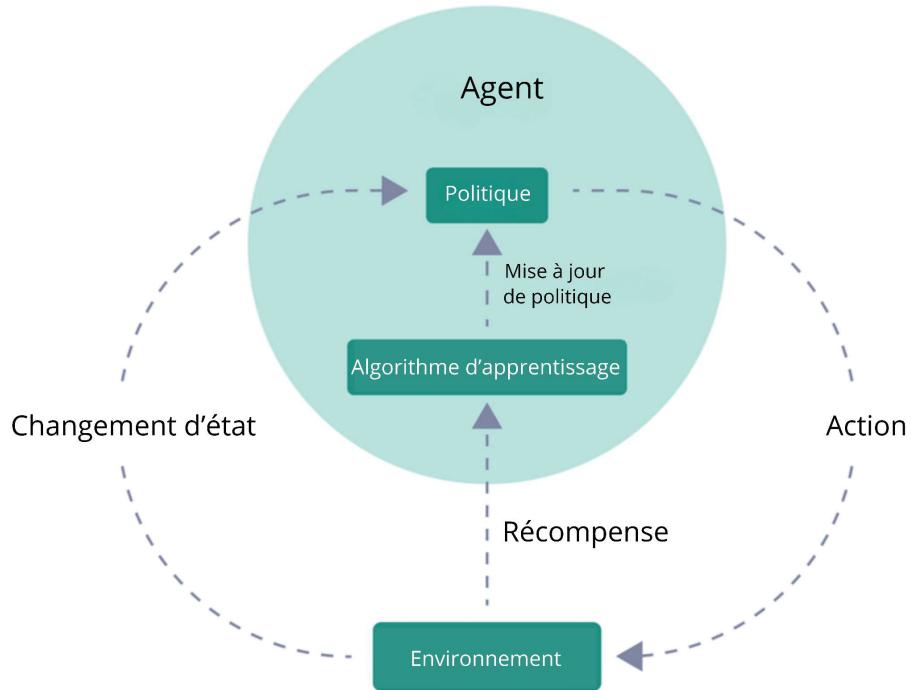


Figure 3.3 Le cadre de RL [5]

Le Meta-RL est une méthode sophistiquée qui cherche à étendre les résultats du modèle à des environnements inconnus. Cette approche utilise des tâches d'entraînement créées de manière dynamique afin de faciliter l'adaptation rapide du modèle à de nouveaux scénarios.

- Entraînement sur des tâches multiples: Le modèle est confronté à différentes configurations de canal (différents SNR, fading, etc.) afin d'acquérir une vision globale. Pour chaque tâche, un ensemble précis de paramètres de canal est défini.
- Boucles internes et externes:
 - Boucle interne (adaptation rapide): On réalise une optimisation rapide sur une tâche précise en modifiant les paramètres du modèle en fonction de cette configuration.
 - Boucle externe (optimisation globale): La mise à jour des paramètres

globaux par l'optimisation externe permet d'optimiser les performances sur toutes les tâches. Les paramètres de l'entraînement Meta-RL sont résumés dans le tableau 3-5. Ces paramètres ont été sélectionnés après quelques tests.

Tableau 3-5 Paramètres d'entraînement pour le Meta-RL

Paramètre	Valeur
Taille de méta-batch	8 (nombre de tâches utilisées simultanément)
Nombre d'itérations	1,000

La mise en place du Meta-RL dans le domaine de la généralisation constitue une avancée significative dans ce projet. Elle assure la résistance et la performance du système de communication basé sur l'autoencodeur dans divers environnements, ce qui rend cette approche particulièrement adaptée aux exigences des systèmes de communication modernes et complexes. La capacité de généralisation sera examinée de manière approfondie dans les résultats du prochain chapitre.

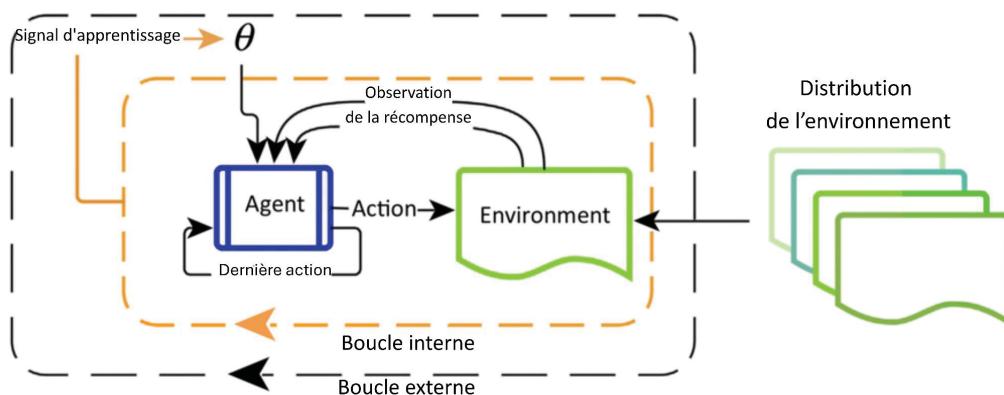


Figure 3.4 Illustration de la Meta-RL [6].

3.5.4 Résumé de paramètres

Grâce à cette méthodologie, des algorithmes de modulation, de simulation de canal et d'apprentissage profond sont intégrés, ce qui permet de créer un système solide et flexible pour les communications sans fil. Tous les paramètres du système sont récapitulés dans le tableau 3-6.

Tableau 3-6 Résumé des paramètres

Paramètre	Valeur
Plage de SNR (Eb/N0)	0 dB à 5.0 dB (pas de 0.5)
Bits par symbole	6 (64-QAM)
Longueur du code LDPC (n)	1500 bits
Taux de codage LDPC (coderate)	0.5
Batch size (entraînement)	32
Itérations d'entraînement	10,000 (conventionnel)
Itérations RL (alterné)	7,000
Itérations RL (fine-tuning)	3,000
Itérations Meta-RL ($N_{\text{Meta-RL}}$)	1,000
Taille du meta-batch	8
Variance de perturbation RL	0.01

L'algorithme *Meta-RL* adopté dans ce projet vise à entraîner un modèle capable de généraliser rapidement à de nouvelles conditions de canal, notamment en s'adaptant à différentes valeurs de SNR. Comme illustré dans l'algorithme 3, l'approche repose sur deux boucles d'optimisation imbriquées. La boucle interne permet au modèle d'effectuer une adaptation rapide à une tâche spécifique en mettant à jour temporairement ses poids à partir d'un sous-ensemble de données. Cette adaptation est réalisée en calculant la perte spécifique à la tâche à l'aide de la fonction `loss_fn()` et les gradients locaux avec la méthode `tape.gradient()` de *TensorFlow*. Ensuite, la boucle externe agrège les gradients issus de plusieurs tâches (environnements de canal simulés via différentes valeurs de SNR) et met à jour les paramètres globaux du modèle à l'aide de la fonction

`optimizer.apply_gradients()`. Le processus est répété pour un nombre d’itérations défini par `N_meta_rl`, une variable utilisée pour contrôler le nombre de méta-étapes.

Algorithm 3 Entraînement basé sur le Meta-RL

Initialiser le modèle d’apprentissage meta

Définir les étapes d’adaptation de la boucle interne et l’optimisation de la boucle externe

3: **for** $i = 1$ à $N_{\text{Meta-RL}}$ **do**

 Échantillonner un lot de tâches (valeurs SNR)

for chaque tâche **do**

 6: **for** étapes de la boucle interne **do**

 Calculer la perte spécifique à la tâche (récepteur et émetteur)

 Calculer les gradients spécifiques à la tâche

 9: Adapter les paramètres du modèle à l’aide des gradients

 Agréger les gradients à travers les tâches

 Mettre à jour les paramètres globaux du modèle avec les gradients agrégés

 12: **if** $i \bmod 100 == 0$ **then**

 Enregistrer la perte méta actuelle pour le suivi

3.6 Généralisation de domaine avec le Meta-RL

Pour ce projet, nous avons examiné le concept de généralisation de domaine en utilisant l’approche de Meta-RL. L’objectif de l’extension de domaine est de créer des modèles qui peuvent maintenir des performances élevées dans des environnements ou des conditions inconnues lors de l’entraînement. Dans les systèmes de communication sans fil, cette caractéristique revêt une importance capitale, car les canaux peuvent fluctuer de manière imprévisible en raison de phénomènes tels que le fading, le bruit ou les interférences.

3.6.1 Définition de la généralisation de domaine

La généralisation de domaine implique d'entraîner un modèle sur une variété de scénarios (tels que des niveaux de SNR ou des types de canaux) afin qu'il puisse s'adapter à des situations nouvelles sans avoir besoin d'un réentraînement spécifique. Cela diffère des méthodes traditionnelles, où les modèles sont généralement adaptés à des environnements fixes ou connus.

3.6.2 Meta-RL pour la généralisation de domaine

Le Meta-RL facilite l'adaptation rapide du système aux fluctuations du canal en développant une politique d'apprentissage flexible et universelle. Les étapes de l'approche Meta-RL sont les suivantes: entraînement sur des tâches variées, adaptation rapide (boucle interne) et optimisation globale (boucle externe).

3.6.3 Application au canal sans fil

Dans ce projet, il est crucial de généraliser le domaine afin de gérer la diversité des canaux sans fil, comme:

- Fluctuations du SNR: Le modèle doit être adapté à divers niveaux de bruit.
- Types de canaux multiples: Rayleigh et AWGN, simulés avec des caractéristiques dynamiques.
- Configurations imprévues: Des canaux qui ne sont pas observés lors de l'entraînement, avec des perturbations supplémentaires ou des conditions exceptionnelles.

Le Meta-RL permet au modèle d'acquérir les compétences nécessaires pour adapter ses constellations optimisées et ses stratégies de décodage afin de maintenir un taux d'erreur bas, même dans ces périodes complexes.

