

الجمهورية الجزائرية الديمقراطية الشعبية
REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
وزارة التعليم العالي و البحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
جامعة أبي بكر بلقايد – تلمسان –
Université Aboubakr Belkaïd – Tlemcen –
Faculté de TECHNOLOGIE



MEMOIRE

Présenté pour l'obtention du **diplôme** de **MASTER**

En : Télécommunications

Spécialité : Réseaux et Télécommunications

Par : KORT CHARIF Chaimaa Mansouria

Sujet :

Classification intelligente des modulations radio par Deep Learning

Soutenu publiquement, le 21/06/2026, devant le jury composé de :

Mme OTMANI Amina
Mme BENLALDJ Lamia
M HADJILA Mourad

MCB
MCB
PR

Université de Tlemcen
Université de Tlemcen
Université de Tlemcen

Président
Examineur
Encadrant

Année universitaire : 2025/2026

Remerciements

Avant tout, je rends grâce à Allah, le Tout-Puissant et le Miséricordieux, qui m'a accordé la santé, la force, la patience et la persévérance nécessaires pour mener à bien ce travail. Sans Sa volonté et Son soutien, l'aboutissement de ce mémoire n'aurait pas été possible.

*Je tiens à exprimer ma profonde gratitude à mon encadrant, Monsieur **HADJILA Mourad**, pour la confiance qu'il m'a accordée, sa disponibilité, ses précieux conseils ainsi que son accompagnement tout au long de cette étude. Ses orientations, sa rigueur scientifique et ses remarques constructives ont été d'une aide précieuse dans la réalisation de ce mémoire.*

J'adresse également mes sincères remerciements à l'ensemble des enseignants et du personnel administratif de l'Université de Tlemcen, qui ont contribué à ma formation et à l'acquisition des connaissances nécessaires à l'accomplissement de ce parcours universitaire.

Je souhaite exprimer ma profonde reconnaissance à ma famille pour son soutien inconditionnel, sa patience, ses encouragements constants et sa confiance en moi. Leur présence et leurs sacrifices ont constitué une source permanente de motivation et de détermination.

Mes remerciements s'adressent également aux membres du jury qui ont accepté d'examiner et d'évaluer ce travail. Je leur suis reconnaissante pour l'intérêt qu'ils lui portent ainsi que pour les remarques et suggestions qu'ils apporteront.

Enfin, j'adresse mes remerciements à toutes les personnes qui, de près ou de loin, ont contribué à la réalisation de ce mémoire et m'ont soutenue tout au long de cette expérience.

À toutes et à tous, j'exprime ma sincère gratitude et mon profond respect.

Dédicace

Bien plus qu'un simple accomplissement académique, ce mémoire représente l'aboutissement d'un parcours riche en défis, en efforts et en persévérance. Entre moments de doute, longues heures de travail et apprentissages enrichissants, chaque étape a contribué à ma formation tant sur le plan académique que personnel. Je dédie ce travail, avec une profonde gratitude et une sincère reconnaissance, à toutes les personnes qui m'ont soutenue, encouragée et accompagnée tout au long de ce cheminement.

À ma chère maman,

Lumière de ma vie et cœur battant de notre foyer. Ton amour inconditionnel, ta patience infinie et tes prières silencieuses ont été mes plus beaux refuges dans les moments d'incertitude. Tu es mon modèle de force et de générosité. Ce travail est le fruit de tes sacrifices et de ton éducation, je te le dédie avec tout l'amour que tu m'as transmis.

À mon cher père,

Pour ton calme olympien, ta sagesse et cette confiance inébranlable que tu as toujours placée en moi. Tu m'as transmis des valeurs de rigueur, d'honnêteté et de responsabilité qui me guident chaque jour. Merci pour ton soutien constant et ta présence aussi discrète que précieuse.

À mon frère,

Merci pour ta présence et ton soutien tout au long de mon parcours. Ton affection et tes encouragements ont toujours été une source de motivation pour moi. Je te souhaite beaucoup de bonheur et de réussite dans ta vie.

À mes sœurs,

Merci pour votre écoute attentive, votre regard bienveillant et votre incroyable capacité à me remobiliser dans les moments de doute. Votre sensibilité, vos attentions et votre affection fraternelle ont été le plus beau des remparts et sont restées essentielles à mon équilibre tout au long de cette aventure.

À l'ensemble de mes professeurs,

Qui ont marqué mon parcours par leur passion, leur rigueur et leur bienveillance. Merci pour le savoir transmis, les échanges inspirants et ces moments formateurs qui resteront gravés en moi.

Chaimaa Mansouria KORT CHARIF

Résumé

Face à la complexité croissante des environnements de communication et aux limites des approches classiques en conditions de faible rapport signal sur bruit, ce mémoire propose une solution de classification intelligente des modulations radio basée sur le Deep Learning. Après une étude approfondie des fondements des communications radio numériques couvrant les techniques de modulation analogiques (AM, FM, PM) et numériques (ASK, FSK, PSK, QAM, OFDM) ainsi que les contraintes du canal de transmission (bruit, fading, SNR), le travail explore les architectures de réseaux de neurones profonds (CNN, RNN, LSTM) et leur capacité à extraire automatiquement des caractéristiques discriminantes à partir de signaux bruts. Le modèle hybride proposé, CNNWithSNR, combine des couches convolutionnelles Conv1D pour l'analyse temporelle du signal et l'intégration explicite du SNR comme information contextuelle. Évalué sur le dataset RadioML2016.10a (11 types de modulations, SNR de -20 dB à $+18$ dB), il atteint des performances élevées mesurées par l'accuracy, le F1-score et les courbes ROC/AUC, tout en affichant une robustesse notable en conditions dégradées. Ce travail démontre que le Deep Learning constitue une approche fiable et compétitive pour la Reconnaissance Automatique des Modulations (AMC), avec des perspectives de déploiement sur systèmes embarqués en temps réel.

Mots-clés : Deep Learning, CNN, Conv1D, AMC, modulations radio, SNR, RadioML2016.10a, réseaux de neurones, communications numériques, radio cognitive.

Abstract

Faced with the increasing complexity of modern communication environments and the limitations of conventional approaches under low signal-to-noise ratio (SNR) conditions, this thesis proposes an intelligent radio modulation classification approach based on Deep Learning. After a comprehensive study of digital radio communication fundamentals, including analog modulation techniques (AM, FM, PM), digital modulation schemes (ASK, FSK, PSK, QAM, OFDM), and transmission channel impairments such as noise, fading, and SNR degradation, this work investigates deep neural network architectures, namely CNNs, RNNs, and LSTMs, and their ability to automatically extract discriminative features from raw signal data.

The proposed hybrid model CNNWithSNR combines one-dimensional convolutional layers (Conv1D) for temporal signal feature extraction with the explicit incorporation of SNR as contextual information. The model was evaluated using the RadioML2016.10a dataset, which includes 11 modulation types and SNR values ranging from -20 dB to $+18$ dB. Experimental results demonstrate high classification performance in terms of accuracy, F1-score, and ROC/AUC metrics, while maintaining notable robustness under challenging noise conditions.

The findings confirm that Deep Learning constitutes a reliable and competitive solution for Automatic Modulation Classification (AMC), offering promising prospects for deployment in real-time embedded communication systems.

Keywords: Deep Learning, CNN, Conv1D, AMC, radio modulations, SNR, RadioML2016.10a, neural networks, digital communications, cognitive radio.

ملخص

في مواجهة التعقيد المتزايد لبيئات الاتصالات ومحدودية الأساليب الكلاسيكية في ظروف انخفاض نسبة الإشارة إلى الضوضاء، يقترح هذا المذكرة حلاً ذكياً لتصنيف أنماط التضمين الراديوي مبنياً على التعلم العميق. بعد دراسة معمّقة لأسس الاتصالات الراديوية الرقمية — تشمل تقنيات التضمين التماثلية AM ، FM ، PM ، والرقمية ASK ، FSK ، PSK ، QAM ، OFDM فضلاً عن قيود قناة الإرسال (ضوضاء، تلاش، — SNR) يستكشف العمل معماريات الشبكات العصبية العميقة (CNN) ، RNN ، LSTM وقدرتها على استخراج الميزات التمييزية تلقائياً من الإشارات الخام. يجمع النموذج المقترح CNNWithSNR بين قدرات طبقات الالتفاف أحادية البعد (Conv1D) في استخراج السمات الزمنية للإشارة وإدراج قيمة SNR كمتغير سياقي إضافي، مما يساهم في تحسين أداء التعرف على أنماط التضمين في مختلف ظروف الضوضاء. وقد تم تقييمه على قاعدة البيانات المرجعية RadioML2016.10a المتضمنة 11 نمطاً من أنماط التضمين عبر مستويات SNR من -20 dB إلى +18 dB ، محققاً أداءً مرتفعاً مقاساً بمعايير Accuracy و F1-score ومنحنيات ROC/AUC، مع متانة ملحوظة في الأحوال المتدهورة. يُثبت هذا العمل أن التعلم العميق يمثل مقارنة موثوقة وتنافسية للتصنيف التلقائي لأنماط التضمين (AMC) ، مع آفاق للنشر على أنظمة مضمّنة في الزمن الحقيقي.

الكلمات المفتاحية: التعلم العميق، CNN ، Conv1D ، AMC ، أنماط التضمين الراديوي، SNR ، RadioML2016.10a ، الشبكات العصبية، الاتصالات الرقمية، الراديو الإدراكي.

Table des matières

<i>Remerciements</i>	II
<i>Dédicace</i>	III
Résumé	IV
Abstract	V
ملخص	VI
Liste des figures	XII
Liste des tableaux	XIII
Liste des abréviations	XIV
Liste des symboles	XV
INTRODUCTION GENERALE	1
CHAPITRE 1	3
GENERALITES SUR LES COMMUNICATIONS RADIO ET LA CLASSIFICATION DES MODULATIONS	3
1.1 Introduction	4
1.2 Communications radio numériques	4
1.2.1 Principes fondamentaux des communications radio	5
1.2.1.1 Onde électromagnétique et propagation	5
1.2.1.2 La Modulation (Le Transport du Message)	5
1.2.1.3 Le Spectre Radioélectrique (Le Partage des Ressources)	5
1.2.1.4 Le Rapport Signal sur Bruit (SNR)	6
1.2.2 Chaîne de transmission et de réception	7
1.2.3 Notions de bande passante	7
1.2.4 Bruit et canal de propagation	8
1.2.4.1 Bruit	8
1.2.4.2 Canal de propagation	9
1.3 Modulations radio analogiques et numériques	9
1.3.1 Modulation analogique	10
1.3.1.1 Modulation AM	10
1.3.1.2 Modulation FM	12
1.3.1.3 Modulation de phase (PM ou ΦM)	14
1.3.2 Modulation numérique	16
1.3.2.1 Amplitude Shift Keying (ASK)	16
1.3.2.2 La Modulation par Déplacement de Fréquence (FSK)	17
1.3.2.3 Description du processus de modulation FSK	18
1.4 Reconnaissance automatique des modulations	18

1.4.1	Définition de l'automatic modulation classification	19
1.4.2	Domaines d'application.....	19
1.4.2.1	Communications militaires et surveillance des fréquences.....	19
1.4.2.2	Radio cognitive	19
1.4.2.3	Administration et supervision du spectre radioélectrique	19
1.4.2.4	Systèmes de communication contemporains	19
1.4.2.5	Guerre électronique et renseignement par les ondes électromagnétiques	19
1.4.3	Enjeux et contraintes.....	20
1.4.3.1	Conditions du canal radio	20
1.4.3.2	Diversité des modulations.....	20
1.4.3.3	Besoin de grandes bases de données.....	20
1.4.3.4	Complexité computationnelle	20
1.4.3.5	Compromis performance / complexité.....	20
1.5	Méthodes classiques de classification des modulations.....	21
1.5.1	Approches basées sur des caractéristiques statistiques et spectrales.....	21
1.5.1.1	Approches basées sur des caractéristiques statistiques	21
1.5.1.2	Approches basées sur des caractéristiques spectrales	21
1.5.2	Limites en environnement bruité	22
1.6	Conclusion.....	22
CHAPITRE 2.....		24
INTELLIGENCE ARTIFICIELLE, MACHINE LEARNING ET DEEP LEARNI		24
2.1	Introduction	25
2.1.1	Contexte et motivation de l'Intelligence Artificielle	25
2.1.1.1	Capacités visées	25
2.1.1.2	Facteurs déclencheurs	25
2.1.2	Évolution des approches en IA	26
2.1.2.1	IA Symbolique (Systèmes Experts)	26
2.1.2.2	IA Connexionniste (Apprentissage Statistique)	26
2.1.3	Positionnement du Machine Learning et du Deep Learning.....	26
2.2	Intelligence Artificielle : concepts et fondements	27
2.2.1	Définition de l'IA	27
2.2.1.1	Sur le plan Conceptuel (L'Objectif)	27
2.2.1.2	Sur le plan Technique (Le Mécanisme)	27
2.2.1.3	Sur le plan Pratique (L'Utilité)	27
2.2.2	Les éléments principaux d'un système IA	27
2.2.2.1	Données et Modèles d'apprentissage.....	27
2.2.2.2	Algorithmes	28

2.2.2.3	Capteurs et Entrées.....	28
2.2.2.4	Unités de traitement (CPU, GPU, TPU)	28
2.2.2.5	Mémoire	28
2.2.2.6	Interface Utilisateur (IU).....	28
2.2.2.7	Mécanismes de prise de décision	28
2.2.2.8	Environnement d'exécution (Cloud vs Local)	28
2.2.3	Approches classiques (symbolique, systèmes experts)	29
2.2.3.1	L'IA Symbolique et l'Hypothèse des Symboles Physiques	29
2.2.3.2	Les Systèmes Experts : Architecture et Ingénierie des Connaissances.....	29
2.2.4	Domaines d'application de l'IA	29
2.2.4.1	Télécommunications et Traitement du Signal.....	29
2.2.4.2	Santé et Médecine de Précision.....	29
2.2.4.3	Finance et Fintech	30
2.2.4.4	Industrie 4.0 et Robotique.....	30
2.2.5	Analyse Critique et Limites des Systèmes d'IA	30
2.2.5.1	Les Limites de l'IA Traditionnelle (Symbolique).....	31
2.2.5.2	Les Limites de l'IA Moderne	31
2.3	Machine Learning	31
2.3.1	Définition et principes du Machine Learning	32
2.3.1.1	Principe	32
2.3.1.2	Objectif.....	32
2.3.2	Types d'apprentissage.....	32
2.3.2.1	Apprentissage Supervisé	32
2.3.2.2	Apprentissage non supervisé.....	34
2.3.2.3	Apprentissage semi-supervisé	37
2.3.2.4	Apprentissage par renforcement	37
2.3.3	Principaux algorithmes de Machine Learning.....	38
2.3.3.1	Algorithmes de classification	38
2.3.3.2	Naïve Bayes (NB).....	39
2.3.3.3	Régression linéaire, logistique, polynomiale.....	39
2.3.3.4	K-plus proches voisins (KNN).....	40
2.3.3.5	Arbre de décision	40
2.3.3.6	Machines à Vecteurs de Support (SVM)	41
2.3.4	Cycle de développement d'un modèle ML	41
2.3.5	Avantages et limites du Machine Learning	42
2.3.5.1	Avantages.....	42
2.3.5.2	Limites.....	43
2.4	Deep Learning	43

2.4.1	Définition et relation avec le Machine Learning.....	43
2.4.2	Réseaux de neurones artificiels (ANN)	44
2.4.3	Architectures majeures (CNN, RNN, LSTM, Transformers)	44
2.4.3.1	Convolutional Neural Networks (CNN).....	44
2.4.3.2	Les réseaux de neurones récurrents (RNN).....	44
2.4.3.3	LSTM (Long Short-Term Memory).....	45
2.4.3.4	Les Transformers.....	45
2.4.4	Entraînement des modèles profonds.....	45
2.4.5	Applications et limites du Deep Learning	46
2.4.5.1	Applications.....	46
2.4.5.2	Limites.....	47
2.5	Comparaison et synthèse IA – ML – DL.....	47
2.5.1	Relation hiérarchique entre IA, ML et DL	47
2.5.2	Comparaison en termes de données, complexité et interprétabilité.....	47
2.5.3	Choix de la méthode selon le contexte applicatif	48
2.6	Enjeux actuels et perspectives.....	48
2.6.1	Éthique et biais algorithmiques.....	48
2.6.2	Explicabilité et robustesse des modèles.....	49
2.6.3	Tendances futures de l'IA.....	49
2.7	Synthèse des concepts clés	49
2.8	Apport du ML et du DL à l'IA moderne.....	50
2.9	Conclusion.....	50
CHAPITRE 3		52
SIMULATION, EVALUATION DES PERFORMANCES ET ETUDE COMPARATIVE DU MODELE AM		52
3.1	Introduction	53
3.2	Description du dataset RadioML 2016.10.a.....	53
3.2.1	Structure du Signal.....	55
3.2.2	Utilisations principales	56
3.3	Les métriques d'évaluations	56
3.3.1	Accuracy (Exactitude).....	57
3.3.2	Précision et Rappel	57
3.3.2.1	Précision.....	57
3.3.2.2	Rappel	57
3.3.3	F1-score	57
3.3.4	ROC et AUC (Receiver Operating Characteristic & Area Under Curve).....	57
3.3.4.1	ROC.....	58

3.3.4.2	AUC	58
3.3.5	Matrice de confusion	58
3.4	Architecture du modèle de classification des types de modulation.....	58
3.5	Résultats et discussions	59
3.6	Etude comparative	68
3.7	Conclusion.....	69
CONCLUSION GENERALE		70
REFERENCES BIBLIOGRAPHIQUES		71

Liste des figures

Figure 1.1: Représentation du spectre radio électrique [8].	5
Figure 1.2: Taux d'erreur sur les symboles en fonction du rapport signal sur bruit [10].	7
Figure 1.3: Chaîne de transmission de l'information [11].	7
Figure 1.4: Classification des types de modulation.	10
Figure 1.5: Représentation visuelle de la modulation AM [16].	11
Figure 1.6: Représentation visuelle de la modulation FM [18].	13
Figure 1.7: Représentation visuelle de la modulation de phase (PM) [35].	16
Figure 1.8: Visualisation de la modulation ASK.	17
Figure 1.9: Représentation visuelle de la modulation BFSK [36].	18
Figure 2.1 : Apprentissage supervisé	33
Figure 2.2 : Apprentissage non supervisé	35
Figure 2.3 : Cycle de développement d'un modèle d'apprentissage automatique.	42
Figure 2.4 : Représentation du processus itératif d'entraînement des réseaux de neurones profonds.	46
Figure 3.1 : Visualisation des composantes I/Q des modulations RadioML2016.10a à un SNR de 2 dB	55
Figure 3.2 : Architecture du modèle CNNWithSNR	59
Figure 3.3 : Évolution de l'accuracy d'entraînement et de validation du modèle au cours des époques.	59
Figure 3.4 : Évolution de la fonction de perte (Loss) durant l'entraînement et la validation du modèle	60
Figure 3.5 : Rapport de classification	61
Figure 3.6 : Matrice de confusion du modèle CNNWithSNR pour tous les niveaux de SNR (All SNR).	62
Figure 3.7 : Matrice de confusion du modèle de classification pour un SNR de -12 dB.	63
Figure 3.8 : Matrice de confusion du modèle de classification pour un SNR de -8 dB.	64
Figure 3.9 : Matrice de confusion du modèle de classification pour un SNR de -4 dB.	64
Figure 3.10 : Matrice de confusion du modèle de classification pour un SNR de 4 dB	65
Figure 3.11 : Matrice de confusion du modèle de classification pour un SNR de 8 dB	65
Figure 3.12 : Matrice de confusion du modèle de classification pour un SNR de 12 dB	66
Figure 3.13 : Évolution des performances de classification en fonction du SNR.	68

Liste des tableaux

Tableau 2.1: Synthèse des sources de référence pour l'étude de l'IA, du ML et du DL.	26
Tableau 3.1 : Évaluation des métriques par SNR	66
Tableau 3.2 : Comparaison des performances du modèle avec celles des modèles AMR	69

Liste des abréviations

AI	Artificial Intelligence
AM	Amplitude Modulation
AMC	Automatic Modulation Classification
ASK	Amplitude Shift Keying
AUC	Area Under Curve
BFSK	Binary Frequency Shift Keying
BPSK	Binary Phase Shift Keying
CNN	Convolutional Neural Network
CPU	Central Processing Unit
DL	Deep Learning
FFT	Fast Fourier Transform
FM	Frequency Modulation
FSK	Frequency Shift Keying
GPU	Graphics Processing Unit
HF	High Frequency
I/Q	In-phase / Quadrature
IoT	Internet of Things
KNN	K-Nearest Neighbors
LSTM	Long Short-Term Memory
ML	Machine Learning
OFDM	Orthogonal Frequency Division Multiplexing
PM	Phase Modulation
PSD	Power Spectral Density
PSK	Phase Shift Keying
QAM	Quadrature Amplitude Modulation
QPSK	Quadrature Phase Shift Keying
RF	Radio Frequency
ROC	Receiver Operating Characteristic
RNN	Recurrent Neural Network
SNR	Signal-to-Noise Ratio
SVM	Support Vector Machine
TPU	Tensor Processing Unit
UHF	Ultra High Frequency
VHF	Very High Frequency

Liste des symboles

SNR / SNR_dB : Rapport Signal sur Bruit (en décibels)
P_signal : Puissance du signal utile
P_bruit : Puissance du bruit
E (t) : Signal électrique émis
s(t) : Signal électrique reçu
f : Fréquence (Hz)
 λ : Longueur d'onde
v : Vitesse de propagation
m : Nombre de symboles (ordre de modulation)
 $\log_2 M$: Nombre de bits par symbole
dB : Décibel
MHz / GHz : Mégahertz / Gigahertz
I / Q : Composante en phase / Composante en quadrature
 Φ M : Modulation de Phase (symbole grec Phi)

INTRODUCTION GENERALE

Dans le contexte des télécommunications modernes, l'évolution rapide des systèmes de communication sans fil ainsi que l'augmentation continue des besoins en services de communication ont entraîné une sollicitation croissante des ressources radio, notamment le spectre et les canaux de transmission. Cette situation a conduit à une complexification des systèmes de communication intelligents et a renforcé la nécessité de développer des méthodes capables d'optimiser l'utilisation du spectre radio disponible.

