

Table des matières

RÉSUMÉ	1
ABSTRACT.....	III
REMERCIEMENT	IV
LISTE DES FIGURES	VII
CHAPITRE 1: INTRODUCTION	1
1.1 CONTEXTE ET MOTIVATION DE PROJET DE RECHERCHE	1
1.2 MILIEU MINIER	2
1.3 LA TECHNOLOGIE ULTRA LARGE BANDE (UWB).....	3
1.3.1 Les applications UWB.....	4
1.3.2 La régulation du spectre radio UWB.....	6
1.3.3 Comparaison entre l'UWB et d'autres technologies sans fil.....	6
1.4 OBJECTIF ET PLAN DE MÉMOIRE	8
CHAPITRE 2: CANAL DE PROPAGATION RADIO.....	10
2.1 INTRODUCTION :	10
2.2 GÉNÉRALITÉS SUR LE CANAL DE PROPAGATION RADIO	10
2.2.1 Propagation en espace libre	10
2.3 PROPAGATION PAR TRAJET MULTIPLE	11
2.2.1 Les variations principales du canal de propagation radio	13
2.3.1.1 La dispersion du canal de propagation radio	14
2.3.1.2 Le phénomène d'évanouissement	16
2.4 MODÉLISATION DE CANAL DE LA PROPAGATION RADIO	18
2.2.1 Formulations mathématiques	19
2.2.2 Distributions statistiques d'amplitude de signal reçu par trajet-multiple	23
2.2.3 La distribution de l'amplitude d'un canal à trajets multiples UWB minier.....	25
CHAPITRE 3: LES RÉSEAUX DE NEURONES.....	26
3.1 INTRODUCTION	26
3.2 LE MODÈLE DE NEURONE	27
3.2.1 Les fonctions de transfert	28
3.2.2 Architecture d'un réseau de neurones.....	30
3.2.3 L'apprentissage.....	31
3.3 LES APPLICATIONS DES RÉSEAUX DE NEURONES.....	32
3.4 LES TYPES DES RÉSEAUX DE NEURONES.....	33
CHAPITRE 4: MODÈLE DE RÉSEAU DE NEURONES ET MESURES UTILISÉES.....	35
4.1 INTRODUCTION :	35
4.2 MÉTHODE RÉTROPROPAGATION :	35
4.3 LES MESURES UTILISÉES :	39

4.4	RÉSEAU ET APPRENTISSAGE:	41
4.4.1	Architecture de réseau :.....	41
4.4.2	Apprentissage :	43
4.5	ORGANISATION ET CONSTRUCTION DE FICHIERS DE DONNÉES :	43
4.6	LES ÉTAPES DE FONCTIONNEMENT DU MODÈLE.....	46
4.7	CONCLUSION :	48
CHAPITRE 5: ANALYSE DES RÉSULTATS.....		49
5.1	INTRODUCTION	49
5.2	CAS D'ESPACE LIBRE	49
5.3	MODÉLISATION DE CANAL UWB AU NIVEAU 70 MÈTRES SOUS TERRAIN	50
5.3.1	Modèle neuronal avec une seule entrée	50
5.3.1.1	Puissance reçue en fonction de distance	50
5.3.1.2	Puissance reçue en fonction de la fréquence.....	51
5.3.2	Modèle neuronal avec deux entrées.....	52
5.4	ÉVALUATION DE RÉSEAU PAR LES MESURES D'UN CANAL DIFFÉRENT.....	59
5.5	CONCLUSION.....	62
CHAPITRE 6: CONCLUSION.....		63
6.1	INTRODUCTION :	63
6.2	SUGGESTION DE TRAVAUX FUTURS	65
BIBLIOGRAPHIES		IX
ANNEXES.....		XII

Liste des figures

FIGURE 1. 1 - LA PHOTO MONTRE LE CANAL MINIER AU NIVEAU 70 M SOUS TERRE.	2
FIGURE 1.2 - LES PRINCIPAUX STANDARDS WLAN / WPAN : DÉBIT ET PORTÉE MAXIMALE.	5
FIGURE 2. 1 - PRINCIPAUX MÉCANISMES DE PROPAGATION À TRAJETS MULTIPLES.	12
FIGURE 2. 2 - LES VARIATIONS PRINCIPALES DE LA PROPAGATION.	13
FIGURE 2. 3 - REPRÉSENTATION SCHÉMATIQUE DU DÉPLACEMENT D'UN RÉCEPTEUR EN MOUVEMENT.	15
FIGURE 2. 4 - REPRÉSENTATION DE L'EFFET DOPPLER EN MULTI-TRAJETS.	15
FIGURE 2. 5 - DISPERSION TEMPORELLE.	16
FIGURE 2. 6 - DIAGRAMME DE BELLO AVEC LES QUATRE FONCTIONS DÉCRIVANT LE CANAL.	22
FIGURE 3. 1 - SCHEMA DE NEURONE BIOLOGIQUE.	26
FIGURE 3. 2 - LES DEUX MODÈLES DE NEURONE SANS ET AVEC BIAIS.	28
FIGURE 3. 3 - MODÈLE DE NEURONE AVEC UN VECTEUR D'ENTRÉES.	28
FIGURE 3. 4 - LES TROIS FONCTIONS LES PLUS UTILISÉES DANS L'INGÉNIEURIE.	29
FIGURE 3. 5 - ARCHITECTURE SIMPLE D'UN RÉSEAU DE NEURONES.	30
FIGURE 3. 6 - CLASSIFICATION DES MODÈLES DE RÉSEAU DE NEURONES.	33
FIGURE 4. 1 - MODÈLE DU NEURONE J.	36
FIGURE 4. 2 - GRADIENT DE L'ERREUR TOTAL.	37
FIGURE 4. 3 - PLAN DE LA MINE AU NIVEAU 70M.	40
FIGURE 4. 4 - MODÈLE DE RÉSEAU DE NEURONES AVEC TROIS COUCHES.	42
FIGURE 4. 5 - MODÈLE DE RÉSEAU DE NEURONES AVEC DEUX COUCHES.	42
FIGURE 4. 6 - ORGANISATION DE DONNÉES.	44
FIGURE 4. 7 - PARTIE DU FICHIER DES DONNÉES DE MESURES MINIÈRES AU NIVEAU 70 M.	45
FIGURE 4. 8 - PARTIE DU FICHIER DE DONNÉES DES MESURES MINIÈRES AU NIVEAU 40 M.	45
FIGURE 4. 9 - LES PHASES D'ESTIMATION DE RÉSEAU.	46
FIGURE 4. 10 - LES ÉTAPES DE FONCTIONNEMENT DE MODÈLE.	48
FIGURE 5. 1 - PUISSANCE REÇUE EN FONCTION DE DISTANCE.	49
FIGURE 5. 2 - PUISSANCE REÇUE EN FONCTION DE DISTANCE AU NIVEAU DE 70M SOUS TERRE.	50
FIGURE 5. 3 - PUISSANCE REÇUE EN FONCTION DE FRÉQUENCE POUR UN DISTANCE FIXE =1M.	51
FIGURE 5. 4 - ZOOM DE LA PARTIE ROUGE DE FIGURE (5.3).	52
FIGURE 5. 5 - RÉPARTITION DES DONNÉES DANS LES DEUX PHASES D'ESTIMATION.	53
FIGURE 5. 6 - PUISSANCE REÇUE DE CANAL UWB MINIER AU NIVEAU 70M.	54
FIGURE 5. 7 - PUISSANCE REÇUE EN FONCTION DE FRÉQUENCE À 1M.	54

FIGURE 5. 8 - PUISSANCE REÇUE DU CANAL UWB MINIER À 70M SOUS TERRE.	55
FIGURE 5. 9 - ZOOM DE LA FIGURE (5.8) À 5M.	56
FIGURE 5. 10 - PUISSANCE REÇUE DU CANAL UWB MINIER À 70M SOUS TERRE.	57
FIGURE 5. 11 - PARTIE MARQUÉE EN ROUGE DE LA FIGURE PRÉCÉDENTE ZOOMÉE.....	57
FIGURE 5. 12 - PUISSANCE REÇUE EN FONCTION DE LA DISTANCE ET DE LA FRÉQUENCE.....	58
FIGURE 5. 13 - PARTIE DE FIGURE (5.12) ZOOMÉE À 6M.	59
FIGURE 5. 14 - IDENTIFICATION DES ENTRÉES D' APPRENTISSAGE ET DE PRÉDICTION.	60
FIGURE 5. 15 - PUISSANCE REÇUE EN FONCTION DE DISTANCE ET FRÉQUENCE	61
FIGURE 5. 16 - UN ZOOM DE LA PARTIE MARQUÉE EN ROUGE DE LA FIGURE (5.15).....	61

LISTE DES TABLEAUX

TABLEAU 1.1 - COMPARAISON ENTRE LA TECHNOLOGIE UWB ET D' AUTRES TECHNOLOGIES SANS FIL.	7
TABLEAU 2.1 - DISTRIBUTIONS STATISTIQUES DE L' AMPLITUDE DES TRAJETS MULTIPLES.	25
TABLEAU 3.1 - FONCTIONS DE TRANSFERT $A=F(N)$	29
TABLEAU 4. 1 - ÉQUIPEMENTS UTILISÉS DANS LES MESURES.	40
TABLEAU 4. 2 - PARAMÈTRES DÉCRIVANT LE RÉSEAU DE NEURONES.	43

Chapitre 1

Introduction

1.1 Contexte et motivation de projet de recherche

Par l'apparition des réseaux radiomobiles cellulaires analogiques au début des années 70, nous avons assisté à une explosion de la demande en systèmes de communication sans fil. Ces dernières années, les vitesses de traitement et les tailles de stockage des ordinateurs ont considérablement augmentés. Ceci explique l'engouement du grand public pour les objets communicants, lesquels requièrent le transfert rapide d'une importante quantité d'informations.