3.6.4 Avantages de la généralisation avec le Meta-RL

1. Flexibilité accrue: Le système peut s'ajuster de manière dynamique à des environnements inconnus, sans avoir besoin d'une phase d'entraînement onéreuse.
2. Performance robuste: Grâce à sa capacité d'adaptation rapide, une qualité de transmission élevée est assurée, même dans des conditions de canal difficiles.
3. Efficacité computationnelle: Au lieu de développer un modèle spécifique pour chaque scénario, une architecture généralisée est assez évidente.

3.6.5 Limites et défis

Malgré ses bénéfices, la généralisation du domaine avec le Meta-RL pose des difficultés:

1. Complexité computationnelle: En raison de la variété des tâches et des boucles internes, l'entraînement demande des ressources considérables.
2. Diversité des environnements d'entraînement: La représentativité des scénarios simulés par rapport aux conditions réelles est un facteur essentiel de la performance.

3.7 Conclusion

Au cours de ce chapitre, nous avons exposé la approche utilisée pour élaborer un système de communication qui repose sur l'apprentissage de bout en bout en utilisant un autoencodeur mis en place avec le framework Sionna. La modélisation de l'architecture de l'autoencodeur, comprenant l'encodeur, le canal simulé et le décodeur, ainsi que les différentes approches différentiables utilisées pour l'optimisation conjointe de ces composants, a été détaillée. Nous avons également abordé les différentes approches d'entraînement utilisées, allant de l'apprentissage supervisé traditionnel à des méthodes

avancées basées sur le renforcement (RL) et le renforcement méta-généralisé (Meta-RL), en expliquant leurs fonctions respectives dans l'adaptation et la résistance du système.

Finalement, nous avons examiné et intégré les paramètres essentiels du projet, tels que les configurations de canal, les métriques d'évaluation et les hyperparamètres d'entraînement, dans une méthodologie complète. Ces facteurs constituent un fondement solide pour les évaluations des performances exposées dans le prochain chapitre, où les résultats obtenus seront analysés afin de confirmer l'efficacité des méthodes utilisées.

Chapitre 4 - Résultats et analyses

4.1 Introduction

Ce chapitre se focalise sur la présentation des résultats obtenus pendant le projet et leur analyse approfondie. L'objectif de ce chapitre est d'évaluer les résultats des méthodes utilisées pour l'apprentissage complet avec des autoencodeurs. On compare les résultats obtenus à l'aide des configurations de canal simulées, des méthodes d'entraînement utilisées (conventionnelle, RL et Meta-RL) et des métriques d'évaluation essentielles, comme le BER et le BLER.

4.2 Contexte de simulation

Les données exposées dans ce chapitre proviennent des analyses approfondies dans le chapitre précédent. Dans ce chapitre, on a effectué des simulations afin d'évaluer les performances de l'autoencodeur dans différents environnements, tels que des canaux AWGN et Rayleigh, ainsi qu'une plage de E_b/N_0 allant de 0 dB à 5 dB (figure 4.1 et figure 4.2). Le BER et le BLER sont les métriques principales utilisées pour évaluer la précision et la fiabilité des transmissions.

En outre, on a utilisé différentes méthodes d'entraînement (conventionnelle, RL et Meta-RL) avec leurs paramètres spécifiques du chapitre 3, tels que le nombre d'itérations et la taille des méta-batches, afin d'assurer une analyse comparative complète. Les prochaines sections portent sur l'analyse des résultats obtenus, en soulignant les atouts et les limites des méthodes utilisées.

Les simulations ont été réalisées selon les paramètres définis dans le tableau 3-6 présenté au chapitre 3. Pour l'entraînement conventionnel et l'apprentissage RL, un *batch* de taille 32 est utilisé. Dans le cas du Meta-RL, un *meta-batch* de taille 8 est appliqué,

correspondant à plusieurs tâches simulées simultanément. La plage des rapports signal à bruit (E_b/N_0) est échantillonnée de manière aléatoire à chaque itération, ce qui permet d'entraîner et d'évaluer les modèles sous diverses conditions de canal.

Les bits d'information sont générés dynamiquement à chaque appel du modèle à l'aide d'une source binaire, garantissant la diversité des données en entrée. Ainsi, la quantité de données n'est pas fixe ni identique entre les différentes valeurs de E_b/N_0 . Les données utilisées pour l'apprentissage ne sont pas réutilisées pour le calcul du BER et du BLER, ce qui permet une évaluation sur des trames non vues par le modèle.

De plus, pour chaque valeur de E_b/N_0 , plusieurs réalisations sont effectuées : cela correspond à la simulation de différentes trames aléatoires, permettant d'estimer les métriques de performance (BER/BLER) de manière fiable et statistiquement robuste.

4.3 Analyse des performances selon le BER

Cette section analyse les performances des méthodes proposées en termes de BER, d'abord dans un canal AWGN, puis dans un canal Rayleigh.

4.3.1 BER dans un canal AWGN

Dans cette partie, nous analysons les performances des méthodes d'entraînement d'un autoencodeur selon le BER, une métrique qui mesure la proportion de bits erronés et évalue la qualité du lien dans un canal AWGN. Les résultats sont présentés en fonction du rapport signal sur bruit E_b/N_0 à la figure 4.1, pour quatre approches: baseline, entraînement conventionnel, apprentissage par renforcement (RL) et Meta-apprentissage par renforcement (Meta-RL).

Dans ce scénario de simulation, chaque méthode a été évaluée sur une plage de valeurs

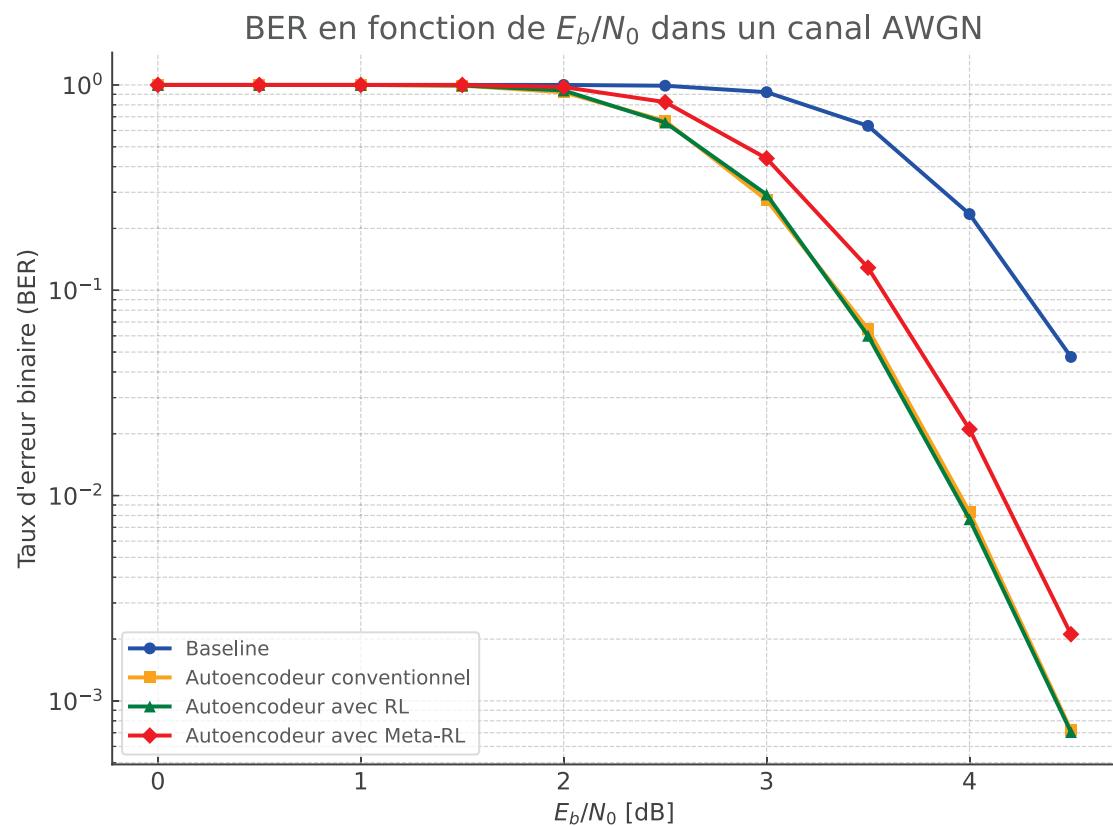


Figure 4.1 Comparaison des performances de BER des algorithmes dans un canal AWGN.

de E_b/N_0 , avec un critère d’arrêt fondé sur l’atteinte d’un nombre prédéfini d’erreurs de blocs (par exemple, 1000 erreurs de blocs). Pour la méthode conventionnelle, le nombre total de bits simulés atteint jusqu’à 96 millions à $E_b/N_0 = 4.5$ dB, répartis sur 128 000 blocs (chacun correspondant à 750 bits). Dans le cas de la méthode RL et meta-RL, un volume de transmission similaire a été utilisé.

La figure 4.1 illustre les performances de différentes approches d’autoencodeurs dans un canal AWGN. La courbe bleue, représentant la méthode *baseline*, montre une dégradation marquée avec un BER relativement élevé, même lorsque le rapport E_b/N_0 dépasse les 3 dB. Cela souligne les limites des techniques classiques dépourvues d’apprentissage. En revanche, l’autoencodeur conventionnel, représenté en orange, dépasse la *baseline* dès 2 dB, traduisant une capacité de généralisation accrue face au bruit. L’approche utilisant l’apprentissage par renforcement (RL), en vert, colle avec celle du conventionnel, atteignant un BER inférieur à 10^{-2} à partir de 4 dB. Cela démontre que l’apprentissage conventionnel de bout en bout est la méthode de référence idéale dont il faut se rapprocher. Enfin, bien que l’autoencodeur basé sur le méta-apprentissage par renforcement (Meta-RL), en rouge, commence avec un BER plus élevé, il converge rapidement vers des performances compétitives, même s’il n’atteint pas tout à fait le niveau du modèle RL.