La classification automatique des modulations (Automatic Modulation Classification – AMC) constitue aujourd'hui une composante essentielle dans les systèmes de communication modernes, en particulier dans les domaines de la radio cognitive et des réseaux intelligents. Son objectif principal est d'identifier automatiquement le type de modulation d'un signal reçu, permettant ainsi une meilleure adaptation des paramètres de transmission et une gestion plus efficace des ressources spectrales.

Traditionnellement, plusieurs méthodes ont été proposées pour la reconnaissance des modulations. Toutefois, bien que ces approches classiques aient démontré leur efficacité dans certains contextes, leurs performances diminuent significativement en présence de bruit, d'interférences et des perturbations du canal de transmission. Ces limitations ont favorisé l'émergence de nouvelles approches plus robustes basées sur l'apprentissage profond (Deep Learning).

Les techniques de Deep Learning offrent des perspectives prometteuses grâce à leur capacité d'extraction automatique des caractéristiques des signaux radio et à leur aptitude à améliorer la précision de classification des modulations, même dans des environnements fortement bruités. Parmi ces approches, les réseaux de neurones convolutifs (Convolutional Neural Networks – CNN) se distinguent par leurs performances élevées dans les tâches de classification et d'analyse des données complexes.

Dans ce contexte, l'objectif principal de ce travail est d'étudier et d'évaluer les performances des modèles de Deep Learning appliqués à la classification automatique des modulations radio en utilisant le dataset RadioML2016.10a. Une étude théorique a été menée, suivie d'une phase expérimentale basée sur l'implémentation d'architectures CNN et l'évaluation des performances à travers différentes métriques de mesure.

Ce mémoire est structuré en trois chapitres. Le premier chapitre présente les fondements des communications radio et des techniques de modulation, en décrivant les principaux schémas de modulation analogiques et numériques. Le deuxième chapitre est consacré aux notions essentielles de l'intelligence artificielle, du Machine Learning et du Deep Learning, ainsi qu'à leur utilisation dans le domaine de la classification automatique des modulations. Le troisième

chapitre détaille le dataset RadioML2016.10a, la méthodologie expérimentale mise en œuvre et les métriques d'évaluation retenues. Il expose également les résultats obtenus et propose une analyse critique ainsi qu'une interprétation de ces derniers.

CHAPITRE 1
GENERALITES SUR LES COMMUNICATIONS RADIO
ET LA CLASSIFICATION DES MODULATIONS

1.1 Introduction

Ce premier chapitre présente les bases théoriques indispensables à la compréhension des systèmes de communication modernes ainsi que des techniques de modulation nécessaires à une transmission efficace des signaux. L'objectif est de fournir un socle technique solide avant d'aborder les problématiques complexes de reconnaissance de formes qui seront traitées plus loin dans ce mémoire.

Le chapitre débute par une présentation des systèmes de communication radio numériques. Nous y explorons l'architecture des chaînes de transmission, leurs composants essentiels ainsi que les différentes classifications basées sur le support, le type de signal et la portée des communications. Un accent particulier est mis sur les défis inhérents au canal de propagation, notamment la gestion de la bande passante et l'impact du bruit [1].

Ensuite, nous approfondissons le concept de modulation en soulignant son rôle essentiel dans l'adaptation des signaux pour une transmission optimale. Les méthodes de modulation analogiques et numériques sont examinées en détail, en présentant leurs principes de fonctionnement ainsi que leurs formulations mathématiques. Des schémas spécifiques, allant des modulations d'amplitude et de fréquence (AM/FM) aux techniques numériques avancées telles que le M-PSK, le M-QAM et le FSK, sont analysés afin d'illustrer la diversité des signaux rencontrés dans le spectre radioélectrique actuel [2].

La troisième partie introduit la problématique de la Reconnaissance Automatique des Modulations (AMC). Nous définissons ce concept, identifions ses principaux domaines d'application — allant de la surveillance civile à la défense — et exposons les contraintes techniques liées à l'identification aveugle des signaux [3].

Enfin, ce chapitre passe en revue les méthodes classiques de classification. En analysant les approches fondées sur les caractéristiques statistiques (moments, cumulants) et spectrales, nous mettons en évidence leurs performances, mais également leurs limites intrinsèques dans des environnements fortement bruités ou non coopératifs. Cette analyse justifie la nécessité d'explorer des solutions plus robustes, qui seront étudiées dans la suite de nos travaux [4].

1.2 Communications radio numériques

Les systèmes de transmission radio numérique sont des dispositifs de diffusion sans fil où les données sont encodées en format numérique (bits 0 et 1) avant d'être diffusées par une onde électromagnétique.

À l'opposé des transmissions analogiques, le signal émis est discontinu.

1.2.1 Principes fondamentaux des communications radio

Les communications radio permettent la transmission d'informations sans fil grâce aux ondes électromagnétiques. Leur compréhension repose sur plusieurs notions fondamentales liées à la propagation des ondes, aux fréquences utilisées et aux mécanismes de transmission des signaux. Ces concepts constituent la base de l'étude des systèmes de communication radio.

1.2.1.1 Onde électromagnétique et propagation

Une onde radio est caractérisée par sa fréquence, sa longueur d'onde, son amplitude et sa phase. La relation essentielle entre la vitesse, la fréquence et la longueur d'onde est :

$$v = f \times \lambda \quad (1.1)$$

Dans le vide, la vitesse correspond à celle de la lumière [5] :

$$c \approx 3 \times 10^8 \text{ m/s} \quad (1.2)$$

1.2.1.2 La Modulation (Le Transport du Message)

Une onde « pure » (la porteuse) ne renferme aucune donnée. Pour transmettre un son ou une image, il est nécessaire de modifier l'une des propriétés de cette onde.

Modulation d'Amplitude (AM) : On fait varier la "force" ou la hauteur de l'onde.

Modulation de Fréquence (FM) : On fait varier la rapidité des oscillations.

Modulation de Phase (PM) : On décale le point de départ de l'oscillation (très utilisé en numérique) [6].

1.2.1.3 Le Spectre Radioélectrique (Le Partage des Ressources)

L'espace hertzien étant limité, le spectre radioélectrique est divisé en bandes de fréquences spécifiques afin d'éviter les interférences. Cependant, plusieurs utilisateurs peuvent exploiter simultanément une ressource ou un groupe de fréquences, ce qui optimise la disponibilité et l'utilisation des ressources. Cela exige une gestion rigoureuse du spectre pour prévenir les conflits et garantir la coexistence des systèmes [7].



Figure1.1: Représentation du spectre radio électrique [8].

a) Hautes Fréquences (HF) également appelées « ondes courtes et décamétriques »

Les ondes radio entre 3 MHz et 30 MHz ont des longueurs d'onde de 10 à 100 m et peuvent atteindre plusieurs milliers de km. Leur portée est affectée par l'activité solaire et des phénomènes physiques variés, ce qui rend la réception fluctuante. Leur utilisation pour les liaisons à courte ou longue distance dépend de la compréhension des modes de propagation, des choix de fréquences, de modulations et d'antennes.

b) Les Très Hautes Fréquences (VHF)

Les fréquences comprises entre 30 MHz et 300 MHz, favorables aux liaisons mobiles ou fixes en radiotéléphonie, se propagent principalement en vue directe et bénéficient de réflexions sur les couches de l'ionosphère.

c) Les Ultras Hautes Fréquences (UHF)

Les gammes de fréquences de 300 à 3 000 MHz sont devenues plus courantes en raison de la saturation de la bande VHF et de la demande croissante de débits de transmission de données plus élevés. Les fréquences à partir de 1 000 MHz appartiennent à la catégorie des micro-ondes (hyperfréquences) et se propagent principalement en visibilité directe, ce qui les rend idéales pour les interactions urbaines et une diffusion efficace dans les sédiments [8].

1.2.1.4 Le Rapport Signal sur Bruit (SNR)

L'expression rapport signal sur bruit (SNR) désigne, dans les domaines de l'ingénierie, du traitement du signal et de la théorie de l'information, le rapport entre la puissance d'un signal utile (information pertinente) et celle du bruit (information indésirable ou parasite). Étant donné que de nombreux signaux présentent une large gamme dynamique, le rapport signal sur bruit est généralement exprimé en décibels (dB) selon une échelle logarithmique. Cette mesure est définie par les normes de l'UIT (Union Internationale des Télécommunications), notamment dans les recommandations des séries V et M [9].

La formule de conversion utilisée est la suivante :

$$SNR_{dB} = 10 \log_{\{10\}} \left(\frac{P_{signal}}{P_{bruit}} \right) \quad (1.3)$$




Figure 1.2 : Taux d'erreur sur les symboles en fonction du rapport signal sur bruit [10].

1.2.2 Chaîne de transmission et de réception

La chaîne de transmission de l'information désigne tous les composants qui facilitent le transfert d'informations d'un lieu à un autre. Cette chaîne comprend :

- Un encodeur qui encode les données à transmettre.
- Un canal de communication constitué d'un émetteur qui transmet l'information codée et d'un récepteur qui reçoit cette information.
- Un décodeur chargé de décoder l'information [11].




Figure 1.3 : Chaîne de transmission de l'information [11].

1.2.3 Notions de bande passante

La bande passante représente l'intervalle de fréquences dans lequel un signal peut être transmis avec une atténuation acceptable par un système ou un canal de transmission. Elle correspond à la

plage de fréquences pour laquelle la puissance du signal en sortie demeure supérieure à un seuil déterminé par rapport à la puissance du signal d'entrée.

Généralement, un système est caractérisé par sa bande passante à 3 dB, qui correspond à l'intervalle de fréquences dans lequel la puissance du signal en sortie ne diminue pas de plus de moitié par rapport à sa valeur maximale. Cette définition constitue une référence largement utilisée pour évaluer les performances des systèmes de transmission et de traitement du signal [12].

1.2.4 Bruit et canal de propagation

La qualité d'une communication radio dépend fortement du bruit présent dans le système ainsi que des caractéristiques du canal de propagation. Ces deux éléments influencent directement la transmission et la réception des signaux.

1.2.4.1 Bruit

Le bruit est défini comme tout signal indésirable susceptible de perturber la transmission, la réception ou le traitement d'un signal porteur d'information. Il peut se manifester sous différentes formes selon l'environnement de communication considéré.

Dans les systèmes de téléphonie mobile numérique, le bruit peut provenir de diverses sources, notamment le bruit acoustique de fond, le bruit thermique, le bruit électromagnétique, les interférences co-canal, les distorsions du canal radio, l'écho ainsi que le bruit de traitement. Ces perturbations sont susceptibles d'altérer la qualité du signal reçu et de provoquer des erreurs lors de la transmission des données. Par conséquent, les techniques de réduction et de suppression du bruit jouent un rôle essentiel dans l'amélioration de la fiabilité et des performances des systèmes de télécommunications.

Le bruit peut être classé en plusieurs catégories principales :

- Bruit acoustique : généré par les sources sonores de l'environnement quotidien, telles que les voitures, les conversations ou les activités humaines.
- Bruit électromagnétique : généré par les équipements électriques et électroniques qui produisent des champs électromagnétiques.
- Bruit électrostatique : produit par la présence de charges ou de tensions électriques dans divers composants ou milieux.
- Distorsions et évanouissement du canal (fading) : phénomènes liés aux conditions de propagation du signal dans le canal de communication.
- Bruit de traitement : introduit lors du traitement numérique ou analogique des signaux, par exemple le bruit de quantification ou la perte de paquets de données [13].

1.2.4.2 Canal de propagation

Un système de transmission radio assure la conversion d'un signal électrique émis ($e(t)$) en un signal électrique reçu ($s(t)$) par l'intermédiaire d'ondes électromagnétiques. Le canal de transmission représente l'ensemble des phénomènes qui affectent le signal lors de son acheminement entre l'émetteur et le récepteur. Il modélise ainsi la transformation du signal ($e(t)$) en signal ($s(t)$) et traduit les interactions entre les ondes électromagnétiques et leur environnement.

Il convient de distinguer le canal de transmission du canal de propagation. Le canal de propagation décrit spécifiquement les modifications subies par les ondes électromagnétiques au cours de leur déplacement dans le milieu de transmission, telles que l'atténuation, la réflexion, la diffraction ou encore la diffusion [14].

1.3 Modulations radio analogiques et numériques

La modulation est essentielle dans les systèmes de communication, permettant d'adapter un signal d'information à une onde porteuse de fréquence plus élevée pour en faciliter la transmission. Les techniques de modulation se divisent en deux catégories : analogiques (comme la modulation d'amplitude et la modulation d'angle) et numériques (telles que l'ASK, FSK et PSK). Cette classification illustre l'évolution des techniques de modulation. La modulation est essentielle dans les systèmes de communication, car elle permet d'adapter un signal d'information à une onde porteuse de fréquence plus élevée afin d'en faciliter la transmission. Les techniques de modulation se répartissent en deux grandes catégories : les modulations analogiques (telles que la modulation d'amplitude et la modulation d'angle) et les modulations numériques (telles que l'ASK, la FSK et la PSK). Cette classification illustre l'évolution des techniques de communication, depuis les approches analogiques traditionnelles jusqu'aux méthodes numériques plus avancées. La Figure 1.4 présente une classification générale des principaux types de modulation utilisés dans les systèmes de communication.




Figure 1.4 : Classification des types de modulation.

1.3.1 Modulation analogique

Nous évoquons trois types de cette modulation.

1.3.1.1 Modulation AM

La modulation d'amplitude (AM) est une technique ancienne de transmission radio développée au XXe siècle par Landell de Moura et Reginald Fessenden. Elle fait varier l'amplitude d'une onde porteuse selon le signal modulant, maintenant une fréquence constante. Cela produit des bandes latérales, créant des variations d'amplitude, en contraste avec la modulation de fréquence et de phase qui modifient respectivement la fréquence et la phase [15].

Dans cette méthode, l'amplitude de l'onde porteuse varie proportionnellement à l'amplitude instantanée du signal modulant (message), tandis que la fréquence et la phase de la porteuse restent inchangées. Cela signifie que le signal porteur est effectivement multiplié par le signal de message pour encoder l'information à transmettre comme illustré dans la Figure 1.5 :




Figure 1.5: Représentation visuelle de la modulation AM [16].

- Le graphique supérieur montre le signal de modulation, une forme d'onde basse fréquence qui représente l'information originale telle que la parole ou la musique.
- Le graphique du milieu affiche le signal porteur, une onde sinusoïdale haute fréquence utilisée comme signal de transmission.
- Le graphique inférieur représente le signal modulé AM résultant, où l'amplitude de la porteuse varie en fonction de la forme du signal modulant [17].

La modulation d'amplitude (AM) est largement utilisée en radiodiffusion et dans d'autres applications de communication en raison de sa simplicité. Cependant, elle est relativement plus sensible au bruit et à la dégradation du signal que d'autres techniques de modulation.

La porteuse est un signal sinusoïdal à haute fréquence qui sert de base ou de support à la transmission d'informations en AM. Elle est représentée mathématiquement comme suit :

$$v(t) = A_c \cos(\omega_c t) \quad (1.4)$$

$$\omega_c = 2\pi f_c \quad (1.5)$$

où ω_p représente la pulsation du signal porteur et f_c sa fréquence. La pulsation correspond à la fréquence angulaire de la porteuse et sert à transporter l'information sur de longues distances [18].

Le signal de modulation contient les informations à transmettre et s'exprime comme [18] :

$$u(t) = A_m \cos(\omega_m t) \quad (1.6)$$

$$\omega_m = 2\pi f_m \quad (1.7)$$

Où ω_m représente la pulsation du signal modulant et f_m sa fréquence.

Lors d'une modulation, l'amplitude du signal porteur est multipliée par le signal modulant, ce qui donne le signal modulé [18] :

$$s(t) = A(1 + KU_m(t))\cos w_c(t) \quad (1.8)$$

Ou de manière équivalente :

$$s(t) = A_c(1 + m \cos(2\pi f_m)) \cos(2\pi f_c) \quad (1.9)$$

$$m = k A_m / A_c \quad (1.10)$$

Où k est un facteur de proportionnalité et m est l'indice de modulation.

L'équation de l'onde modulée peut s'écrire sous la forme :

$$s(t) = A_c \cos(2\pi f_c) + A_c m / 2 [\cos(2\pi(f_c + f_m)t) + \cos(2\pi(f_c - f_m)t)] \quad (1.11)$$

Ceci montre que le signal AM est composé de trois composantes de fréquence : une fréquence porteuse centrale f_c une bande latérale supérieure à $f_c + f_m$ et une bande latérale inférieure à $f_c - f_m$. Ces bandes latérales transportent l'information réelle, tandis que la porteuse facilite la transmission [19].

1.3.1.2 Modulation FM

La modulation de fréquence (FM) est une technique utilisée pour encoder des informations sur une onde porteuse en faisant varier sa fréquence en fonction de l'amplitude instantanée du signal modulant, c'est-à-dire du message ou de l'information à transmettre [17]. Contrairement à la modulation d'amplitude (AM), où l'amplitude de la porteuse est modifiée, la FM maintient une amplitude constante et fait varier la fréquence de l'onde porteuse.

Comme illustré à la Figure 1.6, la fréquence de l'onde porteuse augmente ou diminue en fonction de l'amplitude instantanée du signal modulant, tandis que son amplitude reste inchangée. Cette caractéristique rend la FM plus résistante au bruit, aux interférences et à l'affaiblissement du signal, ce qui permet une transmission de meilleure qualité et plus fiable, notamment pour les applications audio telles que la radiodiffusion FM.




Figure 1.6: Représentation visuelle de la modulation FM [18].

Ce type de modulation est principalement utilisé pour transmettre des informations par ondes radio ou par liaisons filaires. Il est utilisé dans la transmission radio UHF/VHF (radio FM) et la transmission radio par liaisons micro-ondes. De nos jours, il est progressivement remplacé par les méthodes de transmission numérique [18]. L'un des principaux avantages de la FM est son rapport signal/bruit élevé, qui réduit considérablement les interférences provenant d'autres fréquences radio et le bruit électrique. Cela rend la FM particulièrement adaptée à la transmission audio haute-fidélité, comme la musique, où la clarté et la qualité sonore sont essentielles. Par conséquent, la FM est devenu la technique de modulation privilégiée par la plupart des stations de radio modernes [17].

$$s(t) = A_m \cos(2(\pi f_m t)) \quad (1.12)$$

$$s(t) = A_c \cos(2\pi f_c t + \varphi) \quad (1.13)$$

Si la porteuse est modulée en fréquence, cela signifie que f_c varie linéairement avec le signal modulant $u(t)$. La phase du signal porteur est donnée par [17] :

$$2\pi f_c t + \varphi = \delta \quad (1.14)$$

Pour comprendre la relation entre la phase et la fréquence, on dérive δ par rapport au temps.