Par rapport aux transmissions filaires, les télécommunications sans fil permettent d'assurer un accès aux réseaux locaux tout en simplifiant leurs infrastructures. Cependant, le succès de ces nouveaux systèmes conduit à une grande surcharge du spectre radioélectrique et pose un réel problème de cohabitation. De plus, ces nouveaux services nécessitant des débits de plus en plus importants, tout en garantissant une certaine qualité de service, il est nécessaire d'envisager de nouvelles techniques de transmission à très forte efficacité spectrale et/ou utilisant des fréquences porteuses de plus en plus élevées. Parmi les nouvelles techniques candidates, on retrouve la technique Ultra Large Bande (Ultra-WideBand UWB) qui fait l'objet actuellement de travaux et de développements importants. Contrairement aux systèmes radio conventionnels, elle utilise une largeur de bande très importante qui présente des avantages de transmission tel le débit de transmission élevé et la faible densité spectrale de puissance.

Dans le milieu minier souterrain ce système (UWB) peut être utiliser pour transmettre les informations nécessaires pour des applications très importantes telles que la supervision, le contrôle à distance, la surveillance et la gestion de production ou pour offrir un moyen de communication entre les mineurs.

1.2 Milieu minier

La mine expérimentale CANMET à Val d'Or situé à 500 km au nord de Montréal, Canada est une ancienne mine d'or servant aujourd'hui à former des mineurs ou à effectuer des expériences. En effet, c'est un endroit qui respecte les conditions de sécurité et c'est un environnement minier souterrain idéal pour faire une campagne de mesures de propagation d'ondes radios représentatives de ce que l'on rencontre dans les mines. Il s'agit d'un environnement très humide composé de plusieurs galeries rocailleuses dont le plafond, le plancher et les murs montrent une rugosité rocheuse importante. Le plancher, un peu moins rugueux afin de permettre une libre circulation des véhicules et du personnel, comporte de multiples flaques d'eau [2].



FIGURE 1. 1 — Galerie minière du niveau 70 m sous terre.

L'étude de comportement des ondes électromagnétiques sur des surfaces lisses et rugueuses a fait, jusqu'ici, l'objet d'intenses recherches [1]. En effet, les phénomènes de réflexion et de diffraction du signal deviennent aussi complexes et variés que les milieux et les surfaces. Dans le cadre des mines, nous ne pouvons pas facilement prédire la forme de la rugosité des parois à cause de leur variation aléatoire d'un point à un autre. Par conséquent, le coefficient de réflexion des parois d'une galerie de mine peut être considéré aléatoire [1].

1.3 La technologie Ultra Large Bande (UWB)

Le développement d'un système de communication nécessite une parfaite connaissance de son milieu de transmission. Pour les systèmes radio, les architectures de l'émetteur et du récepteur doivent être dimensionnées en fonction des propriétés du canal de propagation. Ce dernier doit être caractérisé dans les environnements où le système sera déployé. Dans notre cas, nous traitons le canal minier en cadre de technologie UWB.

L'Ultra Large Bande est un terme générique utilisé pour représenter une technique d'accès radio qui a été étudiée sous différentes appellations. On peut citer les termes radio impulsionnelle, radio sans-porteuse, radio en bande de base, et radio à grande largeur de bande relative [3]. En définissant la largeur de bande relative par :

$$B_{f3dB} = 2 \cdot \frac{F_H - F_L}{F_H + F_L} \quad (1.1)$$

Où F_H et F_L représentent respectivement les fréquences de coupure supérieure et inférieure à -3 dB, les signaux UWB sont généralement définis par une largeur de bande relative de 25 % ou plus [4], on peut définir les signaux UWB de la façon suivante :

La largeur de bande fractionnelle :

$$LB_f = \frac{F_H - F_L}{F_C} \quad (1.2)$$

La fréquence centrale :

$$F_C = \frac{F_H + F_L}{2} \quad (1.3)$$

La FCC (la commission fédérale de communication) a défini la technologie de communication à très large bande par la satisfaction de l'une des deux Conditions suivantes :

- La largeur de bande fractionnelle LB_f est supérieure ou égale à 0,2,

Ou

- le signal occupe plus de WB=500 MHz du spectre des fréquences [6].

La technologie ultra large bande est une technologie sans fil qui peut être exploitée à très faible densité de puissance pour la communication à des débits de données élevés sur de courtes distances. Cette technologie a été mise au point à l'origine pour des applications militaires [5].

Les signaux UWB occupent une largeur de bande fréquentielle, typiquement de l'ordre de 500 MHz à plusieurs GHz. La théorie de l'information nous apprend que moyennant l'utilisation d'un code approprié, il est possible de transmettre des données à un Taux d'Erreur Binaire (TEB) inférieur à un seuil fixé arbitrairement bas, à condition que le débit de données soit inférieur à la capacité maximale du canal de transmission. La capacité du canal C est donc une indication du débit maximal qu'il est théoriquement possible d'obtenir sur un canal donné. Elle peut être calculée par le théorème de Shannon [5]:

$$C = B_w \cdot \log_2 \left(1 + \frac{S}{N} \right) \quad (1.4)$$

Où C représente la capacité maximale du canal (bit/s), B_w la largeur de bande du canal (Hz), S la puissance du signal (W) et N la puissance du bruit (W). Nous remarquons que la capacité maximale du canal augmente linéairement avec la largeur de bande du signal, et seulement de façon logarithmique avec le rapport signal sur bruit. Dans un contexte de demande croissante de systèmes de communications sans fil à très haut débit, les technologies radio travaillant sur de larges bandes de fréquences sont donc plus à même de proposer des débits adéquats. L'UWB, avec des bandes de fréquences allant jusqu'à plusieurs GHz, est plus adapté à l'augmentation de débit que les systèmes présentant de fortes contraintes sur la largeur de bande.

1.3.1 Les applications UWB

La figure 1.2 présente le positionnement de l'UWB par rapport aux principaux standards de WLAN et WPAN en termes de débit et de portée maximale.

L'UWB se place dans le créneau des réseaux courte portée WPAN. Son débit potentiel dépasse cependant les performances de toutes les normes WLAN et WPAN. Pour parvenir à fournir un débit élevé en tout lieu, les réseaux à venir devront être conçus de façon à optimiser la capacité spatiale, c'est-à-dire le débit global disponible par unité de surface. Les

technologies radio à courte portée et très haut débit comme l'UWB permettront d'augmenter considérablement la capacité spatiale, par le développement de réseaux ad hoc dynamiques [9].




FIGURE 1.2 — Les principaux standards WLAN / WPAN : débit et portée maximale

Les applications potentielles de la technologie radio UWB concernent donc deux techniques : les systèmes très haut débit courte portée (typiquement 200 Mbit/s jusqu'à 10 m), et les systèmes bas débit longue portée (typiquement 200 kbit/s à 100 m). Ces deux types d'utilisation du spectre radio UWB permettent d'envisager un certain nombre d'applications spéciales pour les systèmes UWB [8] [9]:

La technologie UWB permettra d'augmenter le débit des réseaux personnels sans fil traditionnels, par exemple connexion entre différents périphériques (imprimante, lecteurs,...) et transfert multimédia de haute qualité.

D'autre part, l'UWB est envisagé dans la domotique, où un grand nombre d'appareils capables de communiquer à une distance de plusieurs dizaines de mètres sont déployés dans un environnement de bureau ou de résidence. Il est envisagé aussi pour des applications de communication en mode point-à-point. Un exemple d'utilisation est l'échange de données entre plusieurs assistants personnels.

Enfin, des applications de l'UWB sont prévues dans le milieu industriel. En exploitant les possibilités de localisation à longue distance combinées au transfert d'information, des réseaux de capteurs pourront être déployés dans les chaînes de production ou les hangars de stockage, pour procéder au suivi et à la gestion automatique des opérations. Ce type

d'application est adapté au mode de communication bas débit longue portée de l'UWB. Le principal défi à relever pour ce type d'application est la maîtrise de la communication radio dans des conditions de propagation et d'interférence difficiles.

1.3.2 La régulation du spectre radio UWB

La FCC a mis les signaux UWB principalement sur la bande 3 GHz — 10 GHz, en respectant une densité spectrale (située sous le niveau d'émission non-intentionnelle (-41 dBm. MHz $^{-1}$)) de puissance inférieure aux règles déjà en place pour les émissions radio non intentionnelles [6]. Trois classes différentes d'équipements sont considérées :

- les systèmes de visualisation : radars de détection du sol, systèmes de visualisation à travers les murs, systèmes médicaux, systèmes de surveillance ;
- les systèmes radar embarqués : par exemple, radars pour voitures, dans la bande des 24 GHz — 29 GHz ;
- les systèmes de communications et de mesure.

1.3.3 Comparaison entre l'UWB et d'autres technologies sans fil

Le principe de la technologie UWB repose sur l'émission de signaux extrêmement larges (plusieurs GHz) ayant une assez faible puissance; la densité spectrale de puissance ainsi rayonnée est extrêmement faible de sorte qu'en principe les autres communications notamment en bande étroite les perçoivent comme un bruit de fond. Par ailleurs, l'utilisation du spectre très large permet de garantir des débits très importants. Ceci doit théoriquement permettre d'augmenter la capacité du canal, selon le théorème de Shannon. Pour cette même raison, les liaisons UWB sont également réputées être plus robustes aux évanouissements sélectifs en fréquence.