4.3.2 BER dans un canal Rayleigh

Dans cette partie, nous examinons les résultats des autoencodeurs dans un environnement où un canal Rayleigh Fading est présent. À la différence du canal AWGN, le canal Rayleigh présente des fluctuations rapides de gain en amplitude causées par le multi-trajet, ce qui rend la communication plus complexe. Les trois méthodes d’entraînement ont été comparées pour démontrer leur capacité à s’adapter à

ces conditions difficiles.

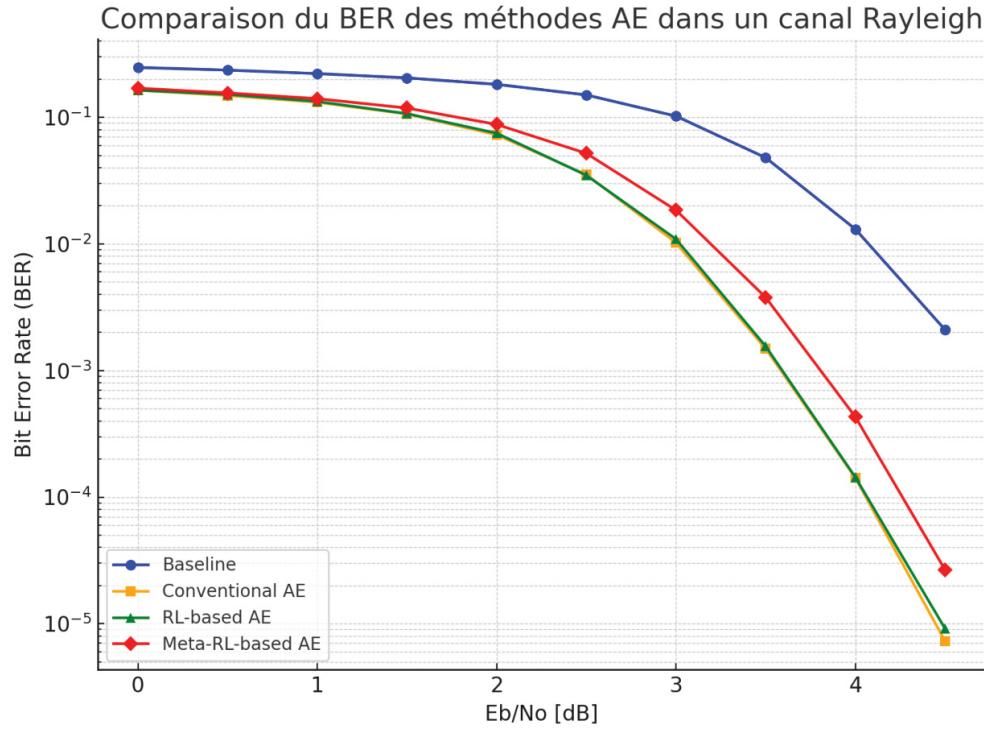


Figure 4.2 Comparaison des performances du BER des algorithmes dans un canal du Rayleigh.

Les résultats illustrés dans la figure 4.2 montrent l'évolution du BER pour différentes méthodes d'entraînement sous un canal Rayleigh Fading. On observe clairement que la méthode baseline, qui repose sur une constellation statique, présente les performances les plus faibles avec un BER élevé sur toute la plage de E_b/N_0 .

L'entraînement conventionnel par autoencodeur permet une amélioration significative, en particulier lorsque E_b/N_0 dépasse 2 dB, grâce à l'optimisation conjointe des modules d'encodage et de décodage. L'approche basée sur le RL est très proche de celle de l'entraînement conventionnel, voire confondue dans la majorité des scénarios, en particulier à faible et moyen E_b/N_0 , grâce à son adaptabilité aux variations du canal. Elle

offre un bon compromis entre performance et robustesse. Quant au Meta-RL, bien qu'il ait été conçu pour améliorer la généralisation à travers des tâches variées, ses bénéfices ne sont pas clairement visibles dans ce contexte. En effet, les scénarios testés (canaux AWGN et Rayleigh) ne représentent pas de véritables changements de domaine. Les performances du Meta-RL restent proches, voire légèrement inférieures à celles du RL dans certaines plages de SNR. Cela suggère que son plein potentiel n'a pas pu être exploité ici.

Ces observations montrent que, dans des environnements à évanouissement rapide mais sans changement de domaine marqué, la méthode conventionnelle reste la méthode la plus efficace parmi les approches et dans les scénarios testés.

4.4 Analyse des performances selon le BLER

Cette section examine les performances des différentes méthodes d'entraînement en termes de BLER, dans les canaux AWGN et Rayleigh, afin d'évaluer leur fiabilité sur des unités de transmission plus longues.

4.4.1 BLER dans un canal AWGN

Cette section présente une comparaison des performances de différentes méthodes d'entraînement appliquées à un autoencodeur, évaluées en fonction du BLER dans un canal AWGN. Chaque bloc de données est constitué de 750 bits, soit une taille correspondant à la taille typique d'un mot de code utilisé dans un système de communication. Ces blocs sont ensuite encodés, modulés, transmis à travers un canal AWGN, puis démodulés et décodés au récepteur afin d'évaluer les erreurs de transmission. L'objectif est de mesurer l'impact des stratégies d'apprentissage sur la qualité de transmission en termes de BLER en fonction du rapport E_b/N_0 .

La figure 4.3 illustre les résultats obtenus pour quatre approches : la méthode

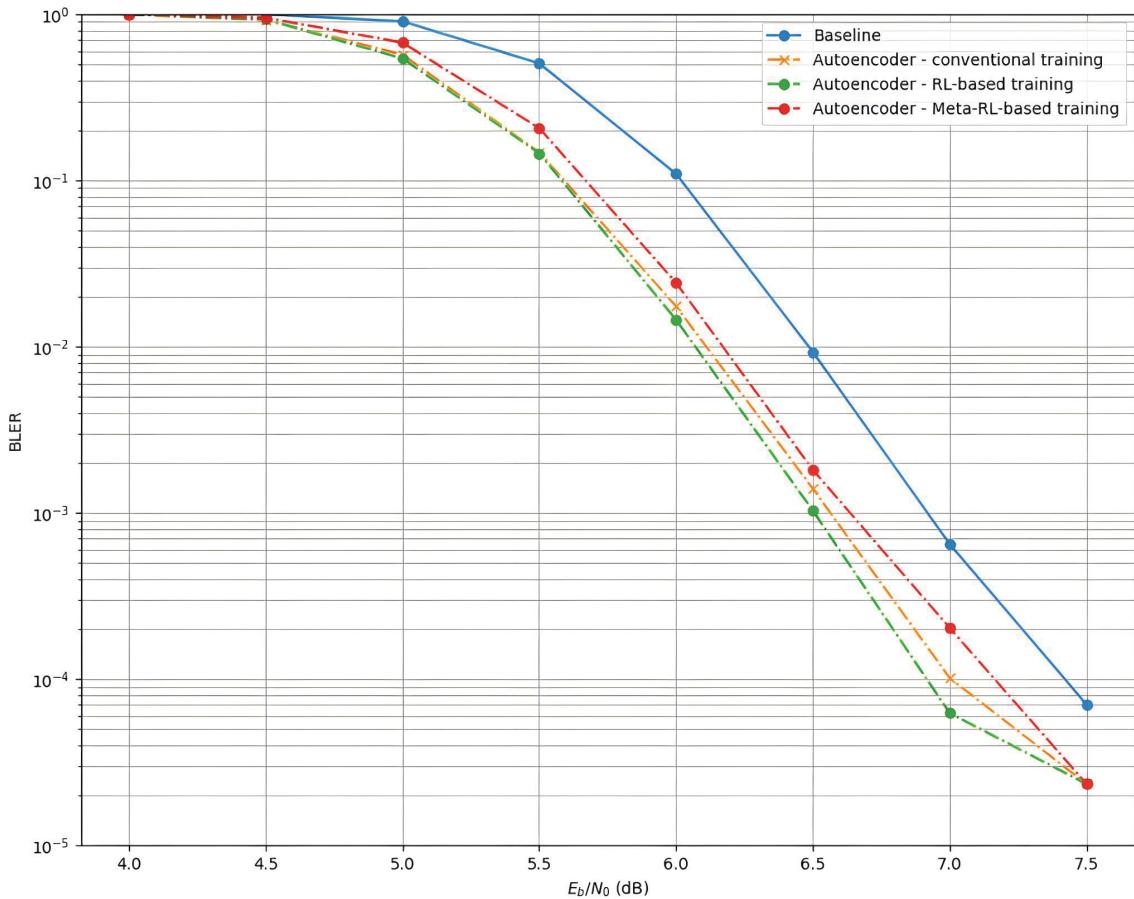


Figure 4.3 Comparaison des performances des algorithmes dans un canal AWGN.

Baseline, l’entraînement conventionnel, l’apprentissage par renforcement (RL), et le métá-apprentissage par renforcement (Meta-RL).

4.4.1.1 *Les performances de l’entraînement conventionnel*

L’entraînement conventionnel est basé sur une méthode supervisée où les paramètres de l’autoencodeur sont ajustés afin de réduire au minimum une fonction de perte globale, comme le MSE ou le BER. Dans cette approche, l’encodeur et le décodeur sont entraînés en même temps sans prendre en considération explicitement les conditions dynamiques du canal.

