

UNIVERSITÉ DU QUÉBEC EN OUTAOUAIS

**CARACTÉRISATION DES MATÉRIAUX PAR
L'INTELLIGENCE ARTIFICIELLE : UNE APPROCHE
COMBINANT L'EXPÉRIMENTATION ET LA SIMULATION**

MÉMOIRE PRÉSENTÉ

COMME EXIGENCE PARTIELLE

DU PROGRAMME DE MAÎTRISE EN SCIENCES ET TECHNOLOGIES DE
L'INFORMATION

PAR

MERIEM SIRINE AMEYOUN

Février 2026

Jury d'évaluation

Président du Jury : Dr. Nadia Baaziz

Membre du Jury : Dr. Miloud Rezkallah

Directeur de recherche : Dr. Larbi Talbi

Dédicace

Je dédie ce mémoire,

À ma mère et à mon père,

À mes frères et à ma belle-sœur,

À mon mari,

Qu'ils trouvent ici l'expression de ma profonde gratitude.

Remerciements

Je tiens à exprimer mes sincères remerciements à mon directeur de recherche, le Professeur Larbi Talbi, pour son encadrement, ses conseils précieux et sa disponibilité tout au long de ce travail. Son expertise, son soutien et ses orientations ont été déterminants pour la réalisation de ce mémoire.

J'adresse également mes remerciements aux membres du jury pour l'intérêt porté à ce mémoire et pour leurs remarques constructives.

Je remercie chaleureusement mes parents, Samia et Mourad, pour leur amour, leurs sacrifices et leur soutien indéfectible. Je remercie également mes frères, Soheib et Moncef, ainsi que ma belle-sœur, Khawla, pour leurs encouragements et leur présence à mes côtés tout au long de ce parcours.

J'exprime une gratitude toute particulière à mon mari, Ayoub, pour son soutien constant, sa patience et sa compréhension, et pour m'avoir toujours encouragée à persévérer, aussi bien dans les moments de doute que dans les périodes de réussite.

Je remercie sincèrement mon oncle Mountassar et ma tante Ghania pour leur soutien moral, leurs prières et leurs encouragements.

Enfin, j'adresse mes remerciements à mes amis, qui, par leur présence, leur écoute et leurs encouragements, ont contribué à rendre ce parcours plus enrichissant et plus motivant.

Table des matières

Liste des figures	vi
Liste des tableaux	ix
Liste des abréviations et acronymes	x
Liste des symboles	xii
Résumé	xiv
Introduction Générale	1
1. État de l’art.....	4
1.1. Introduction.....	4
1.2. Évolution des méthodes de caractérisation des matériaux.....	4
1.2.1. Approches traditionnelles et modélisation classique	5
1.2.2. Intégration de l’intelligence artificielle.....	7
1.3. Justification et contribution du projet de recherche.....	10
1.3.1. Problématique	10
1.3.2. Positionnement du projet de recherche	11
1.4. Méthodologie	12
1.5. Conclusion	13
2. Création de la base de données	15
2.1. Introduction.....	15
2.2. Simulation avec Altair Feko	15
2.2.1. Altair Feko	15
2.3. Mesures expérimentales.....	22
2.3.1. Définition des paramètres S	23
2.3.2. Description de l’expérience.....	24

2.3.3.	Chaîne de traitement des données	28
2.4.	Conclusion	33
3.	Conception du modèle IA	34
3.1.	Introduction.....	34
3.2.	Définition des variables	34
3.3.	Analyse exploratoire des données.....	36
3.4.	Prétraitement et organisation du jeu de données	38
3.4.1.	Architecture du modèle proposé	39
3.4.2.	Résultats et performances	42
3.5.	Fonction de prédiction à partir des mesures expérimentales	47
3.5.1.	La généralisation du modèle sur des matériaux non vus.....	48
3.6.	Conclusion	50
	Conclusion générale	51
	Perspectives et Recommandations.....	52
	Bibliographies.....	53

Liste des figures

Chapitre 2

Figure 2. 1 La Géométrie de l'Antenne Cornet Importée depuis la Bibliothèque dans CADFEKO.....	16
Figure 2. 2 Définition des Variables Paramétriques pour la Modélisation de l'Antenne Cornet dans CADFEKO.....	17
Figure 2. 3 Diagramme de Rayonnement en 3D de l'Antenne Cornet.....	18
Figure 2. 4 Diagramme de Rayonnement 2D en Champ Lointain de l'Antenne Cornet ($\phi = 0^\circ$) à 10 GHz.....	19
Figure 2. 5 Diagramme de Rayonnement Polaire en Champ Lointain de l'Antenne Cornet ($\phi = 0^\circ$) à 10 GHz.....	19
Figure 2. 6 Catalogue des Matériaux dans WallMan.....	20
Figure 2. 7 Propriétés du Matériau Brique dans WallMan	20
Figure 2. 8 Scénario de Propagation avec Antenne Réceptrice en Mouvement sur un Demi-Cercle	21
Figure 2. 9 Scénario de mesure défini pour les mesures expérimentales.....	22
Figure 2. 10 Installation expérimentale comprenant la zone de mesure anéchoïque et la configuration des antennes.....	25

Figure 2. 11 Configuration expérimentale utilisée pour la caractérisation des différents matériaux. (a) Plaque d'aluminium (référence) – (b) Polypropylène alvéolaire – (c) Verre – (d) Polystyrène – (e) Plaque de plâtre – (f) Tuile acoustiques – (g) Panneau de ciment – (h) Contreplaqué – (i) Panneau de particules en bois – (j) Bois tendre.	27
Figure 2. 12 (a) Laser d'alignement pour le positionnement angulaire des antennes. (b) Analyseur de réseau vectoriel Keysight N9950B utilisé pour l'acquisition des paramètres S.	28
Figure 2. 13 Chaîne complète de traitement des données expérimentales.....	29
Figure 2. 14 Variation du paramètre S21 [dB] en fonction de l'angle de réception pour trois angles de transmission (TX = 30°, 45°, 60°).	30
Figure 2. 15 Coefficient de réflexion $ \Gamma $ pour différents matériaux en fonction de l'angle de réception.	31
Figure 2. 16 Profils du coefficient de réflexion réels vs générés pour différents matériaux.....	32

Chapitre 3

Figure 3. 1 Projection PCA en deux dimensions des matériaux.....	36
Figure 3. 2 Projection t-SNE en deux dimensions des matériaux.....	37
Figure 3. 3 Courbes de perte d'entraînement et de validation du modèle DualNet : ..	44

- Figure 3. 4 Courbes d'apprentissage : (a) Évolution de l'accuracy pour la classification et du coefficient et (b) R^2 pour la régression au fil des époques d'entraînement 45
- Figure 3. 5 Matrice de confusion normalisée (%) pour le classifieur DualNet..... 46
- Figure 3. 6 Comparaison entre les valeurs réelles et prédites de (a) la permittivité (ϵ') et (b) la conductivité (σ)..... 47

Liste des tableaux

Chapitre 1

Tableau 1. 1 Comparaison des méthodes de caractérisation électromagnétique des matériaux basées sur l'apprentissage automatique	9
---	---

Chapitre 2

Tableau 2. 1 Familles de matériaux testés et descriptions	33
---	----

Chapitre 3

Tableau 3. 1 Description des variables utilisées dans le jeu de données	35
Tableau 3. 2 Exemple d'un échantillon issu de la base de données expérimentale	35
Tableau 3. 3 Résumé Des Métriques D'évaluation Du Modèle Dualnet	43
Tableau 3. 4 Comparaison des valeurs de permittivité réel (ϵ') issues de la littérature et de ce travail	49

Liste des abréviations et acronymes

ANN : Artificial Neural Network (réseau neuronal artificiel).

CE : Cross-Entropy (entropie croisée, fonction de perte utilisée en classification).

DNN : Deep Neural Network (réseau de neurones profond).

DL : Deep Learning (apprentissage profond).

DT : Decision Tree (arbre de décision).

GB : Gradient Boosting (méthode d'ensemble basée sur l'amélioration séquentielle des erreurs).

GHz : Gigahertz (10^9 hertz, unité de fréquence).

HPBW : Half-Power BeamWidth (largeur de faisceau à mi-puissance).

IA : Intelligence artificielle.

MAE : Mean Absolute Error (erreur absolue moyenne).

ML : Machine Learning (apprentissage automatique).

mmWave : Millimeter Wave (ondes millimétriques).

MP : Perceptron multicouche (Multilayer Perceptron, MLP).

MSE : Mean Squared Error (erreur quadratique moyenne).

NB : Naïve Bayes (classificateur probabiliste basé sur le théorème de Bayes).

NumPy : Numerical Python (bibliothèque Python pour le calcul scientifique).

PCA : Principal Component Analysis (analyse en composantes principales).

PCB : Printed Circuit Board (circuit imprimé).

PyTorch : Bibliothèque Python de deep learning basée sur les tenseurs.

R² : Coefficient de détermination (mesure de la qualité d'ajustement en régression).

RF : Random Forest (forêt aléatoire).

Scikit-learn : Bibliothèque Python dédiée à l'apprentissage automatique.

Softmax : Fonction d'activation produisant une distribution de probabilités.

StandardScaler : Méthode de standardisation des données (centrage et réduction).

t-SNE : t-Distributed Stochastic Neighbor Embedding (méthode de réduction de dimension non linéaire).

THz : Terahertz (10^{12} hertz).

VNA : Vector Network Analyzer (analyseur de réseaux vectoriel).

X-band : Bande X (bande de fréquences comprise entre 8 et 12 GHz).

Liste des symboles

Variables électromagnétiques

ϵ' : Permittivité réelle du matériau

σ : Conductivité électrique du matériau (S/m)

Γ : Coefficient de réflexion complexe

$|\Gamma|$: Module du coefficient de réflexion

$\text{Re}(\Gamma)$: Partie réelle du coefficient de réflexion

$\text{Im}(\Gamma)$: Partie imaginaire du coefficient de réflexion

φ : Phase du coefficient de réflexion ($^\circ$)

S_{21} : Paramètre de transmission (S-parameter)

f : Fréquence (Hz)

θ : Angle d'incidence

T_x : Position de l'antenne émettrice

R_x : Position de l'antenne réceptrice

Variables statistiques / prétraitement

x : Valeur brute d'une caractéristique

x^* : Valeur normalisée

μ : Moyenne de la variable (ensemble d'entraînement)

σ (stat.) : Écart-type

N : Taille du mini-lot

C : Nombre de classes

Variables du modèle DualNet

h : Représentation latente partagée

a_1, a_2 : Sorties linéaires intermédiaires

u_1, u_2 : Sorties après activation ReLU

v_i : Sortie après dropout

s : Sortie linéaire de la tête de classification

z : Vecteur de logits

\hat{y}_i : Probabilité prédite pour la classe i

p : Vecteur réel des paramètres électromagnétiques $[\varepsilon', \sigma]$

\hat{p} : Vecteur prédit des paramètres électromagnétiques

Paramètres du réseau

$W_1 \dots W_6$: Matrices de poids

$b_1 \dots b_6$: Vecteurs de biais

Θ : Ensemble des paramètres du modèle

Fonctions et pertes

$\text{ReLU}(\cdot)$: Fonction d'activation Rectified Linear Unit

$\text{BN}(\cdot)$: Normalisation par lot (Batch Normalization)

$\text{Drop}_p(\cdot)$: Opérateur de dropout avec probabilité p

L_{total} : Fonction de coût totale

L_{CE} : Perte d'entropie croisée

L_{MSE} : Erreur quadratique moyenne

Indicateurs de performance

MAE : Erreur absolue moyenne

MSE : Erreur quadratique moyenne

R^2 : Coefficient de détermination

Résumé

Ce travail présente une méthodologie avancée pour la caractérisation électromagnétique des matériaux à l'aide de l'intelligence artificielle, combinant des mesures expérimentales et des techniques d'apprentissage profond. L'objectif principal est de concevoir un modèle intelligent capable d'identifier la famille d'un matériau et d'estimer simultanément ses propriétés physiques, notamment la permittivité relative réelle (ϵ') et la conductivité (σ), à partir de paramètres mesurés en espace libre. Dans une première étape, le scénario de mesure a été élaboré en simulation à l'aide du logiciel de propagation WinProp, dans un environnement contrôlé. Ce scénario a ensuite été reproduit expérimentalement à l'aide d'un analyseur de réseau vectoriel Keysight N9950B, opérant dans la bande de fréquences 8–12 GHz, afin de collecter des mesures réelles et de constituer la base de données finale destinée à l'entraînement et à l'évaluation du modèle. Le modèle développé, nommé DualNet, repose sur une architecture multitâche comportant une tête de classification pour déterminer la famille du matériau, et une tête de régression pour prédire ses propriétés électromagnétiques. Les résultats obtenus démontrent une précision de classification supérieure à 99 %, un coefficient de détermination R^2 supérieur à 98%, et une erreur absolue moyenne inférieure à 3%. La capacité de généralisation est vérifiée à l'aide de matériaux supplémentaires non inclus dans la phase d'entraînement, montrant une forte concordance avec les valeurs de référence rapportées dans la littérature. En s'appuyant sur un dispositif de mesure simple et un modèle computationnellement efficace, la méthode réduit la complexité expérimentale et fournit un outil pratique pour la caractérisation électromagnétique des matériaux, permettant des simulations plus précises de la propagation des ondes radio en environnement intérieur ainsi qu'une meilleure planification des réseaux.

Mots clés : Caractérisation des matériaux, coefficients de réflexion, intelligence artificielle, apprentissage profond.

Abstract

This work presents an advanced methodology for the electromagnetic characterization of materials based on artificial intelligence, combining experimental measurements with deep learning techniques. The primary objective is to design an intelligent model capable of identifying the material family and simultaneously estimating its physical properties, namely the real part of the relative permittivity (ϵ') and the electrical conductivity (σ), from free-space measurement parameters. In a first stage, the measurement scenario was designed and modeled in simulation using the WinProp propagation software within a controlled environment. This scenario was subsequently reproduced experimentally using a Keysight N9950B vector network analyzer operating over the 8–12 GHz frequency band, in order to acquire real measurements and construct the final dataset used for model training and evaluation. The developed model, referred to as DualNet, is based on a multitask architecture comprising a classification head for material family identification and a regression head for predicting electromagnetic properties. The obtained results demonstrate a classification accuracy exceeding 99%, a coefficient of determination R^2 greater than 98%, and a mean absolute error below 3%. The generalization capability of the proposed approach is assessed using additional materials not included in the training phase, showing strong agreement with reference values reported in the literature. Relying on a simple measurement setup and a computationally efficient model, the proposed method reduces experimental complexity and provides a practical tool for electromagnetic material characterization, enabling more accurate indoor radio-wave propagation simulations and improved wireless network planning.

Keywords: Material characterization, reflection coefficients, artificial intelligence, deep learning.

Introduction Générale

La montée en puissance des communications sans fil, portée par l'explosion du trafic dans les réseaux 5G et le développement des futures solutions 6G, impose des performances toujours plus élevées en termes de couverture, de capacité et de fiabilité [1]. Dans ce contexte, la propagation en environnement intérieur reste particulièrement difficile à modéliser, en raison des interactions complexes entre les ondes électromagnétiques et les matériaux de construction. La connaissance précise des propriétés de ces matériaux est donc cruciale : elle conditionne les mécanismes de réflexion, de transmission et d'absorption, qui déterminent l'atténuation du signal, la richesse du multi-trajet et la robustesse globale des réseaux indoor [2].