Le tableau (1.1) suivant donne la comparaison entre la technologie UWB et d'autres technologies sans fil.

Technologie	Débit de données	Bande de fréquence	PIRE	Modulation	Spécification
UWB	≥ 100 Mbits/s	3 - 10 GHz	-41.3dBm/MHz	PPM, OFDM, CDMA	IEEE 802.15.3a
	≥ 500 Kbits/s	3 - 10 GHz	-41.3dBm/MHz	... PPM, OFDM, CDMA, ...	IEEE 802.15.4a
Bluetooth	≤ 700 Kbits/s	ISM 2.4GHz	Classe 1 : 20dBm Classe 2 : 0 dBm	GMSK	IEEE 802.15.1
Wifi	≤ 54 Mbits/s	5 GHz	0.2 – 1 W	BPSK 16-QAM, QPSK, 64-QAM	IEEE 802.11a
	≤ 11 Mbits/s	ISM 2.4 GHz	0.1 – 2 W	CCK	IEEE 802.11 b
	≤ 54 Mbits/s	ISM 2.4 GHz	0.1 – 1 W	BPSK, 16-QAM, QPSK, 64-QAM	IEEE 802.11 g

Tableau 1.1 — Comparaison entre la technologie UWB et d'autres technologies sans fil.

Nous pouvons résumer les caractéristiques de l'UWB comme suit :

- Grande capacité :
Nous pouvons voir cela clairement à partir du théorème de Shannon, puisque nous avons un grand débit.
- Résolution temporelle très fine :
Ce qui donne une robustesse face aux évanouissements surtout dans l'environnement multi-trajet
- Faible densité spectrale de puissance :
Un signal UWB a une faible densité spectrale de puissance, étant donné que la puissance du signal est répartie sur une grande largeur de bande.
- Court retard de transmission :

Précisément le retard d'une transmission est très court avec un système de communication UWB sans fil, il est d'ordre de 0.1 à 1 ms.

- Grande précision pour la localisation :
Les systèmes UWB fournissent des informations sur la position de l'émetteur avec une précision de 3 à 30 cm.
- Portées limitées :
Sa portée est limitée à des courtes distances, car l'UWB à une faible densité spectrale.

1.4 Objectif et plan de mémoire

Un système de transmission radioélectrique permet de transformer un signal électrique en le transposant en une onde électromagnétique. Le canal de propagation est le système qui fait passer du signal émis au signal reçu et tient donc compte des interactions entre les ondes électromagnétiques et leur environnement. D'autre part il est fondamental d'avoir une bonne connaissance du canal de propagation et de son interaction avec l'environnement, pour le bon fonctionnement d'un système de communication. Le but de notre projet consiste à modéliser le canal UWB minier par l'utilisation de réseaux de neurones, et plus particulièrement la variation de puissance reçue en fonction de fréquence et distance. Nous allons nous baser sur les mesures faites par le laboratoire de recherche en communication souterrain (LRCS) dans la mine CANMET que nous avons définie à la deuxième section de ce chapitre.

Notre mémoire de maîtrise est composée de six chapitres dont les contenus sont les suivants :

Le premier chapitre est une introduction générale sur la motivation et le contexte de sujet de recherche, nous définissons le canal minier que nous utilisons ainsi la technologie UWB. Aussi l'objectif et l'organisation de mémoire.

Dans le deuxième chapitre, nous présentons le canal UWB, les caractéristiques et la modélisation. Puis nous présentons les réseaux de neurones que nous allons utiliser pour la modélisation du canal minier UWB dans le troisième chapitre.

Le modèle que nous avons choisi, la méthode d'apprentissage et l'organisation des données d'entrées et de sorties du réseau de neurones sont présentés au chapitre quatre. Ensuite, nous analysons tous les résultats que nous avons trouvés pendant notre travail dans le chapitre cinq.

Enfin, nous présentons une conclusion générale qui contient un résumé de travail réalisé, et les travaux futurs possibles dans ce stade de recherche.

Chapitre 2

Canal de propagation radio

2.1 Introduction :

Dans un système de communication, l'étude de la propagation des signaux se fait généralement à partir de la modélisation du canal de propagation radio. Ce canal joue un rôle majeur, car il est l'un des obstacles à la transmission fiable de l'information.

Pour estimer la puissance reçue dans un système, une modélisation des différents mécanismes de propagation et de l'environnement est mise en œuvre. La diversité des situations rencontrées (l'environnement et la fréquence) conduit à des traitements de types différents. Deux types de modélisations sont retenus : l'approche statistique et l'approche théorique. Elles conduisent respectivement à des modèles empiriques et à des modèles déterministes. Les modèles empiriques sont basés sur une analyse statistique d'un grand nombre de données expérimentales, réalisées dans différents contextes de propagation et d'environnements. Les modèles théoriques s'appuient sur les lois fondamentales de la physique et plus particulièrement sur celles de l'optique géométrique dans le cas de la propagation à l'intérieur des bâtiments.

2.2 Généralités sur le canal de propagation radio

2.2.1 Propagation en espace libre

La propagation en espace libre est le cas idéal où il n'y a pas d'obstacle entre l'émetteur et le récepteur, c'est-à-dire le système de transmission est situé dans un environnement exempt de toute obstruction. En notant G_E le gain de l'antenne d'émission et P_E la puissance du signal émis, la densité de puissance W présente à une distance d est donnée par [10]:

$$W = \frac{P_E G_E}{4\pi d^2} \quad (2.1)$$

La puissance P_R du signal disponible aux bornes d'une antenne de réception de gain G_T est reliée à la densité de puissance W par la relation :

$$P_R = WA_R = W \frac{\lambda^2 G_R}{4\pi} \quad (2.2)$$

Où A_R représente l'aire effective de l'antenne de réception, et λ représente la longueur d'onde à la fréquence de travail.

$$P_R = P_T G_T G_R \left(\frac{\lambda}{4\pi d} \right)^2 \quad (2.3)$$

Cette relation n'est valable que lorsque la distance d est suffisamment grande pour que l'antenne de réception soit considérée dans le champ lointain de l'antenne d'émission. L'antenne de réception se situe dans le champ lointain lorsque la distance d est supérieure à la distance de Fraunhofer d_F , qui est reliée à la plus large dimension de l'antenne d'émission D et à la longueur d'onde par la relation suivante :

$$d_F = \frac{2D^2}{\lambda} \quad (2.4)$$

2.3 Propagation par trajet multiple

Au contraire de cas idéal, dans un environnement réel, une onde interfère avec les différents obstacles constituant le milieu de propagation. Aussi, elle emprunte plusieurs trajets avant d'atteindre le récepteur. On dit qu'il y a de propagation en trajets multiples.

Dans le cas d'une communication en visibilité directe, un trajet relie directement l'émetteur au récepteur. Généralement, d'autres trajets issus de réflexions, de réfractions, de diffractions ou de diffuseurs constitués par les différents obstacles rencontrés viennent s'ajouter à ce trajet direct (Figure 2.1)

chaque trajet suit un chemin différent avant d'arriver au récepteur. Il est caractérisé par un retard, une amplitude, une phase différente, une direction de départ et d'arrivée, et ainsi le signal reçu est une somme de tous les trajets arrivant au récepteur. Cette somme peut

entraîner des interférences destructrices ou constructrices et est responsable des fluctuations observées sur le signal reçu.

D' autre part, et plus particulièrement à l'intérieur des bâtiments, un trajet en visibilité directe, ou Line Of Sight (LOS), n'est pas toujours disponible. Dans ce cas, ce sont les trajets en non-visibilité, ou Non Line Of Sight (NLOS), qui permettent la communication radio.




FIGURE 2. 1 — Principaux mécanismes de propagation à trajets multiples.

Les principaux mécanismes intervenant lors de la propagation d'une onde dans un environnement sont :

- La réflexion : le phénomène de réflexion se produit lorsque l'onde rencontre un obstacle de grande dimension et qui présente des défauts de surface de petite taille comparée à la longueur d'onde, il y a deux types de réflexion : la réflexion spéculaire si la surface est petite devant la longueur d'onde et réflexion diffuse quand la surface réfléchissante est rugueuse, nous parlons sur le phénomène de diffusion lorsqu'en présence de végétation ou à l'extérieur. Aussi, dans certains environnements comme les tunnels et les couloirs nous parlons sur guide d'onde.
- La transmission : est le phénomène associé à la traversée d'un obstacle par une onde électromagnétique. En effet, pour chaque élément traversé, l'onde subit une

atténuation, directement liée aux caractéristiques électromagnétiques du matériau considéré, mais aussi liée à d'autres paramètres comme l'épaisseur de la paroi traversée et l'angle d'incidence.

- La diffraction : ce phénomène se produit quand l'onde est arrêtée par un corps volumineux dont les dimensions sont grandes par rapport à la longueur d'onde du signal. il cause l'apparition d'ondes secondaires. L'énergie transmise par ces sources permet au signal de se propager dans les zones d'ombres. Ce qui donne une arrivée d'ondes radio au niveau du récepteur en l'absence de visibilité directe et en présence de perturbation causées par les autres types d'interactions.