La dérivée de la phase donne la fréquence instantanée (f_i) [19] :

$$d\delta/dt = (2\pi f_c + \varphi) dt = 2\pi f_i \Rightarrow f_i = 1/2\pi d\delta/dt \quad (1.15)$$

Cette fréquence f_i est modulée par le signal $u(t)$, ce qui provoque un décalage Δf . La fréquence instantanée devient alors [19] :

$$1/2\pi d\delta/dt = f_c + A_m \Delta f \cos(2\pi f_m t) = f_c + \Delta f u(t) \quad (1.16)$$

Ensuite, on fait l'intégration pour trouver la phase δ [18] :

$$\delta = \int 2\pi f_c t + 2\pi \int A_m \Delta f \cos(2\pi f_m t) dt \quad (1.17)$$

$$\delta = 2\pi f_c t + 2\pi \Delta f \int u(t) dt \quad (1.18)$$

L'expression du signal modulé en fréquence $s(t)$ est alors :

$$s(t) = A_c \cos(\delta) = A_c \cos(2\pi f_c t + 2\pi \Delta f \int u(t) dt) \quad (1.19)$$

$$s(t) = A_c \cos(\delta) = A_c \cos(2\pi f_c t + 2\pi \int A_m \Delta f \cos(2\pi f_m t) dt) \quad (1.20)$$

En remplaçant $u(t)$, on obtient :

$$s(t) = A_c \cos(\delta) = A_c \cos(2\pi f_c t + A_m \Delta f f_m \sin(2\pi f_m t) + \Phi) \quad (1.21)$$

Dans cette équation, $A_m \cdot \Delta f$ représente l'écart de fréquence, qui indique la déviation maximale de la fréquence porteuse par rapport à sa fréquence centrale sous l'effet du signal modulant.

$$m = \frac{\Delta f}{f_m} \quad (1.22)$$

1.3.1.3 Modulation de phase (PM ou ΦM)

La modulation de phase est une technique de préparation des signaux de communication pour la transmission. Elle consiste à modifier la phase d'une onde porteuse en fonction de l'amplitude instantanée du signal de message [18]. Dans ce procédé, seule la phase de la porteuse varie selon le signal modulant, tandis que son amplitude et sa fréquence demeurent constantes. Cette méthode permet d'encoder l'information à travers de subtiles variations de phase, comme l'illustre la Figure 1.8. Cette modulation est particulièrement appréciée pour sa grande robustesse face au bruit et à la dégradation du signal, ce qui la rend extrêmement fiable dans des environnements de communication difficiles. Par conséquent, elle est fréquemment utilisée en radiocommunication ainsi que dans des applications critiques telles que les drones et les véhicules aériens sans pilote (UAV), où la stabilité et la précision de la transmission de données sont essentielles [18]. Soit un signal modulant $u(t)$ et un signal porteur $v(t)$ définis respectivement par [17] :

$$u(t) = A_m \cos(2\pi f_m t) \quad (1.23)$$

$$v(t) = A_c \cos(2\pi f_c t + \varphi) \quad (1.24)$$

En modulation de phase (PM), la phase φ du signal porteur varie de manière linéaire en fonction du signal modulant $u(t)$. Par conséquent, la phase instantanée totale θ du signal modulé est définie par l'expression suivante [17] :

$$2\pi f_c t + \varphi(t) = \delta(t) \quad (1.25)$$

En substituant l'expression de la phase instantanée par sa dépendance linéaire vis-à-vis du signal modulant, nous obtenons l'expression temporelle du signal modulé en phase $v(t)$ [17] :

$$\delta(t) = 2\pi f_c t + A_m \cdot \Delta\theta \cos(2\pi f_m t) = w_c + \Delta\theta \cdot u(t) \quad (1.26)$$

La fréquence instantanée $f_i(t)$ d'un signal modulé en phase correspond à la dérivée de la phase totale $\theta(t)$ par rapport au temps, divisée par 2π . En utilisant l'expression de la phase totale présentée précédemment [17], il est possible d'écrire [17] :

$$f_i = 1/2\pi d\delta(t)/dt = f_c - \Delta\theta \cdot A_m \cdot f_m \sin(2\pi f_m t) \quad (1.27)$$

Cela démontre que, bien que la fréquence de la porteuse f_c soit fixe en tant que paramètre de base, la fréquence instantanée f_i oscille de manière sinusoïdale en raison des variations continues de la phase.

L'excursion de fréquence (Δf), qui représente l'écart maximal entre la fréquence instantanée f_i et la fréquence de la porteuse f_c , est donc donnée par l'expression suivante [17] :

$$\Delta f_s = \Delta\theta \cdot A_m \cdot f_m \quad (1.28)$$

L'expression complète du signal modulé en phase (PM) est donnée par :

$$s(t) = A_c \cos(\delta) = A_c \cos(2\pi f_c t + A_m \Delta\theta \cos(2\pi f_m t)) \quad (1.29)$$

En définissant l'indice de modulation :

$$m = A_m \cdot K_p \quad (1.30)$$

Où A_m est l'amplitude du signal modulant et K_p la constante de sensibilité de phase (souvent noté $\Delta\theta$ pour représenter la déviation maximale de phase), l'expression du signal modulé en phase peut être écrite sous une forme plus compacte :

$$s(t) = A_c \cos(2\pi f_c t + m \cos(2\pi f_m t)) \quad (1.31)$$




Figure 1.7: Représentation visuelle de la modulation de phase (PM) [34].

1.3.2 Modulation numérique

Comme indiqué précédemment, les techniques de modulation analogique modifient une onde porteuse pour transmettre des informations analogiques.

En revanche, la modulation numérique consiste à encoder un signal d'information numérique en modifiant une onde porteuse ou d'autres caractéristiques d'une onde porteuse, généralement son amplitude, sa fréquence, sa phase, ou une combinaison de phase et de fréquence. Ce processus a un impact significatif sur la bande passante du signal transmis et sa résistance aux perturbations du canal telles que le bruit, l'évanouissement et les interférences. Une caractéristique clé de la modulation numérique est le regroupement de plusieurs bits en un seul symbole, ce qui augmente l'efficacité spectrale permettant de transmettre davantage de données dans une bande passante donnée. Le débit de symboles, ou débit binaire, détermine les besoins globaux en bande passante pour la communication. Dans les sections suivantes, nous explorerons les techniques de modulation numérique les plus utilisées, y compris leurs principes, leurs avantages et leurs applications typiques [20].

1.3.2.1 Amplitude Shift Keying (ASK)

L'ASK (Amplitude Shift Keying) est une technique de modulation numérique dans laquelle l'amplitude d'une onde porteuse varie en fonction des données numériques transmises, tandis que la fréquence et la phase de cette porteuse restent constantes. En termes simples, l'ASK module la puissance (l'amplitude) du signal porteur pour représenter des valeurs binaires, généralement le «

1 » et le « 0 » [21]. L'ASK se décline principalement en deux catégories selon la complexité du codage des données :

a) ASK Binaire (BASK) ou On-Off Keying (OOK)

Il s'agit de la forme la plus simple de l'ASK. Dans ce mode, un « 1 » binaire est représenté par l'émission de l'onde porteuse avec une amplitude définie (par exemple 12V), tandis qu'un « 0 » binaire est représenté par l'absence totale de signal (0V) [22].

b) ASK M-aire (Modulation d'Amplitude d'Impulsion - PAM)

Dans cette version, plusieurs bits ($\log_2 M$) sont transmis par symbole. À chaque combinaison unique de bits est assigné un niveau d'amplitude distinct. Cette approche permet d'augmenter le débit de données en transportant plus d'informations dans chaque symbole transmis [23].




Figure 1.8: Visualisation de la modulation ASK.

1.3.2.2 La Modulation par Déplacement de Fréquence (FSK)

La FSK (Frequency Shift Keying) est une autre technique fondamentale de modulation numérique. Dans ce procédé, l'amplitude de la porteuse reste constante, mais sa fréquence varie en fonction des données numériques transmises [23]. On distingue deux types principaux de FSK:

a) FSK Binaire (BFSK)

En BFSK, deux fréquences distinctes sont utilisées pour représenter les données binaires. Par exemple, une fréquence de 50 MHz peut être assignée au « 1 » logique, et une fréquence différente, comme 25 MHz, au « 0 » logique. La fréquence de l'onde porteuse alterne entre ces deux valeurs pour encoder l'information [23].

b) FSK M-aire (M-ary FSK)

Dans cette variante, des groupes de $\log_2 M$ bits sont associés à des fréquences uniques, permettant de transmettre plus de données par symbole. Cependant, à mesure que M augmente,

l'efficacité spectrale diminue, les besoins en largeur de bande croissent de manière exponentielle et la complexité du système s'élève. Cela peut accroître la probabilité d'erreurs de transmission et nécessite un équipement plus sophistiqué [23].

1.3.2.3 Description du processus de modulation FSK

La Figure 1.9 illustre le processus de modulation FSK à travers trois graphiques successifs, chacun mettant en évidence une étape essentielle de la modulation.

Le premier graphique présente le signal binaire d'entrée, constitué d'une séquence de bits « 0 » et « 1 » en fonction du temps.

Le deuxième graphique représente le signal porteur, c'est-à-dire une onde continue de haute fréquence servant de support à la modulation.

Le troisième graphique montre le signal modulé en BFSK (Binary Frequency Shift Keying), dans lequel la fréquence de la porteuse varie en fonction du signal binaire d'entrée. Une fréquence plus élevée est associée au bit « 1 », tandis qu'une fréquence plus faible est associée au bit « 0 ». Cette variation de fréquence permet d'encoder les données numériques dans une forme d'onde adaptée à leur transmission sur un canal de communication.




Figure 1.9 : Représentation visuelle de la modulation BFSK [34].

1.4 Reconnaissance automatique des modulations

La reconnaissance automatique des modulations vise à déterminer automatiquement le schéma de modulation d'un signal reçu. Cette technique est devenue un élément clé dans les systèmes de communication modernes et les applications de radio intelligente.

1.4.1 Définition de l'automatic modulation classification

L'identification automatique des modulations (AMC) est une méthode employée dans les dispositifs de communication pour déterminer automatiquement la nature de la modulation d'un signal reçu, sans avoir besoin de connaître au préalable le signal transmis. Elle représente une phase cruciale dans l'examen et la supervision des signaux radio.

Dans un système de communication radio, un signal transmis peut être modulé selon différentes techniques telles qu'ASK, FSK, PSK, QAM, AM ou FM. L'AMC permet d'analyser les caractéristiques du signal reçu (amplitude, phase, fréquence, statistiques du signal ou représentations temps-fréquence) afin de déterminer la modulation utilisée [24].

1.4.2 Domaines d'application

L'identification automatique des modulations (AMC) trouve de nombreuses applications dans les domaines des communications radio, de la surveillance du spectre et des systèmes intelligents. Grâce à sa capacité à reconnaître automatiquement le type de modulation d'un signal reçu, elle joue un rôle essentiel dans plusieurs secteurs technologiques et stratégiques.

Parmi ses principaux domaines d'application figurent :

1.4.2.1 Communications militaires et surveillance des fréquences

L'AMC, dans le contexte militaire, autorise la détection des signaux ennemis ou non identifiés et l'identification de leur modulation pour examiner les communications qui ont été interceptées.

1.4.2.2 Radio cognitive

Dans le cadre des réseaux cognitive-radio, l'AMC facilite la détection et l'analyse des signaux dans le spectre radioélectrique, favorisant ainsi une utilisation dynamique et intelligente de ce dernier.

1.4.2.3 Administration et supervision du spectre radioélectrique

Ces méthodes sont mises en œuvre par les autorités de régulation pour contrôler l'usage du spectre et identifier les transmissions non permises ou les perturbations.

1.4.2.4 Systèmes de communication contemporains

Dans les technologies sans fil comme la 5G, l'IoT et les communications par satellite, l'AMC peut servir à ajuster de manière automatique les paramètres de communication.

1.4.2.5 Guerre électronique et renseignement par les ondes électromagnétiques

Les systèmes de guerre électronique utilisent la classification de modulation pour identifier, analyser et éventuellement perturber les communications adverses [25-26].

1.4.3 Enjeux et contraintes

Malgré les progrès réalisés dans le domaine de la reconnaissance automatique des modulations, plusieurs enjeux et contraintes demeurent et peuvent affecter les performances des systèmes de classification.

1.4.3.1 Conditions du canal radio

Les performances de l'AMC sont fortement influencées par :

- le bruit
- le fading
- les interférences
- la distorsion du canal

Ces facteurs rendent la classification plus difficile dans les environnements réels.

1.4.3.2 Diversité des modulations

Les systèmes de communication modernes utilisent de nombreux types de modulation :

- PSK
- QAM
- FSK
- OFDM

Cette diversité complique la conception d'un modèle capable de reconnaître toutes les modulations avec précision.

1.4.3.3 Besoin de grandes bases de données

Les modèles de Deep learning nécessitent beaucoup de données d'entraînement, souvent simulées. Le problème est que les données simulées ne représentent pas toujours les conditions réelles.

1.4.3.4 Complexité computationnelle

Les architectures Deep learning (CNN, RNN, etc.) demandent beaucoup de puissance de calcul, une grande mémoire et un temps de traitement important. Cela limite leur utilisation dans des systèmes embarqués ou temps réel.

1.4.3.5 Compromis performance / complexité

Les chercheurs doivent trouver un équilibre entre la précision de classification, le temps de calcul, et la consommation énergétique [26].

1.5 Méthodes classiques de classification des modulations

Avant l'émergence des techniques basées sur le machine learning et le Deep learning, la détection automatique des modulations s'appuyait majoritairement sur des méthodes traditionnelles basées sur l'extraction de caractéristiques du signal. Ces techniques impliquent l'examen de certaines caractéristiques statistiques, temporelles ou spectrales du signal reçu pour déterminer le type de modulation employé [28].

1.5.1 Approches basées sur des caractéristiques statistiques et spectrales

Les méthodes basées sur les caractéristiques statistiques et spectrales exploitent les propriétés du signal dans les domaines temporel et fréquentiel pour effectuer la classification des modulations.

1.5.1.1 Approches basées sur des caractéristiques statistiques

Les techniques statistiques font appel à des paramètres statistiques du signal, comme les moments statistiques, les cumulants de haut ordre ou les distributions probabilistes. Ces caractéristiques facilitent l'identification de divers types de modulations, chaque modulation ayant une empreinte statistique propre.

Par exemple, les cumulants d'ordre supérieur sont largement utilisés pour différencier les modulations numériques telles que PSK, QAM ou FSK. L'avantage principal de ces méthodes est leur capacité à fonctionner sans connaissance préalable du signal transmis. De plus, certaines caractéristiques statistiques sont relativement robustes face aux variations du canal de transmission.

Toutefois, ces techniques requièrent fréquemment une grande quantité d'échantillons du signal pour fournir des estimations statistiquement solides [29].

1.5.1.2 Approches basées sur des caractéristiques spectrales

Les approches spectrales reposent sur l'analyse du spectre de fréquence du signal. Elles utilisent des outils comme la densité spectrale de puissance (PSD), la transformée de Fourier (FFT) et l'analyse cyclo stationnaire. Ces méthodes facilitent la détection de motifs distinctifs dans le spectre du signal, associés au genre de modulation employé. Par exemple, il existe des structures spectrales spécifiques ou des périodicités cyclo stationnaires associées à certaines modulations qui peuvent être utilisées pour les classifier.

Les techniques cyclo stationnaires sont particulièrement performantes pour repérer des signaux, même en situation d'interférences, grâce à leur capacité à tirer parti des caractéristiques périodiques du signal modulé. Ces concepts sont également approfondis dans des ressources pédagogiques spécialisées en théorie des communications numériques [30, 32].

1.5.2 Limites en environnement bruité

Bien qu'elles soient performantes sous certaines hypothèses simplificatrices, les approches conventionnelles se heurtent à des obstacles majeurs en conditions réelles. La présence de bruit additif, d'interférences électromagnétiques et les phénomènes de propagation (fading, multi trajets) dégradent significativement la fiabilité de la classification.

Parmi leurs principales limitations :

- Sensibilité au bruit lorsque le rapport signal sur bruit (SNR) est faible,
- Dépendance à l'extraction manuelle des caractéristiques, qui nécessite une expertise du domaine,
- Performance limitée dans les environnements dynamiques,
- Difficulté à gérer un grand nombre de types de modulations.

Afin de pallier ces insuffisances, les recherches récentes se sont orientées vers l'apprentissage automatique (Machine Learning) et l'apprentissage profond (Deep Learning). Contrairement aux méthodes manuelles, ces modèles ont la capacité d'extraire de manière autonome des descripteurs discriminants directement à partir des composantes brutes du signal. Des travaux pionniers, notamment l'utilisation de réseaux de neurones convolutifs (CNN) pour la reconnaissance automatique des modulations radio, ont démontré la supériorité de cette approche sur les méthodes classiques [29, 31].

1.6 Conclusion

Ce premier chapitre a permis d'établir les bases théoriques nécessaires à la compréhension des systèmes de communications radio numériques ainsi que des techniques de modulation associées. Nous avons tout d'abord présenté les principes fondamentaux des communications radio, en mettant en évidence les caractéristiques des ondes électromagnétiques, les mécanismes de propagation ainsi que la gestion du spectre radioélectrique.

Nous avons ensuite étudié la chaîne de transmission et de réception, en détaillant le rôle de chaque bloc dans l'acheminement fiable de l'information. L'analyse des notions de bande passante, de bruit et de canal de propagation a également permis de mettre en évidence les principales contraintes des environnements réels, notamment l'influence du bruit sur les performances des systèmes, en particulier sur le rapport signal sur bruit et le taux d'erreur.

Par ailleurs, les techniques de modulation analogiques et numériques ont été examinées afin de comprendre leurs caractéristiques, leurs avantages et leurs limites en termes de robustesse, d'efficacité spectrale et de complexité.

Enfin, nous avons introduit la problématique de la reconnaissance automatique des modulations, en présentant ses domaines d'application, ses enjeux et les limites des approches classiques, notamment en présence de bruit et de conditions de propagation défavorables.

Le chapitre suivant sera consacré aux concepts d'intelligence artificielle, du Machine Learning et de DeepLarning.

CHAPITRE 2
INTELLIGENCE ARTIFICIELLE, MACHINE
LEARNING ET DEEP LEARNI

2.1 Introduction

L'intelligence artificielle (IA) est aujourd'hui l'un des domaines les plus dynamiques de l'informatique et des technologies numériques. Son objectif est de concevoir des systèmes capables de reproduire certaines capacités humaines telles que l'apprentissage, le raisonnement, la prise de décision et la résolution de problèmes. Au fil des années, l'IA a connu une évolution remarquable, passant des approches symboliques traditionnelles aux méthodes basées sur les données. Cette évolution a conduit à l'émergence du Machine Learning, qui permet aux systèmes d'apprendre automatiquement à partir des données, puis du Deep Learning, une approche fondée sur les réseaux de neurones profonds offrant des performances exceptionnelles dans de nombreux domaines. Ce chapitre présente les concepts fondamentaux de l'intelligence artificielle, du Machine Learning et du Deep Learning, leurs principes de fonctionnement, leurs principales applications ainsi que leurs limites. Une comparaison entre ces différentes approches est également proposée afin de mieux comprendre leurs relations et leurs domaines d'utilisation respectifs.

2.1.1 Contexte et motivation de l'Intelligence Artificielle

L'évolution de l'intelligence artificielle est stimulée par le besoin de gérer des quantités massives de données (Big Data) que l'analyse manuelle par un être humain devient impossible. Dans des secteurs tels que les télécommunications, le but est d'automatiser la gestion des réseaux et d'optimiser le traitement du signal en direct.

2.1.1.1 Capacités visées

L'intelligence artificielle vise à reproduire certaines capacités humaines comme l'apprentissage, le raisonnement et la prise de décision autonome. L'apprentissage permet aux systèmes d'analyser les données afin d'extraire des motifs et d'améliorer leurs performances. Le raisonnement aide à effectuer des déductions logiques pour résoudre des problèmes, tandis que la prise de décision autonome permet d'agir sans intervention humaine directe.

2.1.1.2 Facteurs déclencheurs

Le développement de l'intelligence artificielle a été accéléré par l'augmentation de la puissance de calcul des ordinateurs. Les processeurs spécialisés comme les GPU et les TPU permettent d'exécuter rapidement des calculs complexes et d'entraîner efficacement les modèles d'IA.

De plus, la réduction du coût de stockage des données a facilité la conservation et l'exploitation de grandes quantités d'informations. Cette disponibilité massive des données a joué un rôle essentiel dans l'amélioration des performances des systèmes d'intelligence artificielle [35].

2.1.2 Évolution des approches en IA

L'intelligence artificielle a traversé une évolution significative passant de systèmes inflexibles à des systèmes adaptatifs :

2.1.2.1 IA Symbolique (Systèmes Experts)

Reposait sur des règles logiques de type « Si... Alors... ». Très efficace dans des environnements fermés (par exemple, les jeux d'échecs), mais incapable de gérer l'incertitude et les données non structurées (images, sons, vidéos).

2.1.2.2 IA Connexionniste (Apprentissage Statistique)

C'est l'approche actuelle. Au lieu de dicter les règles à la machine, on lui fournit des exemples. Elle construit elle-même son modèle statistique pour répondre à un problème donné [36].

2.1.3 Positionnement du Machine Learning et du Deep Learning

Il est essentiel de saisir que l'apprentissage automatique et l'apprentissage profond ne constituent pas des éléments distincts de l'intelligence artificielle, mais plutôt des sous-groupes imbriqués [37].

La différence fondamentale entre le ML classique et le DL réside dans la manière dont l'information est traitée :

Caractéristique	Machine Learning (ML)	Deep Learning (DL)
Intervention humaine	Nécessite un expert pour extraire les données pertinentes (Feature Engineering).	Apprend seul à extraire les caractéristiques importantes.
Volume de données	Fonctionne bien avec des jeux de données limités.	Nécessite des quantités massives de données pour être performant.
Complexité	Modèles plus simples (Régression, Arbres de décision).	Réseaux de neurones profonds (plusieurs couches cachées).
Explicabilité	Souvent plus facile à interpréter ("Boîte blanche").	Très complexe à interpréter ("Boîte noire").

Tableau 2.1 : Synthèse des sources de référence pour l'étude de l'IA, du ML et du DL.

Le Machine Learning est l'outil de choix pour des données structurées (tableaux, statistiques), tandis que le Deep Learning s'impose comme la solution de référence pour les données non structurées et les environnements complexes (reconnaissance faciale, traduction automatique, maintenance prédictive des réseaux) [38].