Pour répondre à ces défis, de nombreux travaux se sont consacrés à la caractérisation électromagnétique des matériaux afin d'améliorer la modélisation des canaux de propagation radio en environnement intérieur. Ces études s'appuient sur des approches expérimentales et analytiques variées pour estimer les propriétés électromagnétiques des matériaux, notamment la permittivité relative et la conductivité, sur des bandes de fréquences allant des micro-ondes jusqu'aux domaines millimétrique et térahertz. Malgré leur précision en laboratoire, les approches classiques de caractérisation restent difficiles à généraliser et à déployer dans des contextes réalistes. Leur mise en œuvre exige souvent des dispositifs coûteux, des campagnes de mesure longues et des conditions strictes de calibration et de contrôle, tandis que les méthodes basées sur la simulation ou l'inversion nécessitent des modèles physiques fiables, des ressources de calcul importantes et une connaissance préalable des matériaux. De plus, la variabilité des matériaux réels et les incertitudes environnementales (bruit, multipath, géométrie non maîtrisée) peuvent conduire à des estimations sensibles au scénario, parfois non uniques, limitant ainsi la reproductibilité, la robustesse et la scalabilité de ces techniques pour une utilisation opérationnelle à grande échelle.

Pour surmonter ces difficultés, l'intelligence artificielle (IA) s'est imposée comme une alternative puissante pour la caractérisation électromagnétique des matériaux, en permettant une estimation automatisée et pilotée par les données des propriétés matérielles. Des modèles d'apprentissage automatique ont été utilisés pour déduire les paramètres électromagnétiques à partir de diverses grandeurs mesurables, notamment des mesures de puissance, des coefficients de réflexion et de transmission, des signatures radiofréquences et des réponses impulsionnelles de canal. Ces approches tirent parti de la capacité des réseaux de neurones et des algorithmes d'apprentissage à capturer des relations non linéaires complexes, difficiles à modéliser analytiquement. Dans l'ensemble, bien que les approches basées sur l'intelligence artificielle aient démontré un potentiel important pour la caractérisation électromagnétique, les travaux existants se limitent le plus souvent à un objectif unique, soit l'estimation des paramètres électromagnétiques, soit l'identification des matériaux. En plus, beaucoup de ces méthodes reposent sur des données simulées, ce qui limite leur robustesse et leur capacité de généralisation à des environnements intérieurs réalistes, ce qui motive l'approche proposée dans ce travail.

C'est dans cette perspective que ce mémoire pose la problématique centrale suivante : comment caractériser de manière fiable, rapide et non destructive les propriétés électromagnétiques des matériaux de construction à partir de mesures expérimentales, tout en assurant une bonne précision et une capacité de généralisation aux environnements intérieurs réels ?

Pour répondre à cette problématique, ce travail propose un nouveau cadre basé sur l'apprentissage profond, dénommé DualNet, dédié à la caractérisation intelligente des matériaux de construction. L'approche proposée repose sur une architecture multitâche permettant de réaliser conjointement la classification des familles de matériaux et l'estimation par régression de propriétés électromagnétiques clés, à savoir

la partie réelle de la permittivité relative et la conductivité électrique, directement à partir de coefficients de réflexion mesurés, dans l'ensemble de ce mémoire, la permittivité considérée correspond à la permittivité relative des matériaux étudiés. L'étude porte sur neuf matériaux couramment utilisés en environnements intérieurs, une catégorie encore peu explorée dans la littérature lorsque des données expérimentales réelles sont combinées à des techniques d'intelligence artificielle. Les mesures sont réalisées sur une large bande de fréquences (8–12 GHz), pertinente pour les applications radiofréquences modernes et rarement considérée dans les études expérimentales existantes basées sur l'IA. La capacité de généralisation du modèle a également été évaluée en l'appliquant à des matériaux non vus lors de l'entraînement. Les estimations obtenues présentent un bon accord avec les valeurs de référence rapportées dans la littérature, confirmant la robustesse et la fiabilité de l'approche proposée pour la caractérisation de nouveaux matériaux expérimentaux. Les résultats montrent qu'une approche d'intelligence artificielle entraînée exclusivement à partir de données expérimentales réelles peut fournir une solution rapide, fiable et pratique pour la caractérisation électromagnétique des matériaux et l'amélioration de la modélisation de la propagation en environnements intérieurs.

Ce mémoire est structuré comme suit. Le premier chapitre présente l'état de l'art relatif aux méthodes classiques de caractérisation électromagnétique des matériaux ainsi qu'aux approches basées sur l'intelligence artificielle. Le deuxième chapitre décrit la méthodologie expérimentale et la constitution de la base de données, incluant les phases de simulation pour la première phase et de mesures réelles. Le troisième chapitre est consacré à la conception et à l'architecture du modèle DualNet et présente les résultats obtenus et leur analyse. Enfin, une conclusion générale vient clore ce travail et ouvrir sur des perspectives de recherche futures.

1. État de l'art

1.1. Introduction

La caractérisation électromagnétique des matériaux et la modélisation de la propagation radio sont essentielles dans divers domaines tels que les télécommunications, l'ingénierie des matériaux et la recherche scientifique. Ces disciplines visent à comprendre et prédire l'interaction des ondes électromagnétiques avec différents environnements afin d'optimiser les performances des systèmes de communication et de détection. Historiquement, ces études reposaient sur des méthodes déterministes et empiriques permettant d'extraire les propriétés électromagnétiques des matériaux et de modéliser la propagation radio. Ces approches, bien que fondamentales, présentent des limites en termes de précision, de coût expérimental et de complexité computationnelle, nécessitant ainsi des améliorations pour répondre aux exigences des technologies modernes. Ce chapitre présente les principales méthodes classiques employées. Il s'appuie sur divers travaux de recherche qui ont permis d'importants progrès dans la caractérisation des matériaux et la modélisation des canaux de propagation électromagnétique. Ensuite, ce chapitre souligne les limites des méthodes traditionnelles et leur rôle dans la transition vers des techniques plus avancées, intégrant l'IA. Ces constats serviront à positionner notre projet, qui vise à développer un modèle optimisé capable d'effectuer simultanément la classification de la famille du matériau et l'estimation de ses propriétés diélectriques.

1.2. Évolution des méthodes de caractérisation des matériaux

Depuis les premières approches, deux grandes catégories de méthodes ont émergé : les méthodes résonantes et non résonantes. Les méthodes résonantes, bien que très précises, sont limitées à des bandes de fréquence étroites et nécessitent souvent une préparation complexe des échantillons, les rendant peu adaptées aux applications nécessitant une

large bande passante. Les méthodes non résonantes, qui sont plus flexibles et nécessitent moins de préparation, se sont donc imposées comme une alternative plus pratique pour la caractérisation large bande des matériaux [3].

1.2.1. Approches traditionnelles et modélisation classique

Une première catégorie regroupe les méthodes électromagnétiques directes basées sur la réflexion et la transmission, dans lesquelles les paramètres électromagnétiques sont extraits à partir de coefficients mesurés et ajustés à des modèles analytiques déterministes. Ces approches ont été largement utilisées pour caractériser des matériaux homogènes en conditions contrôlées, notamment à des fréquences millimétriques et térahertz comprises entre 200 et 500 GHz, ou dans les bandes K et W, permettant une estimation précise de la permittivité complexe [2], [4], [5], [6]. Malgré leur précision, ces méthodes reposent sur des hypothèses idéalisées, nécessitent des échantillons préparés et homogènes, et sont difficilement transposables à des matériaux de construction réels intégrés dans des environnements intérieurs complexes.

Une seconde catégorie concerne les méthodes d'estimation in situ basées sur des paramètres effectifs, où les propriétés des matériaux sont déduites à partir de mesures de réflexion réalisées directement sur des surfaces réelles. Ces approches sont principalement utilisées dans un contexte de modélisation du canal de propagation et ont été appliquées à des fréquences millimétriques autour de 60 GHz ou au-delà, notamment dans des cadres orientés réseaux de nouvelle génération [7], [8]. Bien que représentatives des conditions réelles de propagation, ces méthodes fournissent généralement des paramètres effectifs dépendants du scénario de mesure et ne permettent pas une estimation complète et intrinsèque des propriétés électromagnétiques des matériaux.

Les méthodes inverses basées sur l'optimisation numérique constituent une autre famille d'approches, dans lesquelles un modèle électromagnétique est ajusté aux mesures à l'aide d'algorithmes d'optimisation tels que les techniques d'essaim de particules ou multi-objectifs. Ces méthodes ont été appliquées à l'estimation de la permittivité complexe de matériaux spécifiques, notamment des textiles ou des matériaux de mobilier en bois, dans la bande de fréquences 40–50 GHz [1], [9]. Toutefois, leur efficacité dépend fortement du modèle physique choisi, des hypothèses initiales et de la qualité des données mesurées, ce qui peut conduire à des problèmes de non-unicité des solutions, de sensibilité au bruit et à une généralisation limitée à d'autres types de matériaux.

D'autres travaux s'appuient sur des méthodes fondées sur des modèles équivalents de ligne de transmission et des mesures de puissance, permettant d'estimer la permittivité et la conductivité à partir de formulations simplifiées, généralement dans les bandes micro-ondes [10]. Bien que ces approches soient computationnellement efficaces et peu coûteuses, elles supposent des géométries simples et des matériaux homogènes, ce qui limite leur représentativité pour des scénarios de propagation intérieure réalistes.

Enfin, des approches de cartographie radio et d'identification assistée par radio, développées notamment dans le contexte des réseaux 6G, exploitent des signatures radio ou des pertes par réflexion pour identifier des matériaux de construction à des fréquences allant de 28 GHz à plus de 100 GHz [8]. Ces méthodes sont prometteuses pour des applications à grande échelle, mais elles se limitent généralement à une identification qualitative des matériaux sans fournir d'estimation directe de leurs paramètres électromagnétiques intrinsèques.

Dans l'ensemble, bien que ces approches aient contribué de manière significative à l'avancement de la caractérisation électromagnétique des matériaux, elles présentent

des limitations importantes liées à des hypothèses idéalisées, à une forte dépendance au scénario de mesure ou à l'incapacité de combiner l'identification des matériaux et l'estimation simultanée de plusieurs propriétés électromagnétiques. En particulier, aucun cadre existant ne permet une caractérisation unifiée et robuste à partir de mesures expérimentales réalistes en environnements intérieurs variés, ce qui motive le recours à des approches basées sur l'intelligence artificielle.

1.2.2. Intégration de l'intelligence artificielle

Les techniques de l'IA ont récemment été intégrées à la caractérisation électromagnétique des matériaux afin de surmonter les limites des approches analytiques et déterministes traditionnelles. Plusieurs études ont exploité des réseaux de neurones pour estimer la permittivité complexe à partir de mesures électromagnétiques dans des configurations guidées, telles que les lignes coaxiales ou les guides coplanaires [11], [12], [13]. Ces approches ont démontré une bonne précision pour des échantillons diélectriques homogènes, tels que des composites à base de papier ou des matériaux liquides, mais leur applicabilité aux matériaux réels reste limitée.

D'autres travaux se sont intéressés à la caractérisation large bande dans des environnements contrôlés, en combinant des réseaux neuronaux profonds (DNN) avec des jeux de données simulées ou hybrides, notamment pour des substrats ou des matériaux diélectriques dans la bande 10–100 GHz [14], [15]. Bien que ces approches offrent de bonnes performances, elles dépendent fortement de la simulation électromagnétique et négligent la variabilité expérimentale observée dans les scénarios réels. Une autre famille de travaux a proposé des méthodes basées sur les mesures de puissance, exploitant uniquement la magnitude du coefficient de transmission pour reconstruire la permittivité complexe à l'aide de modèles de réseaux neuronaux [16], [17], [18]. Ces études, menées principalement par Mosavirik et al., ont démontré que

les techniques d'apprentissage automatique peuvent contourner la nécessité de mesures de phase complexes, mais reposent sur des hypothèses simplificatrices et des échantillons homogènes, souvent éloignés des matériaux de construction réels. Enfin, plusieurs recherches récentes ont exploré la reconnaissance de matériaux à partir des signatures de propagation ou des réponses impulsionnelles du canal dans des environnements intérieurs [19], [20]. Ces approches visent la détection ou la classification des matériaux via des mesures radiofréquences (28–100 GHz), mais se limitent à une identification qualitative, sans estimer directement les paramètres électromagnétiques intrinsèques.

Dans l'ensemble, bien que ces travaux aient permis d'importants progrès dans la caractérisation assistée par IA, la majorité de ces travaux portent sur des échantillons homogènes (liquides, substrats, composites fins) mesurés dans des environnements simulés, souvent à des fréquences très basses ou très élevées. À ce jour, aucune étude n'a proposé une approche de deep learning appliquée à la caractérisation expérimentale en espace libre des matériaux de construction dans la bande des micro-ondes (8–12 GHz) qui combine simultanément la classification des matériaux et l'estimation de leurs propriétés, pourtant essentielle pour la modélisation réaliste de la propagation en environnements intérieurs. Comme indiqué dans le Tableau 1.1, la plupart des approches existantes basées sur l'IA se concentrent sur des conditions simulées et des plages de fréquences extrêmes, ce qui met en évidence le besoin de méthodes capables de caractériser de manière robuste des matériaux de construction pratiques dans des conditions réalistes. Ce qui motive l'approche proposée dans ce travail.

Tableau 1. 1 Comparaison des méthodes de caractérisation électromagnétique des matériaux basées sur l'apprentissage automatique

Travail	Bande de fréquence	Type de mesure	de Matériaux / Application	Modèle ML	Performance
[9]	2–3 GHz	Simulation	10 liquides diélectriques homogènes. Applications de laboratoire micro-ondes / chimie	ANN, régression	Erreur relative < 0,05. Validation expérimentale
[10]	2,65–18 GHz	Simulation	2 composites à base de papier pour la conception de composites fonctionnels EM	ANN, régression	$R^2 \approx 0,98$. Validation expérimentale
[11]	1–6 GHz	Simulation	8 plaques diélectriques solides pour une modélisation et une conception RF/PCB précises	ANN, régression	Erreur relative < 0,2. Validation expérimentale
[12]	1–10 GHz	Simulation	1 plaque diélectrique solide pour la qualification des matériaux et la modélisation EM	DNN, régression	Erreur relative < 0,012. Validation expérimentale
[13]	2,6–40 GHz	Simulation	1 plaque diélectrique solide pour la caractérisation large bande de la permittivité des substrats RF/PCB	DNN, RF, GB, régression	$R^2 \approx 0,98$. Validation expérimentale
[16]	0,3–3 GHz	Simulation	12 liquides diélectriques homogènes et mélanges liquides pour des applications de laboratoire micro-ondes / chimie	ANN, régression	$MSE \approx 1,7 \times 10^{-3}$ (test) et erreur relative $\approx 0,9$ (validation). Validation expérimentale
[17]	28–100 GHz	Simulation	4 matériaux de construction en intérieur pour la cartographie sémantique et la planification de réseaux sensibles à la propagation	NB, DT, MP, RF, classification	Précision $\approx 0,65$ (NB), 0,70 (DT/MP) et 0,85 (RF). Validation par simulation

Ce travail porte sur l'étude de la propagation des ondes dans la bande de fréquence 8–12 GHz, en s'appuyant sur une méthodologie expérimentale de réflexion en espace libre. L'analyse a été conduite sur neuf matériaux de construction afin d'affiner la modélisation de la propagation indoor et d'optimiser le déploiement des réseaux sans

fil. Pour le traitement de ces données, un réseau de neurones profonds (DNN) multitâche a été développé pour assurer simultanément la classification et la régression. La validité de cette approche est confirmée par des performances élevées, avec une précision de classification d'environ 0,99, ainsi qu'une régression robuste affichant un $R^2 > 0,98$ et une erreur absolue moyenne (MAE) inférieure à 0,03 lors de la validation expérimentale.