2.2.1 Les variations principales du canal de propagation radio

La propagation des ondes électromagnétiques obéit à une multitude de phénomènes qui en font un mécanisme complexe, surtout s'il y a des obstacles entre l'émetteur et le récepteur. Au long de sa propagation, l'onde suit plusieurs chemins qui en raison de leur longueur et de leur vitesse de propagation induisent des temps d'arrivés différentes, de telle façon que le récepteur peut recevoir différentes répliquent du même signal à des instants différents. Ces phénomènes dépendent de la fréquence utilisée et de la nature des obstacles rencontrés. Comme souvent, lorsque les phénomènes sont complexes, on s'appuie sur des modèles mathématiques. Leur complexité est relative au degré de précision désiré : plus la précision requise est grande, plus le modèle mathématique est complexe.

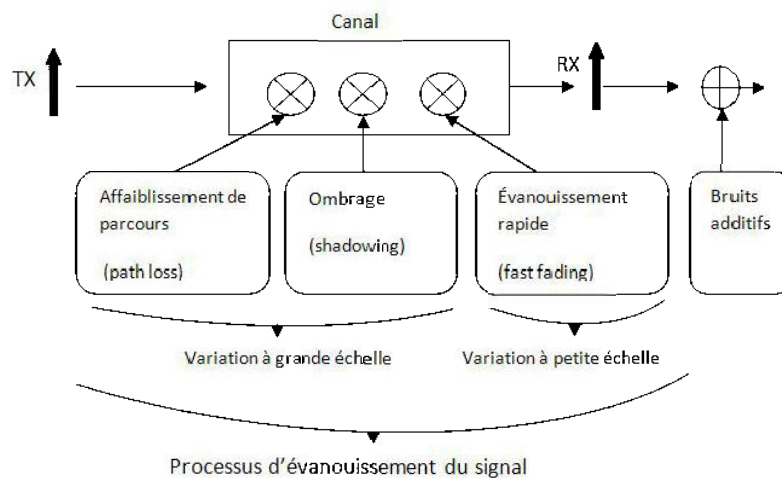


FIGURE 2. 2 — Les variations principales de la propagation.

- L'affaiblissement de parcours (path loss) : Pour un canal radio-mobile « réel », les variations lentes du canal de propagation sont principalement dues aux pertes de puissance par propagation et aux mécanismes de masquage.
- Ombrage (shadowing) : Il représente une variation sur les conditions de propagation, causée par des obstructions importantes comme les bâtiments et les montagnes.
- Évanouissement rapide (fast fading) : ce phénomène est dû à la réception simultanée de signaux d'amplitudes aléatoires et de phases aléatoires correspondant aux différents trajets d'un même signal.

Les performances d'un système de communication sont liées aux deux facteurs de canal radio : le bruit et les effets de dispersion du canal, comme les évanouissements, effets de la propagation en trajets multiples. Ainsi, le bruit additif ou nous appelons aussi bruit thermique, est l'un des importants problèmes rencontrés dans tous les canaux physiques de transmission, il est généralement modélisé par le bruit additif gaussien possédant une densité de puissance constante.

2.3.1.1 La dispersion du canal de propagation radio

À cause des trajets multiples que suit le signal, nous obtenons des différentes variations du délai pour les différentes composantes de ce signal. Aussi le changement de la phase du signal reçu en fonction du temps. Ce qui nous donne une variation des caractéristiques du canal en fonction de temps et de la position.

Nous pouvons classer la dispersion en deux types, au niveau temporel et au niveau fréquentiel :

- La dispersion fréquentielle (Doppler spread):

Dans la majorité des configurations, le point d'émission ou le point de réception sont en mouvement l'un par rapport à l'autre. De même, les éléments à l'intérieur du canal de propagation ne sont pas toujours fixes. Cette mobilité dans le canal de propagation se traduit par un décalage entre la fréquence du signal émis et la fréquence du signal reçu. Prenons l'exemple le plus simple d'une onde plane arrivant avec un angle α au niveau d'un récepteur en mouvement ayant une vitesse V constante




FIGURE 2. 3 — Représentation schématique du déplacement d'un récepteur en mouvement.

Le décalage fréquentiel Doppler maximum est égal à [12] :

$$f_d = f_m \cos \alpha = \frac{v f_c}{c} \quad (2.5)$$

Suivant la valeur de l'angle d'arrivée α , le décalage Doppler est réparti sur l'intervalle $[-f_d; f_d]$

Où c désigne la célérité de la lumière, f_m est la valeur maximale du décalage Doppler, v est la vitesse du récepteur et f_c est la fréquence de la porteuse. L'onde arrive au niveau du récepteur avec une fréquence égale à $f_c + \mu$, avec μ le décalage Doppler.




FIGURE 2. 4 — Représentation de l'effet Doppler en multi-trajets.

La figure 2.4 montre que le spectre du signal se retrouve étalé dans la bande $[-f_d; f_d]$.

Aussi, le spectre Doppler possède une forme caractéristique en U. Cette répartition est une loi de probabilité qui signifie que lorsque le signal est transmis à une certaine fréquence f_c , il sera plus probablement reçu autour de $f_c - \mu$ ou $f_c + \mu$ que de f_c . (Dans la figure (2.4) : le symbole μ est présenté par v)

- La dispersion temporelle (delay spread)

Ce type de dispersion se produit lorsque le signal identique est reçu à la destination dans des instants différents et correspond à la différence de temps entre les moments d'arrivée du premier composant multi-trajet et de la dernière.

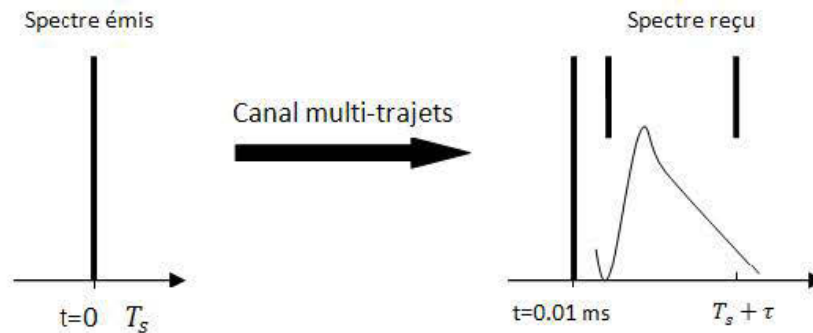


FIGURE 2. 5 — Dispersion temporelle.

La figure 2.5 nous explique la notation de dispersion temporelle. La valeur RMS de la dispersion temporelle est donnée par [12]:

$$\tau_{\text{rms}} = \sqrt{\overline{\tau^2} - (\bar{\tau})^2} \quad (2.6)$$

Avec $\bar{\tau}$ est la dispersion moyenne de retard temporel définie par :

$$\bar{\tau} = \frac{\sum_k P(\tau_k) \tau_k}{\sum_k P(\tau_k)} \quad (2.7)$$

$\overline{\tau^2}$ est la valeur quadratique moyenne de retard définie par :

$$\overline{\tau^2} = \frac{\sum_k P(\tau_k) \tau_k^2}{\sum_k P(\tau_k)} \quad (2.8)$$

2.3.1.2 Le phénomène d'évanouissement

Dans n'importe quel système de communication sans fil, les signaux émis rencontrent les phénomènes des évanouissements et de pertes de puissance. En effet les évanouissements d'un canal de propagation radio en multi-trajets sont classés en deux types : les évanouissements à grande échelle et à petite échelle, les premiers sont introduits à l'extérieur par la présence de bâtiments ou de forêts entre l'émetteur et le récepteur, ils

interprètent l'atténuation de la puissance du signal en fonction de la distance entre l'émetteur et le récepteur. Les deuxièmes interprètent la variation rapide de l'amplitude et de la phase du signal reçu causé par l'addition constructive ou destructive des interférences sur tous les trajets.

Le type d'évanouissement dépend de paramètres du signal et de canal. Les paramètres du signal sont la largeur de bande, B_s et la durée de symbole T_s . Les paramètres du canal sont la valeur RMS de la dispersion temporelle, le décalage Doppler et l'étalement temporel, T_m représentant la durée qui sépare l'arrivée du premier trajet de l'arrivée du dernier trajet [13]. L'un de paramètres les plus importants pour caractériser le canal est la bande de cohérence du canal, noté B_c qui désigne la gamme de fréquences sur laquelle les amplitudes des composantes fréquentielles du signal, corrélées, subissent des atténuations semblables :

$$\mathbf{B}_c \approx \frac{1}{5\tau_{rms}} \quad (2.9)$$

Après la présentation de principaux paramètres du canal et du signal, nous pouvons citer quatre types d'évanouissements, deux dus à la dispersion temporelle qui sont les évanouissements plats et les évanouissements sélectifs en fréquence, les deux autres dus au décalage Doppler qui sont les évanouissements lents et les évanouissements rapides :

- Les évanouissements plats ($B_s \ll B_c$ et $T_s \gg \tau_{rms}$) :

Dans ce cas, le spectre de signal reçu est corrélé. Or, toutes les fréquences du spectre du signal subissent les mêmes atténuations. Par conséquent, le canal considéré comme non sélectif en fréquence.

- Les évanouissements sélectifs en fréquence ($B_s \gg B_c$ et $T_s \ll \tau_{rms}$) :

, le spectre de signal est décorréolé. Pendant un évanouissement dans la bande de cohérence, une partie du signal seulement est perturbée.

- Les évanouissements lents ($T_s \ll T_c$ et $B_s \gg$ décalage Doppler) :

Dans ce cas, le canal est non-sélectif en temps. La réponse impulsionnelle du canal reste constante sur plusieurs symboles consécutifs.