2.2 Intelligence Artificielle : concepts et fondements

L'intelligence artificielle repose sur un ensemble de concepts et de méthodes permettant aux machines de simuler certaines capacités cognitives humaines. Cette section présente les fondements essentiels de ce domaine.

2.2.1 Définition de l'IA

L'Intelligence Artificielle (IA) est un domaine multidisciplinaire à l'intersection de l'informatique, des mathématiques et des sciences cognitives dont le but est la création de systèmes sociotechniques capables de reproduire des fonctions cognitives humaines afin de résoudre des problèmes d'une grande complexité.

2.2.1.1 Sur le plan Conceptuel (L'Objectif)

L'IA se définit comme la capacité d'un agent autonome à percevoir son environnement, à raisonner sur les informations acquises, à apprendre de l'expérience et à agir de manière rationnelle pour atteindre des objectifs spécifiques dans des contextes marqués par l'incertitude [39].

2.2.1.2 Sur le plan Technique (Le Mécanisme)

Techniquement, l'IA moderne est un paradigme d'optimisation mathématique. Elle repose sur l'utilisation d'architectures de réseaux de neurones (connexionnisme) qui fonctionnent comme des approximateurs universels. Par le biais de l'apprentissage (supervisé, non-supervisé ou par renforcement), le système extrait des structures statistiques (patterns) à partir de données brutes pour construire des représentations abstraites et exécuter des tâches de classification, de prédiction ou de génération [42].

2.2.1.3 Sur le plan Pratique (L'Utilité)

Pratiquement, l'IA est définie par sa robustesse. Contrairement à un logiciel classique qui "plante" ou donne une erreur face à une donnée imprévue, l'IA propose une réponse probabiliste cohérente, s'adaptant aux variations de l'environnement [41].

2.2.2 Les éléments principaux d'un système IA

Les éléments principaux d'un système d'intelligence artificielle (IA) sont :

2.2.2.1 Données et Modèles d'apprentissage

L'entraînement des modèles d'apprentissage repose sur les données, qui constituent la base du processus d'apprentissage. On distingue généralement les données structurées des données non structurées [36].

2.2.2.2 Algorithmes

Les algorithmes, en tant que mécanismes mathématiques et statistiques, permettent aux systèmes d'intelligence artificielle d'analyser des données, d'apprendre des modèles et de prendre des décisions ou de faire des prédictions. Ils se classifient en plusieurs types : apprentissage supervisé, non supervisé et par renforcement [39].

2.2.2.3 Capteurs et Entrées

Les systèmes d'intelligence artificielle ont fréquemment besoin de capteurs pour recueillir des informations en temps réel. Cela peut englober des équipements tels que des caméras, des micros ou tout autre appareil capable de recueillir des données environnementales [42].

2.2.2.4 Unités de traitement (CPU, GPU, TPU)

Pour gérer efficacement les informations et réaliser des algorithmes sophistiqués, un système d'intelligence artificielle s'appuie sur des unités de traitement performant, telles que les processeurs centraux (CPU), les processeurs graphiques (GPU) ou encore des unités spécialisées comme les TPU [43].

2.2.2.5 Mémoire

La mémoire est cruciale pour stocker les données d'entraînement, les paramètres du modèle et les résultats intermédiaires, facilitant ainsi la réutilisation des informations dans le processus décisionnel et l'apprentissage continu [44].

2.2.2.6 Interface Utilisateur (IU)

Cet élément facilite l'interaction entre l'humain et le système d'intelligence artificielle, que ce soit via une interface graphique, un chatbot, ou d'autres dispositifs d'interaction homme-machine [45].

2.2.2.7 Mécanismes de prise de décision

Ces dispositifs donnent à l'intelligence artificielle la capacité d'examiner les résultats produits par le modèle et de faire des choix basés sur des buts préétablis ou un cadre décisionnel perfectionné [46].

2.2.2.8 Environnement d'exécution (Cloud vs Local)

Le contexte de déploiement du système d'IA, qu'il soit local (sur une machine dédiée) ou basé sur le cloud, influence la disponibilité et la vitesse des ressources requises pour son fonctionnement [47].

2.2.3 Approches classiques (symbolique, systèmes experts)

Les approches classiques de l'intelligence artificielle sont basées sur la manipulation de symboles et l'utilisation de règles permettant de simuler le raisonnement humain.

2.2.3.1 L'IA Symbolique et l'Hypothèse des Symboles Physiques

La méthode traditionnelle, fréquemment désignée sous le nom d'IA symbolique ou de GOFAI (Good Old-Fashioned Artificial Intelligence), repose sur l'idée que l'intelligence peut être reproduite par la manipulation de symboles abstraits selon des règles de logique formelle. Cette approche considère l'esprit humain comme un système de traitement de l'information comparable à un ordinateur [48].

2.2.3.2 Les Systèmes Experts : Architecture et Ingénierie des Connaissances

Les systèmes experts représentent l'application pratique la plus aboutie de ce paradigme. Ils séparent strictement la connaissance (faits et règles) du mécanisme de raisonnement. L'architecture type comprend une base de connaissances, un moteur d'inférence (utilisant le chaînage avant ou arrière) et une base de faits [49].

2.2.4 Domaines d'application de l'IA

L'intelligence artificielle n'est plus une simple technologie spécialisée ; elle s'est transformée en un puissant levier transversal qui influence l'ensemble des secteurs d'activité. En 2026, son utilisation a évolué au-delà de la simple automatisation pour atteindre des capacités avancées de prise de décision et de génération de contenu.

2.2.4.1 Télécommunications et Traitement du Signal

Il s'agit de l'un des domaines les plus avancés, dans lequel l'intelligence artificielle remplace progressivement les algorithmes déterministes afin de gérer la complexité croissante des réseaux de communication modernes (5G/6G).

a) Optimisation du spectre

Gestion dynamique des fréquences en temps réel.

b) Classification Automatique des Modulations (AMC)

Identification des signaux dans des environnements à faible rapport signal/bruit (SNR)

c) Maintenance prédictive

Identification précoce des anomalies dans les infrastructures réseau afin de prévenir les pannes [50].

2.2.4.2 Santé et Médecine de Précision

L'IA révolutionne le parcours de soin, de la recherche fondamentale au lit du patient.

- a) **Imagerie médicale** : Détection précoce de pathologies (cancers, anomalies cardiaques) avec une précision supérieure à l'œil humain.
- b) **Découverte de médicaments (Drug Discovery)** : Simulation de repliement de protéines pour créer de nouvelles molécules.
- c) **Chirurgie assistée** : Robots capables de stabiliser les gestes chirurgicaux en temps réel [51].

2.2.4.3 Finance et Fintech

Le secteur financier utilise l'IA pour traiter des volumes de données massifs à une vitesse milliseconde.

- a) **Trading Haute Fréquence (HFT)** : Algorithmes prenant des décisions d'achat/vente en quelques microsecondes.
- b) **Détection de la fraude** : Analyse comportementale pour bloquer les transactions suspectes en temps réel.
- c) **Scoring de crédit** : Evaluation plus fine du risque de prêt grâce à l'analyse de données non conventionnelles [52].

2.2.4.4 Industrie 4.0 et Robotique

L'IA permet aux machines de devenir collaboratives et adaptatives.

- a) **Maintenance Prédictive** : Analyse des vibrations et de la température pour anticiper les pannes d'usine.
- b) **Robotique** : Robots capables de travailler en toute sécurité aux côtés des humains sans barrières physiques.
- c) **Optimisation de la Supply Chain** : Prévision de la demande et gestion intelligente des stocks [53].

Le domaine le plus médiatisé, repose sur la fusion de capteurs (LiDAR, RADAR, Caméras).

- a) **Véhicules autonomes** : Systèmes de perception et de planification de trajectoire.
- b) **Gestion du trafic urbain** : Optimisation des flux de circulation pour réduire la pollution et les embouteillages [54].

2.2.5 Analyse Critique et Limites des Systèmes d'IA

Le progrès de l'Intelligence Artificielle a été marqué par la révélation de contraintes structurelles, évoluant d'une incapacité à traiter des problématiques complexes (IA classique) vers des défis liés à l'explicabilité et aux ressources nécessaires (IA contemporaine).

2.2.5.1 Les Limites de l'IA Traditionnelle (Symbolique)

L'IA classique, bien qu'efficace dans des environnements déterministes, s'est heurtée à trois obstacles majeurs :

a) Le goulot d'étranglement de l'acquisition des connaissances

La dépendance totale au codage manuel des règles par des experts humains rend ces systèmes coûteux, longs à développer et limités par le savoir explicite de l'expert [55].

b) La fragilité opérationnelle

Ces systèmes sont incapables de gérer l'incertitude ou les données bruitées. Un manque d'information ou une légère variation du signal d'entrée entraîne un échec total du système [56].

c) L'absence d'apprentissage

Contrairement aux approches connexionnistes, l'IA symbolique ne peut pas s'améliorer par l'expérience ni généraliser son raisonnement à des situations inédites [57].

2.2.5.2 Les Limites de l'IA Moderne

Malgré la révolution apportée par l'apprentissage profond (Deep Learning), de nouveaux défis apparaissent en 2026 :

a) L'opacité décisionnelle (Black Box)

L'architecture complexe des réseaux de neurones profonds complique considérablement, voire rend impossible, la traçabilité du raisonnement qui a conduit à un résultat, soulevant des enjeux de confiance et d'éthique [58].

b) La dépendance et le biais des données

La performance d'un modèle dépend étroitement de la qualité de son jeu de données d'entraînement. Des données biaisées ou manquantes aboutissent nécessairement à des prévisions incorrectes ou discriminatoires [59].

c) Le coût énergétique et environnemental

L'entraînement des modèles de pointe nécessite une puissance de calcul massive, soulevant des préoccupations majeures quant à l'empreinte carbone de la discipline [60].

2.3 Machine Learning

Le Machine Learning est une branche de l'intelligence artificielle qui permet aux machines d'apprendre à partir des données afin d'accomplir diverses tâches de manière autonome. Cette section présente ses concepts fondamentaux, ses principales méthodes et ses domaines d'application.

2.3.1 Définition et principes du Machine Learning

L'apprentissage automatique est une branche de l'intelligence artificielle qui offre aux systèmes la faculté d'évoluer et de s'améliorer en se basant sur l'expérience, sans nécessiter une programmation explicite.

2.3.1.1 Principe

Contrairement à l'algorithmique classique qui reçoit des données et des règles pour produire un résultat, le ML reçoit des données et des résultats (ou des structures) pour extraire les règles mathématiques sous-jacentes.

2.3.1.2 Objectif

Créer une fonction mathématique f telle que : $y = f(x)$, où x est l'entrée (ex: un échantillon de signal) et y est la sortie (ex: le type de modulation) [61].

2.3.2 Types d'apprentissage

On classifie l'apprentissage selon la manière dont le modèle interagit avec les données :

2.3.2.1 Apprentissage Supervisé

L'apprentissage supervisé pourrait être le type de problème de Machine Learning le plus simple à comprendre : son objectif est d'apprendre à effectuer des prédictions, sur la base d'une série d'exemples étiquetés, c'est-à-dire associés à la valeur qu'on souhaite prédire (voir Figure 1.1). Les étiquettes agissent en qualité de « professeur » et supervisent l'apprentissage de l'algorithme. On définit sous le terme d'apprentissage supervisé la partie du Machine Learning dédiée aux problèmes qui peuvent être formulés comme suit : On dispose de n observations $\{\vec{x}^i\}_{i=1,\dots,n}$ situées dans un espace X , et leurs étiquettes correspondantes $\{\vec{y}^i\}_{i=1,\dots,n}$ situées dans un espace Y . On postule que ces étiquettes peuvent être dérivées des observations via une fonction $\varphi : X \rightarrow Y$ fixe et inconnue : $y^i = \varphi(\vec{x}^i) + \epsilon_i$, où ϵ_i représente un bruit aléatoire. Il convient donc d'exploiter les données pour définir une fonction $f : X \rightarrow Y$ de sorte que, pour chaque paire $(\vec{x}, \varphi(\vec{x})) \in X \times Y$, on ait $f(\vec{x}) \approx \varphi(\vec{x})$.

Les données sont généralement définies dans l'espace $X = \mathbb{R}^p$. Toutefois, nous examinerons également comment gérer d'autres formes de représentations, telles que des variables binaires, discrètes, catégorielles, voire des chaînes de caractères ou des graphes [62].




Figure 2.1: apprentissage supervisée.

a) Apprentissage supervisée par régression

La régression est une forme d'apprentissage supervisé où l'objectif est de prédire une valeur numérique continue. Contrairement à la classification qui cherche à deviner une "étiquette" (comme "chat" ou "chien"), la régression cherche à estimer une quantité exacte sur une échelle infinie [63].

Voici les principaux types de régression utilisés en apprentissage automatique :

- **Régression linéaire**

La régression linéaire constitue une méthode statistique fondamentale visant à modéliser la relation entre une variable dépendante continue et une ou plusieurs variables explicatives, sous l'hypothèse d'un lien de nature linéaire. L'objectif principal est d'établir une fonction reliant la variable dépendante y aux variables explicatives x . À cet effet, la méthode des moindres carrés ordinaires (MCO) est généralement employée afin d'estimer les paramètres du modèle, en minimisant la somme des carrés des résidus, c'est-à-dire les écarts entre les valeurs observées et les valeurs prédites. Ce modèle repose sur plusieurs hypothèses fondamentales, notamment la linéarité de la relation ainsi que la normalité des résidus [64].

- **Régression polynomiale**

La régression polynomiale est une variante de la régression linéaire qui offre la possibilité de représenter des liens non linéaires entre les variables. À l'opposé de la régression linéaire traditionnelle qui ajuste une ligne droite, cette méthode permet d'utiliser des puissances des variables indépendantes (x^2 , x^3 , ...) pour mieux capturer les courbures présentes dans les données. Pour y parvenir, on génère de nouvelles caractéristiques en élevant les variables d'entrée à diverses puissances, ce qui facilite la conversion du modèle linéaire en un modèle polynomial. Cette technique est particulièrement bénéfique pour saisir des tendances compliquées et modéliser une courbe à partir des données, comme dans l'analyse du mouvement

d'un objet où une simple ligne droite ne suffit pas et où une courbe quadratique (x^2) serait plus pertinente [65].

- **Régression logistique**

La régression logistique, bien qu'elle repose sur une fonction mathématique de régression, est principalement utilisée pour des tâches de classification plutôt que pour la régression au sens classique. En effet, elle permet de prédire la probabilité d'appartenance d'un individu à une classe donnée (généralement 0 ou 1), ce qui explique qu'elle soit considérée comme une méthode de régression. Son principe consiste à combiner les différentes caractéristiques d'entrée à l'aide d'une fonction linéaire, de manière similaire à la régression linéaire. Toutefois, la valeur obtenue n'est pas directement utilisée comme prédiction finale: elle est transformée en une probabilité comprise entre 0 et 1 grâce à la fonction logistique. Ainsi, la probabilité qu'un échantillon, décrit par les variables $x^1, \dots, x^n$, appartienne à une classe y peut être calculée à partir de cette transformation [66].

b) Apprentissage supervisé par les réseaux de neurones

L'apprentissage supervisé par réseaux de neurones, également connu sous le nom de Deep Learning, constitue une approche inspirée du fonctionnement biologique des neurones du cerveau. Contrairement aux modèles linéaires classiques, ces modèles sont capables de capturer et de modéliser des relations extrêmement complexes entre les données d'entrée et les sorties. Un réseau de neurones est généralement structuré en plusieurs couches : une couche d'entrée, qui reçoit les données brutes telles que les pixels d'une image ou des signaux radio ; une ou plusieurs couches cachées, qui réalisent des transformations mathématiques afin d'extraire des caractéristiques de plus en plus abstraites ; et enfin une couche de sortie, qui fournit la prédiction sous forme de valeur continue dans le cas de la régression, ou de probabilité dans le cas de la classification. Le processus d'apprentissage repose sur deux étapes principales répétées de manière itérative : la propagation avant (forward propagation), durant laquelle les données traversent le réseau et une erreur est calculée en comparant la sortie prédite à la valeur réelle, et la rétropropagation (backpropagation), qui permet d'ajuster les poids des connexions entre neurones afin de minimiser cette erreur et d'améliorer les performances du modèle au fil des itérations [44].

2.3.2.2 Apprentissage non supervisé

L'apprentissage non supervisé est une méthode d'apprentissage automatique dans laquelle l'algorithme exploite des données non étiquetées, sans disposer de réponses correctes préalables. Son objectif est de découvrir des motifs, des structures cachées ou des relations entre les

données, afin de mieux les comprendre et les organiser. Cela inclut notamment des tâches comme le clustering, où des éléments similaires sont regroupés, ainsi que la réduction de dimension, qui permet de simplifier les données pour les rendre plus analysables. Le modèle explore ainsi les données pour en extraire des informations pertinentes et des structures sous-jacentes [67]. Dans ce contexte, cette approche peut être formalisée comme suit :

On appelle apprentissage non supervisé la branche du Machine Learning qui s'intéresse aux problèmes pouvant être formalisés de la façon suivante : étant données n observations $\{\vec{x}^i\}_{i=1, \dots, n}$ décrites dans un espace X , il s'agit d'apprendre une fonction sur X qui vérifie certaines propriétés [62].



Figure 2.2: Apprentissage non supervisé.

Voici les principaux types de méthodes d'apprentissage non supervisé:

a) Clustering

Le clustering est la méthode d'apprentissage non supervisé la plus courante et permet de comprendre le regroupement naturel ou la structure inhérente d'un jeu de données. Il est utilisé pour l'analyse exploratoire des données, la reconnaissance de formes, la détection d'anomalies, la segmentation d'images, etc. Les algorithmes de clustering, tels que le clustering k-means ou le clustering hiérarchique, regroupent les points de données de manière à ce que les points de données d'un même groupe (ou cluster) soient plus similaires entre eux qu'avec les points de données d'autres groupes. Dans la continuité, le clustering se décline en deux grandes approches. D'une part, le clustering dur (hard clustering), où chaque donnée est assignée à un unique groupe, comme c'est le cas avec l'algorithme k-means. D'autre part, le clustering flou ou souple (soft clustering), qui autorise une appartenance multiple des données à plusieurs groupes, à l'image des modèles de mélange gaussien [67].

b) Réduction de la dimensionnalité

Les données multivariées contiennent généralement un grand nombre de variables ou de caractéristiques, ce qui peut entraîner une augmentation du temps d'exécution ainsi que des besoins en mémoire. Les méthodes de réduction de la dimensionnalité permettent de diminuer le nombre de ces caractéristiques tout en préservant l'essentiel de l'information contenue dans les

données initiales. Lorsqu'elles sont combinées à l'apprentissage non supervisé, ces techniques contribuent à alléger la charge de calcul et à améliorer la rapidité ainsi que l'efficacité des algorithmes de Machine learning.

Par ailleurs, un grand nombre de variables rend la visualisation des données plus complexe. En simplifiant les données sans altérer les informations pertinentes, la réduction de la dimensionnalité facilite leur représentation visuelle et améliore leur analyse.

Voici quelques méthodes populaires d'apprentissage non supervisé pour réduire la dimensionnalité :

- **ACP (Analyse en Composantes Principales)**

L'ACP transforme les données en un ensemble de composantes orthogonales visant à maximiser la variance tout en réduisant la dimensionnalité. Ces nouvelles variables sont appelées composantes principales. Chaque composante principale est une combinaison linéaire des variables initiales.

Le premier axe de composante principale est unique dans l'espace. Lorsque chaque observation est projetée sur cet axe, les valeurs obtenues constituent une nouvelle variable dont la variance est maximale parmi toutes les directions possibles.

La seconde composante principale est un autre vecteur de l'espace, orthogonal au premier. La projection des observations sur cet axe définit une nouvelle variable, dont la variance est également maximale parmi toutes les directions orthogonales au premier axe.

L'ensemble des composantes principales est de même taille que l'ensemble des variables initiales, mais en pratique, les premières composantes capturent souvent plus de 80 % de la variance totale des données.

- **t-SNE / UMAP**

Est parfaitement conçue pour la visualisation de données à haute dimensionnalité. Elle incorpore des données à haute dimensionnalité dans des dimensions réduites tout en maintenant les ressemblances entre les points. Il est généralement possible d'observer les points de faible dimensionnalité pour déceler les regroupements naturels dans les données initialement à haute dimensionnalité.

- **Les auto-encodeurs**

Il s'agit de réseaux de neurones formés pour reproduire leurs données d'entrée. On peut les employer pour diverses sortes de données, y compris des images, des séries chronologiques et du texte. Les autoencodeurs trouvent leur utilité dans divers domaines, notamment la détection des anomalies, la création de texte, la production d'images, le filtrage du bruit des images et les transmissions numériques. On les utilise fréquemment pour diminuer la dimensionnalité.

Un autoencodeur se compose de deux sous-ensembles : un encodeur et un décodeur. Pendant l'entraînement, l'encodeur assimile une série de caractéristiques, nommée représentation latente, à partir des données d'entrée. Parallèlement, le décodeur est formé pour reconstruire les données basées sur ces caractéristiques.