L’autoencodeur présente de bonnes performances dans un environnement AWGN. Dans l’intervalle de E_b/N_0 simulé (entre 4 dB et 8 dB), les taux d’erreur sont relativement faibles, ce qui indique que le modèle parvient efficacement à reconstituer les données transmises malgré la présence de bruit gaussien. Cette bonne performance s’explique par la simplicité du canal AWGN, où le seul facteur de perturbation est le bruit additif, sans interférence due au multi-trajet. Comme illustré dans la figure 4.3 (courbe orange), le BLER diminue progressivement avec l’augmentation de E_b/N_0 , ce qui reflète une bonne capacité de généralisation du modèle dans un environnement relativement simple et stable.

4.4.1.2 Performances de l’entraînement basé sur le RL

L’apprentissage basé sur le renforcement propose une méthode adaptative pour améliorer l’autoencodeur, ce qui permet d’améliorer sa résistance face aux fluctuations dynamiques du canal de communication. À la différence de l’entraînement conventionnel, qui optimise les paramètres du modèle de manière globale pour un environnement donné, le RL permet d’adapter les paramètres de l’encodeur et du décodeur en fonction des conditions instantanées du canal, telles que le rapport signal-bruit ou les effets du fading.

La figure 4.3 montre que les performances du RL surpassent quelque peu celles de l’entraînement conventionnel dans la plage $5.5 \text{ dB} \leq E_b/N_0 \leq 7.0 \text{ dB}$. Cette proximité valide l’efficacité du RL à approcher les performances d’une méthode idéale. À un BLER de 10^{-4} , on observe un léger gain de 0.1 dB.

Cependant, il est essentiel de rappeler que l’entraînement conventionnel de bout en bout repose sur une hypothèse irréaliste : la disponibilité du gradient du canal au niveau du transmetteur. Cette contrainte limite son applicabilité dans les systèmes réels. Le RL a justement été introduit pour pallier cette limitation, en optimisant les paramètres sans

nécessiter la différentiabilité du canal. Ainsi, le RL apparaît comme une alternative réaliste et performante dans un cas pratique, atteignant des résultats comparables à ceux de la méthode théorique idéale. Le tableau 4-1 souligne les avantages de l’entraînement basé sur le RL.

Tableau 4-1 Avantages de l’entraînement basé sur le RL

Aspect	Avantage de l’entraînement basé sur le RL
Adaptabilité dynamique	Le modèle peut ajuster ses paramètres en fonction des variations du canal, offrant des performances robustes dans des conditions bruitées.
Réduction des erreurs	Grâce à l’optimisation guidée par la fonction de récompense, le RL parvient à réduire considérablement le BLER, même dans des environnements à faible E_b/N_0 .
Surpasser la baseline	Le RL montre une supériorité systématique par rapport à la baseline, qui utilise des constellations QAM fixes et manque d’adaptabilité.

4.4.1.3 Performances de l’entraînement Meta-RL

Grâce à sa capacité à combiner adaptation rapide et généralisation, l’entraînement basé sur le Meta-RL constitue une approche prometteuse pour les systèmes de communication sans fil. Notamment dans des contextes où les conditions de canal peuvent varier de manière imprévisible. Contrairement aux méthodes classiques et au RL, le Meta-RL permet au modèle d’apprendre à partir d’un ensemble de tâches diversifiées, facilitant ainsi une adaptation rapide à de nouveaux environnements de canal.

Dans les scénarios expérimentaux étudiés, le Meta-RL démontre des performances comparables, voire légèrement inférieures, à celles du RL et de l’entraînement conventionnel. À 10^{-4} dB, par exemple, le BLER est à seulement 0.15 dB de plus que le conventionnel, illustrant l’efficacité de son mécanisme d’apprentissage multitâche. Le Meta-RL parvient à maintenir son BLER par rapport au RL, ce qui confirme sa capacité à

optimiser conjointement l'encodeur et le décodeur dans des environnements bruités.

Cependant, il est important de noter que le principal objectif du Meta-RL est de gérer des situations de *changement de domaine* — c'est-à-dire des changements significatifs entre les distributions des canaux d'entraînement et de test. Or, dans ce travail, les scénarios de test se limitent aux canaux AWGN et Rayleigh Fading (section 4.4.3), qui ne constituent pas de véritables changements de domaine. Par conséquent, bien que les performances du Meta-RL soient encourageantes, le mérite principal de cette méthode — sa capacité à généraliser à des environnements fondamentalement nouveaux — ne peut pas être pleinement démontré avec ce canal AWGN.

Ce constat ne remet pas en question la validité de l'approche, mais souligne l'importance d'étendre l'évaluation future à des contextes plus variés, tels que des canaux non stationnaires, des interférences dynamiques ou des scénarios de mobilité rapide. Une telle extension permettrait de mieux mettre en lumière la valeur ajoutée du Meta-RL face à des défis réels de généralisation.

4.4.1.4 Comparaison du Meta-RL avec le RL classique

L'approche basée sur le Meta-RL a été comparée directement à celle fondée sur le RL classique dans un canal AWGN, afin d'évaluer ses bénéfices potentiels. Comme le montre la figure 4.3, les performances obtenues avec le RL classique sont légèrement supérieures à celles de l'apprentissage conventionnel de bout en bout, ce qui démontre son efficacité dans un environnement stable, sans hypothèse irréaliste sur la rétropropagation des gradients à l'émetteur.

En revanche, le Meta-RL, bien que théoriquement plus flexible et conçu pour s'adapter rapidement à des changements de domaine (domain shift), n'a pas surpassé le RL classique

dans ce scénario. Cela s'explique par le fait que le canal AWGN utilisé ici ne constitue pas un changement de domaine suffisamment fort pour mettre en valeur la capacité de généralisation du Meta-RL. Les tâches générées à l'entraînement (variation modérée du SNR dans un canal fixe) ne produisent pas de décalage important entre entraînement et test, ce qui limite l'intérêt de la stratégie d'adaptation méta. Des travaux futurs sont à réaliser pour en faire la démonstration plus poussée.

4.4.1.5 *Interprétation*

Les performances des différentes approches peuvent être évaluées dans un environnement relativement simple, le canal AWGN, qui se distingue par un bruit gaussien additif sans fading. Dans cette situation, les approches basées sur l'apprentissage sont clairement meilleures que la baseline, en raison de leur manque d'adaptabilité et de l'utilisation de constellations fixes. Les performances du RL et du Meta-RL révèlent leur aptitude à optimiser efficacement les constellations et les décodeurs, même dans des conditions de canal bruitées, tout en offrant une plus grande robustesse dans les environnements à faible SNR.

4.4.2 *BLER dans un canal Rayleigh*

Dans ce scénario, la simulation pour chaque méthode transmet entre 768 000 bits (cas de faibles E_b/N_0) et jusqu'à plus de 384 millions de bits pour atteindre le seuil de précision exigé à hauts rapports E_b/N_0 . Le nombre total de blocs transmis varie de 1024 à 512 000, ce qui correspond à un volume important de données permettant une estimation fiable des métriques.

La figure 4.4 illustre l'évolution du BLER en fonction du rapport signal sur bruit E_b/N_0 , dans un canal de Rayleigh, pour quatre configurations différentes: un système

de référence (baseline), un autoencodeur entraîné classiquement, un entraînement par renforcement (RL), et un entraînement basé sur le Meta-RL. Le modèle de référence

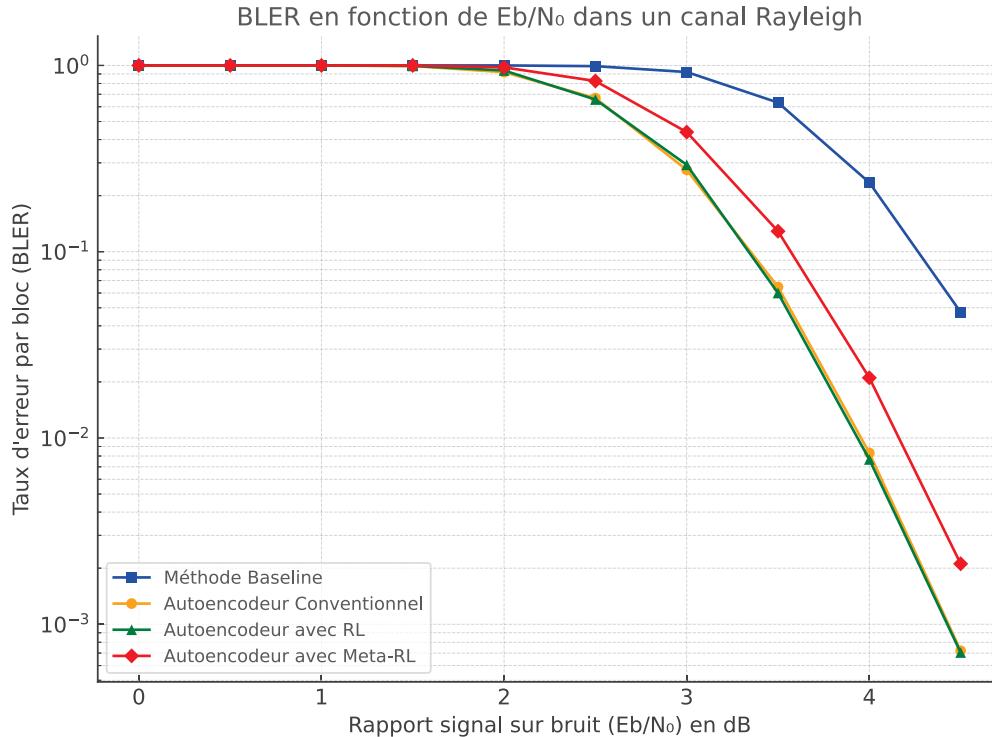


Figure 4.4 Comparaison des performances du BLER des algorithmes dans un canal du Rayleigh.