- Les évanouissements rapides ($T_s \gg T_c$ et $B_s \ll$ décalage Doppler) :

Dans ce cas, la réponse impulsionnelle du canal varie de façon significative pendant la durée d'un symbole. Le canal est sélectif en temps.

2.4 Modélisation de canal de la propagation radio

La description réaliste du canal de propagation en environnement complexe nécessite l'utilisation de modélisations adaptées. Les méthodes de modélisation du canal peuvent être divisées en de types : les modélisations statistiques et les modélisations déterministes.

- Modélisation statistique :

La modélisation statistique du canal de propagation radio consiste à extraire le comportement moyen du canal, à partir de signaux généralement issus de campagnes de mesures. On traduit ainsi l'influence du canal sur une liaison, à l'aide d'outils statistiques.

Cette méthode permet de résumer le comportement du canal à travers quelques variables correctement choisies et des lois statistiques adéquates. Par exemple, on considère le plus souvent que la variation temporelle du canal dans le cas d'évanouissement de type plat suit une distribution de Rayleigh. Par contre, la distribution de Rice permet de décrire l'évanouissement à petite échelle sur le niveau du signal.

La validité d'un modèle statistique dépend de la quantité et surtout de la fiabilité des données initiales qui ont servi à l'établir. Un modèle statistique est d'autant plus fiable qu'un nombre important de données initiales auront été utilisées pour l'obtenir.

Les modèles statistiques sont utilisés pour tester les performances des systèmes de communication. L'évaluation des performances en termes de débit atteignable et de probabilité d'erreur est réalisée à partir d'un modèle de canal prédéfini associé à un scénario donné.

- Modélisation déterministe :

La modélisation déterministe est le plus souvent assimilée à l'utilisation d'un outil de simulation qui permet de prédire le signal reçu pour une liaison donnée. La modélisation faite est spécifique à l'environnement simulé.

Parfois, les signaux utilisés pour la modélisation statistique sont issus de la modélisation déterministe. Toutefois, ceux-ci doivent être suffisamment représentatifs de la réalité, car une modélisation déterministe est une opération qui consiste à imiter une campagne de mesures.

On peut noter qu'il y a une dépendance mutuelle entre les outils de simulation et les campagnes de mesures réalisées. En effet, les outils de simulation doivent être validés afin de s'assurer de la pertinence des signaux générés et des résultats obtenus. La validation est donc faite à partir de campagnes de mesures. A l'inverse, les mesures constituent une globalisation d'un ensemble de phénomènes modifiant le signal lors de son passage à travers le canal. Les outils de modélisation déterministe peuvent donc être utilisés pour mieux extraire les différents phénomènes intervenant dans le cas d'une mesure.

Contrairement à la modélisation statistique pour laquelle les campagnes de mesures sont les données de départ du modèle, la modélisation déterministe utilise les mesures comme élément de validation principal. Un outil de simulation du canal de propagation sera considéré comme fiable si les signaux prédits sont assez proches de ceux obtenus en mesure. Quelle que soit la modélisation réalisée, la validation avec les mesures peut aussi être faite à partir d'une comparaison des paramètres du second ordre caractérisant le canal tels que τ_m , τ_{rms} , n et PL.

La spécificité du canal UWB est sa largeur de bande. Aussi, des dispositifs de caractérisation du canal appropriés doivent être utilisés. Par exemple, les antennes retenues pour la caractérisation du canal doivent être suffisamment large bande et avoir des paramètres relativement constants sur la bande d'étude. L'UWB présente la capacité de résoudre des trajets très proches. Ceci entraîne un étalement relativement plus important des retards, car peu de trajets sont susceptibles de se recombinaison destructivement. D'ailleurs, les modèles adoptés qui permettent de décrire à partir de quelques paramètres le comportement du canal doivent tenir compte de cet élément [15].

2.2.1 Formulations mathématiques

Lors de sa transmission, le signal radio transite à travers le canal qui agit comme un filtre linéaire. Le canal étant variant dans le temps, le filtre équivalent varie également dans le temps. Les signaux en entrée et sortie de ce filtre peuvent être représentés dans le domaine temporel ou fréquentiel.

Nous pouvons caractériser un canal par l'étude de sa réponse impulsionnelle. En considérant l'émetteur ou le récepteur en mouvement, l'expression de la réponse impulsionnelle h s'exprime comme :

$$\mathbf{h}(\mathbf{t}, \boldsymbol{\tau}) = \sum_{l=0}^L \mathbf{a}_l e^{j(2\pi v_l + \theta_l(t))} \delta(\boldsymbol{\tau} - \boldsymbol{\tau}_l) \quad (2.10)$$

Où $h(t, \tau)$ est la réponse impulsionnelle variable dans le temps t du canal, et τ est le retard subi par le signal dans le canal. Ainsi L présente le nombre de trajets discernables par le récepteur. Le nombre de trajets discernables et le nombre de trajets réellement existant dans le canal ne sont pas toujours égaux. En effet, chaque signal retardé résulte de la combinaison de plusieurs trajets.

Chaque trajet discernable peut être modélisé par une amplitude a_l et un déphasage θ_l , associés au retard τ_l . Le terme v_l correspond à la fréquence de décalage Doppler, c'est-à-dire le décalage provoqué par les déplacements liés au l'émetteur, au récepteur et aux obstacles de canal. Le but de la réponse impulsionnelle du canal est de lier les signaux reçus $r(t)$ et les signaux émis $s(t)$, avec $n(t)$ désigne le terme de bruit additif gaussien.

$$\mathbf{r}(\mathbf{t}) = \mathbf{s}(\mathbf{t}) * \mathbf{h}(\mathbf{t}, \boldsymbol{\tau}) + \mathbf{n}(\mathbf{t}) \quad (2.11)$$

Le filtre représentant le canal peut être modélisé selon quatre fonctions initialement proposées par Bello [14]:

Fonction temporelle $\mathbf{h}(\boldsymbol{\tau}, \mathbf{t})$:

Cette fonction est la réponse impulsionnelle du canal. τ Désigne la variable retard et t la variable temporelle. Le signal de sortie $y(t)$ est obtenu en convolant le signal émis $x(t)$ avec la réponse impulsionnelle $h(t)$ du canal [15]:

$$\mathbf{y}(\mathbf{t}) = \int_{-\infty}^{+\infty} \mathbf{x}(\mathbf{t} - \boldsymbol{\tau}) \mathbf{h}(\boldsymbol{\tau}, \mathbf{t}) d\boldsymbol{\tau} \quad (2.12)$$

Avec $\mathbf{h}(\boldsymbol{\tau}, \mathbf{t})$ la réponse du canal à l'instant t et à une excitation à l'instant τ dans le passé. Un canal réel étant nécessairement causal, $\mathbf{h}(\boldsymbol{\tau}, \mathbf{t})$ est nul pour $\tau < 0$.

Fonction fréquentielle T (f, ϑ) :

Une autre manière d'illustrer la réponse du canal est d'utiliser le dual de $h(\tau, t)$ qui est T (f, ϑ) . Cette fonction permet de relier le spectre du signal reçu Y(f) à celui du signal émis X(f) par [15]:

$$Y(f) = \int_{-\infty}^{+\infty} X(f - \vartheta) T(f, \vartheta) d\vartheta \quad (2.13)$$

T (f, ϑ) est une fonction bi-fréquentielle qui permet de caractériser l'étalement Doppler du canal. On l'obtient en appliquant une double transformation de Fourier sur $h(\tau, t)$:

$$T(f, \vartheta) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} h(\tau, t) e^{-j2\pi f\tau} e^{-j2\pi\vartheta t} d\tau dt \quad (2.14)$$

Fonction tempo-fréquentielle H (f, t) :

Cette fonction correspond à la réponse fréquentielle du canal variant dans le temps. Elle permet de relier le signal temporel y(t) en sortie du filtre au spectre du signal en entrée X(f) par [15]:

$$Y(t) = \int_{-\infty}^{+\infty} X(f) H(f, t) e^{j2\pi ft} df \quad (2.15)$$

H (f, t) est liée à $h(\tau, t)$ et T (f, ϑ) par :

$$H(f, t) = \int_{-\infty}^{+\infty} h(\tau, t) e^{-j2\pi f\tau} d\tau = \int_{-\infty}^{+\infty} T(f, \vartheta) e^{j2\pi\vartheta t} d\vartheta \quad (2.16)$$

Fonction retard-Doppler S (τ, ϑ) :

S (τ, ϑ) est une fonction qui traduit les variations du canal. Elle illustre l'évolution du canal en fonction du retard et du Doppler. D'après la relation (2.17), le signal reçu peut être représenté comme une somme des versions décalées du signal émis, chacune subissant un effet Doppler [15].

$$y(t) = \int_{-\infty}^{+\infty} x(t - \tau) \left\{ \int_{-\infty}^{+\infty} S(\tau, \vartheta) e^{j2\pi\vartheta t} d\vartheta \right\} d\tau \quad (2.17)$$

$S(\tau, \vartheta)$ est reliée à la réponse impulsionnelle et à la fonction bi-fréquentielle du canal par:

$$S(\tau, \vartheta) = \int_{-\infty}^{+\infty} h(\tau, t) e^{-j2\pi\vartheta t} dt = \int_{-\infty}^{+\infty} T(f, \vartheta) e^{j2\pi f \tau} \quad (2.18)$$

La figure 2.6 illustre la détermination de chacune des fonctions caractéristiques du canal à partir de l'une des trois autres.