1.3. Justification et contribution du projet de recherche

1.3.1. Problématique

Les travaux partagés [1-2], [4], [5-9] témoignent d'une progression constante, depuis les premières approches analytiques itératives jusqu'à l'intégration des techniques d'IA et des algorithmes avancés. Malgré les avancées significatives dans la caractérisation électromagnétique des matériaux et l'intégration de l'IA, plusieurs limitations majeures subsistent :

- **Dépendance forte aux données simulées** : La majorité des approches reposent principalement, voire exclusivement, sur des données issues de simulations électromagnétiques, ce qui limite leur représentativité et leur robustesse face aux conditions expérimentales réelles.
- **Fréquences extrêmes ou peu représentatives** : Plusieurs travaux se concentrent sur des bandes de fréquences très élevées (mmWave, térahertz) ou spécifiques (RF/PCB), laissant peu de place à l'étude de bandes pratiques largement utilisées pour les environnements intérieurs réels.
- **Matériaux simplifiés et peu diversifiés** : Les matériaux considérés sont souvent homogènes, idéalisés ou en nombre limité (liquides diélectriques, plaques simples), ce qui ne reflète pas la complexité et l'hétérogénéité des matériaux de construction réels.

- **Objectif unique (classification ou régression)** : La plupart des méthodes traitent soit l'identification des matériaux, soit l'estimation de paramètres électromagnétiques, sans cadre unifié permettant de combiner les deux tâches simultanément.
- **Faible capacité de généralisation** : Les modèles sont généralement entraînés et validés sur des configurations spécifiques, ce qui limite leur transfert vers de nouveaux matériaux.

1.3.2. Positionnement du projet de recherche

L'objectif général de ce mémoire est de proposer une méthodologie intelligente pour la caractérisation électromagnétique des matériaux de construction en environnements intérieurs à l'aide de l'apprentissage profond. Les principales contributions de ce mémoire sont :

- La proposition d'une nouvelle méthodologie complète de caractérisation électromagnétique des matériaux, développée de bout en bout, depuis la conception du protocole expérimental jusqu'à l'exploitation des résultats par un modèle d'apprentissage profond.
- La construction d'une base de données expérimentale originale, entièrement issue de mesures réelles en espace libre, non destructives, spécifiquement conçue pour la caractérisation électromagnétique des matériaux de construction.
- L'étude et la caractérisation de neuf matériaux de construction couramment utilisés en environnements intérieurs, pour lesquels peu de travaux exploitant des données expérimentales réelles couplées à l'intelligence artificielle ont été rapportés dans la littérature.
- L'exploitation d'une bande de fréquences large (8–12 GHz), correspondant à des applications radiofréquences modernes, ce qui distingue ce travail de nombreuses

études existantes généralement limitées à d'autres bandes ou à des configurations plus restreintes.

- Le développement d'un modèle multitâche simple, efficace et facile à utiliser, permettant simultanément la classification des familles de matériaux et l'estimation de leurs propriétés électromagnétiques, sans recourir à des dispositifs expérimentaux complexes.
- La démonstration qu'une approche basée sur l'intelligence artificielle, entraînée exclusivement sur des données expérimentales non destructives, peut offrir une solution pratique, rapide et fiable pour la caractérisation électromagnétique et la modélisation de la propagation en environnements intérieurs.

Le choix de la bande 8–12 GHz s'explique par sa pertinence scientifique et par les moyens disponibles au laboratoire. Cette bande, correspondant à la bande X, est adaptée à l'étude des interactions onde–matériau et permet d'obtenir des mesures sensibles aux variations de permittivité et de conductivité. Elle correspond également aux équipements disponibles, notamment des antennes directives, facilitant un contrôle précis des mesures en espace libre. Il est important de préciser que l'approche proposée peut être étendue à d'autres bandes de fréquences, sous réserve de disposer d'un dispositif expérimental approprié.

1.4. Méthodologie

La méthodologie adoptée dans cette étude repose sur trois étapes principales : la création de la base de données, la conception du modèle d'IA et la validation finale accompagnée d'une analyse des erreurs.

Cette méthodologie introduit une nouvelle dimension dans la caractérisation électromagnétique, non seulement en termes de précision et d'efficacité computationnelle, mais également en ouvrant la voie à de nouvelles applications dans

les domaines des télécommunications, de la recherche scientifique et de l'industrie des matériaux. Elle permet en outre de généraliser les prédictions à des matériaux expérimentaux non testés, ce qui représente une avancée majeure par rapport aux études actuelles. Afin d'atteindre cet objectif principal, plusieurs objectifs spécifiques sont définis :

- Collecter et structurer une base de données expérimentale comprenant des coefficients de réflexion mesurés sous différents angles et configurations d'antennes.
- Développer un modèle d'apprentissage profond capable d'extraire des caractéristiques pertinentes à partir des données expérimentales.
- Mettre en place une architecture multitâche permettant de réaliser simultanément la classification des matériaux et l'estimation de leurs propriétés électromagnétiques.
- Évaluer les performances du modèle en termes de précision, de robustesse et de capacité de généralisation.
- Comparer les résultats obtenus avec ceux des approches classiques afin de démontrer la valeur ajoutée de l'approche IA proposée.

1.5. Conclusion

Ce chapitre a présenté l'évolution des méthodes de caractérisation électromagnétique des matériaux, depuis les approches classiques jusqu'aux techniques modernes fondées sur l'intelligence artificielle. Les méthodes traditionnelles, bien qu'essentielles, montrent des limites en termes de précision, de coûts expérimentaux et de capacité d'adaptation aux environnements complexes. Les travaux récents intégrant le machine learning ont permis d'améliorer la reconstruction des paramètres électromagnétiques, mais demeurent sensibles au bruit, aux conditions réelles et à l'extrapolation vers de nouveaux matériaux. Ces constats justifient le positionnement du projet, dont

l'approche vise à répondre aux limites identifiées et ouvre la voie à des outils plus robustes et généralisables pour la caractérisation des matériaux en environnements réels. Le chapitre suivant sera consacré à la création de cette base de données.

2. Création de la base de données

2.1. Introduction

Ce chapitre présente le processus de conception du cadre expérimental utilisé pour l'étude de la réflexion des ondes électromagnétiques en environnement intérieur. Il décrit les différentes étapes mises en œuvre pour définir le scénario de mesure, depuis sa modélisation en simulation jusqu'à sa reproduction expérimentale.

Dans une première phase, la simulation est utilisée exclusivement pour définir et paramétrer le scénario de mesure à l'aide des logiciels Altair FEKO et WinProp, notamment pour le choix et la modélisation de l'antenne cornet. Dans une seconde phase, des mesures expérimentales sont réalisées dans un scénario reproduisant fidèlement les conditions définies en simulation et portant sur neuf matériaux de construction. Cette étape vise à constituer un ensemble de données expérimentales destiné à l'entraînement et à la validation du modèle d'intelligence artificielle. L'objectif final est de disposer d'une base de données fiable et représentative pour l'apprentissage et l'évaluation du modèle proposé.

2.2. Simulation avec Altair Feko

2.2.1. Altair Feko

2.2.1.1. CADFEKO

CADFEKO est un module de modélisation CAO de FEKO permettant la création et la modification de géométries complexes à l'aide de structures primitives et d'opérations booléennes. Il facilite l'importation et l'exportation de modèles sous divers formats industriels et intègre une bibliothèque de composants pour optimiser la conception. En

plus de configurer les simulations et d'ajuster les paramètres de calcul, il prend en charge la génération de maillages adaptés aux méthodes de résolution employées [21].

2.2.1.2. Utilisation de CADFEKO et importation de l'antenne cornet

Dans ce projet, CADFEKO a été utilisé pour modéliser et importer une antenne cornet depuis la bibliothèque intégrée du logiciel, dont la géométrie est présentée à la Figure 2.1.

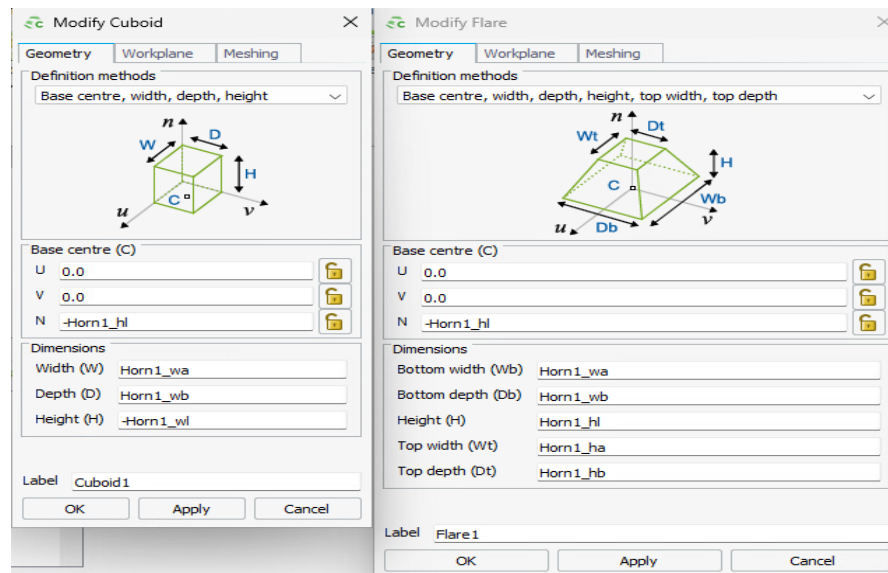


Figure 2. 1 La Géométrie de l'Antenne Cornet Importée depuis la Bibliothèque dans CADFEKO

Cette approche permet d'assurer une cohérence entre les simulations numériques et les mesures expérimentales, en utilisant une antenne identique à celle employée lors des tests réels. Grâce aux fonctionnalités de CADFEKO, la géométrie de l'antenne a été paramétrée à l'aide de variables définissant ses dimensions et ses caractéristiques électromagnétiques, comme présenté dans la figure 2.2.

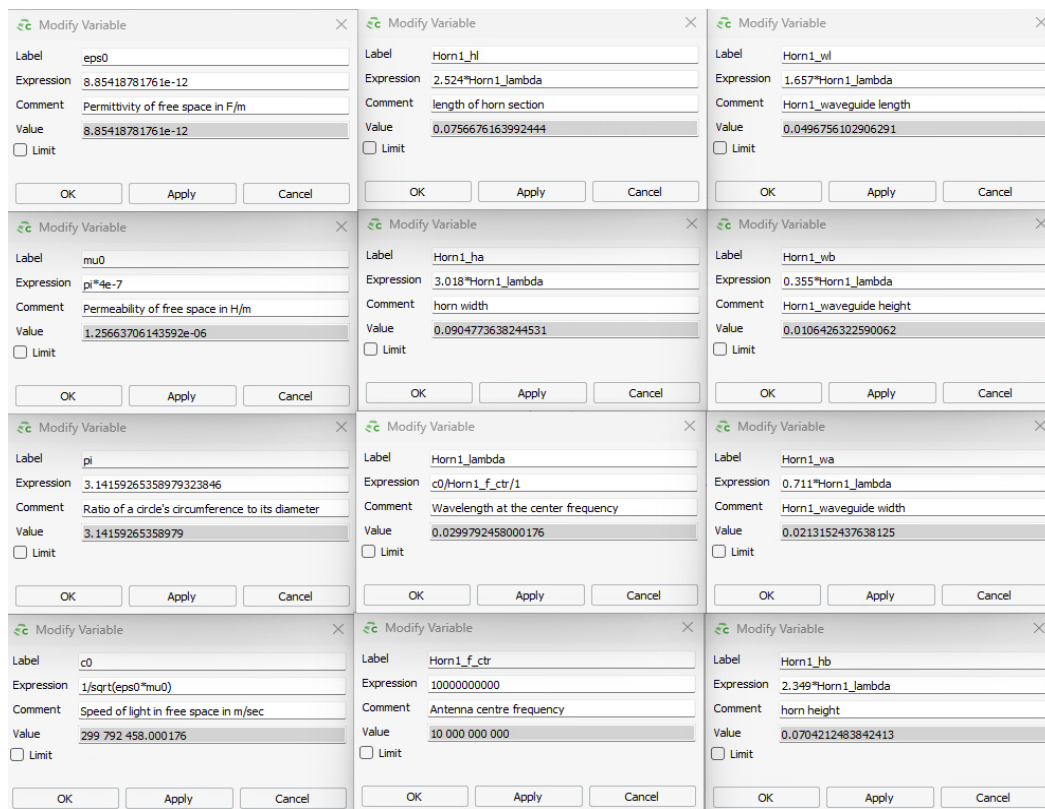


Figure 2. 2 Définition des Variables Paramétriques pour la Modélisation de l'Antenne Cornet dans CADFEKO

2.2.1.3. POSTFEKO

POSTFEKO est un module dédié à la vérification des modèles et à l'analyse des résultats après simulation. Il permet de s'assurer que les modèles créés dans CADFEKO sont correctement configurés avant l'exécution des simulations. Sa principale fonction est le post-traitement des résultats, offrant des outils de visualisation avancés tels que des vues 3D, des diagrammes de Smith et des graphiques polaires. Il prend en charge l'importation de données de mesure pour comparer les résultats simulés avec des données expérimentales. Une interface de script intégrée permet d'automatiser les tâches répétitives et de personnaliser l'expérience utilisateur [22].

2.2.1.4. Utilisation de POSTFEKO pour l'analyse

Dans ce projet, POSTFEKO a été utilisé pour analyser et exploiter les résultats de simulation de l'antenne cornet modélisée dans CADFEKO. Une fois l'antenne importée, POSTFEKO a permis de vérifier la configuration du modèle, d'afficher les résultats de simulation et d'examiner les caractéristiques électromagnétiques de l'antenne comme illustré à la Figure 2.3.