(baseline) affiche les performances les plus faibles, comme attendu, avec un taux d'erreur élevé même à des niveaux de E_b/N_0 relativement élevés. L'autoencodeur entraîné de manière conventionnelle atteint de très bonnes performances, avec un BLER de 10^{-2} à environ 3.9 dB, mais cette méthode repose sur une hypothèse irréaliste : l'accès au gradient à l'émetteur. Le RL, en revanche, parvient à des résultats similaires à cette référence tout en étant applicable dans des conditions réelles, grâce à l'estimation du retour via une fonction de récompense. Le Meta-RL, quant à lui, n'apporte pas d'amélioration notable dans ce scénario, et montre même une légère dégradation par rapport au RL classique. Cela s'explique par l'absence de changement de domaine significatif dans l'environnement

simulé : le canal Rayleigh reste relativement stable et prévisible. Or, le Meta-RL est spécialement conçu pour gérer des changements brusques de conditions (domaines) entre les phases d’entraînement et de test. Par conséquent, son avantage n’est pas pleinement révélé ici, et son potentiel devra être exploré dans des scénarios plus dynamiques et variés.

4.5 Analyse des constellations apprises dans un canal AWGN

Les constellations analysées dans cette section sont obtenues à partir de l’entraînement de différents modèles d’autoencodeurs. L’entraînement des autoencodeurs dans un canal AWGN permet d’améliorer les constellations utilisées pour la modulation et la transmission des données. À la différence des constellations fixes, comme celles employées dans les modulations classiques (64-QAM), les constellations apprises (learned constellations) sont ajustées en fonction des conditions du canal et de l’objectif d’optimisation défini par la fonction de perte. Dans la méthode conventionnelle, l’autoencodeur est optimisé via une fonction de perte supervisée, et la constellation est figée après convergence. En RL, le modèle apprend une politique qui maximise une récompense liée au taux d’erreur. Avec Meta-RL, l’autoencodeur est entraîné sur une distribution de conditions de canal. Les résultats obtenus pour les constellations apprises sont analysés dans cette section, en soulignant leurs caractéristiques et leurs performances par rapport à une constellation traditionnelle fixe.

4.5.1 Constellation issue de l’entraînement conventionnel

La représentation graphique dans la figure 4.5 illustre une constellation produite par un autoencodeur entraîné de manière traditionnelle dans un canal AWGN. Les symboles modulés sont placés dans un environnement complexe déterminé par leurs composantes réelles et imaginaires. On peut faire les observations suivantes:

- Répartition régulière des points: La distribution des points de la constellation est assez homogène dans l'espace complexe. Toutefois, il est possible d'observer certaines densités locales, ce qui suggère une optimisation restreinte.
- Impact de l'entraînement: La distance minimale entre les symboles n'est pas toujours optimale, ce qui peut entraîner une augmentation des erreurs de démodulation en cas de bruit élevé.
- Label binaire des symboles: Tous les points sont liés à une séquence binaire qui représente les informations transmises. Ces labels sont répartis de façon homogène, mais leur structure demeure proche de celle des constellations traditionnelles.

4.5.2 Avantages des constellations apprises

L'apprentissage des constellations, comme le montre la figure 4.5, présente des avantages importants par rapport aux constellations fixes (baseline). En premier lieu, elles offrent la possibilité d'optimiser adaptativement, où les positions des points dans l'espace complexe sont adaptées en fonction des conditions particulières du canal (AWGN) et de la fonction de perte utilisée pendant l'entraînement. Cette capacité d'adaptation optimise la transmission tout en diminuant les erreurs. Elles garantissent ensuite une plus grande résistance au bruit en augmentant les distances minimales entre les points, ce qui renforce la résistance aux perturbations du canal. Enfin, les constellations acquises sont élaborées pour être adaptées aux tâches particulières, contrairement aux constellations classiques qui sont adaptées à des scénarios génériques. Grâce à cette personnalisation, les performances globales sont améliorées, ce qui permet une modulation et une démodulation plus efficaces pour des applications spécifiques.

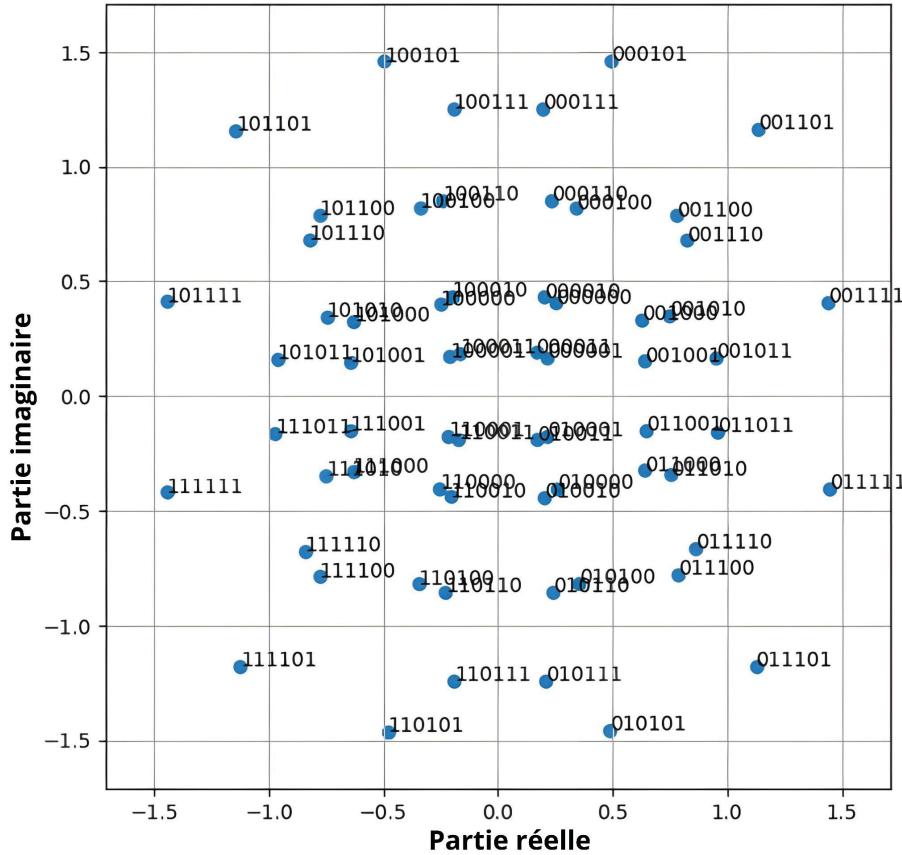


Figure 4.5 Constellation pour l'algorithme conventionnel.

4.5.3 Limitations

Toutefois, la méthode traditionnelle comporte certaines contraintes dans l'amélioration des constellations. En premier lieu, elle dépend étroitement de la fonction de perte, car la qualité des constellations acquises est directement liée à la formulation de cette fonction pendant l'entraînement. Une définition erronée de la fonction de perte peut conduire à des performances inférieures, ce qui restreint l'efficacité du système. Par la suite, l'acquisition des constellations peut être difficile et demander une période d'entraînement prolongée afin d'atteindre des performances optimales, notamment dans des situations où les conditions du canal sont plus variables. Ces contraintes mettent en évidence

l'importance de créer des fonctions de perte solides et d'explorer des techniques avancées afin de stimuler le processus d'entraînement dans les travaux futurs.

4.5.4 Constellation issue de l'entraînement basé sur RL

La figure 4.6 montre une constellation acquise dans un canal AWGN grâce à l'entraînement basé sur RL. À la différence de la méthode traditionnelle, cette méthode présente des constellations plus optimisées, mettant en évidence plusieurs caractéristiques différentes.

Les constellations acquises grâce à l'apprentissage basé sur le RL possèdent diverses caractéristiques qui les rendent particulièrement résistantes et adaptées aux environnements bruités. En premier lieu, une optimisation de la répartition des points dans l'espace complexe permet d'accroître la distance minimale entre les symboles. Cet espacement diminue grandement les risques d'erreurs de démodulation, ce qui améliore la résistance au bruit dans un canal AWGN. Par la suite, le RL offre une adaptabilité dynamique qui diffère nettement de la méthode conventionnelle où les positions des points sont déterminées exclusivement par la fonction de perte. Grâce à cette capacité d'ajustement, les constellations RL s'adaptent constamment aux variations particulières du canal, assurant ainsi une distribution plus efficace des points, même dans des environnements très bruités. Enfin, la structure cohérente et logique des labels organisés des points facilite leur démodulation et leur interprétation, ce qui aide à diminuer les erreurs et à améliorer les performances globales.