- **L'analyse factorielle**

Il s'agit d'une méthode permettant d'ajuster un modèle à des données multivariées afin d'évaluer la dépendance entre les variables, en mettant en évidence les facteurs sous-jacents expliquant les

corrélations observées. Dans ce type d'apprentissage non supervisé, les variables observées sont influencées par un nombre restreint de facteurs latents non directement observables. Les facteurs susceptibles d'influencer simultanément plusieurs variables sont appelés facteurs communs.

On suppose que chaque variable est une combinaison linéaire de ces facteurs communs, et les coefficients associés sont appelés charges factorielles. Chaque variable comporte également une composante de variabilité aléatoire indépendante, appelée variance spécifique, car elle est propre à chaque variable [67].

2.3.2.3 Apprentissage semi-supervisé

L'apprentissage semi-supervisé repose sur l'exploitation de jeux de données partiellement étiquetés afin d'inférer les étiquettes manquantes. L'un des principaux avantages de cette approche réside dans la réduction du besoin d'annotation complète des données, ce qui s'avère particulièrement pertinent lorsque la collecte de données est aisée, mais que leur étiquetage nécessite un effort humain important.

À titre d'exemple, dans le domaine de la classification d'images, il est relativement simple de constituer une base de données contenant un grand nombre d'images. En revanche, l'attribution d'une étiquette précise à chacune d'entre elles peut s'avérer longue et coûteuse. Par ailleurs, les annotations humaines peuvent introduire des biais susceptibles d'être reproduits par des modèles entièrement supervisés. L'apprentissage semi-supervisé offre ainsi une alternative permettant, dans certains cas, de limiter ces biais. Il s'agit toutefois d'une approche plus avancée, qui ne sera pas abordée en détail dans ce travail [62].

2.3.2.4 Apprentissage par renforcement

Dans le contexte de l'apprentissage renforcé, le système d'apprentissage est en mesure de communiquer avec son environnement et de réaliser diverses actions. Suite à ces actions, il reçoit une récompense qui peut être bénéfique si l'action était judicieuse, ou défavorable dans le cas inverse. Il arrive parfois que la récompense ne soit obtenue qu'après une longue série d'actions

; c'est le cas, par exemple, d'un système qui apprend à jouer au go ou aux échecs. Dans ce contexte, l'apprentissage se résume donc à établir une politique, autrement dit une stratégie ce qui permet d'obtenir constamment la meilleure récompense envisageable [62].

2.3.3 Principaux algorithmes de Machine Learning

On compte de nombreux algorithmes d'apprentissage automatique, chacun étant spécifiquement élaboré pour traiter des types précis de problèmes ou s'ajuster à différentes structures de données. Nous allons explorer diverses catégories de tâches ainsi que les algorithmes qui les exécutent.

2.3.3.1 Algorithmes de classification

La classification est perçue comme une technique d'apprentissage supervisé en Machine Learning, se référant à un problème de modélisation prédictive dans lequel une étiquette de classe est anticipée pour un exemple spécifique [68]. Autrement dit, l'objectif est de déterminer la catégorie d'un nouvel exemple en utilisant les connaissances acquises à partir des exemples déjà classés dans le jeu de données d'entraînement. C'est une mission essentielle dans divers domaines comme la reconnaissance d'images, le traitement de la langue naturelle et l'identification des spams. En termes mathématiques, cela implique d'associer une fonction f des variables d'entrée (x) aux variables de sortie y , que ce soit en tant que cible, étiquette ou catégorie. On peut réaliser cette prédiction de classe sur des données qu'elles soient structurées ou non structurées [69].

La classification se divise en trois catégories selon le nombre de classes ou d'étiquettes à prédire.

a) Classification binaire

Elle fait référence aux tâches de classification comportant deux étiquettes de classe, comme «vrai et faux » ou « oui et non » [68]. Dans ces missions, une classe peut symboliser l'état normal, alors que l'autre illustre l'état anormal. Par exemple, dans le cadre d'un test médical, «cancer non détecté » pourrait représenter l'état normal, tandis que « cancer détecté » serait considéré comme l'état anormal. De la même manière, les termes « spam » et « non-spam » utilisés dans les filtres de messagerie constituent une forme de classification binaire [69].

b) Classification multiclasse

Il s'agit d'une tâche d'apprentissage supervisé dans laquelle les données sont réparties en plusieurs catégories possibles. À la différence de la classification binaire, aucune distinction n'est faite entre résultats normaux et anormaux. Les exemples sont plutôt classés dans plusieurs catégories spécifiques. Par exemple, la catégorisation des types d'attaques réseau dans le jeu de données NSL-KDD [71] peut comporter des classes telles que DoS (Denial of Service Attack), U2R (User to Root Attack), R2L (Root to Local Attack) et Probing Attack [68], [69].

c) Classification multi-étiquettes

Dans le domaine de l'apprentissage automatique, cela représente une extension de la classification multi classe où chaque exemple peut être lié à plusieurs classes ou labels. Cette notion est particulièrement applicable dans des secteurs tels que le classement de texte multi-niveau, où les catégories peuvent être organisées par hiérarchie et ne sont pas mutuellement exclusives. Cette capacité de prédire plusieurs étiquettes pour un même exemple est supportée par des algorithmes sophistiqués d'apprentissage automatique [71].

Ce qui suit présente un récapitulatif des méthodes les plus fréquemment employées et appréciées dans différents secteurs d'application.

2.3.3.2 Naïve Bayes (NB)

Le classifieur Naïve Bayes est un algorithme d'apprentissage supervisé probabiliste fondé sur l'application du théorème de Bayes, dont la particularité repose sur l'hypothèse « naïve » d'indépendance conditionnelle entre les caractéristiques. Mathématiquement, pour une classe donnée C et un vecteur de données X , il simplifie le calcul de la vraisemblance en considérant que chaque attribut contribue de manière indépendante à la probabilité finale, soit :

$$P(X|C) = \prod_{i=1}^n P(x_i|C) \quad (2.1)$$

Où $P(X|C)$ représente la probabilité conditionnelle de l'ensemble des caractéristiques X sachant la classe C , et $P(x_i|C)$ la probabilité conditionnelle de chaque caractéristique x_i appartenant à la classe C .

Malgré cette hypothèse simplificatrice forte d'indépendance conditionnelle entre les caractéristiques, l'algorithme Naïve Bayes est reconnu pour sa grande efficacité computationnelle, sa rapidité d'exécution et sa robustesse, même lorsqu'il est appliqué à des jeux de données de grande dimension ou de taille réduite. Il constitue ainsi une solution de référence particulièrement adaptée aux environnements nécessitant des prédictions en temps réel et sert souvent de modèle de comparaison pour l'évaluation de méthodes de classification plus complexes [72].

2.3.3.3 Régression linéaire, logistique, polynomiale

La régression linéaire, la régression logistique et la régression polynomiale constituent des méthodes fondamentales de l'apprentissage supervisé en Machine Learning. La régression linéaire est utilisée pour modéliser la relation entre une variable dépendante continue et une ou plusieurs variables indépendantes, en supposant une relation linéaire entre elles. En revanche, la

régression logistique est adaptée aux problèmes de classification, où la variable cible est qualitative ; elle repose sur une fonction sigmoïde permettant d'estimer la probabilité d'appartenance à une classe donnée. Quant à la régression polynomiale, elle représente une extension de la régression linéaire permettant de capturer des relations non linéaires en introduisant des termes de degré supérieur (tels que x^2 , x^3 , etc.). Ces trois approches, bien que différentes dans leurs objectifs et leurs formulations, partagent le même principe d'apprentissage à partir de données étiquetées afin de modéliser et prédire des phénomènes réels avec précision [73].

2.3.3.4 K-plus proches voisins (KNN)

L'algorithme des K-plus proches voisins (KNN) constitue un autre modèle d'apprentissage supervisé non-paramétrique couramment utilisé pour résoudre les problèmes de classification. Contrairement aux approches fondées sur l'apprentissage d'une fonction discriminante explicite, cet algorithme repose sur le principe de l'apprentissage dit « paresseux », où le modèle se contente de stocker les données d'entraînement pour n'effectuer ses calculs qu'au moment de l'inférence. Le processus de décision repose sur la proximité géométrique : pour classer une nouvelle instance, l'algorithme mesure la distance la séparant de chaque point du jeu de données, identifie les K voisins les plus proches et lui attribue la catégorie majoritaire par un mécanisme de vote. Cette méthode se distingue par sa grande flexibilité et sa capacité à modéliser des frontières de décision complexes sans nécessiter d'hypothèses préalables sur la distribution des données. Cependant, son efficacité reste étroitement liée au choix de la métrique de distance et à la définition optimale du paramètre K, tout en exigeant une puissance de calcul proportionnelle au volume des données traitées [74].

2.3.3.5 Arbre de décision

Un arbre de décision est un modèle statistique couramment utilisé pour résoudre des problèmes de classification. Il s'agit d'un modèle d'apprentissage supervisé qui représente la connaissance sous forme d'une structure arborescente composée de différents types de nœuds. Plus précisément, un arbre de décision comprend un nœud racine, qui constitue le point de départ et correspond à la caractéristique la plus pertinente pour diviser les données d'entraînement, des nœuds de décision, où sont effectués des tests sur les attributs avec des branches représentant les différents résultats possibles, ainsi que des nœuds feuilles, qui indiquent la classe finale ou la valeur cible des exemples.

Le processus de construction de cet arbre repose sur une division récursive de l'espace des données, dans le but de maximiser la pureté des sous-ensembles obtenus, à l'aide de critères tels que l'entropie.

Par ailleurs, il existe plusieurs types d'arbres de décision selon la nature du problème traité. On distingue principalement les arbres de classification, utilisés lorsque la variable cible est qualitative (catégorielle), et les arbres de régression, employés lorsque la variable cible est quantitative (continue). En outre, certains algorithmes spécifiques permettent de construire ces arbres, tels que ID3, C4.5 ou encore CART (Classification and Regression Trees), chacun se différenciant par les critères de division et les méthodes d'élagage utilisées.

L'un des principaux avantages de ce modèle réside dans sa grande interprétabilité, puisqu'il permet de suivre de manière claire et structurée le raisonnement menant à une prédiction.

Cependant, lorsque l'arbre devient trop complexe, il peut être sujet au surapprentissage (overfitting), ce qui peut nuire à ses performances sur de nouvelles données. Pour remédier à ce problème, des techniques de simplification, telles que l'élagage (pruning), sont généralement utilisées afin d'améliorer sa capacité de généralisation [74].

2.3.3.6 Machines à Vecteurs de Support (SVM)

Les Machines à Vecteurs de Support (SVM) constituent une méthode d'apprentissage supervisé largement utilisée pour les tâches de classification et de régression. Le principe fondamental de ce modèle repose sur la recherche d'un hyperplan optimal permettant de séparer les différentes classes de données dans un espace de grande dimension. Cet hyperplan est choisi de manière à maximiser la marge, c'est-à-dire la distance entre la frontière de décision et les points de données les plus proches, appelés vecteurs de support. Cette propriété confère aux SVM une bonne capacité de généralisation, notamment face à des ensembles de données complexes. Dans les cas où les données ne sont pas linéairement séparables, les SVM utilisent des fonctions noyau (kernels), telles que le noyau linéaire, polynomial ou gaussien (RBF), afin de projeter les données dans un espace de dimension supérieure où une séparation linéaire devient possible. Grâce à cette approche, les SVM sont particulièrement efficaces dans des contextes de haute dimension, comme la classification de texte ou d'images. Cependant, leur performance dépend fortement du choix du noyau et des paramètres associés, ce qui peut rendre leur optimisation plus complexe [76].

2.3.4 Cycle de développement d'un modèle ML

Le processus de développement d'un modèle de Machine Learning est itératif et comprend plusieurs étapes essentielles : la compréhension du problème, la collecte des données, le prétraitement, la sélection du modèle, l'entraînement, l'évaluation, l'optimisation, le déploiement et la surveillance continue. Ce cycle s'inscrit dans les approches standardisées telles que CRISP-DM et les méthodologies modernes d'ingénierie des données [78].




Figure 2.3 : Cycle de développement d'un modèle d'apprentissage automatique.

2.3.5 Avantages et limites du Machine Learning

Le Machine Learning présente de nombreux avantages qui expliquent son adoption croissante dans différents secteurs. Toutefois, il comporte également certaines limitations qu'il convient de prendre en compte pour garantir une utilisation efficace et adaptée aux besoins des applications.

2.3.5.1 Avantages

Le succès du Machine Learning repose sur plusieurs avantages qui en font une technologie incontournable dans de nombreuses applications.

a) Haute précision des prédictions

Le ML permet d'analyser de grandes quantités de données et de produire des résultats plus précis que les méthodes classiques.

b) Automatisation des tâches

Il automatise des tâches complexes comme la classification, la détection de fraude, et la reconnaissance d'images ou de texte.

c) Capacité à traiter de grandes données (Big Data)

Le ML peut exploiter des volumes massifs de données rapidement.

d) Amélioration continue

Les modèles peuvent s'améliorer avec de nouvelles données sans être totalement recréés.

e) Aide à la prise de décision

Il fournit des prédictions utiles pour la santé, la finance, les réseaux, et le marketing.

2.3.5.2 Limites

Bien que le Machine Learning ait démontré son efficacité dans de nombreux domaines, il demeure confronté à plusieurs défis liés à l'interprétation des résultats, à la qualité des données et aux exigences de calcul.

a) Manque d'interprétabilité (boîte noire)

Beaucoup de modèles (comme les réseaux de neurones) sont difficiles à expliquer.

b) Dépendance aux données

Les mauvaises données conduisent aux mauvais résultats.

c) Coût élevé

- Besoin de puissance de calcul
- Besoin de grandes bases de données
- Besoin d'experts

d) Risque de surapprentissage (overfitting)

Le modèle peut apprendre "par cœur" les données au lieu de généraliser [78].

e) Problèmes de sécurité et éthique

- Utilisation abusive des données
- Risques de confidentialité
- Discrimination algorithmique

2.4 Deep Learning

Le Deep Learning est aujourd'hui l'une des technologies les plus performantes de l'intelligence artificielle. Basé sur des réseaux de neurones profonds, il permet de traiter efficacement des données complexes et d'obtenir des résultats remarquables dans de nombreux domaines. Cette section présente ses principes fondamentaux et ses principales caractéristiques.

2.4.1 Définition et relation avec le Machine Learning

Le Deep Learning constitue une sous-discipline spécifique du Machine Learning (ML), se distinguant principalement par l'architecture de ses modèles ainsi que par le degré réduit d'intervention humaine qu'il requiert. Il s'inscrit dans une hiérarchie où l'Intelligence Artificielle englobe le Machine Learning, lequel inclut à son tour le Deep Learning, à l'image d'un système imbriqué.

La différence fondamentale entre ces approches réside dans le traitement des données: contrairement aux méthodes classiques de Machine Learning, qui nécessitent généralement une étape d'extraction manuelle des caractéristiques (feature engineering), le Deep Learning permet

l'apprentissage automatique de ces caractéristiques directement à partir des données brutes, grâce à l'utilisation de réseaux composés de multiples couches de traitement [79].

2.4.2 Réseaux de neurones artificiels (ANN)

Les réseaux de neurones artificiels, briques élémentaires du Deep Learning, s'inspirent de la structure biomimétique du cerveau humain pour modéliser des relations complexes au sein des données. Le cœur de ce système repose sur le neurone artificiel (ou perceptron), qui agrège des signaux d'entrée en leur appliquant des poids et un biais, avant de transformer le résultat via une fonction d'activation (comme ReLU ou Sigmoid) pour générer une sortie. Ces neurones sont organisés en une architecture stratifiée comprenant une couche d'entrée pour la réception des données brutes, plusieurs couches cachées responsables de l'extraction de motifs abstraits dont la multiplicité définit la "profondeur" du réseau et enfin une couche de sortie qui produit la prédiction finale, telle qu'une classification d'image ou une valeur numérique [80].

2.4.3 Architectures majeures (CNN, RNN, LSTM, Transformers)

Cette section présente les principales architectures du Deep Learning, notamment les réseaux de neurones convolutifs (CNN), les réseaux de neurones récurrents (RNN), les réseaux LSTM et les Transformers, qui constituent aujourd'hui les modèles les plus utilisés pour le traitement et l'analyse de données complexes.

2.4.3.1 Convolutional Neural Networks (CNN)

Les Convolutional Neural Networks sont des architectures de Deep Learning spécialement conçues pour le traitement des données à structure spatiale, en particulier les images. Leur principe repose sur l'utilisation de filtres de convolution capables d'extraire automatiquement des caractéristiques pertinentes telles que les contours, les textures et les formes, sans nécessiter une intervention manuelle. Une architecture typique de CNN comprend plusieurs couches de convolution permettant la détection des caractéristiques, suivies de couches de pooling qui réduisent la dimension des données tout en conservant l'information essentielle, puis de couches entièrement connectées (fully connected) utilisées pour la phase de classification. Grâce à leur efficacité, les CNN sont largement appliqués dans divers domaines, notamment en vision par ordinateur pour la reconnaissance d'images et la détection d'objets, en analyse médicale pour l'interprétation d'images médicales, ainsi qu'en reconnaissance faciale [81].

2.4.3.2 Les réseaux de neurones récurrents (RNN)

Les réseaux de neurones récurrents (RNN) sont des modèles adaptés au traitement des données séquentielles, capables d'exploiter les informations issues des étapes précédentes grâce à une

forme de mémoire interne. Toutefois, ces réseaux présentent une limitation importante liée au problème du vanishing gradient, qui rend difficile l'apprentissage des dépendances à long terme. Pour remédier à cette contrainte, une architecture améliorée appelée Long Short-Term Memory (LSTM) a été proposée, introduisant un mécanisme de mémoire permettant de conserver et de gérer l'information sur de longues périodes. Ce modèle repose sur des structures spécifiques contrôlant le flux d'information, ce qui améliore significativement la capacité d'apprentissage des relations temporelles complexes par rapport aux RNN classiques [82].

2.4.3.3 LSTM (Long Short-Term Memory)

Le modèle Long Short-Term Memory (LSTM) constitue une amélioration significative des réseaux de neurones récurrents, développée pour pallier les limites liées à l'apprentissage des dépendances à long terme, notamment le problème du vanishing gradient. Cette architecture repose sur l'introduction d'une cellule de mémoire interne capable de conserver l'information sur de longues séquences, tout en contrôlant son flux à travers des mécanismes spécifiques. Le LSTM intègre ainsi des unités de régulation permettant de sélectionner, de maintenir ou d'ignorer certaines informations au cours du temps, ce qui favorise une meilleure modélisation des relations temporelles complexes. Grâce à ces caractéristiques, il offre une capacité d'apprentissage plus stable et plus efficace que les modèles récurrents traditionnels dans le traitement des données séquentielles [82].

2.4.3.4 Les Transformers

Les Transformers représentent une rupture technologique majeure en Deep Learning, particulièrement pour le Traitement du Langage Naturel (NLP). Contrairement aux modèles séquentiels traditionnels, ils s'appuient sur le mécanisme d'auto-attention (self-attention) pour traiter l'intégralité d'une séquence simultanément, facilitant ainsi la capture des corrélations globales. L'architecture, structurée autour de blocs encodeurs et décodeurs, intègre des encodages positionnels afin de pallier l'absence de récurrence. Cette approche permet une parallélisation accrue des calculs et une gestion optimisée des dépendances à long terme, jetant ainsi les bases de modèles précurseurs tels que BERT et GPT [83].

2.4.4 Entraînement des modèles profonds

L'entraînement est un processus itératif d'optimisation mathématique :

a) Propagation avant (Forward Propagation)

Les données passent à travers le réseau pour générer une prédiction.

b) Fonction de perte (Loss Function)

Calcule l'écart entre la prédiction et la réalité (l'erreur).

c) Rétropropagation (Backpropagation)

L'erreur est renvoyée en arrière dans le réseau pour identifier quels poids sont responsables de l'erreur.

d) Optimiseur (exemple : Descente de gradient)

Ajuste les poids pour réduire la perte lors du prochain passage [84].




Figure 2.4 : Représentation du processus itératif d'entraînement des réseaux de neurones profonds.

2.4.5 Applications et limites du Deep Learning

Malgré les avancées significatives qu'il a apportées dans de nombreux secteurs, le Deep Learning présente à la fois des applications prometteuses et des limitations qui influencent son adoption et son efficacité dans les contextes réels.

2.4.5.1 Applications

Le Deep Learning trouve aujourd'hui des applications majeures dans plusieurs domaines clés : en santé, il est utilisé pour l'analyse d'images médicales afin de détecter automatiquement des anomalies telles que les tumeurs ; dans le secteur automobile, il constitue le cœur des systèmes de navigation et de perception des véhicules autonomes ; en finance, il permet la détection de fraudes complexes en temps réel grâce à l'analyse de grands volumes de données ; enfin, dans le domaine du divertissement, il alimente les systèmes de recommandation personnalisée, comme ceux utilisés par Netflix ou Spotify, afin de proposer des contenus adaptés aux préférences des utilisateurs.