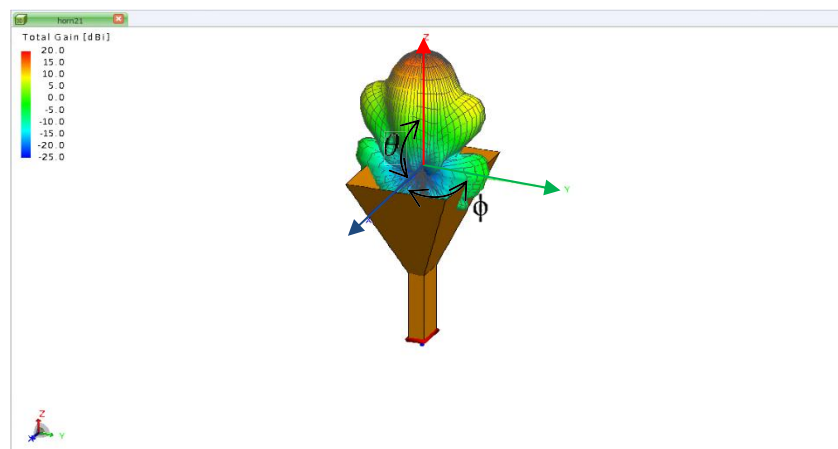


Figure 2. 3 Diagramme de Rayonnement en 3D de l'Antenne Cornet

L'élément clé de cette analyse a été la génération du diagramme de rayonnement de l'antenne, essentiel pour la simulation de la propagation des ondes dans WinProp, comme illustré aux Figures 2.4 et 2.5. Cette étape garantit que la source utilisée dans la simulation reflète fidèlement le comportement de l'antenne réelle, assurant ainsi une meilleure précision dans l'étude de la réflexion des ondes électromagnétiques en fonction des matériaux étudiés.




Figure 2. 4 Diagramme de Rayonnement 2D en Champ Lointain de l'Antenne Cornet ($\phi = 0^\circ$) à 10 GHz

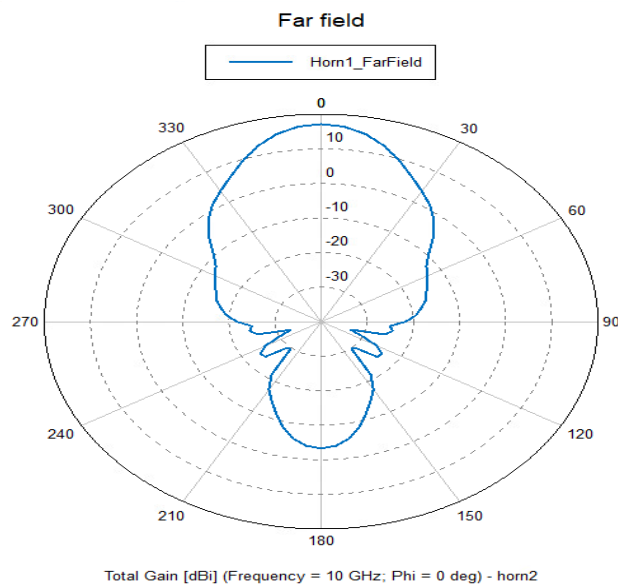


Figure 2. 5 Diagramme de Rayonnement Polaire en Champ Lointain de l'Antenne Cornet ($\phi = 0^\circ$) à 10 GHz

2.2.1.5. Introduction à Winprop

WinProp est un logiciel de simulation électromagnétique développé par Altair et spécialisé dans la modélisation de la propagation des ondes radio en environnements intérieurs et extérieurs. Il permet d'évaluer l'impact des obstacles, des matériaux et des configurations géométriques sur la propagation du signal, rendant son utilisation essentielle pour les études de couverture et d'atténuation [23]. Dans ce projet, WinProp est utilisé pour simuler la réflexion on des ondes électromagnétiques en fonction des matériaux. Toutefois, WinProp repose sur des modèles simplifiés et peut présenter des limites lorsqu'une très haute précision électromagnétique est requise.

2.2.1.6. WallMan

WallMan est un module de modélisation géométrique utilisé dans WinProp pour définir les environnements de simulation. Il permet de créer des structures en 2D et 3D, en spécifiant les propriétés des matériaux (permittivité, conductivité, épaisseur, etc.) [24]. Dans ce projet, WallMan a été utilisé pour modéliser les scénarios de simulation, en s'appuyant sur la base de données de WinProp, figure 2.6 et 2.7, qui contient une large gamme de matériaux aux caractéristiques électromagnétiques prédéfinies.

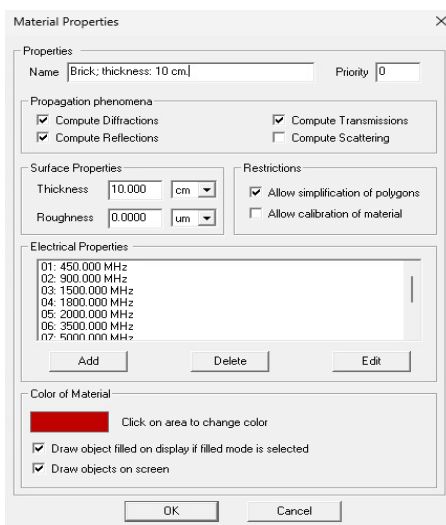


Figure 2. 7 Propriétés du Matériau Brique dans WallMan

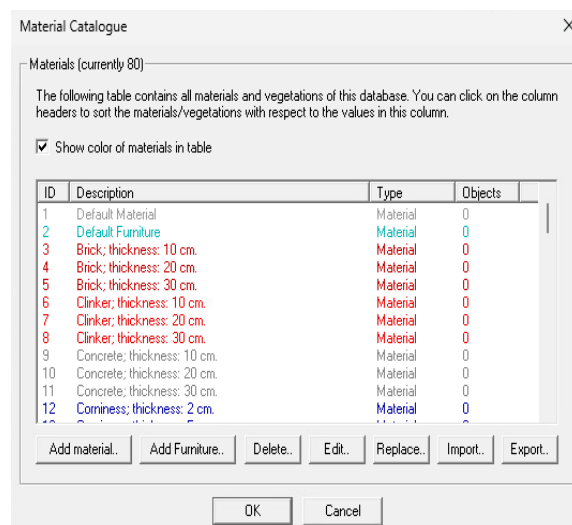


Figure 2. 6 Catalogue des Matériaux dans WallMan

2.2.1.7. ProMan

ProMan est le module principal de WinProp, dédié à la simulation de la propagation des ondes. Il prend en compte les paramètres définis dans WallMan et permet d'exécuter des calculs basés sur différentes méthodes de prédiction, comme les modèles ray-tracing ou empiriques [25]. Dans ce projet, ProMan a été utilisé pour analyser la propagation des ondes électromagnétiques dans des environnements contenant différents matériaux. La configuration du scénario de propagation est présentée à la Figure 2.8.

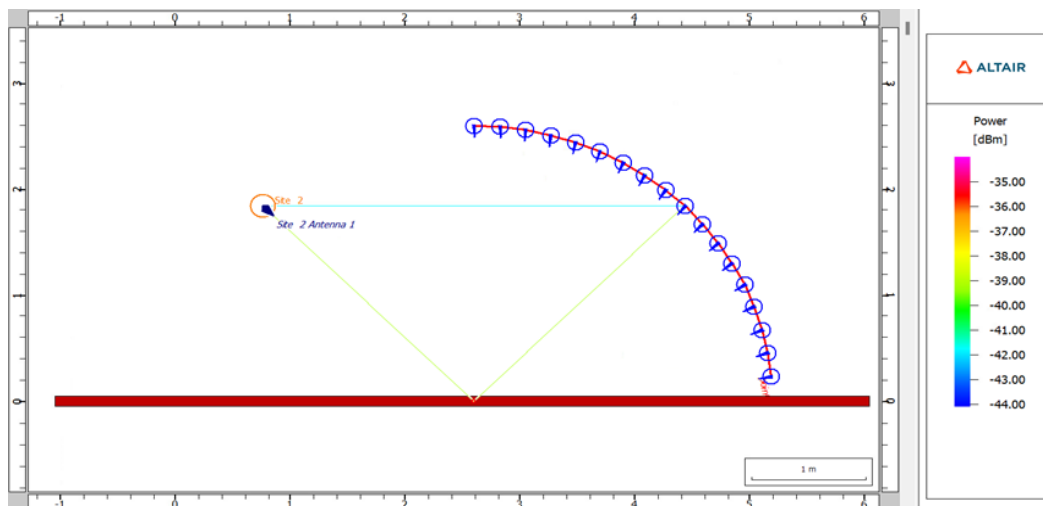


Figure 2. 8 Scénario de Propagation avec Antenne Réceptrice en Mouvement sur un Demi-Cercle

Ces différentes étapes permettent de réaliser une modélisation précise de la propagation des ondes dans l'environnement défini. Elles assurent que les interactions des ondes avec les murs sont bien prises en compte, tout en permettant une comparaison avec les mesures expérimentales.

Le scénario de mesure présenté à la Figure 2.9 a été conçu en simulation et constitue la configuration retenue pour la réalisation des mesures expérimentales.

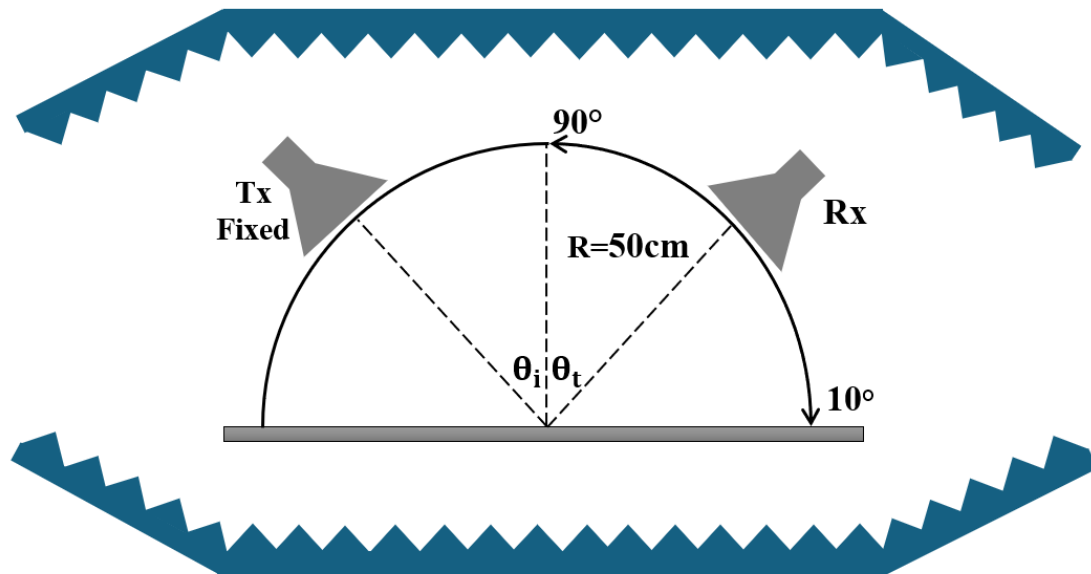


Figure 2. 9 Scénario de mesure défini pour les mesures expérimentales

2.3. Mesures expérimentales

Après avoir élaboré et validé le scénario de propagation sur le plan théorique à l'aide des simulations, et après avoir démontré la fiabilité de la méthodologie proposée, nous avons reproduit exactement la même configuration dans un environnement expérimental. Ainsi, le même dispositif basé sur un demi-cercle, avec une antenne émettrice fixe et une antenne réceptrice se déplaçant selon des angles définis, a été mis en place afin de collecter un ensemble de mesures représentatives. La base de données expérimentale a été obtenue à l'aide d'un analyseur de réseau vectoriel (VNA) Keysight N9950B, opérant dans la bande 8–12 GHz. Les mesures ont été réalisées pour neuf matériaux distincts. Pour chaque configuration, les paramètres suivants ont été enregistrés, notamment les positions des antennes d'émission (Tx) et de réception (Rx), les composantes réelle et imaginaire du coefficient de réflexion (Γ_{real} et Γ_{imag}), ainsi que l'amplitude et la phase du coefficient de réflexion (Γ).

L'antenne cornet utilisée dans cette étude est un modèle à large ouverture conçu pour fonctionner dans la bande de fréquences 8–12 GHz. Sa géométrie est définie par une ouverture supérieure de 90 mm × 70 mm, une ouverture inférieure de 20 mm × 10 mm, et une hauteur d'évasement de 75 mm, suivie d'une section de guide d'onde rectangulaire mesurant 20 mm × 10 mm avec une longueur de 50 mm.

Les antennes d'émission (Tx) et de réception (Rx) sont toutes deux montées sur des trépieds réglables afin d'assurer une position stable et un alignement précis vers le centre du dispositif de mesure. Elles présentent une largeur de faisceau à mi-puissance (HPBW) d'environ 15°, garantissant un lobe principal suffisamment étroit et bien focalisé pour une illumination précise du matériau testé.

Cette configuration permet d'obtenir des mesures reproductibles, une sensibilité accrue aux variations angulaires, et une caractérisation fiable du coefficient de réflexion pour chaque matériau étudié. L'ensemble des données recueillies reflète le comportement électromagnétique complexe de différents matériaux de construction. Cette base de données constitue la source principale pour l'entraînement et la validation du modèle d'apprentissage profond (DualNet) développé dans cette étude.

2.3.1. Définition des paramètres S

Les paramètres S, ou paramètres de diffusion (Scattering Parameters), sont des coefficients utilisés en hyperfréquences et en radiofréquences (RF) pour caractériser le comportement d'un réseau à plusieurs ports. Ils permettent de décrire la manière dont un signal électromagnétique est transmis et réfléchi lorsqu'il traverse un dispositif, tel qu'une ligne de transmission, un filtre ou une antenne. Les paramètres S sont généralement représentés sous la forme d'une matrice S, où chaque coefficient S_{ij} exprime la relation entre les puissances transmises et réfléchies entre les ports d'un réseau [26].

- S11 (Réflexion d'entrée) : Mesure la quantité d'onde réfléchie vers le port d'entrée.
- S21 (Transmission) : Indique la proportion du signal transmis du port 1 vers le port 2.
- S12 (Transmission inverse) : Représente la transmission de l'autre sens, du port 2 vers le port 1.
- S22 (Réflexion de sortie) : Similaire à S11 , mais pour le port de sortie.

2.3.2. Description de l'expérience

L'objectif de la phase expérimentale est d'automatiser le prétraitement et l'extraction du coefficient de réflexion complexe (Γ) à partir des paramètres S mesurés, obtenus pour différents angles de réception. Pour chaque matériau testé (MUT — Material Under Test), les mesures sont comparées à une référence métallique, une plaque en aluminium de dimensions $24'' \times 48'' \times 0.025''$, afin d'isoler la contribution intrinsèque du matériau.

2.3.2.1. Emplacement des mesures


Les mesures expérimentales ont été réalisées dans le sous-sol de l'Université du Québec en Outaouais (UQO). L'ensemble du dispositif a été installé sur une grande table, sur laquelle le scénario de mesure a été entièrement tracé au sol à l'aide d'un papier quadrillé. Ce tracé a permis de définir avec précision la position des antennes, les angles d'émission et de réception (30° , 45° , 60°) ainsi que l'emplacement exact des matériaux testés. Un ensemble de panneaux absorbants en mousse anéchoïque a été disposé autour de la zone de mesure afin de réduire les réflexions parasites et de

garantir un environnement contrôlé. Les matériaux sous test (MUT) étaient fixés verticalement à l'aide de pinces de maintien, comme illustré sur la figure 2.10.




Figure 2. 10 Installation expérimentale comprenant la zone de mesure anéchoïque et la configuration des antennes.