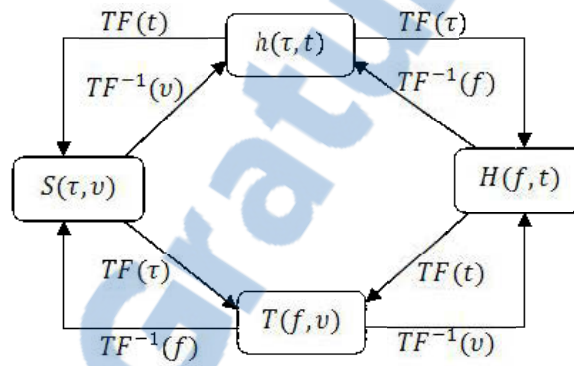


FIGURE 2. 6 — Diagramme de Bello avec les quatre fonctions décrivant le canal.

Lorsque le canal de transmission varie aléatoirement dans le temps, les quatre fonctions qui le décrivent sont aléatoires. La variation temporelle d'un canal est généralement extraite par l'étude des moments des processus aléatoires correspondant aux autocorrélations des quatre fonctions du canal.

Dans le cas d'un canal pour lequel l'effet de la mobilité est considéré comme négligeable, on applique une hypothèse de stationnarité au sens large Wide Sense Stationary Uncorrelated Scattering (WSSUS). Dans ce cas, les quatre fonctions précédemment décrites se résument aux deux fonctions duales : $h(\tau)$ (la réponse impulsionnelle du canal) et $H(f)$ (la fonction de transfert du canal) [11][15].

2.2.2 Distributions statistiques d'amplitude de signal reçu par trajet-multiple

Nous présentons les principales distributions :

- **La distribution de Rayleigh**

Un modèle très employé pour les fluctuations à petite échelle de l'amplitude en l'absence d'une composante forte à la réception est l'évanouissement de Rayleigh avec une fonction de densité de probabilité donnée par :

$$P_r(r) = \frac{r}{\sigma^2} e^{-\left(\frac{r^2}{2\sigma^2}\right)}, \quad r > 0 \quad (2.19)$$

Où σ est le paramètre de Rayleigh représentant la valeur la plus probable. La moyenne et la variance de cette distribution sont données par $\sqrt{\pi/2}\sigma$ et $(2 - \pi/2)\sigma^2$, respectivement. La distribution de Rayleigh est largement utilisée pour décrire l'évanouissement par trajets multiples en raison de son explication théorique élégante et ses vérifications expérimentales disponibles.

- **La distribution de Rice**

Cette distribution se produit lorsqu'un trajet puissant existe en plus des trajets dispersés de puissance plus basse. Cette forte composante peut résulter d'un trajet à visibilité directe ou d'un trajet qui subit beaucoup moins d'atténuation comparée aux autres composantes reçues. Quand une composante aussi dominante existe, le signal reçu peut être considéré comme la somme de deux signaux : un signal de Rayleigh dispersé avec une amplitude et une phase aléatoire, et un signal dont l'amplitude et la phase sont déterministes, représentant le trajet fixe.

Si $ue^{j\alpha}$ est le composant aléatoire, avec u suivant la loi de Rayleigh et α uniformément distribuée sur $[0, 2\pi]$, et $ve^{j\beta}$ est la composante fixe (v et β ne sont pas aléatoires), alors le signal reçu $re^{j\theta}$ est la somme de ces deux signaux et la fonction de densité de probabilité conjointe de r et θ peut être exprimée par :

$$P_r(r, \theta) = \frac{r}{2\pi\sigma^2} \exp\left(\frac{-r^2 + v^2 + 2rv \cos(\theta - \beta)}{2\sigma^2}\right), \quad r > 0, -\pi \leq \theta - \beta \leq \pi \quad (2.20)$$

En outre, puisque la longueur du trajet fixe change souvent, β est lui-même une variable aléatoire uniformément distribuée sur $[0, 2\pi]$. Cette considération rend r et θ indépendantes,

θ ayant une distribution uniforme et r étant distribuée suivant la distribution de Rice dont la fonction de densité de probabilité s'écrit :

$$P_r(r) = \frac{r}{\sigma^2} \exp\left(\frac{-r^2+v^2}{2\sigma^2}\right) I_0\left(\frac{rv}{\sigma^2}\right), \quad r > 0 \quad (2.21)$$

Où I_0 désigne la fonction de Bessel modifiée de première espèce et d'ordre 0, v est l'amplitude, ou l'enveloppe, de la composante forte et σ^2 est proportionnel à la puissance de la composante de Rayleigh.

Dans la formule de la fonction de densité de probabilité de Rice, si v tend vers 0, ou si $v^2/2\sigma^2 \ll r^2/2\sigma^2$, la composante forte est éliminée et la distribution de l'amplitude se réduit, comme prévu, à celle de Rayleigh. Par conséquent, la distribution de Rice englobe la distribution de Rayleigh comme un cas particulier.

- **La distribution Lognormale**

Cette distribution est souvent employée pour expliquer des variations à moyenne échelle de l'amplitude des signaux dans un environnement d'évanouissement par trajets multiples. La fonction de densité de probabilité lognormale est donnée par :

$$P_r = \frac{r}{\sqrt{2\pi}} e^{-\left(\frac{\ln r - \mu}{\sigma}\right)^2}, \quad r > 0 \quad (2.22)$$

Où σ est la variance de la distribution lognormale, μ est le paramètre de lognormale représentant la valeur la plus probable. La moyenne et la variance de cette distribution sont données par $e^{\mu+\sigma^2/2}$ et $(e^{\sigma^2} - 1)e^{2\mu+\sigma^2}$, respectivement.

- **La distribution de Nakagami**

Cette distribution englobe beaucoup d'autres distributions en tant que ça particuliers. Pour décrire la distribution de Rayleigh, on a assumé que les amplitudes des signaux diffusés sont égales et que leurs phases sont aléatoires. Un modèle proposé par Nakagami est plus réaliste puisqu'il autorise également à l'amplitude des signaux d'être aléatoire. La fonction de densité de probabilité de Nakagami relative à r est donnée par :

$$P_r(r) = \frac{2m^m r^{2m-1}}{\Gamma(m)\Omega^m} e^{-\left(\frac{mr^2}{\Omega}\right)}, \quad r > 0 \quad (2.23)$$

Où Γ est la fonction gamma, $\Omega = E[r^2]$, $m = [E(r^2)]^2 / var(r^2)$ est le facteur d'évanouissement qui se réduit à la distribution de Rayleigh pour $m=1$ et à la distribution gaussienne unilatérale pour $m=1/2$. Elle représente une bonne approximation de la distribution de Rice et s'approche dans certaines conditions de la distribution lognormale.

2.2.3 La distribution de l'amplitude d'un canal à trajets multiples UWB minier

Après le test des distributions Nakagami, Gamma, Rayleigh et lognormal dans les travaux de [2], avec l'utilisation de la méthode de Kolmogorov-Smirnov pour savoir lesquelles donnent un bon ajustement pour le signal reçu par trajets multiples, l'étude a montré que la distribution de Nakagami donne le meilleur résultat tableau :

Distributions	LOS	NLOS
Nakagami(%)	89	81
Gamma(%)	19	16
Lognormal(%)	54	41
Rayleigh(%)	83	76

Tableau 2.1 — Comparaison des distributions statistiques de l'amplitude des trajets multiples.

Chapitre 3

Les Réseaux de neurones

3.1 Introduction

Le cerveau humain contient environ 100 milliards de neurones. Ces neurones nous permettent entre autres, de lire un texte tout en maintenant une respiration régulière permettant d'oxygéner notre sang, en actionnant notre cœur qui assure une circulation efficace de ce sang pour nourrir nos cellules, etc. Ils nous permettent même de comprendre et analyser certaines idées et de mémoriser les visages des gens.

Les réseaux de neurones sont apparus parallèlement à la naissance de l'informatique, ont été créés à la base du modèle du neurone naturel. Ce dernier étant excité par un stimulus, il y répond selon sa fonction de transfert par une sortie qui peut être une atténuation ou une amplification de l'entrée.




FIGURE 3.1 — Schéma de neurone biologique.

Plusieurs caractéristiques clés des éléments de traitement des réseaux de neurones artificiels sont suggérées par les propriétés des neurones biologiques [16] [17] :

- L'élément de traitement reçoit de nombreux signaux,
- Les signaux peuvent être modifiés par un poids à la synapse de réception,

- L'élément de traitement des sommes entrées pondérées,
- Dans des circonstances appropriées (entrée suffisante), le neurone transmet une seule sortie,
- La sortie d'un neurone particulier peut se propager à de nombreux autres neurones (les branches axone).

D'autres caractéristiques des réseaux neuronaux artificiels qui sont suggérées par les neurones biologiques :

- Traitement de l'information est locale (bien que d'autres moyens de transmission, tels que l'action des hormones, peut suggérer des moyens de contrôle du processus global),
- La mémoire est distribuée :
 - Mémoire à long terme réside dans les synapses des neurones ou des poids ;
 - Mémoire à court terme correspond aux signaux envoyés par les neurones ;
- La force de connexion synaptique peut être modifiée par l'expérience,
- Neurotransmetteurs pour les synapses peuvent jouer le rôle de fonctions excitatrices ou inhibitrices.

3.2 Le modèle de neurone

Un neurone est essentiellement constitué d'un intégrateur qui effectue la somme pondérée de ses entrées. Le résultat n de cette somme est ensuite transformé par une fonction non linéaire pour produire la sortie a du neurone.

Le biais b du neurone, il s'appelle aussi le seuil d'activation du neurone. Lorsque le niveau d'activation atteint ou dépasse le seuil b , alors l'argument de f devient évidemment positif (ou nul). Comme elle montre la figure 3.2, il existe deux types de neurone simple, modèle simple sans biais et modèle avec biais.