2.4.5.2 Limites

Le Deep Learning présente toutefois plusieurs limites importantes : il nécessite des volumes très importants de données étiquetées pour atteindre de bonnes performances, ce qui peut être coûteux et difficile à obtenir ; il requiert également une puissance de calcul élevée, impliquant l'usage de ressources matérielles spécialisées telles que les GPU ou les TPU ; de plus, son fonctionnement est souvent assimilé à une « boîte noire », rendant l'interprétation et l'explication des décisions prises par les modèles complexes ; enfin, lorsque les données d'entraînement sont biaisées, les modèles de Deep Learning ont tendance à reproduire, voire amplifier, ces biais, ce qui peut poser des problèmes éthiques et décisionnels [44].

2.5 Comparaison et synthèse IA – ML – DL

L'intelligence artificielle, le Machine Learning et le Deep Learning sont des domaines étroitement liés qui se distinguent par leurs approches, leurs méthodes et leurs niveaux de complexité. Afin de mieux comprendre leurs relations et leurs spécificités, il est nécessaire d'examiner leur organisation hiérarchique ainsi que leurs principales caractéristiques.

2.5.1 Relation hiérarchique entre IA, ML et DL

L'Intelligence Artificielle (IA), le Machine Learning (ML) et le Deep Learning (DL) sont des domaines qui ne sont pas autonomes, mais plutôt des composants imbriqués hiérarchiquement. Effectivement, l'Intelligence Artificielle couvre le domaine le plus vaste, intégrant toutes les méthodes destinées à permettre aux machines de reproduire certaines aptitudes de l'intelligence humaine, y compris via des systèmes experts basés sur des règles logiques du genre « si-alors ». Dans ce secteur, l'apprentissage automatique est une branche spécialisée qui s'appuie sur des techniques statistiques pour permettre aux systèmes d'évoluer automatiquement à partir des données, sans avoir besoin de coder chaque règle spécifiquement. Enfin, le Deep Learning s'inscrit comme une branche spécialisée du Machine Learning, basée sur l'utilisation de réseaux de neurones artificiels profonds comportant plusieurs couches cachées, et s'inspirant du fonctionnement du cerveau humain pour traiter efficacement des données complexes et non structurées [44].

2.5.2 Comparaison en termes de données, complexité et interprétabilité

Le Machine Learning et le Deep Learning se distinguent par plusieurs aspects liés aux données, à la complexité des modèles et à leur interprétabilité. Le Machine Learning est généralement efficace avec des jeux de données de taille faible ou moyenne et nécessite souvent une intervention humaine pour l'extraction et la sélection des caractéristiques pertinentes. De plus, ses modèles présentent une complexité relativement modérée et peuvent être exécutés sur des

processeurs standards, tout en offrant une meilleure transparence dans le processus de prise de décision. À l'inverse, le Deep Learning repose sur des réseaux de neurones profonds capables d'apprendre automatiquement les caractéristiques à partir des données brutes. Cette approche nécessite généralement de très grands volumes de données ainsi qu'une puissance de calcul importante, souvent assurée par des accélérateurs matériels tels que les GPU ou les TPU. Bien que le Deep Learning permette d'obtenir des performances remarquables sur des tâches complexes, son fonctionnement reste souvent difficile à interpréter en raison du grand nombre de paramètres impliqués dans le processus d'apprentissage [85].

2.5.3 Choix de la méthode selon le contexte applicatif

Le choix d'une méthode de Machine Learning (ML) ou de Deep Learning (DL) repose sur une analyse multidimensionnelle du contexte applicatif. Pour les problèmes impliquant des données structurées (tableaux, variables numériques) et nécessitant une forte interprétabilité pour justifier les décisions, le ML classique (ex: Random Forest, SVM) reste la norme [86]. À l'inverse, le DL excelle sur les données non structurées (images, signaux bruts, texte) grâce à sa capacité d'extraction automatique de caractéristiques, éliminant ainsi l'étape manuelle de feature engineering indispensable au ML [87]. Sur le plan opérationnel, le volume de données est un pivot majeur : alors que le ML est efficace sur des jeux de données réduits, le DL nécessite des volumes massifs (Big Data) pour surpasser les algorithmes traditionnels [88]. Ces performances accrues du DL se font toutefois au prix de ressources de calcul intensives, exigeant des GPU/TPU, là où le ML peut s'exécuter sur de simples CPU ou systèmes embarqués [89]. Enfin, le choix doit intégrer la dette technique et le coût de maintenance : un modèle de DL complexe peut offrir un gain de précision marginal au détriment d'une opacité ("boîte noire") et d'un coût de calcul injustifié selon les contraintes métiers [90].

2.6 Enjeux actuels et perspectives

L'essor rapide de l'intelligence artificielle et du Deep Learning s'accompagne de nombreux défis techniques, éthiques et sociétaux. Il est donc essentiel d'examiner les principaux enjeux actuels ainsi que les perspectives futures qui orienteront le développement de ces technologies.

2.6.1 Éthique et biais algorithmiques

Les systèmes d'intelligence artificielle, notamment ceux basés sur le Machine Learning et le Deep Learning, soulèvent des enjeux éthiques majeurs liés à la prise de décision automatisée. En effet, ces modèles apprennent à partir de données historiques qui peuvent contenir des biais implicites, conduisant ainsi à des décisions discriminatoires ou injustes. Ces biais peuvent provenir de différentes sources, telles que la qualité des données, leur représentativité ou encore

les choix de conception des modèles. Par ailleurs, le caractère souvent opaque des modèles complexes, en particulier dans le cas du Deep Learning, rend difficile l'interprétation des décisions prises, ce qui pose un problème d'explicabilité et de transparence. Cette situation soulève des questions fondamentales concernant la responsabilité des décisions automatisées, ainsi que le respect des droits fondamentaux des individus. Ainsi, il devient essentiel de mettre en place des mécanismes de contrôle, d'audit et de régulation afin de garantir une utilisation éthique, équitable et responsable des systèmes intelligents [91].

2.6.2 Explicabilité et robustesse des modèles

L'explicabilité des modèles de Machine Learning constitue un enjeu majeur pour garantir leur robustesse et leur fiabilité dans des contextes critiques. En effet, les modèles complexes, souvent qualifiés de « boîtes noires », produisent des prédictions sans fournir d'explications claires sur les mécanismes internes ayant conduit à ces résultats. Cette absence de transparence limite la capacité à détecter les erreurs, les biais ou les comportements inattendus, ce qui fragilise leur robustesse face à des données nouvelles ou perturbées. Par ailleurs, une explication apparente peut parfois être trompeuse, car elle ne reflète pas nécessairement les véritables relations apprises par le modèle, souvent basées sur des corrélations plutôt que sur des causalités. Ainsi, l'explicabilité ne doit pas être considérée uniquement comme un outil d'interprétation, mais aussi comme un moyen d'évaluer la solidité et la fiabilité des modèles, en permettant une meilleure compréhension de leurs limites et de leurs conditions d'utilisation [92].

2.6.3 Tendances futures de l'IA

Les perspectives d'avenir de l'intelligence artificielle indiquent la mise en place de systèmes plus performants, plus autonomes, plus accessibles. L'IA s'oriente vers des modèles multimodaux traitant en parallèle plusieurs types de données (texte, image, audio). En outre, des efforts sont consentis pour concevoir des modèles qui, tout en étant plus légers et plus efficaces, permettent de diminuer les coûts computationnels tout en maintenant un niveau de performance. La démocratisation de l'IA constitue aussi une tendance forte, grâce à l'apparition d'outils allégés permettant son appropriation par des non-spécialistes, alors que se met en place des systèmes intelligents autonomes, sans intervention humaine, prenant la décision. Tout ceci participe à l'intégration progressive de l'IA dans de nombreux secteurs, accompagnée de bouleversements économiques et sociaux [93].

2.7 Synthèse des concepts clés

L'Intelligence Artificielle (IA) a évolué, passant d'une collection de systèmes experts stricts à des structures capables de tirer des leçons de l'expérience. L'apprentissage automatique (ML) a permis à une machine de perfectionner ses aptitudes dans une tâche spécifique sans nécessité

d'être spécifiquement codée pour chaque situation [44]. Cette progression culmine avec le Deep Learning (DL), qui exploite des réseaux de neurones profonds pour fragmenter les données en strates d'abstraction successives. Cette structure facilite la conversion de données non traitées en concepts de complexité croissante, ce qui permet de résoudre des problèmes qui dépassaient auparavant les capacités de l'informatique traditionnelle [44, 94].

2.8 Apport du ML et du DL à l'IA moderne

Les nouvelles propositions d'intégration du Machine Learning et du Deep Learning ont donné un nouvel élan à l'efficacité de l'intelligence artificielle. L'un des apports majeurs est la possibilité d'extraire automatiquement les caractéristiques, les modèles de Deep Learning s'occupant eux-mêmes d'identifier les motifs intéressants dans les données et réduisant ainsi la dépendance à l'ingénierie manuelle, ce qui favorise la capacité d'adaptation des systèmes. De plus, ces méthodes se révèlent efficaces pour gérer les données non structurées telles que la voix, les images et les signaux complexes, ce qui favorise une interprétation plus intuitive d'environnements non standardisés. Finalement, en raison de l'énorme amélioration de la capacité de calcul, principalement grâce aux GPU, et à l'accès à d'importantes quantités d'informations, le Machine Learning et le Deep Learning affichent des performances de haut niveau et une meilleure généralisation. Cela les rend particulièrement propices à être utilisés pour des applications en temps réel, telles que le traitement du signal et les réseaux communicants intelligents [94, 95].

Pour conclure, la transition de l'IA symbolique à l'IA fondée sur le Deep Learning a permis d'accomplir une avancée majeure : la mise en place de systèmes non seulement prédictifs, mais également aptes à ajuster leur perception du monde en fonction des données reçues. Cette évolution souligne l'importance grandissante des techniques d'apprentissage dans l'élaboration de systèmes intelligents efficaces. Dans cette lignée, le prochain chapitre met l'accent sur les mises en pratique de ces progrès, particulièrement dans des secteurs essentiels tels que la télécommunication et le traitement du signal.

2.9 Conclusion

Ce chapitre a permis d'établir les bases théoriques nécessaires à la compréhension de l'Intelligence Artificielle, du Machine Learning et du Deep Learning, ainsi que de leur rôle dans les systèmes intelligents modernes. Nous avons tout d'abord présenté le contexte et les motivations ayant conduit au développement de l'IA, en mettant en évidence ses capacités d'apprentissage, de raisonnement et de prise de décision autonome. L'évolution des différentes approches, depuis l'IA symbolique jusqu'aux méthodes connexionnistes basées sur les données, a également été étudiée afin de mieux comprendre les transformations majeures de ce domaine.

Nous avons ensuite analysé les principaux éléments constituant un système d'intelligence artificielle, notamment les données, les modèles d'apprentissage, les algorithmes, les unités de traitement ainsi que les mécanismes de prise de décision. Cette étude a permis de souligner l'importance des ressources matérielles et logicielles dans le développement et l'exécution des modèles intelligents.

Par ailleurs, les concepts fondamentaux du Machine Learning ont été abordés à travers les différents types d'apprentissage et les principaux algorithmes de classification et de prédiction. Ces méthodes ont montré la capacité des systèmes à apprendre automatiquement à partir des données sans être explicitement programmés pour chaque situation. Les avantages et les limites du Machine Learning ont également permis de mettre en évidence les défis liés à la qualité des données, à la généralisation des modèles et à leur interprétabilité.

Le Deep Learning a également été étudié en présentant les réseaux de neurones artificiels et les architectures majeures telles que les CNN, les RNN et les LSTM. Cette approche représente une évolution avancée du Machine Learning grâce à l'utilisation de réseaux de neurones profonds capables d'extraire automatiquement des caractéristiques complexes à partir de données brutes. L'organisation des données en plusieurs niveaux d'abstraction permet ainsi de traiter efficacement des informations non structurées telles que les images, la voix et les signaux complexes, notamment dans les domaines du traitement du signal et des télécommunications.

Nous avons également montré que l'intégration du Machine Learning et du Deep Learning a considérablement renforcé les performances de l'intelligence artificielle moderne. Les progrès réalisés dans les capacités de calcul, notamment grâce aux GPU, ainsi que la disponibilité de grandes quantités de données, ont favorisé le développement de modèles plus performants, plus robustes et capables de fonctionner dans des applications en temps réel. Cette évolution marque ainsi la transition d'une IA purement symbolique vers des systèmes intelligents capables d'adapter automatiquement leur comportement en fonction des données reçues.

Enfin, une comparaison entre l'IA, le Machine Learning et le Deep Learning a permis de clarifier leurs relations, leurs domaines d'application ainsi que leurs contraintes respectives. Les enjeux actuels liés à l'éthique, aux biais algorithmiques, à l'explicabilité et à la robustesse des modèles ont également été présentés afin de mieux situer les défis futurs de ces technologies.

Le chapitre suivant sera consacré à la simulation et à la mise en œuvre pratique du modèle CNN, ainsi qu'à l'analyse des résultats obtenus dans le cadre de la reconnaissance automatique des modulations. Le chapitre suivant sera consacré à la simulation, à l'évaluation des performances et à l'étude comparative du modèle AMR proposé, afin d'analyser son efficacité et de comparer ses résultats à ceux des approches existantes.

CHAPITRE 3
SIMULATION, EVALUATION DES PERFORMANCES
ET ETUDE COMPARATIVE DU MODELE AM

3.1 Introduction

Ce chapitre présente le cadre méthodologique adopté pour le déploiement et la validation de notre modèle de reconnaissance automatique des modulations (AMC) basé sur l'apprentissage profond. Dans un premier temps, les caractéristiques du jeu de données RadioML2016.10a, largement utilisé dans ce domaine, sont détaillées. Cette présentation permet de mettre en évidence la structure des signaux sous forme de composantes I/Q, le volume des données disponibles, ainsi que la diversité des schémas de modulation et des niveaux de rapport signal sur bruit (SNR) intégrés. Ces caractéristiques permettent de reproduire des conditions de transmission réalistes et de fournir un environnement adapté à l'évaluation des performances du modèle proposé.

Ensuite, nous abordons les principales métriques d'évaluation utilisées pour mesurer les performances du modèle, notamment l'accuracy, la précision, le rappel, le F1-score, les courbes ROC/AUC ainsi que la matrice de confusion. Ces métriques permettent d'analyser la capacité du système à distinguer correctement les différentes modulations et à évaluer sa robustesse face au bruit.

Enfin, nous présentons l'architecture proposée du modèle de classification des signaux. Cette architecture hybride repose sur l'exploitation des signaux I/Q à travers des couches convolutionnelles Conv1D combinées à des informations contextuelles liées au rapport signal/bruit (SNR). L'objectif est d'améliorer les performances de classification en extrayant efficacement les caractéristiques discriminantes des signaux dans différentes conditions de transmission.

3.2 Description du dataset RadioML 2016.10.a

Utilisée comme standard pour tester les algorithmes de classification automatique des modulations (AMC), la base de données RML2016a (RadioML 2016.10a) simule un environnement de communication réaliste. Sa modélisation inclut des dégradations de signal concrètes, notamment des effets de bruit, de dérive fréquentielle et de gigue temporelle. Elle contient des signaux I/Q complexes générés pour 11 types de modulations (analogiques et numériques) suivantes :

1. BPSK (Binary Phase Shift Keying): Cette méthode de modulation utilise deux états de phase distincts pour transmettre les données binaires : le passage du bit 0 au bit 1 (et inversement) se traduit graphiquement par une inversion de phase de 180° .
2. QPSK (Quadrature Phase Shift Keying): Utilise quatre phases différentes (0° , 90° , 180° , 270°) pour coder deux bits par symbole.

3. 8PSK (8-Phase Shift Keying): Modulation par déplacement de phase à huit états (8-PSK ou MDP8) permet d'associer trois bits de données à chaque symbole transmis. Cette configuration offre une efficacité spectrale accrue en augmentant le débit d'information dans une bande passante donnée.
4. QAM16 (16-Quadrature Amplitude Modulation): Reposant sur deux porteuses orthogonales, cette technique associe des variations d'amplitude et de phase pour encoder quatre bits au sein d'un même symbole.
5. QAM64 (64-Quadrature Amplitude Modulation): Extension du QAM16 avec 64 symboles, permettant de coder 6 bits par symbole.
6. GFSK (Gaussian Frequency Shift Keying): Cette technique de modulation de fréquence intègre un pré-filtrage gaussien afin d'adoucir les transitions de phase, ce qui permet de réduire l'encombrement spectral et de limiter les interférences adjacentes.
7. CPFSK (Continuous Phase Frequency Shift Keying): Variante de FSK avec une phase continue, réduisant la largeur de bande occupée.
8. AM-DSB (Amplitude Modulation - Double Side Band): La modulation d'amplitude consiste à faire varier l'enveloppe d'un signal porteuse en fonction des variations du signal utile, tout en maintenant sa fréquence et sa phase constantes.
9. AM-SSB (Amplitude Modulation - Single Side Band): Se caractérise par la transmission exclusive d'une seule bande latérale (USB ou LSB). Ce procédé supprime la redondance spectrale intrinsèque à l'AM classique, offrant ainsi une efficacité spectrale maximale et une réduction significative de la puissance consommée par le système d'émission.
10. FM (Frequency Modulation): Transmet l'information en faisant varier la fréquence instantanée de la porteuse proportionnellement au signal modulant, à amplitude constante
11. WB-FM (Wideband Frequency Modulation): Version à large bande de la FM, comme utilisée dans la radio FM, offrant une meilleure qualité sonore au prix d'une bande passante plus large.

Pour chaque type de modulation, le signal reçu est évalué à travers vingt valeurs du rapport signal sur bruit (SNR), s'étalant de -20 dB à +18 dB avec un pas de 2 dB. La base de données associe ainsi 1 000 exemples de signaux à chaque combinaison de modulation et de niveau de bruit. Plus précisément, chaque échantillon se compose d'une séquence complexe de 128 points (I/Q), indexée par son étiquette de modulation et son SNR respectif. Par sa structure rigoureuse et son grand volume de données annotées, cet ensemble s'avère particulièrement propice à l'entraînement de modèles d'apprentissage profond. Il offre ainsi un cadre d'expérimentation

réaliste pour tester la robustesse des algorithmes face aux fluctuations du canal, ouvrant la voie à des applications concrètes en radio cognitive et en guerre électronique [97].

La figure 3.1 présente les signaux issus du dataset RadioML2016.10a pour différentes techniques de modulation numériques et analogiques, observés à un rapport signal sur bruit (SNR) de 2 dB. Chaque sous-graphe illustre l'évolution temporelle des composantes en phase (I) et en quadrature (Q), qui représentent la structure complexe du signal radio. Cette visualisation permet d'analyser le comportement des différentes modulations face au bruit et de mettre en évidence leurs caractéristiques distinctives, utiles pour les tâches de classification automatique et de reconnaissance de modulation en Deep Learning.



Figure 3.1 : Visualisation des composantes I/Q des modulations RadioML2016.10a à un SNR de 2 dB.

Voici une description détaillée de sa composition :

3.2.1 Structure du Signal

Format I/Q

- Les signaux sont fournis sous forme de composantes In-phase (I) et Quadrature (Q). Le dataset RadioML2016.10a fournit des signaux radio complexes en bande de base sous forme de composantes I/Q (In-phase et Quadrature), chaque échantillon étant représenté

par une matrice réelle de dimension 2×128 , où la première ligne correspond à la partie I et la seconde à la partie Q, sur 128 échantillons temporels consécutifs. Chaque signal peut ainsi être modélisé par $s[n]=I[n]+jQ[n]$, ce qui permet de préserver à la fois l'amplitude et la phase du signal modulé.

Dimensions

- Chaque échantillon est une matrice de 2×128 .
- La première ligne correspond à la composante I.
- La seconde ligne correspond à la composante Q.
- Les 128 colonnes représentent les échantillons temporels successifs [97].

Contenu du Dataset

- Le dataset contient un total de 220 000 échantillons ($11 \text{modulations} \times 20 \text{niveaux de SNR} \times 1000 \text{exemples} = 220000 \text{ échantillons total}$), répartis comme suit:
 - **11 Modulations différentes**
 - Numériques (8) : BPSK, QPSK, 8PSK, 16QAM, 64QAM, BFSK, CPFSK, GMSK.
 - Analogiques (3): AM-DSB (Amplitude Modulation Double Side Band), AM-SSB (Single Side Band), WBFM (Wideband FM) [98].
 - **Niveaux de Bruit (SNR)**
 - Les signaux ont été générés avec 20 niveaux de rapport signal sur bruit différents, allant de -20 dB à +18 dB (par pas de 2 dB).

Équilibre

- Il y a exactement 1 000 échantillons pour chaque combinaison (Exemple : 1000 échantillons de QPSK à +10 dB) [99].

3.2.2 Utilisations principales

Le dataset RadioML 2016.10a est principalement utilisé pour évaluer les performances des modèles de Deep Learning, notamment les réseaux de neurones convolutifs (CNN), dans la tâche de classification automatique des modulations. Il permet également d'analyser la robustesse des modèles en fonction du rapport signal sur bruit (SNR). Ces travaux s'inscrivent dans le contexte des systèmes radio intelligents, où l'identification automatique des signaux est essentielle [100].