Deux antennes cornet — l'émetteur (Tx) et le récepteur (Rx) — étaient positionnées de part et d'autre du matériau sous test. Leur orientation et leur distance ont été ajustées selon le scénario prédéfini. Un rapporteur circulaire placé au centre de la table a permis d'assurer une mesure précise des angles d'incidence et de réception. Cette configuration expérimentale, illustrée à la Figure 2.11 et mettant en œuvre les neuf matériaux étudiés, a permis de reproduire fidèlement les conditions prévues par le protocole expérimental et d'obtenir des mesures cohérentes, reproductibles et compatibles avec les données nécessaires à l'entraînement du modèle DualNet.




(a)




(b)



(c)



(d)



(e)



(f)




Figure 2. 11 Configuration expérimentale utilisée pour la caractérisation des différents matériaux. (a) Plaque d'aluminium (référence) – (b) Polypropylène alvéolaire – (c) Verre – (d) Polystyrène – (e) Plaque de plâtre – (f) Tuile acoustiques – (g) Panneau de ciment – (h) Contreplaqué – (i) Panneau de particules en bois – (j) Bois tendre.

Dans cette configuration, l'antenne émettrice est maintenue fixe sur un quart de cercle, tandis que l'antenne réceptrice se déplace le long de l'autre quart de cercle afin d'échantillonner des angles de réception compris entre 10° et 90° , avec un pas angulaire de 5° . Les mesures sont réalisées en environnement contrôlé à l'aide d'un VNA, garantissant une acquisition fiable des paramètres électromagnétiques. Un système de visée laser est utilisé pour assurer un alignement précis des antennes, permettant ainsi de maintenir une orientation optimale du faisceau réfléchi et d'assurer la reproductibilité des mesures, telle que présentée dans la Figure 2.12.




Figure 2. 12 (a) Laser d’alignement pour le positionnement angulaire des antennes. (b) Analyseur de réseau vectoriel Keysight N9950B utilisé pour l’acquisition des paramètres S.

2.3.3. Chaîne de traitement des données

Le prétraitement et l’extraction du coefficient de réflexion (Γ) sont réalisés à partir des mesures de paramètres S acquises pour différents angles de réception, en comparant chaque matériau testé (MUT — *Material Under Test*) à une référence métallique (REF). Les résultats sont ensuite agrégés, visualisés et exportés pour une analyse approfondie. La Figure 2. 13 illustre l’ensemble du flux de traitement appliqué à chaque fichier et pour chaque angle de mesure. La chaîne de traitement automatisée permet

d'agrégier, de visualiser et d'exporter les résultats sous forme de bases de données structurées, adaptées à la modélisation et à l'analyse le modèle.

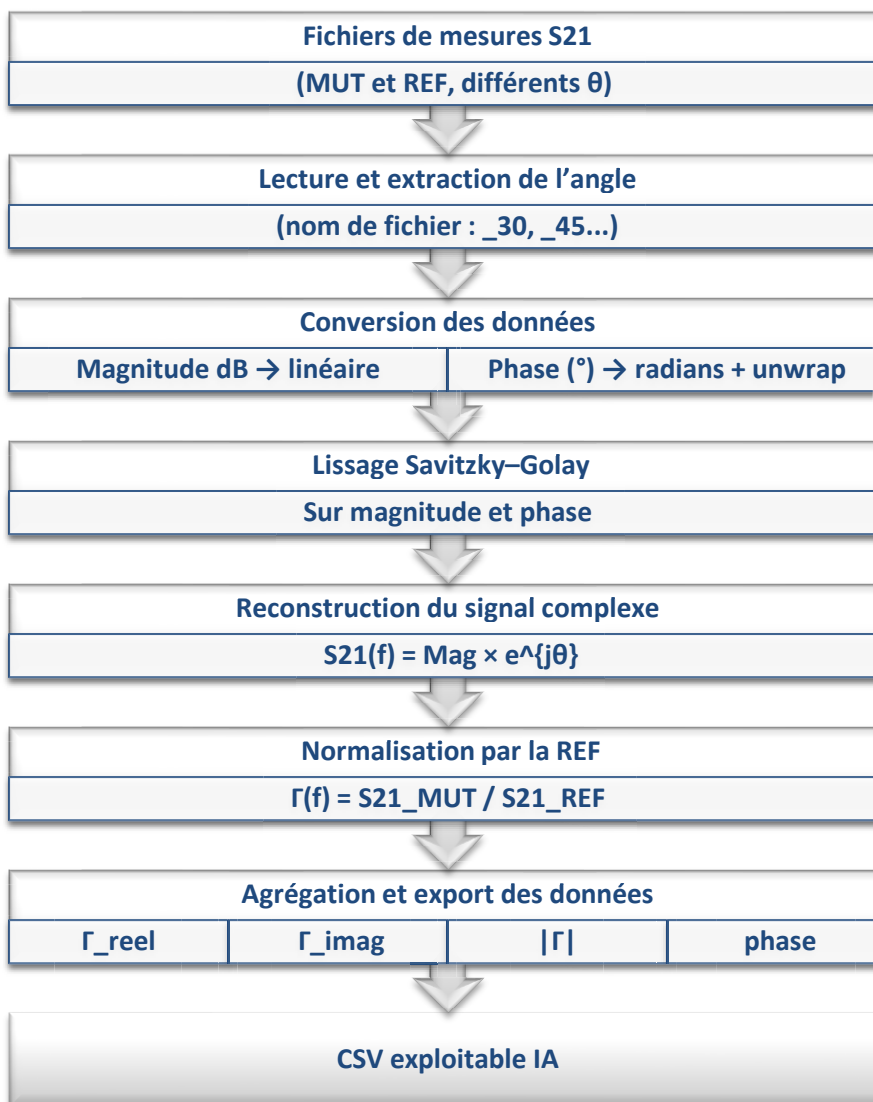


Figure 2. 13 Chaîne complète de traitement des données expérimentales

2.3.3.1. Résultats de mesure directe (S21)

Les courbes de la figure 2.14 représentent les mesures directes du coefficient de transmission S21 pour différents matériaux. La courbe noire correspond à la référence métallique (REF). Une diminution de l'amplitude est observée lorsque l'angle de réception augmente, accompagnée d'une atténuation plus marquée pour les matériaux à faible réflectivité tels que le polystyrène et le plastique ondulé.

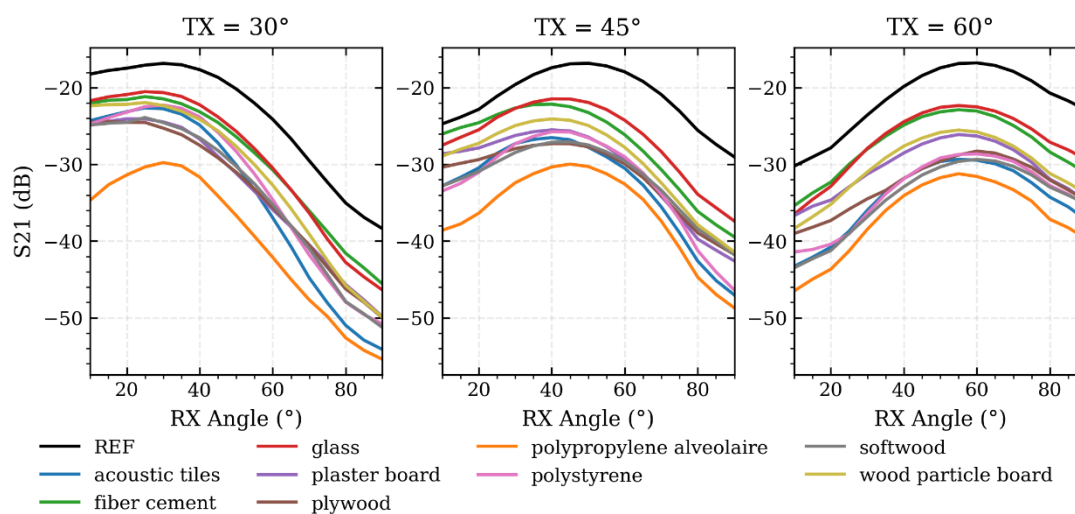


Figure 2. 14 Variation du paramètre S21 [dB] en fonction de l'angle de réception pour trois angles de transmission (TX = 30°, 45°, 60°).

2.3.3.2. Coefficients de réflexion normalisés

Les coefficients de réflexion (Γ) sont obtenus après normalisation par rapport à la référence métallique selon :

$$\Gamma = \frac{S21(\text{MUT})}{S21(\text{Metal})} \quad 2.1$$

Les résultats dans la figure 2.15 montrent une dépendance à la fois au type de matériau et à l'angle d'incidence. Les matériaux vitreux (par exemple, le verre, le panneau de ciment) présentent des coefficients de réflexion élevés, tandis que les matériaux légers tels que le bois, le plastique ondulé et le polystyrène affichent une réflexion plus faible et de meilleures propriétés de transmission.

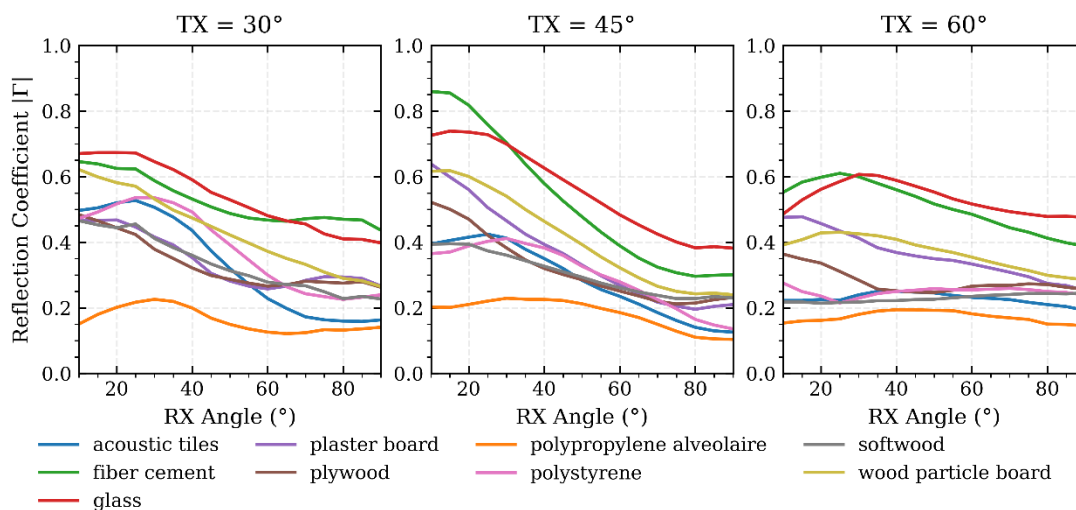


Figure 2. 15 Coefficient de réflexion $|\Gamma|$ pour différents matériaux en fonction de l'angle de réception.

Avant l'entraînement, une étape d'augmentation des données a été réalisée à l'aide d'une méthode d'interpolation locale, permettant de densifier les points de mesure entre les angles de réception voisins. Comme illustré à la Figure 2.16, cette approche permet de générer des points synthétiques (représentés par des croix "x") qui s'intègrent de manière cohérente entre les mesures réelles (représentées par des cercles "o") pour chaque matériau.

L'examen de cette figure montre que les données générées suivent fidèlement les tendances physiques du coefficient de réflexion en fonction de la position du récepteur. Par exemple, pour le verre (Real glass), les points interpolés respectent la décroissance continue du coefficient de réflexion observée expérimentalement. Cette densification améliore la représentativité du jeu d'apprentissage en offrant une continuité spatiale

que les seules mesures discrètes ne permettaient pas d'obtenir. À l'issue de cette étape, le jeu de données final est composé de 693 échantillons, offrant ainsi une base plus robuste pour l'apprentissage du réseau de neurones et réduisant les risques de surapprentissage (overfitting).

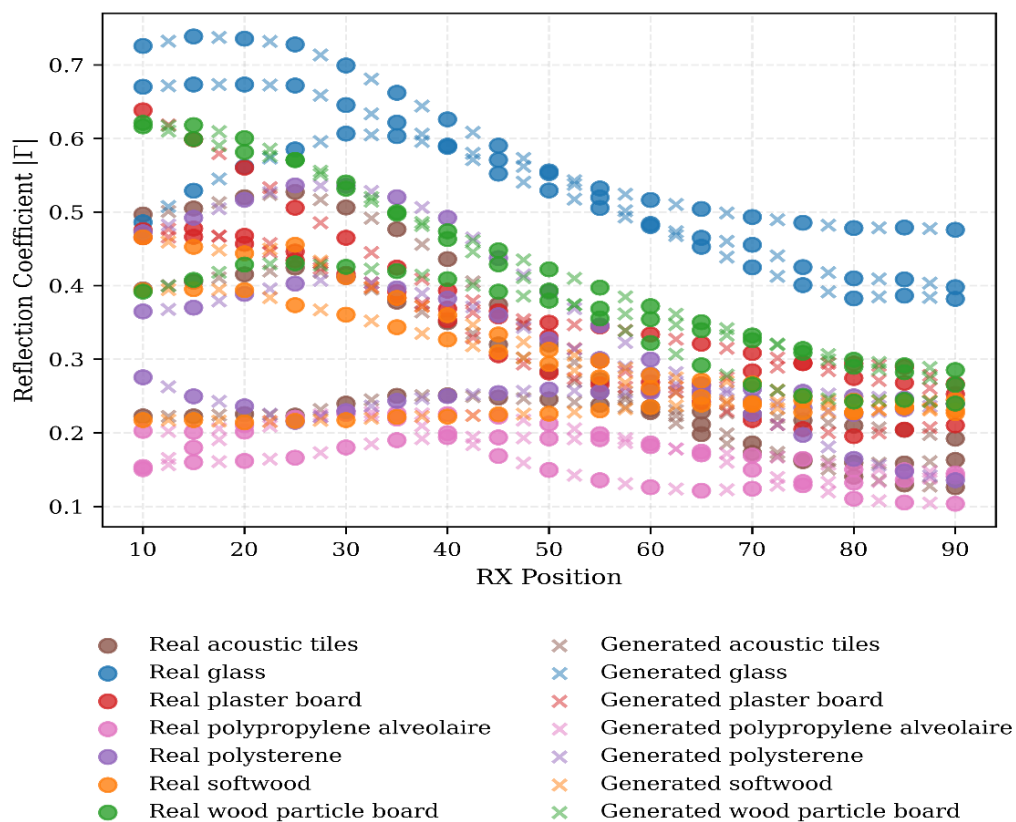


Figure 2. 16 Profils du coefficient de réflexion réels vs générés pour différents matériaux.