FIGURE 3. 2 — Les deux modèles de neurone sans et avec biais.

Dans la plupart cas des réseaux de neurones, les neurones ont des entrées sous forme d'un vecteur comme elle montre la figure 3.3.




FIGURE 3. 3 — Modèle de neurone avec un vecteur d'entrées.

Dans ce cas la sortie n de l'intégrateur est définie par l'équation suivante :

$$\mathbf{n} = \sum_{j=1}^R \mathbf{w}_{1,j} \mathbf{p}_j = \mathbf{w}_{1,1} \mathbf{p}_1 + \mathbf{w}_{1,2} \mathbf{p}_2 + \dots + \mathbf{w}_{1,R} \mathbf{p}_R + \mathbf{b} \quad (3.1)$$

Et la sortie de neurone est :

$$\mathbf{a} = \mathbf{f}(\mathbf{n}) \quad (3.2)$$

3.2.1 Les fonctions de transfert

La fonction de transfert joue un rôle important dans un réseau de neurones, le tableau 3.1 présente les différents types des fonctions de transfert avec la relation entre l'entrée et la

sortie de neurone :










Nom de la fonction	Relation d'entrée/sortie	Icône
seuil	$a = 0$ si $n < 0$ $a = 1$ si $n \geq 0$	
seuil symétrique	$a = -1$ si $n < 0$ $a = 1$ si $n \geq 0$	
linéaire	$a = n$	
linéaire saturée	$a = 0$ si $n < 0$ $a = n$ si $0 \leq n \leq 1$ $a = 1$ si $n > 1$	
linéaire saturée symétrique	$a = -1$ si $n < -1$ $a = n$ si $-1 \leq n \leq 1$ $a = 1$ si $n > 1$	
linéaire positive	$a = 0$ si $n < 0$ $a = n$ si $n \geq 0$	
sigmoïde	$a = \frac{1}{1+\exp^{-n}}$	
tangente hyperbolique	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	
compétitive	$a = 1$ si n maximum $a = 0$ autrement	

Tableau 3.1 - Fonctions de transfert $a=f(n)$.

Parmi ces fonctions, il y a trois sont les plus utilisées dans le domaine de l'ingénierie, ces fonctions sont : "seuil" (a) ("hard limit"), "linéaire" (b) et "sigmoïde" (c) représentées à la figure 3.4 :




FIGURE 3.4 — Les trois fonctions les plus utilisées dans l'ingénierie.

Comme son nom l'indique, la fonction seuil applique un seuil sur son entrée. Plus précisément, une entrée négative ne passe pas le seuil, la fonction retourne la valeur 0 (faux), alors qu'une entrée positive ou nulle dépasse le seuil, et la fonction retourne 1 (vrai). Il est évident que ce genre de fonction permet de prendre des décisions binaires.

La fonction linéaire est quant à elle très simple, elle affecte directement son entrée à sa sortie selon la relation $n = f(n) = n$. Il est évident que la sortie du neurone correspond alors à son niveau d'activation dont le passage à zéro (l'ordonnée à l'origine) se produit lorsque $W \cdot \vec{p} = b$

La fonction de transfert sigmoïde est quant à elle définie par la relation mathématique :

$$a = \frac{1}{1 + e^{-n}} \quad (3.3)$$

Elle ressemble soit à la fonction seuil, soit à la fonction linéaire, selon que nous sommes loin ou près de b respectivement. La fonction seuil est très non linéaire, car il y a une discontinuité lorsque $W \cdot \vec{p} = b$. De son côté, la fonction linéaire est tout à fait linéaire. Elle ne comporte aucun changement de pente. La sigmoïde est un compromis intéressant entre les deux précédentes. Notons finalement que la fonction tangente hyperbolique (tansig) est une version symétrique de la sigmoïde.

3.2.2 Architecture d'un réseau de neurones

En général, un réseau de neurones se compose de trois types de couches :




FIGURE 3.5 — Architecture simple d'un réseau de neurones.

- **La couche d'entrée**

La première couche est appelée couche d'entrée. Elle recevra les données sources que nous voulons utiliser pour l'analyse. Sa taille est directement déterminée par le nombre de variables d'entrées.

- **La couche cachée**

La couche cachée est la couche suivante après la couche d'entrée, dans un réseau nous pouvons avoir une couche cachée ou plusieurs. Nous notons que si les fonctions de transfert sont linéaires alors, toutes les couches cachées, nous considérons, comme une seule couche. Or les fonctions d'activations sont en général non linéaires sur cette couche, mais il n'y a pas de règle à respecter. Le choix de sa taille n'est pas implicite et doit être ajusté. En général, nous pouvons commencer par une taille moyenne des couches d'entrée et de sortie, mais ce n'est pas toujours le meilleur choix. Il sera souvent préférable pour obtenir de bons résultats, d'essayer le plus de tailles possible.

- **La couche de sortie**

La troisième couche est appelée couche de sortie. Elle donne le résultat obtenu après compilation par le réseau des données entrée dans la première couche. Sa taille est directement déterminée par le nombre de variables que nous voulons en sortie.

3.2.3 L'apprentissage

Les réseaux de neurones possèdent une grande capacité à apprendre (par exemple à reconnaître une image, une lettre, un son...). Mais cette connaissance n'est pas acquise dès le départ. La plupart des réseaux de neurones apprennent par l'entraînement à l'aide d'un nombre des fichiers exemplaires. Ils ont donc une capacité à classer, à généraliser, et à mémoriser par un processus d'apprentissage.

L'apprentissage est l'étape la plus importante dans le fonctionnement d'un réseau de neurones, c'est un processus dynamique et itératif permettant de modifier les paramètres d'un réseau en réaction avec les stimulus qu'il reçoit de son environnement. Ainsi, le type d'apprentissage est déterminé par la manière dont les changements des paramètres

surviennent. Il existe plusieurs types d'apprentissage, nous présentons les deux les plus importants et les plus utilisés :

- L'apprentissage supervisé :

Dans ce type, une information précise sur la sortie désirée est disponible. Le réseau apprend par présentation de pair d'entrée/sortie. Durant l'apprentissage, les valeurs de sorties désirées sont comparées à celles produites par le réseau. L'erreur résultante est utilisée pour l'ajustement des poids des connexions. La règle du delta en méthode rétropropagation telle qu'elle est utilisée dans les réseaux multicouches que nous détaillerons dans le chapitre suivant.

- L'apprentissage non-supervisé :

Dans cet apprentissage, aucune information sur la sortie désirée du réseau n'est disponible. Ainsi, le réseau manipule des données qui lui sont présentées en entrée et cherche à extraire quelques propriétés qui formeront les sorties du réseau. L'extraction de ces propriétés dépend de la règle d'apprentissage utilisée dans le réseau.

3.3 Les applications des réseaux de neurones

Les réseaux de neurones sont généralement utilisés dans des problèmes de nature statistique et perceptive, tels que la classification, l'évaluation ou la prédiction. Les réseaux de neurones sont utilisés pour bâtir des systèmes de vision par ordinateur, pour faire des prévisions sur les marchés monétaires, pour évaluer le risque financier ou en assurance, pour différents processus manufacturiers, pour le diagnostic médical, pour l'exploration pétrolière ou gazière, en robotique, en télécommunication.

Il est à noter que le réseau de neurones ne fournit pas de règle exploitable par un humain. Le réseau reste une boîte noire qui fournit une réponse quand on lui présente une donnée, mais le réseau ne fournit pas de justification facile à lire sur la façon dont celle-ci est obtenue.

Les réseaux de neurones sont réellement utilisés, par exemple:

- En télécommunication, les réseaux de neurones utilisés dans plusieurs sujets comme la localisation, les canaux de propagation, le radio téléphonique, les satellites... [19] [20] [22] [25].

- Pour la classification ; par exemple pour la classification d'espèces animales par espèce étant donnée une analyse ADN,
- Reconnaissance de motif ; par exemple pour la Reconnaissance optique de caractères (OCR), et notamment par les banques pour vérifier le montant des chèques, par La Poste pour trier le courrier en fonction du code postal, etc. ; ou bien encore pour le déplacement automatisé de robots mobiles autonomes,
- Approximation d'une fonction inconnue,
- Modélisation accélérée d'une fonction connue, mais très complexe à calculer avec exactitude ; par exemple certaines fonctions d'inversions utilisées pour décrypter les signaux de télédétection émis par les satellites et les transformer en données sur la surface de la mer,
- Estimations boursières.

3.4 Les types des réseaux de neurones

Un réseau est caractérisé par plusieurs paramètres, l'apprentissage est l'un des principaux caractères pour définir un type de réseau. La figure montre une classification des types de réseaux de neurones se basant sur le type d'apprentissage.




FIGURE 3. 6 — Classification des modèles de réseaux de neurones par le type d'apprentissage.

- Les perceptrons multicouches (PMC)

Ils sont une amélioration du perceptron comprenant une ou plusieurs couches cachées. Ils utilisent, pour modifier leurs poids, un algorithme de rétropropagation du gradient, qui est une généralisation de la règle de Widrow-Hoff.

Il s'agit toujours de minimiser l'erreur quadratique, ce qui est assez simple quand on utilise une fonction f dérivable (la sigmoïde par exemple). On propage la modification des poids de la couche de sortie jusqu'à la couche d'entrée.

Les PMC agissent comme un séparateur non linéaire et peuvent être utilisés pour la classification, le traitement de l'image ou l'aide à la décision.