3.3 Les métriques d'évaluations

L'évaluation des modèles sur le dataset RML2016.10a repose principalement sur la capacité du système à classifier correctement les modulations malgré le bruit. Voici les métriques et outils d'analyse incontournables utilisés dans la littérature scientifique pour les datasets.

3.3.1 Accuracy (Exactitude)

Elle correspond à la proportion de prédictions correctes par rapport à l'ensemble des observations.

$$Precision = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.1)$$

3.3.2 Précision et Rappel

Ces métriques sont principalement sollicitées pour résoudre le problème des classes déséquilibrées, où une mesure classique pourrait masquer des faiblesses locales. En offrant une analyse plus fine des erreurs de prédiction, elles constituent des indicateurs clés pour valider la robustesse du système face à des jeux de données complexes.

3.3.2.1 Précision

La précision mesure la proportion d'observations réellement positives parmi l'ensemble des prédictions identifiées comme positives par le modèle.

$$Precision = \frac{TP}{TP + FP} \quad (3.2)$$

3.3.2.2 Rappel

Le rappel quantifie la capacité du modèle à identifier l'intégralité des instances appartenant réellement à la classe positive.

$$Recall = \frac{TP}{TP + FN} \quad (3.3)$$

3.3.3 F1-score

Le F1-score est un indicateur de compromis qui permet de stabiliser l'évaluation du modèle en pondérant équitablement la précision et le rappel.

$$F1 = 2 \times \frac{Precision * Recall}{Precision + Recall} \quad (3.4)$$

3.3.4 ROC et AUC (Receiver Operating Characteristic & Area Under Curve)

Parmi les métriques couramment utilisées pour évaluer les performances d'un modèle de classification, la courbe ROC et l'AUC occupent une place importante en raison de leur capacité à mesurer le pouvoir discriminant du modèle.

3.3.4.1 ROC

ROC est une courbe permettant d'évaluer la capacité de discrimination d'un modèle en mettant en corrélation le taux de vrais positifs (TPR) et le taux de faux positifs (FPR) pour l'ensemble des seuils de décision possibles.

$$TRP = \frac{TP}{(TP + FN)} \quad (3.5)$$

$$FRP = \frac{FP}{(FP + TN)} \quad (3.6)$$

3.3.4.2 AUC

Cette métrique correspond à l'intégrale de la fonction de performance entre le taux de vrais positifs et le taux de faux positifs. Une AUC de 0,5 indique un modèle aux performances équivalentes à un tirage aléatoire, tandis qu'une valeur de 1,0 caractérise un classificateur parfait [101].

3.3.5 Matrice de confusion

Outil de visualisation incontournable, la matrice de confusion permet d'appréhender globalement la fiabilité de la classification en mettant en relief les performances par classe. Elle facilite l'identification des confusions récurrentes (notamment entre des modulations proches comme la QPSK et la 8PSK) et offre une base d'analyse précise pour corriger les erreurs spécifiques du modèle sur les signaux les plus complexes [102].

3.4 Architecture du modèle de classification des types de modulation

Le modèle CNN utilisé dans ce travail, baptisé CNNWithSNR, est un réseau de neurones convolutif unidimensionnel léger, conçu pour la classification des modulations en tenant explicitement compte du rapport signal/bruit. Il traite des signaux IQ de forme (lot, 2, 128) à travers trois couches Conv1d (64, 128 et 128 filtres avec des tailles de noyau de 5, 5 et 3, respectivement), chacune suivie d'une normalisation par lots, d'une activation ReLU et d'un max pooling (à l'exception de la couche finale qui utilise un average pooling adaptatif). Ce bloc convolutif produit un vecteur de caractéristiques de 128 dimensions représentant le contenu du signal. En parallèle, la valeur scalaire du rapport signal/bruit (normalisée) traverse deux couches entièrement connectées (1 → 16 unités) dotées de fonctions ReLU et de dropout, générant ainsi une représentation du rapport signal/bruit de 16 dimensions. Les deux branches sont ensuite concaténées en un vecteur de 144 dimensions, puis transmises à un classificateur comportant

deux couches linéaires (128 unités cachées, puis num_classes sorties) et un paramètre de dropout (0,3), ce qui donne les prédictions de modulation finales.

Cette architecture utilise explicitement le rapport signal/bruit (SNR) connu comme entrée auxiliaire, ce qui permet au classificateur d'adapter ses seuils de décision en fonction du niveau de bruit, une capacité essentielle pour garantir des performances robustes dans des conditions de canal variables. Avec environ 180 000 à 200 000 paramètres entraînables et l'absence de couches récurrentes (pas de LSTM), le modèle est efficace sur le plan informatique et rapide à entraîner. La figure 3.2 montre l'architecture du modèle CNNWithSNR proposé.




Figure 3.2 : Architecture du modèle CNNWithSNR.

3.5 Résultats et discussions

La figure 3.3 illustre l'évolution de l'exactitude (Accuracy) du modèle durant les phases d'entraînement et de validation sur 50 époques. Les courbes permettent d'évaluer les performances globales du modèle ainsi que sa capacité de généralisation sur des données non vues.

On observe une amélioration progressive de l'accuracy au fil des itérations, avec une convergence stable des courbes d'entraînement et de validation autour de 63 %, indiquant un apprentissage efficace et une absence significative de surapprentissage (Overfitting).




Figure 3.3 : Évolution de l'accuracy d'entraînement et de validation du modèle au cours des époques

La figure 3.4 représente l'évolution de la fonction de perte (Loss) du modèle pendant les phases d'entraînement et de validation au cours des différentes époques. Cette métrique permet d'évaluer l'erreur de prédiction du modèle et de suivre la qualité de l'apprentissage au fil du temps.

On observe une diminution progressive des valeurs de perte, traduisant une amélioration des performances du modèle. Malgré quelques fluctuations au début de l'apprentissage, notamment au niveau de la validation, les courbes deviennent ensuite stables et convergentes, ce qui indique un entraînement efficace et une bonne capacité de généralisation du modèle.

Les valeurs des métriques precision, recall, et F1-score pour les 11 classes de modulation sont données par le rapport de classification (voir Figure 3.5).




Figure 3.4 : Évolution de la fonction de perte (Loss) durant l'entraînement et la validation du modèle.

	precision	recall	f1-score	support
8PSK	0.7926	0.5980	0.6817	2000
AM-DSB	0.4738	0.7745	0.5880	2000
AM-SSB	0.5018	0.7880	0.6131	2000
BPSK	0.7053	0.7025	0.7039	2000
CPFSK	0.7891	0.6530	0.7146	2000
GFSK	0.6620	0.7030	0.6819	2000
PAM4	0.8255	0.7595	0.7911	2000
QAM16	0.6173	0.5855	0.6010	2000
QAM64	0.6793	0.7435	0.7100	2000
QPSK	0.7483	0.6200	0.6782	2000
WBFM	0.6052	0.2200	0.3227	2000
accuracy			0.6498	22000
macro avg	0.6728	0.6498	0.6442	22000
weighted avg	0.6728	0.6498	0.6442	22000

Figure 3.5 : Rapport de classification

Le rapport de classification montre que le modèle CNN+SNR atteint une précision globale de 64,98 % sur l'ensemble de test, très proche de la meilleure précision obtenue en validation (64,45 %), ce qui indique une bonne capacité de généralisation sans surapprentissage. Les performances varient toutefois de manière significative selon les 11 classes de modulation.

La modulation PAM4 obtient le meilleur score F1 (0,7911), grâce à une précision élevée (0,8255) et un rappel solide (0,7595), tandis que les modulations BPSK et CPFSK affichent également de bonnes performances ($F1 \approx 0,70-0,71$). À l'inverse, la classe la plus problématique est WBFM, qui présente un rappel très faible de seulement 0,22 et un score F1 de 0,3227, ce qui signifie que le modèle échoue presque systématiquement à l'identifier correctement.

Les deux autres modulations analogiques, AM-DSB et AM-SSB, affichent des rappels élevés (0,7745 et 0,7880), mais des précisions très faibles (0,4738 et 0,5018), indiquant qu'elles sont fréquemment prédites à tort comme faux positifs — probablement en raison de confusions mutuelles et avec WBFM. Parmi les modulations numériques, QAM16 et QPSK présentent également des performances inférieures, avec des scores F1 compris entre 0,60 et 0,68, tandis que 8PSK et QAM64 obtiennent des résultats modérément meilleurs ($F1 > 0,68$).

Les moyennes macro et pondérée sont identiques ($F1 = 0,6442$) en raison de l'équilibre du nombre d'échantillons par classe, ce qui confirme que les performances globales sont principalement pénalisées par les classes analogiques, en particulier WBFM. Ces résultats montrent que, bien que le CNN conditionné par le SNR fonctionne de manière satisfaisante pour la majorité des modulations numériques (notamment PAM4, BPSK et CPFSK), il éprouve des

difficultés à discriminer les formes d'onde analogiques. Cela suggère que l'utilisation de séquences d'entrée plus longues, de représentations alternatives (par exemple des spectrogrammes), ou de mécanismes spécifiques dédiés aux modulations analogiques serait nécessaire pour améliorer la robustesse du modèle.




Figure 3.6 : Matrice de confusion du modèle CNNWithSNR pour tous les niveaux de SNR (All SNR)

La figure 3.6 présente la matrice de confusion obtenue à partir du modèle CNNWithSNR évalué sur l'ensemble des niveaux de rapport signal/bruit (All SNR). Cette matrice permet d'analyser les performances globales du modèle dans la reconnaissance des différentes modulations radio. Les valeurs situées sur la diagonale principale correspondent aux classifications correctes, tandis que les valeurs hors diagonale représentent les confusions entre certaines classes de modulation. Cette analyse permet d'évaluer la robustesse du modèle CNNWithSNR face aux variations du bruit et d'identifier les modulations les plus difficiles à distinguer.

Les figures 3.7 à 3.12 présentent les matrices de confusion obtenues pour différents niveaux de rapport signal sur bruit (SNR). Ces résultats mettent clairement en évidence l'influence du bruit sur les performances du modèle CNNWithSNR de classification des modulations. Pour des valeurs faibles de SNR, notamment à -12 dB et -8 dB, les matrices montrent une forte dispersion des prédictions avec de nombreuses confusions entre certaines classes proches telles que BPSK/QPSK, AM-DSB/WBFM et QAM16/QAM64. Cela traduit la difficulté du modèle à extraire des caractéristiques discriminantes lorsque les signaux sont fortement dégradés par le bruit. À mesure que le SNR augmente vers -4 dB puis 4 dB, la diagonale principale devient

progressivement plus dominante, indiquant une amélioration significative du taux de classification correcte et une réduction des erreurs. Pour des conditions plus favorables, notamment à 8 dB et 12 dB, les matrices sont largement dominées par la diagonale principale, ce qui reflète une très bonne capacité de reconnaissance des modulations. Certaines classes comme PAM4, BPSK et GFSK sont alors détectées avec une grande précision, tandis que les confusions restantes concernent principalement des modulations présentant des caractéristiques spectrales similaires, notamment QAM16 et QAM64. La matrice de confusion globale obtenue sur l'ensemble des SNR confirme également cette tendance générale et met en évidence la robustesse du modèle CNNWithSNR face au bruit ainsi que son efficacité croissante lorsque les conditions de transmission deviennent plus favorables.

True	8PSK -	0	10	33	6	5	17	5	6	0	9	0
	AM-DSB -	1	64	17	4	1	2	5	0	0	5	3
	AM-SSB -	0	9	44	11	3	10	4	3	0	7	0
	BPSK -	2	13	36	13	6	13	9	5	0	13	0
	CPFSK -	3	12	43	11	6	20	4	3	0	9	0
	GFSK -	0	17	31	14	1	20	5	6	0	6	0
	PAM4 -	2	9	10	9	6	4	29	10	0	8	5
	QAM16 -	1	4	6	8	8	9	11	53	12	3	4
	QAM64 -	0	0	0	0	0	0	3	2	101	0	0
	QPSK -	1	11	28	13	4	8	7	3	0	8	1
	WBFM -	0	60	19	4	3	14	4	7	0	5	4
		Predicted										
		BPSK	AM-DSB	AM-SSB	BPSK	CPFSK	GFSK	PAM4	QAM16	QAM64	QPSK	WBFM

Figure 3.7 : Matrice de confusion du modèle de classification pour un SNR de -12 dB.




Figure 3.8 : Matrice de confusion du modèle de classification pour un SNR de -8 dB




Figure 3.9 : Matrice de confusion du modèle de classification pour un SNR de -4 dB.




Figure 3.10 : Matrice de confusion du modèle de classification pour un SNR de 4 dB.




Figure 3.11 : Matrice de confusion du modèle de classification pour un SNR de 8 dB.




Figure 3.12: Matrice de confusion du modèle de classification pour un SNR de 12 dB.

SNR (dB)	Accuracy	Precision	Recall	F1-score	Samples
-20	0.1105	0.0855	0.1105	0.0869	1041
-18	0.1292	0.1527	0.1292	0.1097	1107
-16	0.1458	0.1282	0.1458	0.1233	1125
-14	0.2106	0.1722	0.2106	0.1810	1092
-12	0.2948	0.2731	0.2948	0.2678	1126
-10	0.4040	0.4034	0.4040	0.3873	1047
-8	0.5379	0.5336	0.5379	0.5249	1069
-6	0.6688	0.6664	0.6688	0.6581	1102
-4	0.8040	0.7950	0.8040	0.7804	1112
-2	0.8564	0.8666	0.8564	0.8373	1107
0	0.8953	0.9046	0.8953	0.8837	1117
2	0.9051	0.9251	0.9051	0.8980	1075
4	0.8897	0.9128	0.8897	0.8839	1142
6	0.8799	0.9009	0.8799	0.8735	1116
8	0.8528	0.8862	0.8528	0.8402	1141
10	0.8774	0.8990	0.8774	0.8708	1126
12	0.8820	0.9000	0.8820	0.8744	1136
14	0.8583	0.8789	0.8583	0.8494	1129
16	0.8813	0.9011	0.8813	0.8728	1070
18	0.8706	0.8885	0.8706	0.8628	1020

Tableau 3.1: Evaluation des métriques par SNR.

Le tableau 3.1 présente l'évaluation par SNR, qui met en évidence une tendance claire et attendue : les performances de classification s'améliorent progressivement à mesure que le

rapport signal/bruit augmente, passant de niveaux très faibles à des niveaux modérés, puis se stabilisent et diminuent légèrement aux SNR les plus élevés.

Au SNR le plus faible de -20 dB, la précision n'est que de $11,05$ % avec un score F1 de $0,0869$, ce qui indique que le modèle se comporte à peine mieux qu'un tirage aléatoire (avec 11 classes, une précision aléatoire serait d'environ 9 %). Lorsque le SNR augmente, toutes les métriques progressent de manière cohérente : la précision atteint $29,48$ % à -12 dB, $53,79$ % à -8 dB, $66,88$ % à -6 dB et $80,40$ % à -4 dB.

Les meilleures performances sont observées autour de 0 à 2 dB, où la précision culmine à $89,53$ % (0 dB) et $90,51$ % (2 dB), avec des scores F1 correspondants de $0,8837$ et $0,8980$. Au-delà de ce pic, les performances montrent une dégradation très légère mais progressive : à 4 dB, la précision descend à $88,97$ %, à 8 dB à $85,28$ %, et à 18 dB à $87,06$ %, tout en restant supérieure à 85 % pour tous les SNR compris entre 0 dB et 18 dB.

Cette légère baisse aux très hauts SNR (au-delà de 10 dB) peut être due à une dépendance excessive du modèle à l'encodage du SNR ou à de subtils déséquilibres du jeu de données, bien qu'elle reste limitée. Les métriques moyennes sur l'ensemble des niveaux de SNR (précision globale de $64,77$ %, précision de $65,37$ %, rappel de $64,77$ % et score F1 de $63,33$ %) correspondent étroitement aux performances globales sur l'ensemble de test ($64,98$ % de précision) rapportées précédemment, confirmant que les performances globales du modèle sont fortement influencées par les échantillons à faible SNR, pour lesquels les prédictions sont médiocres.

Il est également notable que le modèle n'atteint une précision acceptable (> 80 %) que pour des $\text{SNR} \geq -4$ dB, ce qui signifie qu'en pratique, une reconnaissance fiable des modulations nécessite au minimum un SNR de -4 dB. Cette analyse détaillée met en évidence à la fois la sensibilité du modèle au bruit et sa robustesse dans les régimes de SNR modérés à élevés, tout en révélant une légère dégradation aux SNR les plus élevés qui mérite une investigation plus approfondie.

La figure 3.13 illustre l'évolution des principales métriques de performance données par le tableau 3.1.




Figure 3.13 : Évolution des performances de classification en fonction du SNR.

3.6 Etude comparative

Le Tableau 3.2 compare les performances du modèle proposé CNNWithSNR à plusieurs méthodes récentes de l'état de l'art en reconnaissance automatique des modulations (AMR) sur différentes plages de SNR. Les résultats montrent que, dans des conditions de très faible SNR (-20 à -8 dB), où le bruit domine fortement le signal, CNNWithSNR surpasse nettement les modèles de référence en atteignant une accuracy moyenne de 26.18 %, grâce à l'intégration explicite de l'information SNR dans le processus d'apprentissage. Dans la plage intermédiaire (-6 à 4 dB), le modèle confirme sa robustesse en obtenant la meilleure performance globale (83.66 %), dépassant les architectures profondes et hybrides comparées. En revanche, pour des SNR élevés (6 à 18 dB), CNNWithSNR présente une légère baisse par rapport aux meilleurs modèles, l'apport du SNR devenant moins déterminant lorsque le bruit est négligeable. Globalement, avec une accuracy de 64.98 % et la meilleure accuracy minimale, le modèle proposé offre un compromis particulièrement intéressant entre robustesse en environnements bruités et performance globale, le positionnant comme une solution efficace et pragmatique pour des applications AMR réelles.

Modèle	Average Accuracy(%)			Overall Accuracy %	Min Accuracy %	Max Accuracy %
	-20~-8dB	-6dB~4dB	6dB~18dB			
MCLDNN [103]	17.09	79.29	92.30	62.08	9.25	92.71
PET-CGDNN [104]	17.35	76.20	90.78	60.71	9.40	91.07
AMC-Net [105]	17.33	78.70	90.24	61.26	9.32	90.64
FEA-T [106]	17.14	76.09	88.68	59.86	9.42	89.08
SMTrans [107]	17.95	81.47	92.99	63.27	9.52	93.34
ICRNNA [108]	--	--	--	63.24	--	93.40
CBADNN [109]	--	--	--	64.02	9.94	93.66
CNNWithSNR (Ours)	26.18	83.66	87.18	64.98	11.05	90.51

Tableau 3.2 : Comparaison des performances du modèle avec celles des modèles AMR.

3.7 Conclusion

Ce chapitre est dédié à la phase expérimentale ainsi qu'à l'évaluation du modèle proposé pour la classification automatique des signaux radio. Dans un premier temps, le jeu de données RadioML2016.10a a été présenté en détaillant sa structure, le format des données I/Q, les dimensions des signaux, les diverses modulations considérées, ainsi que les niveaux de bruit (SNR) utilisés pour simuler des conditions de transmission réalistes. Les principales applications de ce jeu de données ont également été discutées afin de justifier son choix dans le cadre de cette étude.

Par la suite, diverses métriques d'évaluation ont été introduites, notamment l'exactitude, la précision, le rappel, le score F1, les courbes ROC/AUC, ainsi que la matrice de confusion, permettant une analyse exhaustive des performances du système de classification.

L'architecture proposée du modèle de classification a ensuite été décrite, suivie de la présentation et de l'analyse des résultats obtenus. Les performances observées ont permis d'évaluer la capacité du modèle à reconnaître les différentes modulations sous divers niveaux de bruit. Enfin, une étude comparative a été effectuée afin de situer les performances du modèle proposé par rapport aux approches existantes, mettant en exergue ses atouts ainsi que ses limitations. Ainsi, cette étude expérimentale représente une étape cruciale pour valider l'efficacité de la méthode proposée et pour préparer les perspectives d'amélioration futures.

CONCLUSION GENERALE

Ce mémoire a porté sur l'étude et l'application des techniques d'apprentissage profond dans le cadre de la reconnaissance automatique des modulations radio. L'objectif principal était d'évaluer la capacité des méthodes basées sur le Deep Learning à améliorer la classification des signaux de communication, en particulier dans des environnements bruités.

Le premier volet de ce travail a consisté en une étude théorique de l'intelligence artificielle et des concepts fondamentaux du Deep Learning, mettant en évidence leur importance croissante dans le domaine du traitement des signaux. Une attention particulière a été accordée aux réseaux de neurones convolutifs (CNN), reconnus pour leur efficacité dans l'extraction automatique des caractéristiques pertinentes des signaux radio. Le dataset RadioML2016.10a ainsi que les principales métriques d'évaluation ont également été présentés afin d'établir un cadre expérimental rigoureux.

La phase expérimentale a permis d'évaluer les performances du modèle CNN dans la tâche de classification automatique des modulations. Les résultats obtenus ont montré une amélioration progressive des performances du modèle avec l'augmentation du rapport signal sur bruit (SNR), atteignant une précision satisfaisante pour les signaux faiblement affectés par le bruit. Ces observations confirment l'efficacité des architectures CNN dans la reconnaissance des modulations radio et leur capacité à apprendre automatiquement des représentations discriminantes à partir des données brutes.