Enfin, l'ensemble des matériaux a été regroupé en quatre classes représentatives, comme présenté dans le tableau 2.1 :

Tableau 2. 1 Familles de matériaux testés et descriptions

Classe	Exemples de matériaux	Description
Matériaux vitreux (Vitreous materials)	Verre, panneau de ciment	Matériaux denses et rigides tels que le verre et le ciment sec
Matériaux composites et polymériques (Composite and polymeric materials)	Polypropylène alvéolaire, polystyrène	Plastiques et polymères caractérisés par une faible permittivité
Matériaux à base de bois (Ligno-cellulosic materials)	Contreplaqué (plywood), panneau de particules, bois tendre	Matériaux dérivés du bois, présentant une permittivité modérée
Matériaux à base de gypse (Gypsum-based materials)	Plaque de plâtre, tuiles acoustiques	Matériaux minéraux poreux avec une faible conductivité

2.4. Conclusion

Ce chapitre a présenté de manière détaillée la méthodologie mise en place pour l'étude expérimentale de la réflexion des ondes électromagnétiques. Après avoir défini et validé le scénario théorique basé sur une configuration en quart ou demi-cercle, celui-ci a été rigoureusement reproduit en conditions réelles afin d'assurer la cohérence entre simulation et expérimentation. Cette base servira de fondation pour la modélisation par intelligence artificielle présentée dans le chapitre suivant, où les matériaux seront caractérisés automatiquement à partir des coefficients de réflexion mesurés. Ainsi, ce chapitre marque la transition entre l'acquisition des données expérimentales et leur exploitation au sein d'un modèle d'apprentissage profond destiné à prédire les propriétés électromagnétiques des matériaux.

3. Conception du modèle IA

3.1. Introduction

L'objectif de cette section est de développer un modèle d'apprentissage profond capable d'exploiter l'ensemble des caractéristiques extraites des mesures expérimentales afin de produire simultanément deux types d'informations : la classification du matériau selon sa famille et la prédiction de ses propriétés électromagnétiques. Cette approche multitâche établit une correspondance directe entre la nature physique du matériau et son comportement électromagnétique, permettant ainsi une interprétation plus cohérente et plus robuste des mesures expérimentales. Le recours au deep learning se justifie par la complexité des relations non linéaires qui existent entre les paramètres d'entrée et les propriétés recherchées. Les réseaux neuronaux profonds offrent en effet une capacité d'apprentissage adaptée à la structure multidimensionnelle des données électromagnétiques. Le modèle proposé s'appuie entièrement sur les données expérimentales (693 échantillons) acquises dans la bande 8–12 GHz, garantissant ainsi une représentativité plus fidèle des conditions réelles de propagation. Le modèle a été développé sous Visual Studio Code en langage Python, en utilisant des bibliothèques telles que NumPy, Scikit-learn et PyTorch pour le traitement des données et l'entraînement du réseau neuronal.

3.2. Définition des variables

Les matériaux testés dans le cadre de cette étude sont les suivants : polypropylène alvéolaire, verre, polystyrène, plaque de plâtre, tuiles acoustiques, panneau de ciment, contreplaqué, panneau de particules en bois et bois tendre.

Il convient de préciser que les mesures expérimentales ont été réalisées sur un total de neuf matériaux. Toutefois, seuls sept matériaux ont été utilisés pour constituer le jeu

de données d'entraînement, de validation interne et de test du modèle. Les deux matériaux restants ont été volontairement exclus de cette phase afin d'évaluer la capacité de généralisation du modèle sur des données totalement non vues.

Ces deux matériaux n'ont donc participé ni à l'apprentissage, ni à l'optimisation des hyperparamètres, ni à l'évaluation intermédiaire du modèle. Ils ont été utilisés exclusivement dans une phase de validation externe indépendante, permettant d'analyser la robustesse et la transférabilité du modèle proposé. Les variables d'entrée et de sortie utilisées pour la constitution du jeu de données sont résumées dans le Tableau 3.1.

Tableau 3. 1 Description des variables utilisées dans le jeu de données

Type de variable	Description
Entrées	- Angle de transmission (Tx)
	- Angle de réception (Rx)
	- Coefficient de réflexion
	- Phase du coefficient de réflexion
Sorties (Classification)	- Famille du matériau
Sorties (Régression)	- Permittivité réelle ϵ' - Conductivité σ

Afin d'illustrer la structure des données utilisées pour l'entraînement du modèle, le tableau 3.2 présente un échantillon représentatif extrait de la base de données expérimentale.

Tableau 3. 2 Exemple d'un échantillon issu de la base de données expérimentale

Matériau	Permittivité ϵ'	Conductivité σ	Position Tx (°)	Position Rx (°)	Γ réel	Γ imaginaire	$ \Gamma $	Phase (°)
Vitreous materials	6.0000	0.0417	30	10	-0.635074	0.214196	0.670223	-49.386765

3.3. Analyse exploratoire des données

L'analyse de la structure des données constitue une étape essentielle avant la conception d'un modèle d'apprentissage profond. Dans ce travail, deux techniques de réduction de dimension ont été utilisées afin d'évaluer la nature des relations existant entre les paramètres électromagnétiques mesurés et les familles de matériaux : l'analyse en composantes principales (PCA) et la méthode t-SNE.

La PCA est une méthode de projection linéaire qui consiste à représenter les données dans un espace de plus faible dimension en maximisant la variance globale selon des combinaisons linéaires des variables d'entrée. Elle permet ainsi d'identifier les directions dominantes de variation dans les données. La projection PCA obtenue en figure 3.2 met en évidence une certaine structuration des matériaux selon leur famille, ce qui indique que les paramètres mesurés contiennent une information discriminante pertinente. Toutefois, la présence de zones de recouvrement entre plusieurs classes montre que cette séparation reste partielle. Cette observation suggère que les relations

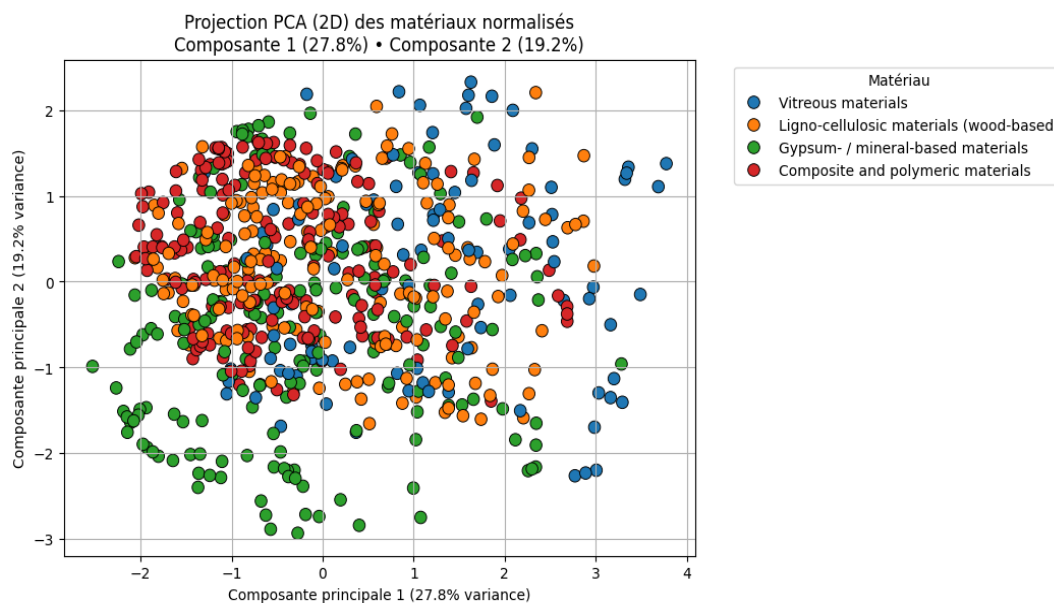


Figure 3. 1 Projection PCA en deux dimensions des matériaux

entre les caractéristiques électromagnétiques et les familles de matériaux ne peuvent pas être décrites uniquement à l'aide de frontières de décision linéaires.

À l'inverse, la méthode t-SNE est une technique de réduction de dimension non linéaire qui préserve les relations de voisinage locales. La visualisation t-SNE dans la figure 3.3 révèle des regroupements beaucoup plus distincts entre les familles de matériaux,

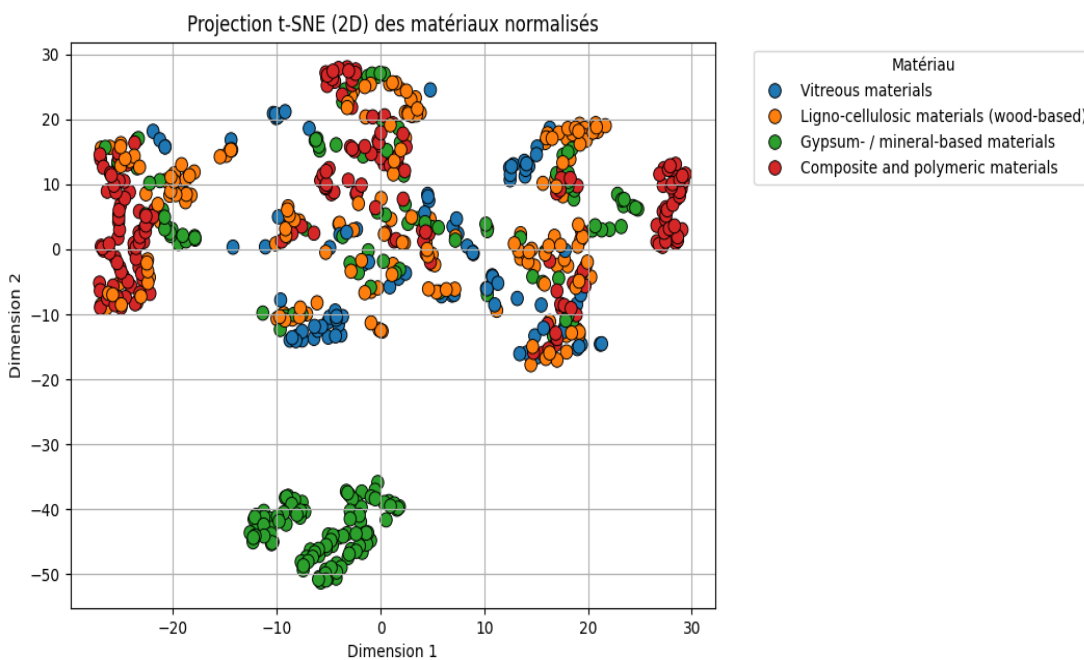


Figure 3. 2 Projection t-SNE en deux dimensions des matériaux

mettant en évidence l'existence de relations non linéaires complexes dans l'espace des caractéristiques électromagnétiques.

Ces résultats indiquent que, bien que les données présentent une organisation globale partiellement linéaire, leur structure réelle est dominée par des relations non linéaires liées aux interactions complexes entre les propriétés électromagnétiques des matériaux. Par conséquent, l'utilisation d'un modèle d'apprentissage profond, capable d'exploiter efficacement ces relations non linéaires et multidimensionnelles, apparaît comme un

choix pertinent et justifié pour la tâche de classification et d'estimation des propriétés électromagnétiques.

Voici la répartition globale des échantillons par classe :

- Matériaux composites et polymériques: 198
- Matériaux à base de gypse : 198
- Matériaux à base de bois :198
- Matériaux vitreux : 99

On observe que les classes Composite and polymeric materials, Gypsum / mineral-based materials et Ligno-cellulosic materials (wood-based) comptent chacune 198 échantillons, tandis que la classe Vitreous materials en contient 99.

Cette différence s'explique par la structure du jeu de données utilisé dans cette étude. L'ensemble d'entraînement comprend sept matériaux répartis en quatre familles. Les trois premières familles regroupent plusieurs matériaux, ce qui conduit naturellement à un nombre plus élevé d'échantillons. En revanche, la famille des matériaux vitreux ne comprend qu'un seul matériau, ce qui réduit proportionnellement le nombre total d'échantillons associés à cette classe. Ainsi, le léger déséquilibre observé entre les classes est directement lié à la composition physique des familles de matériaux et non à un biais introduit lors de la constitution ou du découpage du jeu de données.

3.4. Prétraitement et organisation du jeu de données

Avant l'entraînement du modèle, les étiquettes correspondant aux matériaux ont été encodées numériquement à l'aide d'un *LabelEncoder*. Le jeu de données a ensuite été divisé selon les proportions suivantes : 70 % pour l'entraînement, 15 % pour la validation et 15 % pour le test. Les variables d'entrée numériques ont été normalisées à l'aide d'un *StandardScaler* afin de centrer les données et d'harmoniser les échelles

des caractéristiques, garantissant ainsi un apprentissage équilibré et une convergence stable du modèle.

La normalisation est définie par l'équation suivante :

$$x^* = \frac{x - \mu}{\sigma} \quad 3.1$$

où :

- x est la valeur brute d'une caractéristique.
- μ est la moyenne de la caractéristique dans l'ensemble d'entraînement.
- σ est son écart type.
- x^* est la valeur normalisée de la caractéristique.

3.4.1. Architecture du modèle proposé

Le modèle DualNet proposé se compose de trois modules. Le bloc partagé extrait des caractéristiques communes à partir des coefficients de réflexion mesurés pour les deux tâches. La tête de classification prédit la famille du matériau, tandis que la tête de régression estime la permittivité réelle ε' et la conductivité électrique σ , permettant ainsi une identification et une caractérisation simultanées du matériau.

DualNet commence par projeter le vecteur d'entrée x dans une représentation latente partagée $h \in \mathbb{R}^{128}$ à l'aide de deux blocs entièrement connectés intégrant une activation ReLU, une normalisation par lot (batch normalization) et une régularisation par dropout :

$$a_1 = W_1 x^* + b_1 \quad 3.2$$

$$u_1 = \text{ReLU}(a_1) \quad 3.3$$

$$\tilde{u}_1 = \text{BN}_1(u_1) \quad 3.4$$

$$v_1 = \text{Drop}_{0.3}(\tilde{u}_1) \quad 3.5$$

$$a_2 = W_2 v_1 + b_2 \quad 3.6$$

$$u_2 = \text{ReLU}(a_2) \quad 3.7$$

$$h = \text{Drop}_{0.2}(\text{BN}_2(u_2)) \quad 3.8$$

où :

- $W_1 \in \mathbb{R}^{256 \times d}$ et $b_1 \in \mathbb{R}^{256}$ désignent respectivement la matrice de poids et le vecteur de biais de la première couche entièrement connectée.
- $W_2 \in \mathbb{R}^{128 \times 256}$ et $b_2 \in \mathbb{R}^{128}$ sont les paramètres de la seconde couche linéaire.
- $\text{ReLU}(\cdot)$ désigne la fonction d'activation rectifiée.
- Les opérateurs $\text{BN}_1(\cdot)$ et $\text{BN}_2(\cdot)$ représentent les opérateurs de normalisation par lot.
- $\text{Drop}_p(\cdot)$ correspond à l'opérateur de *dropout* appliqué avec une probabilité p .
- $h \in \mathbb{R}^{128}$ est la représentation latente partagée.

À partir de la représentation partagée h , la tête de classification produit un vecteur de logits $z \in \mathbb{R}^C$, où C représente le nombre de classes de matériaux :

$$s = W_3 h + b_3 \quad 3.9$$

$$q = \text{ReLU}(s) \quad 3.10$$

$$\tilde{q} = \text{Drop}_{0.2}(q) \quad 3.11$$

$$z = W_4 \tilde{q} + b_4 \quad 3.12$$

Les probabilités de classe sont obtenues à l'aide de la fonction Softmax :

$$\hat{y}_i = \frac{e^{z_i}}{\sum_{j=1}^C e^{z_j}}, i = 1, \dots, C \quad 3.13$$

La classe prédite correspond à $\arg \max_i \hat{y}_i$.

où :

- $W_3 \in \mathbb{R}^{64 \times 128}$ et $b_3 \in \mathbb{R}^{64}$.