4.5.5 Comparaison du RL avec la méthode conventionnelle

En comparaison avec la méthode traditionnelle, l'entraînement basé sur le RL présente des améliorations significatives dans divers aspects essentiels. En premier lieu, en ce qui

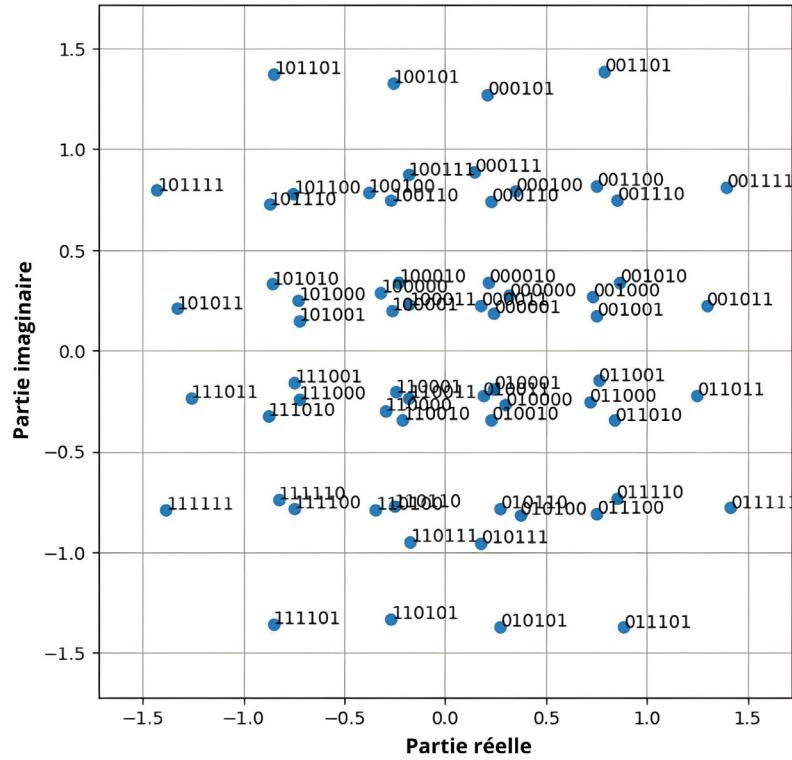


Figure 4.6 Constellation pour l'algorithme RL.

concerne la distance entre les points, les points des constellations créées par la méthode conventionnelle sont plus concentrés, ce qui les rend plus exposés au bruit et accroît le risque d'erreurs de démodulation pour elles. D'autre part, l'approche RL optimise les distances entre les symboles, ce qui diminue considérablement le taux d'erreurs. Deuxièmement, en ce qui concerne la résistance au bruit, les constellations RL sont plus appropriées pour faire face aux perturbations engendrées par le canal AWGN. Plus précisément, avec une faible E_b/N_0 , elles offrent une diminution significative du BLER par rapport à la méthode traditionnelle.

Finalement, l'utilisation de la récompense pour optimiser l'entraînement RL présente un avantage supplémentaire. À la différence de la méthode traditionnelle, qui se restreint

à une dépendance stricte à la fonction de perte, le RL intègre une fonction de récompense qui oriente les ajustements des constellations, ce qui permet d'obtenir des performances globales plus élevées.

4.5.6 Caractéristiques des constellations Meta-RL

Dans le canal AWGN, la constellation apprise par le Meta-RL (figure 4.7) présente une répartition régulière et espacée des symboles dans l'espace complexe, favorisant la réduction des erreurs de démodulation.

Toutefois, en la comparant à celle obtenue avec l'algorithme RL (figure 4.6), on observe une structure très similaire. Cette ressemblance, également reflétée dans les résultats de BLER, montre que dans les scénarios testés (AWGN et Rayleigh), le Meta-RL n'exploite pas pleinement son potentiel.

Conçu pour s'adapter à des tâches variées, le Meta-RL ne montre pas ici d'avantage marqué, car les canaux testés n'induisent pas de véritables changements de domaine. Des scénarios plus complexes seraient nécessaires pour évaluer pleinement sa capacité de généralisation.

4.5.7 Comparaison des méthodes en terme de constellation

1. Distance inter-points :

- *Conventionnel* : Les constellations fixes présentent des regroupements plus serrés, augmentant le risque d'erreurs de démodulation en présence de bruit.
- *RL* : permet une meilleure séparation des symboles, contribuant à une réduction du BLER, surtout dans des environnements modérés.
- *Meta-RL* : Les distances entre symboles sont également bien optimisées, mais restent très proches de celles obtenues par le RL dans les scénarios testés.

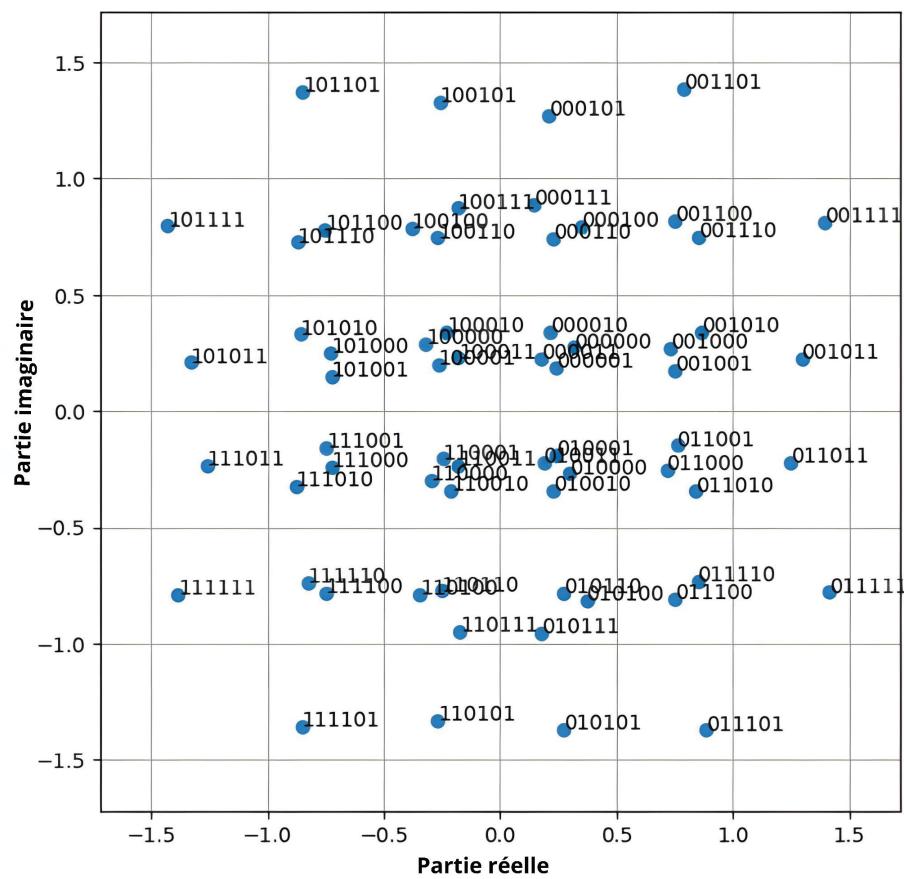


Figure 4.7 Constellation pour l'algorithme Meta-RL.

2. Robustesse au bruit :

- *Conventionnel* : Les performances se dégradent rapidement lorsque le rapport E_b/N_0 est faible.
- *RL* : Montre une bonne robustesse dans des environnements bruités grâce à son adaptabilité.
- *Meta-RL* : Comparable au RL dans les conditions testées ; son avantage potentiel reste limité dans l'absence de changement marqué de domaine.

3. Capacité de généralisation :

- *Conventionnel* : Optimisé pour un canal spécifique, sans capacité d'adaptation.
- *RL* : S'adapte progressivement, mais reste sensible aux variations imprévues du canal.
- *Meta-RL* : Conçu pour gérer des variations de domaine, mais ses bénéfices ne se manifestent pas clairement dans les scénarios actuels (AWGN et Rayleigh). Il offre toutefois une structure prometteuse pour des contextes plus complexes.

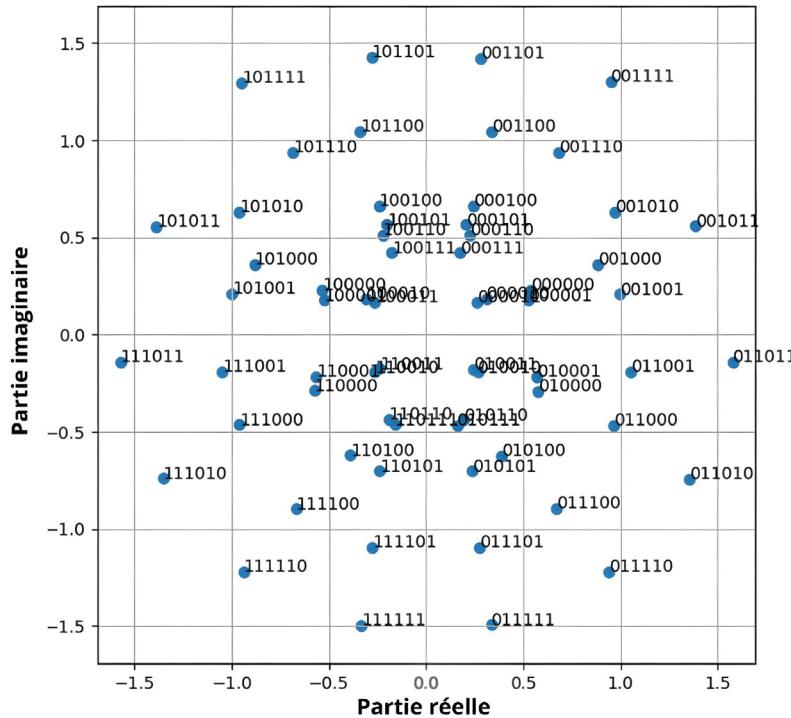
Dans l'ensemble, le Meta-RL se distingue par son architecture orientée vers la généralisation rapide. Néanmoins, dans les conditions testées ici, ses performances restent comparables à celles du RL. Son potentiel devrait être réévalué dans des environnements présentant des variations plus marquées du canal, où sa capacité d'adaptation multitâche pourrait se révéler pleinement avantageuse.

4.6 Analyse des constellations apprises dans un canal Rayleigh

Dans cette section, nous étudions les constellations optimisées par différentes approches d'apprentissage automatique dans un canal Rayleigh, qui se caractérise par une variabilité rapide de l'amplitude et de la phase du signal en raison de l'évanouissement multi-trajets.

4.6.1 Constellation issue de l'entraînement conventionnel

La figure 4.8 montre une répartition des symboles dans le plan complexe sans structure géométrique claire. Les points sont dispersés de manière relativement désorganisée, ce



qui reflète une limitation dans la capacité de l'entraînement conventionnel à s'adapter aux conditions dynamiques du canal Rayleigh. Cette distribution irrégulière peut entraîner une forte confusion entre symboles proches, augmentant ainsi le taux d'erreur binaire.