Cependant, malgré ces résultats encourageants, certaines limites ont été identifiées, notamment la persistance de confusions entre des modulations présentant des caractéristiques similaires lorsque le niveau de bruit est élevé, particulièrement pour les faibles valeurs du SNR. Ces difficultés soulignent la nécessité de développer des approches plus robustes afin d'améliorer davantage la précision et la généralisation des modèles.

Comme perspectives de ce travail, il serait pertinent d'explorer des architectures plus avancées, telles que les réseaux hybrides combinant CNN et LSTM, les architectures ResNet, ainsi que les modèles récents basés sur l'architecture Transformer, afin d'optimiser les performances de classification. L'intégration de techniques d'amélioration des données et l'évaluation sur des ensembles de données plus variés pourraient également contribuer à renforcer la robustesse et l'applicabilité de ces méthodes dans des systèmes de communication réels.

REFERENCES BIBLIOGRAPHIQUES

- [1] J. G. Proakis et M. Salehi, *Digital Communications*, 5e éd. New York, NY, USA: McGraw-Hill, 2008, pp. 1–18.
- [2] S. Haykin, *Communication Systems*, 4e éd. New York, NY, USA: Wiley, 2001, pp. 154–210.
- [3] O. A. Dobre, A. Abdi, Y. Bar-Ness et W. Su, « Survey of Automatic Modulation Classification Techniques: Classical Approaches and New Trends », *IET Communications*, vol. 1, n° 2, pp. 137–139, 2007.
- [4] A. Swami et B. M. Sadler, « Hierarchical digital modulation classification using cumulants », *IEEE Transactions on Communications*, vol. 48, n° 3, pp. 416–420, 2000.
- [5] E. Russ et M. Roux, « A comparison of PDE-based non-linear anisotropic diffusion techniques for image processing », *J. Math. Pures Appl.*, vol. 77, pp. 839–849, 1998. [En ligne]. Disponible sur : <https://pdf.sciencedirectassets.com/>
- [6] IEEE Xplore Digital Library, portail de la littérature technique en ingénierie et technologie. [En ligne]. Disponible sur : <https://ieeexplore.ieee.org/> [Consulté le 11/02/2026].
- [7] Commission Européenne, Digital Strategy Portal – politiques et initiatives numériques de l'Union européenne. [En ligne]. Disponible sur : <https://digital-strategy.ec.europa.eu/> [Consulté le 16/02/2026].
- [8] ADRASEC 08, Association Départementale des Radio-Amateurs au Service de la Sécurité Civile. [En ligne]. Disponible sur : <https://adrasec08.fr/> [Consulté le 16/02/2026].
- [9] Techno-Science.net, encyclopédie scientifique et technique en ligne. [En ligne]. Disponible sur : <https://www.techno-science.net/> [Consulté le 20/02/2026].
- [10] ScienceDirect (Elsevier), plateforme d'articles scientifiques et techniques. [En ligne]. Disponible sur : <https://www.sciencedirect.com> [Consulté le 22/02/2026].
- [11] MesMaths.com, ressources pédagogiques en mathématiques. [En ligne]. Disponible sur : <https://www.mesmaths.com/> [Consulté le 20/02/2026].
- [12] Keyyo, solutions de communication d'entreprise (VoIP, téléphonie IP). [En ligne]. Disponible sur : <https://www.keyyo.com/> [Consulté le 23/02/2026].
- [13] CloudFront (AWS), dépôt de documents académiques partagés. [En ligne]. Disponible sur : <https://d1wqtxts1xzle7.cloudfront.net/> [Consulté le 21/02/2026].
- [14] ResearchGate, réseau social académique et dépôt de publications scientifiques. [En ligne]. Disponible sur : <https://www.researchgate.net/>
- [15] BYJU'S, « Amplitude Modulation – Definition, Principle, Types and Applications », ressource pédagogique en ligne. [En ligne]. Disponible sur : <https://byjus.com/jee/amplitude-modulation/>
- [16] Lycée Blaise Pascal, ressources pédagogiques en sciences et ingénierie. [En ligne]. Disponible sur : <https://si.blaisepascal.fr/>
- [17] X. B. Bian et A. D. Bandrauk, « Probing Nuclear Motion by Frequency Modulation of Molecular High-Order Harmonic Generation », *Physical Review Letters*, pp. 193901, 2014.
- [18] D. R. Stephens, *Phase-Locked Loops for Wireless Communications: Digital and Analog Implementations*. USA: Springer, 2012, pp. 1–434.
- [19] M. Steer, « Microwave and RF Design I – Radio Systems », LibreTexts, Carolina, 2019.
- [20] J. B. Anderson, T. Aulin et C. Sundberg, *Digital Phase Modulation*. USA: Springer Science & Business Media, 2013, pp. 1–509.

- [21] S. Ghavami, R. Adve et F. Lahouti, « Information Rates of ASK-Based Molecular Communication in Fluid Media », *IEEE Transactions on Molecular, Biological and Multi-Scale Communications*, pp. 277–291, 2015.
- [22] F. A. Rakhmadi, Mitrayana et H. Shalihah, « Design of green laser modulation system based on Arduino uno microcontroller », *Conference Proceedings*, 2018.
- [23] PROAKIS, John G. *Digital Communications*. 4^e édition. New York : McGraw-Hill, 2001, pp. 287–295.
- [24] O. A. Dobre, A. Abdi, Y. Bar-Ness et W. Su, « Survey of Automatic Modulation Classification Techniques: Classical Approaches and New Trends », *IEEE Communications Surveys & Tutorials*, vol. 9, n° 2, pp. 41–56, 2007.
- [25] E. E. Azzouz et A. K. Nandi, *Automatic Modulation Recognition of Communication Signals*. Boston, MA, USA: Springer, 1996. DOI: 10.1007/978-1-4757-2469-1.
- [26] T. J. O'Shea et J. Corgan, « Convolutional Radio Modulation Recognition Networks », in *Proc. International Conference on Engineering Applications of Neural Networks (EANN)*, 2016.
- [27] B. Jdid, K. Hassan, I. Dayoub, W. H. Lim et M. Mokayef, « Machine Learning Based Automatic Modulation Recognition for Wireless Communications: A Comprehensive Survey », *IEEE Access*, vol. 9, pp. 57851–57873, 2021. [En ligne]. Disponible sur : <https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=9576081> [Consulté le 28/02/2026].
- [28] E. E. Azzouz et A. K. Nandi, *Automatic Modulation Recognition of Communication Signals*. Boston, MA, USA: Springer, 1996. DOI: 10.1007/978-1-4757-2469-1.
- [29] A. Swami et B. M. Sadler, « Hierarchical digital modulation classification using cumulants », *IEEE Transactions on Communications*, vol. 48, n° 3, pp. 416–429, 2000.
- [30] W. A. Gardner, « Exploitation of spectral redundancy in cyclostationary signals », *IEEE Signal Processing Magazine*, 1991.
- [31] T. J. O'Shea, J. Corgan et T. C. Clancy, « Convolutional Radio Modulation Recognition Networks », in *Proc. International Conference on Engineering Applications of Neural Networks (EANN)*, 2016.
- [32] LNTwww – Lehrstuhl für Nachrichtentechnik (TU Munich), ressources pédagogiques en théorie des communications numériques. [En ligne]. Disponible sur : <https://en.lntwww.de/> [Consulté le 03/03/2026].
- [33] VDBLive, ressources en traitement du signal et communications. [En ligne]. Disponible sur : <https://vdblive.com/> [Consulté le 04/03/2026].
- [34] MathWorks, documentation MATLAB/Simulink pour le traitement du signal et les communications. [En ligne]. Disponible sur : <https://www.mathworks.com/> [Consulté le 04/03/2026].
- [35] S. J. Russell et P. Norvig, site officiel d'*Artificial Intelligence: A Modern Approach*. [En ligne]. Disponible sur : <https://aima.cs.berkeley.edu/>
- [36] I. Goodfellow, Y. Bengio et A. Courville, *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016.
- [37] F. Chollet, *Deep Learning with Python*. Shelter Island, NY, USA: Manning Publications, 2017.
- [38] C. Janiesch, P. Zschech et K. Heinrich, « Machine learning and deep learning », *Electronic Markets*, vol. 31, n° 3, pp. 685–695, sept. 2021.
- [39] S. J. Russell et P. Norvig, *Artificial Intelligence: A Modern Approach*, 4e éd. Upper Saddle River, NJ, USA: Pearson, 2020.

- [40] I. Goodfellow, Y. Bengio et A. Courville, *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016.
- [41] P. Stone et al., *Artificial Intelligence and Life in 2030*. Stanford University (AI100), 2021.
- [42] G. J. Sullivan et al., « Overview of the High Efficiency Video Coding (HEVC) Standard », *IEEE Transactions on Circuits and Systems for Video Technology*, 2012.
- [43] J. L. Hennessy et D. A. Patterson, *Computer Architecture: A Quantitative Approach*, 6e éd. Burlington, MA, USA: Morgan Kaufmann, 2017.
- [44] Y. LeCun, Y. Bengio et G. Hinton, « Deep learning », *Nature*, vol. 521, pp. 436–444, 2015.
- [45] B. Shneiderman et al., *Designing the User Interface: Strategies for Effective Human-Computer Interaction*, 6e éd. Upper Saddle River, NJ, USA: Pearson, 2016.
- [46] R. S. Sutton et A. G. Barto, *Reinforcement Learning: An Introduction*, 2e éd. Cambridge, MA, USA: MIT Press, 2018.
- [47] M. Armbrust et al., « A view of cloud computing », *Communications of the ACM*, vol. 53, n° 4, pp. 50–58, 2010.
- [48] A. Newell et H. A. Simon, « Computer science as empirical inquiry: symbols and search », *Communications of the ACM*, vol. 19, n° 3, pp. 113–126, 1976.
- [49] E. A. Feigenbaum, « Knowledge Engineering: The Applied Side of Artificial Intelligence », Stanford University, Dept. of Computer Science, Report No. STAN-CS-80-808, 1980.
- [50] J. Jagannath et al., « Machine learning for wireless communications in the Internet of Things: A comprehensive survey », *Ad Hoc Networks*, 2021.
- [51] E. J. Topol, « High-performance medicine: the convergence of human and artificial intelligence », *Nature Medicine*, 2019–2024.
- [52] L. Cao, « AI in Finance: Challenges, Techniques, and Opportunities », *ACM Computing Surveys*, 2022.
- [53] P. Zheng et al., « Smart manufacturing systems for Industry 4.0: Conceptual framework, emerging technologies, and future perspectives », *Frontiers of Mechanical Engineering*, 2021.
- [54] S. Grigorescu et al., « A survey of deep learning techniques for autonomous driving », *Journal of Field Robotics*, 2020.
- [55] E. A. Feigenbaum, « Knowledge Engineering: The Applied Side », Stanford Univ., CA, Tech. Rep., 1984.
- [56] J. H. Holland, « Escaping Brittleness: The Possibilities of General-Purpose Learning Algorithms », in *Machine Learning*. Burlington, MA, USA: Morgan Kaufmann, 1986, pp. 593–623.
- [57] H. L. Dreyfus, *What Computers Still Can't Do: A Critique of Artificial Reason*. Cambridge, MA, USA: MIT Press, 1992.
- [58] R. Guidotti et al., « A survey of methods for explaining black box models », *ACM Computing Surveys*, vol. 51, n° 5, pp. 1–42, 2018.
- [59] N. Mehrabi et al., « A survey on bias and fairness in machine learning », *ACM Computing Surveys*, vol. 54, n° 6, pp. 1–35, 2021.
- [60] R. Schwartz et al., « Green AI », *Communications of the ACM*, vol. 63, n° 12, pp. 54–63, 2020.
- [61] T. M. Mitchell, *Machine Learning*. New York, NY, USA: McGraw-Hill, 1997.

- [62] C.-A. Azencott, cours et ressources en apprentissage automatique (Mines ParisTech). [En ligne]. Disponible sur : <https://cazencott.info/>
- [63] C. M. Bishop, *Pattern Recognition and Machine Learning*. New York, NY, USA: Springer, 2006.
- [64] CloudFront (AWS), dépôt de documents académiques partagés. [En ligne]. Disponible sur : <https://d1wqtxts1xzle7.cloudfront.net/>
- [65] G. James, D. Witten, T. Hastie et R. Tibshirani, *An Introduction to Statistical Learning*. New York, NY, USA: Springer, 2013, pp. 270–271.
- [66] D. W. Hosmer Jr., S. Lemeshow et R. X. Sturdivant, *Applied Logistic Regression*. Hoboken, NJ, USA: John Wiley & Sons, 2013.
- [67] MathWorks, « Unsupervised Learning », documentation MATLAB. [En ligne]. Disponible sur : <https://www.mathworks.com/discovery/unsupervised-learning.html> [Consulté le 11/04/2026].
- [68] J. Han, J. Pei et H. Tong, *Data Mining: Concepts and Techniques*, 4e éd. Burlington, MA, USA: Morgan Kaufmann, 2022.
- [69] I. H. Sarker, « Machine learning: Algorithms, real-world applications and research directions », *SN Computer Science*, vol. 2, n° 3, p. 160, 2021.
- [70] M. Tavallaee et al., « A detailed analysis of the KDD CUP 99 data set », in *Proc. IEEE Symposium on Computational Intelligence for Security and Defense Applications*. IEEE, 2009, pp. 1–6.
- [71] M. L. Zhang et Z. H. Zhou, « A Review on Multi-Label Learning Algorithms », *IEEE Transactions on Knowledge and Data Engineering*, vol. 26, n° 8, pp. 1819–1837, août 2014.
- [72] R. Rish, « An empirical study of the naive Bayes classifier », in *Proc. IJCAI Workshop on Empirical Methods in Artificial Intelligence*, vol. 3, n° 22, pp. 41–46, 2001.
- [73] T. Hastie, R. Tibshirani et J. Friedman, *The Elements of Statistical Learning*, 2e éd. New York, NY, USA: Springer, 2009, chap. 3–4.
- [74] T. Cover et P. Hart, « Nearest neighbor pattern classification », *IEEE Transactions on Information Theory*, vol. 13, n° 1, pp. 21–27, janv. 1967.
- [75] J. R. Quinlan, « Induction of decision trees », *Machine Learning*, vol. 1, n° 1, pp. 81–106, 1986.
- [76] C. Cortes et V. Vapnik, « Support-Vector Networks », *Machine Learning*, 1995.
- [77] L. Visengeriyeva, A. Kammer, I. Bär, A. Kniesz et M. Plöd, « MLOps Principles », 2020.
- [78] M. J. Rahaman, « A comprehensive review to understand the definitions, advantages, disadvantages and applications of machine learning algorithms », *International Journal of Computer Applications*, vol. 186, n° 31, pp. 43–47, 2024.
- [79] C. Janiesch, P. Zschech et K. Heinrich, « Machine learning and deep learning », *Electronic Markets*, vol. 31, pp. 685–695, 2021.
- [80] C. M. Bishop, *Neural Networks for Pattern Recognition*. Oxford, UK: Oxford University Press, 1995, chap. 3, pp. 61–140.
- [81] Y. LeCun, L. Bottou, Y. Bengio et P. Haffner, « Gradient-based learning applied to document recognition », *Proceedings of the IEEE*, 1998.
- [82] S. Hochreiter et J. Schmidhuber, « Long Short-Term Memory », *Neural Computation*, 1997.
- [83] A. Vaswani et al., « Attention Is All You Need », in *Advances in Neural Information Processing Systems (NeurIPS)*, 2017.

- [84] D. E. Rumelhart, G. E. Hinton et R. J. Williams, « Learning representations by back-propagating errors », *Nature*, 1986.
- [85] Comet.ml, « Machine Learning vs. Deep Learning: A Comparison ». [En ligne]. Disponible sur : <https://www.comet.com/site/blog/machine-learning-vs-deep-learning-a-comparison/> [Consulté le 09/04/2026].
- [86] T. Hastie, R. Tibshirani et J. Friedman, *The Elements of Statistical Learning*, 2e éd. New York, NY, USA: Springer, 2009.
- [87] F. Chollet, *Deep Learning with Python*, 2e éd. Shelter Island, NY, USA: Manning Publications, 2021.
- [88] A. Ng, « Nuts and Bolts of Building AI Applications », in *Proc. NIPS Tutorial*, 2016.
- [89] N. C. Thompson et al., « The Computational Limits of Deep Learning », arXiv : 2007.05558, 2020.
- [90] D. Sculley et al., « Hidden Technical Debt in Machine Learning Systems », in *Proc. Advances in Neural Information Processing Systems (NIPS)*, 2015.
- [91] HAL Science (CNRS), dépôt ouvert de publications scientifiques françaises. [En ligne]. Disponible sur : <https://hal.science/hal-02864885v1/file/main.pdf> [Consulté le 09/04/2026].
- [92] ROIA – Revue d'Intelligence Artificielle, Centre Mersenne. [En ligne]. Disponible sur : <https://roia.centre-mersenne.org/item/10.5802/roia.32.pdf> [Consulté le 10/04/2026].
- [93] IBM, « The Future of Artificial Intelligence », IBM Think Insights. [En ligne]. Disponible sur : <https://www.ibm.com/fr-fr/think/insights/artificial-intelligence-future>
- [94] Y. Bengio, A. Courville et P. Vincent, « Representation Learning: A Review and New Perspectives », *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 35, n° 8, pp. 1798–1828, août 2013.
- [95] T. O'Shea et J. Hoydis, « An Introduction to Deep Learning for the Physical Layer », *IEEE Transactions on Cognitive Communications and Networking*, vol. 3, n° 4, pp. 563–575, déc. 2017.
- [96] T. J. O'Shea et N. West, « Radio machine learning dataset generation with GNU radio », in *Proc. GNU Radio Conference*, vol. 1, n° 1, sept. 2016. [En ligne]. Disponible sur : <https://pubs.gnuradio.org/index.php/grcon/article/view/11> [Consulté le 24/04/2026].
- [97] PMC (PubMed Central), article en ligne sur l'intelligence artificielle et les communications. [En ligne]. Disponible sur : <https://pmc.ncbi.nlm.nih.gov/articles/PMC12390484/> [Consulté le 24/04/2026].
- [98] T. J. O'Shea, T. Roy et T. C. Clancy, « Over-the-Air Deep Learning Based Radio Signal Classification – Dataset RML2016.10a », arXiv : 2501.17888. [En ligne]. Disponible sur : <https://arxiv.org/html/2501.17888v1> [Consulté le 26/04/2026].
- [99] ResearchGate, « Modulation Recognition Method for Wireless Signals Based on Joint Neural Networks ». [En ligne]. Disponible sur : <https://www.researchgate.net/publication/383683266> [Consulté le 28/04/2026].
- [100] T. J. O'Shea, J. Corgan et T. C. Clancy, « Over-the-Air Deep Learning Based Radio Signal Classification », *IEEE Journal of Selected Topics in Signal Processing*. IEEE, 2016.
- [101] Scribd, « Métriques d'évaluation en apprentissage automatique ». [En ligne]. Disponible sur : <https://fr.scribd.com/document/961181298/Metriques-1>
- [102] DataCamp, « What is a Confusion Matrix in Machine Learning? ». [En ligne]. Disponible sur : <https://www.datacamp.com/fr/tutorial/what-is-a-confusion-matrix-in-machine-learning>

- [103] J. Xu, C. Luo, G. Parr et Y. Luo, « A spatiotemporal multi-channel learning framework for automatic modulation recognition », *IEEE Wireless Communications Letters*, vol. 9, n° 10, pp. 1629–1632, 2020. DOI: 10.1109/LWC.2020.2999453.
- [104] F. Zhang, C. Luo, J. Xu et Y. Luo, « An efficient deep learning model for automatic modulation recognition based on parameter estimation and transformation », *IEEE Communications Letters*, vol. 25, n° 10, pp. 3287–3290, 2021. DOI: 10.1109/LCOMM.2021.3102656.
- [105] J. Zhang, T. Wang, Z. Feng et S. Yang, « AMC-Net: an effective network for automatic modulation classification », in *Proc. ICASSP 2023 – IEEE International Conference on Acoustics, Speech and Signal Processing*. IEEE, 2023, pp. 1–5. DOI: 10.1109/ICASSP49357.2023.10097070.
- [106] Y. Chen, B. Dong, C. Liu, W. Xiong et S. Li, « Abandon locality: frame-wise embedding aided transformer for automatic modulation recognition », *IEEE Communications Letters*, vol. 27, n° 1, pp. 327–331, 2022. DOI: 10.1109/LCOMM.2022.3213523.
- [107] Y. Huo, C. Wang, J. Liang et al., « SMTrans: An Efficient Automatic Modulation Recognition Network Based on the Scale-Aware Modulation Transformer », *Physical Communication*, p. 102966, 2025.
- [108] N. El-Haryqy, A. Kharbouche, H. Ouamna et al., « Improved automatic modulation recognition using deep learning with additive attention », *Results in Engineering*, vol. 26, p. 104783, 2025.
- [109] S. Wu, C. Wang, J. Liang et al., « A transformer-based framework with complex-valued convolution and enhanced Bi-LSTM for automatic modulation recognition », *Physical Communication*, p. 102824, 2025.