- $W_4 \in \mathbb{R}^{C \times 64}$ et $b_4 \in \mathbb{R}^C$.
- z est le vecteur de logits.
- C est le nombre de classes de matériaux.
- \hat{y}_i est la probabilité prédite pour la classe i .

En parallèle, la tête de régression prédit les paramètres électromagnétiques continus, à savoir la permittivité réelle ε' et la conductivité σ :

$$t = W_5 h + b_5 \quad 3.14$$

$$r = \text{ReLU}(t) \quad 3.15$$

$$\hat{p} = W_6 r + b_6 \quad 3.16$$

où :

- $W_5 \in \mathbb{R}^{64 \times 128}$ et $b_5 \in \mathbb{R}^{64}$.
- $W_6 \in \mathbb{R}^{2 \times 64}$ et $b_6 \in \mathbb{R}^2$.
- $\hat{p} = \begin{bmatrix} \hat{\varepsilon}' \\ \hat{\sigma} \end{bmatrix}$ est le vecteur des paramètres électromagnétiques prédits.

Le modèle DualNet est entraîné de bout en bout en minimisant une fonction de coût multitâche combinant une perte d'entropie croisée pour la classification et une erreur quadratique moyenne (MSE) pour la régression :

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{CE}} + \mathcal{L}_{\text{MSE}} \quad 3.17$$

Pour un mini-lot de taille N , la perte de classification est définie par :

$$\mathcal{L}_{\text{CE}} = -\frac{1}{N} \sum_{n=1}^N \sum_{i=1}^C y_{n,i} \log(\hat{y}_{n,i}) \quad 3.18$$

où :

- N est la taille du mini-lot.

- C est le nombre de classes.
- $y_{n,i}$ représente l'étiquette réelle de l'échantillon n.
- \hat{y}_i désigne la probabilité prédite pour la classe i.

Et la perte de régression par :

$$\mathcal{L}_{\text{MSE}} = \frac{1}{N} \sum_{n=1}^N \|p_n - \hat{p}_n\|^2 \quad 3.19$$

où :

- $p = \begin{bmatrix} \hat{\epsilon}' \\ \hat{\sigma} \end{bmatrix}$ est le vecteur réel des paramètres électromagnétiques.
- \hat{p} est le vecteur prédit correspondant.

L'optimisation des paramètres du réseau $\Theta = \{W_l, b_l\}_{l=1}^6$, incluant ceux de la normalisation par lot, est réalisée à l'aide de l'optimiseur AdamW avec un taux d'apprentissage = 1×10^{-3} , et un facteur de décroissance des poids weight decay = 1×10^{-3} .

Le temps d'entraînement du modèle est relativement court, de l'ordre de 1 minute et 50 secondes sur la configuration matérielle utilisée. Cette durée modérée s'explique par la taille maîtrisée du jeu de données et par l'architecture compacte du réseau proposé.

3.4.2. Résultats et performances

3.4.2.1. Résultats globaux

Le modèle DualNet proposé est évalué à l'aide du jeu de données expérimental de réflexion en espace libre décrit précédemment. Les performances élevées obtenues peuvent être attribuées au dispositif expérimental contrôlé ainsi qu'à la forte différenciation électromagnétique entre les familles de matériaux considérées. Les

paramètres mesurés constituent ainsi des caractéristiques hautement discriminantes, permettant au modèle d'apprendre des relations physiques stables sans s'appuyer sur des corrélations triviales. La cohérence des résultats observée sur les ensembles d'entraînement, de validation et de test confirme la capacité de généralisation du modèle dans le cadre du scénario expérimental proposé. Le Tableau 3.3 récapitule les métriques d'évaluation du modèle, mettant en évidence une précision de classification quasi parfaite et des erreurs de régression minimales pour la prédiction de la permittivité et de la conductivité. Les résultats présentés dans cette section correspondent à la stratégie de partitionnement 70 % / 15 % / 15 %. À titre de vérification, une division alternative de type 80 % / 10 % / 10 % a également été évaluée et a conduit à des performances très similaires, confirmant la robustesse du modèle et son indépendance vis-à-vis du choix du découpage des données.

Tableau 3. 3 Résumé Des Métriques D'évaluation Du Modèle Dualnet

Type d'évaluation	Entraînement	Test
Accuracy (classification)	0.9999	1.0000
MSE (régression)	$9.46 \cdot 10^{-4}$	$1.28 \cdot 10^{-3}$
MAE (régression)	0.0236	0.0272
R² (régression)	0.9991	0.9987

3.4.2.2. Visualisation des performances

Les courbes présentées dans la Figure 3.3 illustrent l'évolution des pertes d'entraînement et de validation pour les deux sous-tâches du modèle DualNet :

- La classification (CrossEntropy),
- La régression (MSE).

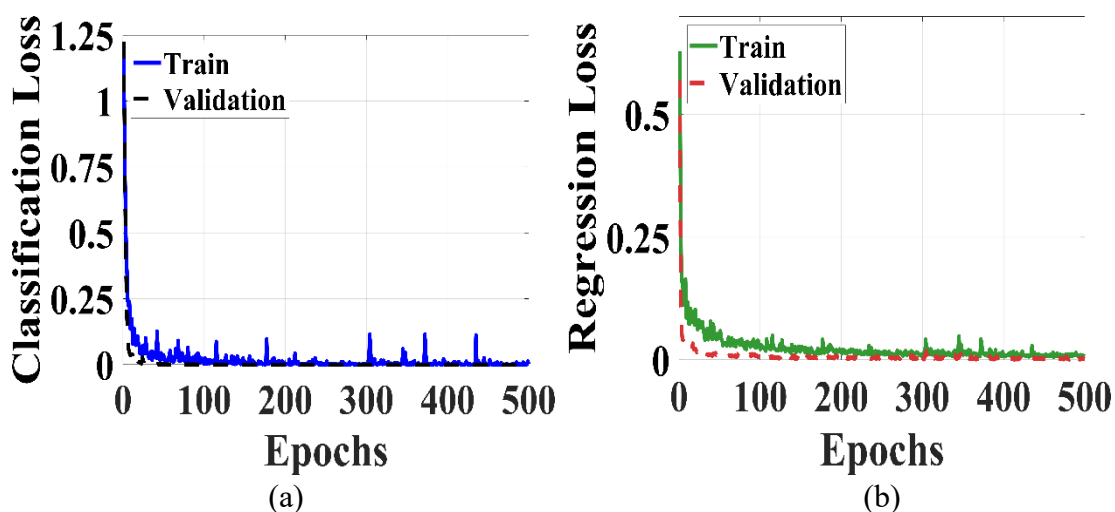


Figure 3. 3 Courbes de perte d'entraînement et de validation du modèle DualNet :
(a) perte de classification et (b) perte de régression

Une convergence rapide est observée dès les premières itérations, suivie d'une stabilisation après environ 50 époques. Le faible écart entre les courbes d'entraînement et de validation indique une bonne capacité de généralisation ainsi qu'une absence de surapprentissage. La diminution quasi exponentielle du MSE confirme la capacité du réseau à modéliser efficacement la relation entre les caractéristiques physiques et les propriétés électromagnétiques des matériaux.

La Figure 3.4 présente l'évolution de l'accuracy pour la tâche de classification et du coefficient de détermination (R^2) pour la tâche de régression au fil des époques.

L'accuracy dépasse rapidement les 99 %, démontrant une excellente capacité à distinguer les quatre familles de matériaux.

En parallèle, le coefficient R^2 dépasse 0,99 pour les ensembles d'entraînement et de validation, indiquant que les valeurs prédites (permittivité et conductivité) correspondent de manière très proche aux valeurs mesurées. Ces résultats valident la stabilité du modèle ainsi que la cohérence entre l'apprentissage supervisé et sa capacité de généralisation.

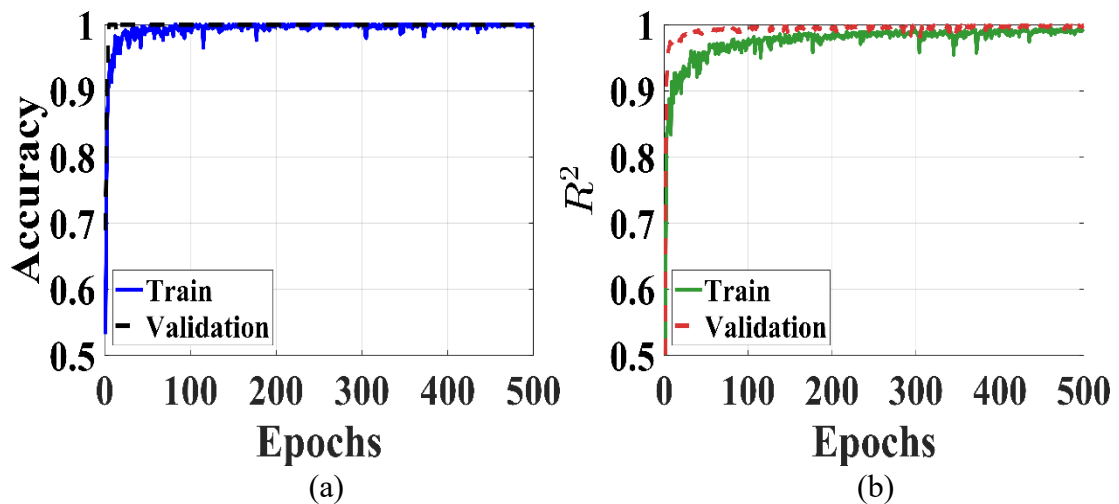


Figure 3. 4 Courbes d'apprentissage : (a) Évolution de l'accuracy pour la classification et du coefficient et (b) R^2 pour la régression au fil des époques d'entraînement

La Figure 3.5 représentant la matrice de confusion, montre une précision de 100 % pour les quatre catégories de matériaux :

- Composites polymériques,
- Matériaux vitreux,
- Matériaux à base de gypse / minéraux,
- Matériaux ligno-cellulosiques (à base de bois).

Aucune erreur de classification n'est observée, ce qui traduit une séparation claire des distributions de classes dans l'espace des caractéristiques. Cela confirme que le modèle DualNet a réussi à capturer des caractéristiques discriminantes robustes, lui permettant de distinguer efficacement les signatures électromagnétiques propres à chaque type de matériau.

True label	Composite and polymeric materials	100.0	0.0	0.0	0.0
	Gypsum / mineral-based materials	0.0	100.0	0.0	0.0
	Ligno-cellulosic materials (wood-based)	0.0	0.0	100.0	0.0
	Vitreous materials	0.0	0.0	0.0	100.0
		Composite and polymeric materials	Gypsum / mineral-based materials	Ligno-cellulosic materials (wood-based)	Vitreous materials
		Predicted label			

Figure 3. 5 Matrice de confusion normalisée (%) pour le classifieur DualNet

La Figure 3.6 compare les valeurs réelles et prédites de la permittivité (ϵ') et de la conductivité (σ). Les points expérimentaux s'alignent presque parfaitement sur la diagonale de référence ($y = x$), ce qui indique une corrélation quasi parfaite entre les valeurs mesurées et les valeurs estimées par le modèle.

Cette précision démontre la capacité du modèle à estimer de manière fiable les propriétés électromagnétiques à partir des paramètres d'entrée. La très faible dispersion autour de la diagonale confirme à la fois la robustesse du modèle de régression et la cohérence du jeu de données expérimental.

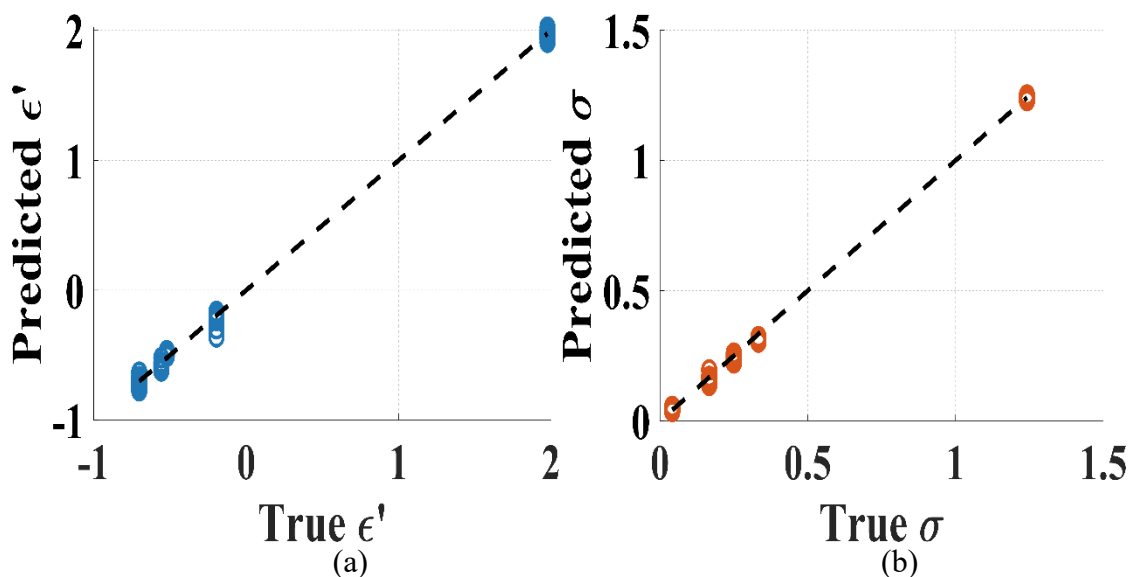


Figure 3. 6 Comparaison entre les valeurs réelles et prédites de (a) la permittivité (ϵ') et (b) la conductivité (σ)

3.5. Fonction de prédiction à partir des mesures expérimentales

La fonction de prédiction développée permet au modèle DualNet d'estimer simultanément la famille du matériau (classification) ainsi que ses propriétés électromagnétiques (régression), à savoir la permittivité réelle (ϵ') et la conductivité (σ). Cette fonction prend en entrée un fichier CSV expérimental contenant les paramètres mesurés du matériau. Le réseau DualNet réalise une double inférence :

1. **Classification** : prédiction de la famille du matériau parmi les classes apprises.
2. **Régression** : estimation des valeurs continues de ϵ' et σ .

Les résultats sont automatiquement enregistrés dans un fichier contenant les valeurs prédites pour chaque échantillon. Ce processus automatisé constitue un outil rapide, reproductible et précis pour relier directement les mesures expérimentales de réflexion aux propriétés électromagnétiques. Il permet ainsi une caractérisation fiable de nouveaux échantillons de matériaux à partir de simples mesures S-paramètres.

En phase d'inférence, le temps de prédiction est quasi instantané, inférieur à une seconde pour un nouvel échantillon. Cette rapidité d'exécution constitue un avantage important, notamment pour des applications nécessitant une estimation rapide et automatisée des propriétés électromagnétiques.