4.6.2 Constellation optimisée par apprentissage par renforcement (RL)

Comme le montre la figure 4.9, l'apprentissage par renforcement permet une meilleure dispersion des symboles par rapport à la méthode conventionnelle. On observe une tentative d'espacement plus stratégique des points, ce qui réduit les chevauchements

et améliore la robustesse face aux effets du fading. Néanmoins, la structure reste partiellement désorganisée, suggérant que le modèle RL peut encore être affecté par une généralisation imparfaite.

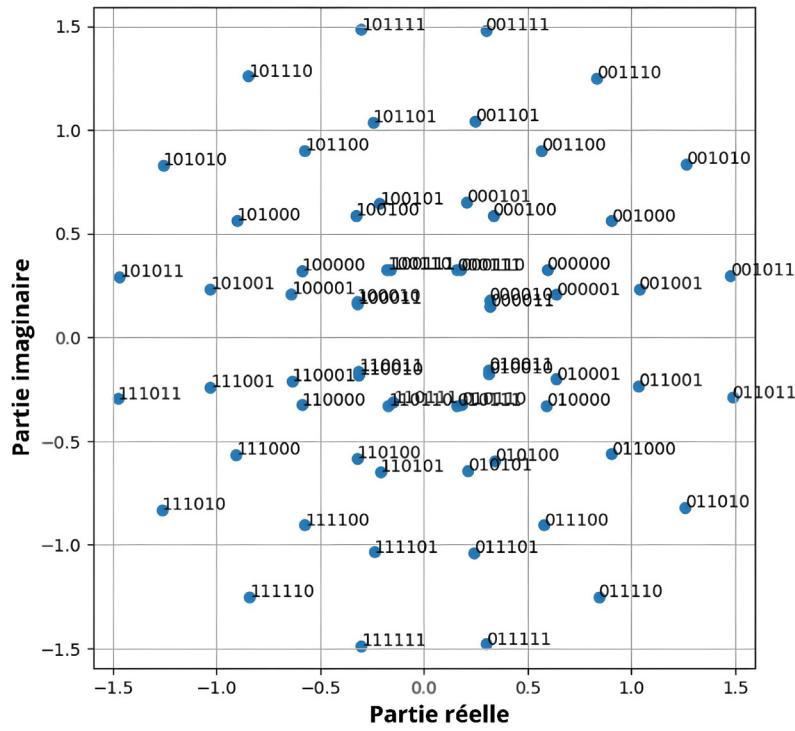


Figure 4.9 Constellation optimisée par RL dans un canal Rayleigh

4.6.3 Constellation optimisée par apprentissage par renforcement Meta-RL

La figure 4.10 présente une constellation beaucoup plus régulière et symétrique, résultant de l'approche Meta-RL. Les symboles sont répartis de manière homogène avec des distances inter-symboles bien définies. Cette structure permet non seulement de minimiser les erreurs de démodulation, mais elle indique également une meilleure capacité du modèle à s'adapter rapidement à différentes réalisations du canal Rayleigh. L'approche Meta-RL démontre ici son efficacité supérieure en termes de robustesse et de généralisation.

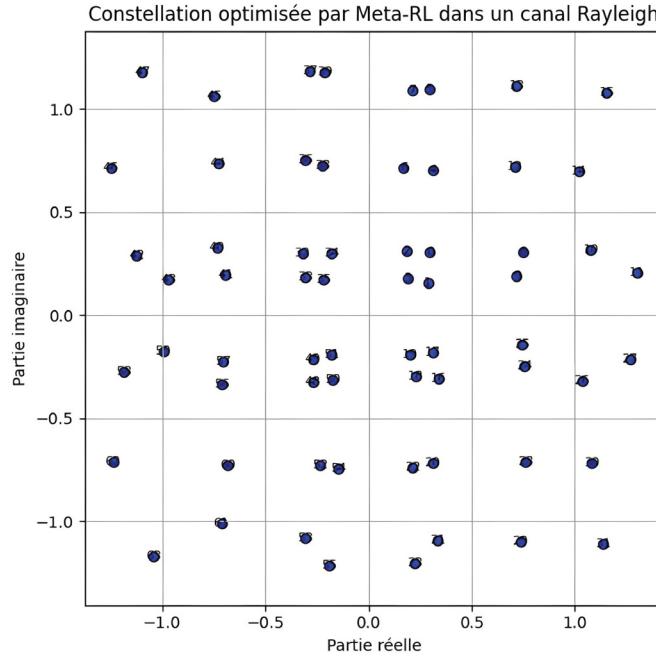


Figure 4.10 Constellation optimisée par Meta-RL dans un canal Rayleigh

4.7 Conclusion

Dans ce chapitre, nous avons examiné les résultats des autoencodeurs dans divers environnements de canal, tels que AWGN et Rayleigh Fading, en comparant différentes méthodes d’entraînement telles que la méthode conventionnelle, la méthode RL et la méthode Meta-RL.

La méthode traditionnelle d’entraînement demeure un standard de référence en termes de performance, même si elle est difficilement applicable pratiquement du fait de l’impossibilité d’accéder au gradient à l’émetteur. Le RL représente une option concrète qui lui ressemble beaucoup, particulièrement dans des contextes où le bruit est présent. Le Meta-RL, élaboré pour gérer les variations de domaine, n’a pas montré d’avantage notable dans les situations évaluées (AWGN et Rayleigh). Il convient donc d’explorer son potentiel dans des contextes plus complexes.

Finalement, les résultats de simulation montrent que le canal Rayleigh offre de meilleures performances que le canal AWGN pour l'ensemble des méthodes testées, y compris la baseline. Cette observation, bien que contre-intuitive, peut s'expliquer par plusieurs facteurs. Tout d'abord, l'hypothèse d'une connaissance parfaite du canal (perfect CSI) permet une égalisation efficace, atténuant ainsi les effets négatifs du fading. Ensuite, le canal Rayleigh introduit une forme de diversité (spatiale ou temporelle), notamment en configuration MIMO, ce qui peut renforcer la robustesse de la transmission par rapport à un canal AWGN dépourvu de diversité. De plus, la nature aléatoire du fading dans Rayleigh expose les méthodes d'apprentissage à une plus grande variabilité des conditions de canal, ce qui favorise une meilleure capacité de généralisation. Enfin, il est également possible que des différences dans la normalisation du bruit ou dans la conversion entre E_b/N_0 et la puissance du bruit aient contribué à cette tendance, conduisant à un SNR effectif légèrement plus favorable dans le cas du canal Rayleigh.

Chapitre 5 - Conclusion

Le défi majeur dans le domaine des télécommunications modernes est de concevoir des systèmes de communication sans fil performants et solides dans des environnements complexes. Ce mémoire a porté sur l'étude des méthodes d'apprentissage profond, telles que l'utilisation d'autoencodeurs pour l'entraînement complet, afin de faire face à ces défis dans différents canaux de communication tels que AWGN et Rayleigh. En adoptant une approche méthodique et rigoureuse et en analysant attentivement les performances, plusieurs contributions significatives ont été soulignées.

Tout d'abord, une introduction aux systèmes de communication sans fil et à leurs difficultés a été exposée, puis une analyse approfondie de la littérature. Dans cette étude, il a été souligné l'évolution des méthodes classiques, comme les constellations fixes et les algorithmes d'égalisation classiques, ainsi que leurs limites face aux lieux complexes. Par la suite, on a examiné l'intégration des techniques d'intelligence artificielle, notamment l'apprentissage de bout en bout, comme une solution prometteuse. Dans cette étude, l'emploi d'autoencodeurs entraînés a été essentiel pour optimiser l'encodeur et le décodeur de manière à maximiser l'efficacité du système. Les constellations acquises lors de ces entraînements ont démontré une adaptation dynamique aux caractéristiques particulières du canal, ce qui a permis d'obtenir des avantages considérables par rapport aux méthodes classiques. Les résultats obtenus dans ce mémoire soulignent les différences de performances entre les méthodes conventionnelles, le RL (Reinforcement Learning) et le Meta-RL (Meta-Reinforcement Learning) dans des environnements de communication complexes.

Les performances pourraient encore être améliorées à l'avenir en incorporant des modèles plus complexes, comme les réseaux génératifs ou les approches basées sur les

transformers. En outre, l'analyse de ces méthodes dans des environnements concrets avec des configurations matérielles spécifiques, telles que les plateformes SDR, offre une perspective prometteuse pour approfondir cette étude.

Références

- [1] Y. S. Cho, J. Kim, W. Y. Yang, and C. G. Kang, *MIMO-OFDM wireless communications with MATLAB*. John Wiley & Sons, 2010.
- [2] D. P. Kingma and J. Ba, “Adam: A method for stochastic optimization,” *International Conference on Learning Representations (ICLR)*, 2015. [Online]. Available: <https://arxiv.org/abs/1412.6980>
- [3] Wikipédia, “Auto-encodeur — wikipédia, l’encyclopédie libre,” 2025, [En ligne; Page disponible le 11-mars-2025]. [Online]. Available: \url{http://fr.wikipedia.org/w/index.php?title=Auto-encodeur&oldid=223787784}
- [4] T. J. O’Shea and J. Hoydis, “An introduction to deep learning for the physical layer,” *IEEE Transactions on Cognitive Communications and Networking*, vol. 3, no. 4, pp. 563–575, 2017.
- [5] R. S. Sutton and A. G. Barto, *Reinforcement Learning: An Introduction*, 2nd ed. Cambridge, MA: MIT Press, 2018.
- [6] L. Weng, “Meta reinforcement learning,” *lilianweng.github.io*, 2019. [Online]. Available: <https://lilianweng.github.io/posts/2019-06-23-meta-rl/>
- [7] D. Tse and P. Viswanath, *Fundamentals of wireless communication*. Cambridge university press, 2005.
- [8] A. Goldsmith, *Wireless Communications*. Cambridge University Press, 2005.
- [9] T. L. Marzetta, “Noncooperative cellular wireless with unlimited numbers of base station antennas,” *IEEE transactions on wireless communications*, vol. 9, no. 11, pp. 3590–3600, 2010.
- [10] J. G. Andrews, S. Buzzi, W. Choi, S. V. Hanly, A. Lozano, A. C. Soong, and J. C. Zhang, “What will 5g be?” *IEEE Journal on selected areas in communications*, vol. 32, no. 6, pp. 1065–1082, 2014.
- [11] E. Björnson, L. Sanguinetti, H. Wymeersch, J. Hoydis, and T. L. Marzetta, “Massive mimo is a reality—what is next ?: Five promising research directions for antenna arrays,” *Digital Signal Processing*, vol. 94, pp. 3–20, 2019.
- [12] J. Hoydis, S. Cammerer, F. A. Aoudia, A. Vem, N. Binder, G. Marcus, and A. Keller, “Sionna: An open-source library for next-generation physical layer research,” *arXiv preprint arXiv:2203.11854*, 2022.
- [13] P. Kairouz, H. B. McMahan, B. Avent, A. Bellet, M. Bennis, A. N. Bhagoji, K. Bonawitz, Z. Charles, G. Cormode, R. Cummings *et al.*, “Advances and open problems in federated learning,” *Foundations and trends® in machine learning*, vol. 14, no. 1–2, pp. 1–210, 2021.
- [14] A. A. Huurdeman, *The Worldwide History of Telecommunications*. Hoboken, NJ: Wiley-Interscience, 2003.
- [15] T. S. Rappaport, *Wireless Communications: Principles and Practice*, 2nd ed. Upper Saddle River, NJ: Prentice Hall, 2002.

- [16] A. Osseiran, F. Boccardi, V. Braun, K. Kusume, P. Marsch, M. Maternia, O. Queseth, M. Schellmann, H. Schotten, H. Taoka, H. Tullberg, M. Uusitalo, B. Timus, and M. Fallgren, “Scenarios for 5g mobile and wireless communications: The vision of the metis project,” *Communications Magazine, IEEE*, vol. 52, pp. 26–35, 05 2014.
- [17] “Modulations numériques,” <https://eduscol.education.fr/sti/sites/eduscol.education.fr.sti/files/ressources/pedagogiques/15945/15945-chap2-modulations-numeriques.pdf>, 2017, ministère de l’Éducation nationale, France.
- [18] J. G. Proakis and M. Salehi, *Digital communications*. McGraw-hill, 2008.
- [19] S. Haykin, *Communication systems*. John Wiley & Sons, 2008.
- [20] B. Sklar, *Digital communications: fundamentals and applications*. Pearson, 2021.
- [21] T. S. Rappaport, *Wireless communications: principles and practice*. Cambridge University Press, 2024.
- [22] G. J. Foschini and M. J. Gans, “On limits of wireless communications in a fading environment when using multiple antennas,” *Wireless personal communications*, vol. 6, pp. 311–335, 1998.
- [23] L. Zheng and D. N. C. Tse, “Diversity and multiplexing: A fundamental tradeoff in multiple-antenna channels,” *IEEE Transactions on information theory*, vol. 49, no. 5, pp. 1073–1096, 2003.
- [24] R. W. Heath and A. J. Paulraj, “Switching between diversity and multiplexing in mimo systems,” *IEEE transactions on Communications*, vol. 53, no. 6, pp. 962–968, 2005.
- [25] Z. Wang and G. B. Giannakis, “Wireless multicarrier communications,” *IEEE signal processing magazine*, vol. 17, no. 3, pp. 29–48, 2000.
- [26] L. Hanzo, Y. Akhtman, L. Wang, and M. Jiang, *MIMO-OFDM for LTE, WiFi and WiMAX: Coherent versus non-coherent and cooperative turbo transceivers*. John Wiley & Sons, 2010, vol. 9.
- [27] H. Bolcskei, “Mimo-ofdm wireless systems: basics, perspectives, and challenges,” *IEEE wireless communications*, vol. 13, no. 4, pp. 31–37, 2006.
- [28] S. Cammerer, F. A. Aoudia, J. Hoydis, A. Oeldemann, A. Roessler, T. Mayer, and A. Keller, “A neural receiver for 5g nr multi-user mimo,” in *2023 IEEE Globecom Workshops (GC Wkshps)*. IEEE, 2023, pp. 329–334.
- [29] M. Goutay, F. A. Aoudia, J. Hoydis, and J.-M. Gorce, “Machine learning-enhanced receive processing for mu-mimo ofdm systems,” in *2021 IEEE 22nd International Workshop on Signal Processing Advances in Wireless Communications (SPAWC)*. IEEE, 2021, pp. 246–250.
- [30] L. Litwin and M. Pugel, “The principles of ofdm,” *RF signal processing*, vol. 2, pp. 30–48, 2001.
- [31] R. Kudo, S. M. Armour, J. P. McGeehan, and M. Mizoguchi, “A channel state information feedback method for massive mimo-ofdm,” *Journal of Communications and Networks*, vol. 15, no. 4, pp. 352–361, 2013.

- [32] S. McKiernan, “Foundational techniques for wireless communications: Channel coding, modulation, and equalization,” 2023. [Online]. Available: <https://arxiv.org/abs/2310.13209>
- [33] R. F. Masood, “Adaptive modulation (qpsk, qam),” 2013. [Online]. Available: <https://arxiv.org/abs/1302.7145>
- [34] A. F. Molisch, *Wireless communications*. John Wiley & Sons, 2012, vol. 34.
- [35] S. R. Saunders and A. A. Aragón-Zavala, *Antennas and propagation for wireless communication systems*. John Wiley & Sons, 2024.
- [36] J. D. Parsons, *The Mobile Radio Propagation Channel*, 2nd ed. Wiley, 2000.
- [37] X. Moorkattil, “Wireless fading,” *SSRN*, 2023. [Online]. Available: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4545457
- [38] GeeksforGeeks. (2023) Fading in wireless communication. [Online]. Available: <https://www.geeksforgeeks.org/fading-in-wireless-communication/>
- [39] S. J. of Wireless Personal Communications, “Fluctuating fading distributions,” *Wireless Personal Communications*, vol. 122, pp. 1–12, 2024. [Online]. Available: <https://link.springer.com/article/10.1007/s11277-024-11557-7>
- [40] A. S. Ahmed, M. M. Hamdi, M. S. Aboot, A. M. Khaleel, M. Fathy, and S. H. Khaleefah, “Channel estimation using ls and mmse channel estimation techniques for mimo-ofdm systems,” in *2022 international congress on human-computer interaction, optimization and robotic applications (HORA)*. IEEE, 2022, pp. 1–6.
- [41] B. Le Saux, “Estimation de canal pour systemes multi-antennes multi-porteuses,” Ph.D. dissertation, INSA de Rennes, 2007.
- [42] J. A. Zhang, H. Zhang, K. Wu, X. Huang, J. Yuan, and Y. J. Guo, “Wireless communications in doubly selective channels with domain adaptivity,” *arXiv preprint arXiv:2407.21514*, 2024.
- [43] X. Lu, D. Xu, and M. Guizani, “Reinforcement learning for wireless network resource management: Recent advances and open issues,” *IEEE Communications Magazine*, vol. 57, no. 7, pp. 94–100, 2019.
- [44] U. Challita, W. Saad, and C. Bettstetter, “Machine learning for wireless connectivity and security in autonomous vehicular systems,” *IEEE Transactions on Wireless Communications*, vol. 18, no. 2, pp. 2443–2456, 2019.
- [45] F. Liang, H. Ye, and G. Y. Li, “Towards intelligent vehicular networks: A machine learning framework,” *IEEE Internet of Things Journal*, vol. 6, no. 1, pp. 124–135, 2019.
- [46] T. Luo, S. Wang, and T. Wo, “Deep reinforcement learning for resource allocation in 5g radio access networks,” *IEEE Wireless Communications*, vol. 27, no. 5, pp. 32–39, 2020.
- [47] H. Sun, X. Chen, Q. Shi, M. Hong, X. Fu, and N. D. Sidiropoulos, “Learning to optimize: Training deep neural networks for wireless resource management,” *IEEE Transactions on Signal Processing*, vol. 66, no. 20, pp. 5438–5453, 2018.

- [48] H. Ye, G. Y. Li, and B. H. Juang, “Deep reinforcement learning based resource allocation for v2v communications,” *IEEE Transactions on Vehicular Technology*, vol. 69, no. 10, pp. 11 049–11 061, 2020.
- [49] Y. Wei, W. Ye, S. Sleder, and Z.-L. Zhang, “Towards a meta-learning assisted universal neural receiver: An empirical study,” in *2024 3rd International Conference on 6G Networking (6GNet)*, 2024, pp. 241–248.
- [50] J. Zhu, B. Liu, and H. Yao, “Transferable multi-task reinforcement learning for efficient wireless communication,” *IEEE Transactions on Wireless Communications*, vol. 19, no. 6, pp. 4065–4078, 2020.
- [51] J. Zhao, J. Xu, and Y. Song, “Meta-learning for mimo-ofdm systems: Fast adaptation and generalization,” *IEEE Transactions on Communications*, vol. 70, no. 1, pp. 123–136, 2022.
- [52] S. Dörner, S. Cammerer, J. Hoydis, and S. ten Brink, “Deep learning based communication over the air,” *IEEE Journal of Selected Topics in Signal Processing*, vol. 12, no. 1, pp. 132–143, 2018.
- [53] F. A. Aoudia and J. Hoydis, “Model-free training of end-to-end communication systems,” *IEEE Journal on Selected Areas in Communications*, vol. 37, no. 11, pp. 2503–2516, 2019.
- [54] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016, <http://www.deeplearningbook.org>.