3.5.1. La généralisation du modèle sur des matériaux non vus

Dans le cadre de cette étude, deux matériaux dont le panneau de ciment et contreplaqué ont été volontairement exclus du jeu de données utilisé pour l'entraînement et validation du modèle DualNet. Cette exclusion a été effectuée afin de tester la capacité du modèle à généraliser vers des matériaux entièrement nouveaux, dont les propriétés électromagnétiques n'avaient pas été vues durant l'apprentissage. Grâce à la fonction de prédiction décrite précédemment, ces matériaux ont été soumis au réseau afin d'en estimer automatiquement la famille ainsi que leurs paramètres ϵ' et σ . Les valeurs obtenues ont ensuite été comparées aux données issues de la littérature, comme illustré dans le tableau 3.4, permettant ainsi de valider la cohérence et la fiabilité du modèle sur des matériaux « inconnus ». Cette démarche confirme que DualNet est capable non seulement de reproduire les propriétés des matériaux utilisés pour l'entraînement, mais également de fournir des estimations précises pour de nouveaux matériaux expérimentaux.

Tableau 3. 4 Comparaison des valeurs de permittivité réel (ϵ') issues de la littérature et de ce travail

Matériau	[2] 10 10 GHz	[9] 40 40 - 50 GHz	[27] 2 2 - 260 GHz	[28] 20 2-7 GHz	[29] 1-100 GHz	Cette étude 8 - 12 GHz		
	ϵ'					ϵ'	σ	Classe du matériau
Plywood (contreplaqué)	2.4	3.253	2	2.47	2.71	2.605 ± 0.154	0.209 ± 0.032	Ligno-cellulosic materials (wood-based)
Cement board (Panneau de ciment)	5.5	-	4.6	-	5.24	4.797 ± 0.7	0.088 ± 0.05	Vitreous materials

Les valeurs de permittivité relative obtenues dans cette étude pour le contreplaqué et le panneau de ciment s'accordent étroitement avec celles rapportées dans la littérature, confirmant la fiabilité du protocole expérimental. Le contreplaqué présente une permittivité faible, typique des matériaux ligno-cellulosiques, tandis que le panneau de ciment est classé comme matériau vitreux non pas au sens chimique, mais en raison de son comportement électromagnétique effectif dans la bande 8–12 GHz. Sa permittivité élevée et ses pertes modérées sont caractéristiques des matériaux minéraux denses, proches des bétons et des matériaux silico-calcaires. Les valeurs de conductivité mesurées (faibles pour les deux matériaux) sont également compatibles avec leur comportement diélectrique attendu dans la bande 8–12 GHz. Cette cohérence globale valide non seulement la méthode d'extraction des propriétés électromagnétiques, mais aussi la capacité du modèle DualNet à fournir des estimations fiables pour des matériaux exclus du jeu d'entraînement.

3.6. Conclusion

Ce chapitre a présenté la conception complète du modèle DualNet dédié à la caractérisation électromagnétique des matériaux. Après un prétraitement rigoureux incluant la normalisation des données et l'encodage des classes, l'architecture multitâche du réseau a été définie afin de répondre simultanément aux deux objectifs de l'étude : la classification des familles de matériaux et l'estimation de leurs propriétés physiques (permittivité réelle ϵ' et conductivité σ). Le modèle a démontré une capacité d'apprentissage efficace, soutenue par une convergence stable des fonctions de perte et par des performances particulièrement élevées dans les deux tâches. Les résultats obtenus sur les mesures expérimentales montrent une précision remarquable, aussi bien dans l'identification de la classe des matériaux que dans la prédiction de leurs propriétés électromagnétiques. L'évaluation du modèle sur des matériaux volontairement exclus du jeu d'entraînement confirme également sa capacité de généralisation, un aspect essentiel pour son utilisation sur de nouveaux échantillons.

Conclusion générale

Ce travail de recherche a permis de développer et de valider une nouvelle approche combinant mesures expérimentales, modélisation électromagnétique et intelligence artificielle pour la caractérisation des matériaux. À partir d'un protocole expérimental rigoureux basé sur des mesures en espace libre, une base de données fiable et représentative a été constituée. Ces données ont servi à entraîner et évaluer le modèle DualNet, un réseau neuronal multitâche capable de classifier les familles de matériaux et d'estimer simultanément leurs propriétés électromagnétiques fondamentales, telles que la permittivité réelle et la conductivité. Les résultats obtenus démontrent la capacité remarquable du modèle à capturer la relation complexe entre les paramètres expérimentaux et les caractéristiques physiques des matériaux. L'architecture proposée a montré une précision quasi parfaite en classification et des performances élevées en régression, confirmées par des métriques robustes telles que le MAE et le coefficient de détermination R^2 . L'un des apports importants de ce travail est la démonstration de la généralisation du modèle : les matériaux non vus pendant l'entraînement ont été correctement identifiés et estimés, avec des valeurs cohérentes par rapport à la littérature. Au-delà de ses performances, cette approche ouvre la voie à une nouvelle manière d'envisager la caractérisation des matériaux, en offrant une alternative rapide, automatisée et moins coûteuse que les méthodes expérimentales classiques. Elle permet également d'envisager des applications dans des contextes variés, notamment la planification radio, la modélisation des canaux de propagation, ou encore la conception de matériaux innovants.

Perspectives et Recommandations

Afin de prolonger ces travaux, plusieurs pistes de recherche peuvent être envisagées pour valoriser davantage l'apport de l'intelligence artificielle dans ce domaine :

- Élargissement spectral et matériel : L'intégration de données multi-fréquences et l'étude de nouveaux types de matériaux permettraient de généraliser le modèle à des environnements indoor plus complexes.
- Évolution des modèles : L'exploration d'architectures de réseaux profonds plus sophistiquées pourrait accroître la finesse de l'extraction des caractéristiques électromagnétiques.
- Application pratique : Une recommandation majeure concerne le déploiement en temps réel pour permettre une caractérisation in situ lors de la planification des réseaux sans fil.

Ces perspectives soulignent le rôle crucial de l'IA comme outil performant et complémentaire pour la caractérisation des matériaux, ouvrant la voie à des solutions de modélisation plus dynamiques et précises.

Bibliographies

- [1] J. Luo, Y. Shao, X. Liao, J. Liu, et J. Zhang, « Complex Permittivity Estimation for Cloths Based on QPSO Method Over (40 to 50) GHz », *IEEE Trans. Antennas Propag.*, vol. 69, n° 1, p. 600-605, janv. 2021, doi: 10.1109/TAP.2020.3005032.
- [2] S. S. Zhekov, O. Franek, et G. F. Pedersen, « Dielectric Properties of Common Building Materials for Ultrawideband Propagation Studies [Measurements Corner] », *IEEE Antennas Propag. Mag.*, vol. 62, n° 1, p. 72-81, févr. 2020, doi: 10.1109/MAP.2019.2955680.
- [3] U. C. Hasar, H. Ozturk, M. Ertugrul, J. J. Barroso, et O. M. Ramahi, « Artificial Neural Network Model for Evaluating Parameters of Reflection-Asymmetric Samples From Reference-Plane-Invariant Measurements », *IEEE Trans. Instrum. Meas.*, vol. 72, p. 1-8, 2023, doi: 10.1109/TIM.2023.3273664.
- [4] A. Hirata, K. Suizu, N. Sekine, I. Watanabe, et A. Kasamatsu, « Measurement of Glass Complex Permittivity at 200-500 GHz for THz Propagation Simulation », in *2020 International Symposium on Antennas and Propagation (ISAP)*, janv. 2021, p. 617-618. doi: 10.23919/ISAP47053.2021.9391155.
- [5] C. Yang, K. Ma, et J.-G. Ma, « A Noniterative and Efficient Technique to Extract Complex Permittivity of Low-Loss Dielectric Materials at Terahertz Frequencies », *IEEE Antennas Wirel. Propag. Lett.*, vol. 18, n° 10, p. 1971-1975, oct. 2019, doi: 10.1109/LAWP.2019.2935170.
- [6] N. Vohra et M. El-Shenawee, « K- and W-Band Free-Space Characterizations of Highly Conductive Radar Absorbing Materials », *IEEE Trans. Instrum. Meas.*, vol. 70, p. 1-10, 2021, doi: 10.1109/TIM.2020.3041821.
- [7] U. T. Virk, S. L. H. Nguyen, K. Haneda, et J.-F. Wagen, « On-Site Permittivity Estimation at 60 GHz Through Reflecting Surface Identification in the Point Cloud », *IEEE Trans. Antennas Propag.*, vol. 66, n° 7, p. 3599-3609, juill. 2018, doi: 10.1109/TAP.2018.2829798.
- [8] Y. Geng, « Map-Assisted Material Identification at 100 GHz and Above Using Radio Access Technology », in *2022 Joint European Conference on Networks and Communications & 6G Summit (EuCNC/6G Summit)*, juin 2022, p. 476-481. doi: 10.1109/EuCNC/6GSummit54941.2022.9815822.
- [9] P. Li, Y. Shao, et R. Xu, « Complex Permittivity Extraction of Typical Wooden Furniture Materials Based on Multi-Objective Particle Swarm Optimization Over 40-50 GHz », in *2024 18th European Conference on Antennas and Propagation (EuCAP)*, mars 2024, p. 1-5. doi: 10.23919/EuCAP60739.2024.10501676.
- [10] T. Mosavirik, M. Soleimani, V. Nayyeri, S. H. Mirjahanmardi, et O. M. Ramahi, « Permittivity Characterization of Dispersive Materials Using Power Measurements », *IEEE Trans. Instrum. Meas.*, vol. 70, p. 1-8, 2021, doi: 10.1109/TIM.2021.3062676.
- [11] Q. Chen, K.-M. Huang, X. Yang, M. Luo, et H. Zhu, « AN ARTIFICIAL NERVE NETWORK REALIZATION IN THE MEASUREMENT OF MATERIAL

- PERMITTIVITY », *Prog. Electromagn. Res.*, vol. 116, p. 347-361, 2011, doi: 10.2528/PIER11012902.
- [12] C. Xia *et al.*, « A novel method for extracting and optimizing the complex permittivity of paper-based composites based on an artificial neural network model », *Sci. China Technol. Sci.*, vol. 67, n° 10, p. 3190-3204, oct. 2024, doi: 10.1007/s11431-023-2643-x.
- [13] S. Panda, N. K. Tiwari, et M. J. Akhtar, « Computationally Intelligent Sensor System for Microwave Characterization of Dielectric Sheets », *IEEE Sens. J.*, vol. 16, n° 20, p. 7483-7493, oct. 2016, doi: 10.1109/JSEN.2016.2599856.
- [14] L. Nov, J.-Y. Chung, et J. Park, « Broadband Permittivity Characterization of a Substrate Material Using Deep Neural Network Trained With Full-Wave Simulations », *IEEE Access*, vol. 10, p. 48464-48471, 2022, doi: 10.1109/ACCESS.2022.3172300.
- [15] A. C. Martínez, J. F. de la Torre, R. S. González, B. P. Gallardo, et D. P. Martínez, « Machine Learning Methods Applied to Broadband Electromagnetic Characterization », in *2025 Antenna Measurement Techniques Association Symposium (AMTA)*, nov. 2025, p. 1-6. doi: 10.23919/AMTA66658.2025.11317850.
- [16] T. Mosavirik, M. Hashemi, M. Soleimani, V. Nayyeri, et O. M. Ramahi, « Accuracy-Improved and Low-Cost Material Characterization Using Power Measurement and Artificial Neural Network », *IEEE Trans. Instrum. Meas.*, vol. 70, p. 1-9, 2021, doi: 10.1109/TIM.2021.3126011.
- [17] T. Mosavirik, M. Hashemi, M. Soleimani, V. Nayyeri, et O. M. Ramahi, « Material Characterization Using Power Measurements: Miracle of Machine Learning », in *2021 51st European Microwave Conference (EuMC)*, avr. 2022, p. 606-609. doi: 10.23919/EuMC50147.2022.9784321.
- [18] T. Mosavirik, V. Nayyeri, M. Hashemi, M. Soleimani, et O. M. Ramahi, « Direct Permittivity Reconstruction From Power Measurements Using a Machine Learning Aided Method », *IEEE Trans. Microw. Theory Tech.*, vol. 71, n° 10, p. 4437-4448, oct. 2023, doi: 10.1109/TMTT.2023.3267390.
- [19] T. Kocevská, T. Javornik, A. Švigelj, et A. Hrovat, « Framework for the Machine Learning Based Wireless Sensing of the Electromagnetic Properties of Indoor Materials », *Electronics*, vol. 10, n° 22, Art. n° 22, janv. 2021, doi: 10.3390/electronics10222843.
- [20] T. Kocevská, T. Javornik, A. Švigelj, K. Guan, A. Rashkovska, et A. Hrovat, « Impact of Room Size on Machine Learning-based Material Prediction using Channel Impulse Response », in *2023 30th International Conference on Systems, Signals and Image Processing (IWSSIP)*, juin 2023, p. 1-4. doi: 10.1109/IWSSIP58668.2023.10180272.
- [21] « CADFEKO ». Consulté le: 4 mars 2025. [En ligne]. Disponible sur: https://help.altair.com/2023/feko/topics/feko/user_guide/cadfeko/cadfeko_intro_feko_t-cadfeko.htm

- [22] « POSTFEKO ». Consulté le: 4 mars 2025. [En ligne]. Disponible sur: https://help.altair.com/2023/feko/topics/feko/user_guide/postfeko/postfeko_intro_feko_t-postfeko.htm
- [23] « Introduction to WinProp ». Consulté le: 4 mars 2025. [En ligne]. Disponible sur: https://2021.help.altair.com/2021/winprop/topics/winprop/user_guide/introduction/intro_winprop_c.htm
- [24] « WallMan ». Consulté le: 4 mars 2025. [En ligne]. Disponible sur: https://2021.help.altair.com/2021/winprop/topics/winprop/user_guide/wallman_tuman/intro_wallman_winprop_c.htm
- [25] « ProMan ». Consulté le: 4 mars 2025. [En ligne]. Disponible sur: https://2021.help.altair.com/2021/winprop/topics/winprop/user_guide/proman/intro_proman_winprop_c.htm
- [26] G. Duncan, « VNA FAQ: An Introduction | Keysight Blogs ». Consulté le: 4 mars 2025. [En ligne]. Disponible sur: <https://www.keysight.com/blogs/en/tech/rfmw/2023/03/02/vna-faq-an-introduction>
- [27] J.-M. Conrat, M. A. Aliouane, J.-C. Cousin, et X. Begaud, « Material Permittivity and Conductivity Estimation From 2 to 260 GHz and Extension of the ITU-R P.2040 Model at Frequency Above 100 GHz », in *2024 IEEE 35th International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC)*, sept. 2024, p. 1-6. doi: 10.1109/PIMRC59610.2024.10817451.
- [28] R. Wilson, « Propagation losses through common building materials 2.4 GHz vs 5 GHz », *Magis Netw. Inc*, août 2002, Consulté le: 25 novembre 2025. [En ligne]. Disponible sur: https://www.zardo.com/files/E10589_Propagation_Losses_2_and_5GHz.pdf
- [29] « P.2040 : Effects of building materials and structures on radiowave propagation in the range of 1 MHz to 450 GHz ». Consulté le: 26 janvier 2026. [En ligne]. Disponible sur: <https://www.itu.int/rec/R-REC-P.2040-4-202509-I/en>