- Les réseaux de Hopfield

Un réseau de Hopfield réalise une mémoire adressable par son contenu. Il s'agit d'un réseau constitué de neurones de McCulloch et Pitts (à deux états, -1 et 1 ou 0 et 1), dont la loi d'apprentissage est la règle de Hebb (1949), qui veut qu'une synapse améliore son activité si et seulement si l'activité de ses deux neurones est coraillée (c'est à dire que le poids w_{ij} d'une connexion entre un neurone i et un neurone j augmente quand les deux neurones sont activés au même temps).

- Les réseaux de Kohonen

Contrairement aux réseaux de Hopfield où les neurones sont modélisés de la façon la plus simple possible, ces réseaux sont inspirés des observations biologiques du fonctionnement des systèmes nerveux de perception des mammifères. Une loi de Hebb modifiée (tenant compte de l'oubli) est utilisée pour l'apprentissage. La connexion est renforcée dans le cas où les neurones reliés ont une activité simultanée, et diminuée dans le cas contraire. Ainsi, une loi d'interaction latérale (observée biologiquement) est aussi modélisée. Les neurones très proches (physiquement) interagissent positivement (le poids des connexions est augmenté autour quand une synapse est activée), négativement pour les neurones un peu plus loin, et pas du tout pour les neurones éloignés.

Les réseaux de Kohonen ont des applications dans la classification, le traitement de l'image, l'aide à la décision et l'optimisation.

Chapitre 4

Modèle de réseau de neurones et mesures utilisées

4.1 Introduction :

Dans ce chapitre, nous présentons en détail le modèle que nous avons exploré. Nous présentons d'abord l'architecture du réseau de neurones ainsi que la méthode d'apprentissage utilisé. Nous décrivons ensuite les mesures et les données que nous avons utilisées pour entraîner et tester notre réseau, nous détaillons enfin l'algorithme de fonction de ce modèle.

Notre modèle se basait sur le réseau perceptron multicouche d'architecture feedforward, nous avons utilisé l'algorithme rétropropagation (backpropagation), cet algorithme est actuellement l'outil le plus utilisé dans le domaine de réseaux de neurones. C'est une technique de calcul des dérivées qui peut être appliquée à n'importe quelle structure de fonctions dérivables. Cette méthode est basée mathématiquement sur l'algorithme de descente du gradient et utilise les règles de dérivation des fonctions dérivables. De telles façons l'erreur commise en sortie du réseau sera rétropropagée vers les couches cachées d'où le nom de rétropropagation.

4.2 Méthode rétropropagation :

Le perceptron multicouche est un des réseaux de neurones les plus utilisés pour des problèmes d'approximation, de classification et de prédiction. Il est habituellement constitué de deux ou trois couches de neurones totalement connectés où l'information se propage dans un seul sens, de la couche d'entrée vers la couche de sortie. Il peut posséder un nombre de neurones (ou d'entrées) par couche quelconque. La rétropropagation est la méthode utilisée dans l'apprentissage de ce réseau [29] [30].

Pour expliquer cette méthode, nous commençons par la présentation des entrées, des sorties désirées et des sorties observées :

Soit le couple $(\vec{x}(n), \vec{d}(n))$ désignant la n^e donnée d'entraînement du réseau où :

$$\vec{x}(n) = \langle x_1(n), \dots, x_p(n) \rangle \text{ et } \vec{d}(n) = \langle d_1(n), \dots, d_q(n) \rangle \quad (4.1)$$

Correspondent respectivement aux p entrées et aux q sorties désirées du système. L'algorithme de rétropropagation consiste alors à mesurer l'erreur entre les sorties désirées $\vec{d}(n)$ et les sorties observées $\vec{y}(n)$:

$$\vec{y}(n) = \langle y_1(n), \dots, y_q(n) \rangle \quad (4.2)$$

Résultant de la propagation vers l'avant des entrées $\vec{x}(n)$, et à rétropropager cette erreur à travers les couches du réseau en allant des sorties vers les entrées. L'objectif de la méthode de la rétropropagation est d'adapter les poids par neurone de façon à minimiser une fonction de coût donné par :

$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (4.3)$$

Avec

$$e_j(n) = d_j(n) - y_j(n) \quad (4.4)$$

$e_j(n)$ est l'erreur pour le neurone j et la donnée d'entraînement n. Où $d_j(n)$ correspond à la sortie désirée du neurone j et $y_j(n)$ à sa sortie observée (voir la figure 4.1)




FIGURE 4. 1 — Modèle du neurone j.

La sortie $y_j(n)$ du neurone j est définie par :

$$y_j(n) = \varphi[v_j(n)] = \varphi\left[\sum_{i=0}^r w_{ji}(n) y_i(n)\right] \quad (4.5)$$

Où $\varphi[.]$ est la fonction d'activation du neurone, $v_j(n)$ est la somme pondérée des entrées du neurone j, $w_{ji}(n)$ est le poids de la connexion entre le neurone i de la couche précédente

et le neurone j de la couche courante, et $y_i(n)$ est la sortie du neurone i . On suppose ici que la couche précédente contient r neurones numérotés de 1 à r , que le poids $w_{j0}(n)$ correspond au biais du neurone j et que l'entrée $y_0(n) = -1$.

L'indice i représentera toujours un neurone sur la couche précédente par rapport au neurone j ; nous supposons par ailleurs que cette couche contient r neurones.

Pour corriger l'erreur observée, il s'agit de modifier le poids $w_{ji}(n)$ dans le sens opposé au gradient $\frac{\partial E(n)}{\partial w_{ji}(n)}$ de l'erreur (voir figure 4.2).




FIGURE 4. 2 — Gradient de l'erreur total.

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \cdot \frac{\partial e_j(n)}{\partial y_j(n)} \cdot \frac{\partial y_j(n)}{\partial w_{ji}(n)} \quad (4.6)$$

Et nous exprimons la variation de poids $\Delta w_{ji}(n)$ sous la forme suivante :

$$\Delta w_{ji}(n) = -\eta \frac{\partial E(n)}{\partial w_{ji}(n)} \quad (4.7)$$

Avec $0 \leq \eta \leq 1$ représentant un taux d'apprentissage ou gain de l'algorithme.

La dérivée partielle (équation (4.6)) représente un facteur de sensibilité : si nous changeons beaucoup $w_{ji}(n)$ dans le sens inverse de cette dérivée cela devrait nous rapprocher beaucoup du minimum local. Sinon, on doit changer seulement un peu $w_{ji}(n)$ pour corriger l'erreur, car nous sommes tout près de ce minimum.

Au niveau de la couche de sortie :

Puisqu'il y a r neurones sur la couche précédant la couche de sortie, il y a aussi r poids à adapter, et il importe donc de remarquer que la courbe de la figure 4.2 correspond en fait à une hyper-surface de $r+1$ dimensions.

Par l'évaluation de chacun de termes du gradient (équation (4.6)), nous obtenons donc:

$$\frac{\partial E(\mathbf{n})}{\partial w_{ji}(\mathbf{n})} = -e_j(\mathbf{n})y_j(\mathbf{n})[1 - y_j(\mathbf{n})]y_i(\mathbf{n}) \quad (4.8)$$

Et la règle dite du « delta » pour, la couche de sortie s'exprime, par :

$$\Delta w_{ji}(\mathbf{n}) = -\eta \frac{\partial E(\mathbf{n})}{\partial w_{ji}(\mathbf{n})} = \eta \delta_j(\mathbf{n})y_i(\mathbf{n}) \quad (4.9)$$

Avec :

$$\delta_j(\mathbf{n}) = e_j(\mathbf{n})y_j(\mathbf{n})[1 - y_j(\mathbf{n})] \quad (4.10)$$

Qui correspond à ce qu'on appelle le « gradient local ».

Au niveau de la couche cachée :

Considérons maintenant le cas des neurones sur la dernière couche cachée (le cas des autres couches cachées est semblable).au cas qu'on a une seule cachée ou la couche cachée première puisqu'il n'y a pas de couche précédente de neurones, nous substituons la variable $y_i(\mathbf{n})$ par l'entrée $x_i(\mathbf{n})$.

- Les indices i et j désigneront respectivement (comme précédemment) un neurone sur la couche précédente et un neurone sur la couche courante.
- L'indice k servira maintenant à désigner un neurone sur la couche suivante.

Reprenons l'expression de la dérivée partielle de l'erreur totale $E(\mathbf{n})$ par rapport à, w_{ji} mais en ne dérivant plus par rapport à l'erreur, $e_j(\mathbf{n})$ car celle-ci est maintenant inconnue :

$$\frac{\partial E(\mathbf{n})}{\partial w_{ji}(\mathbf{n})} = \frac{\partial E(\mathbf{n})}{\partial y_j(\mathbf{n})} \cdot \frac{\partial y_j(\mathbf{n})}{\partial v_j(\mathbf{n})} \cdot \frac{\partial v_j(\mathbf{n})}{\partial w_{ji}(\mathbf{n})} \quad (4.11)$$

Par rapport aux résultats obtenus pour la couche de sortie, les deux derniers termes de cette équation restent inchangés, seul le premier terme requiert d'être évalué :

$$\frac{\partial E(\mathbf{n})}{\partial y_j(\mathbf{n})} = \frac{\partial \left[\frac{1}{2} \sum_{k \in C} e_k^2(\mathbf{n}) \right]}{\partial y_j(\mathbf{n})} \quad (4.12)$$

Après l'évaluation d'équation (4.12) nous obtenons :

$$\frac{\partial E(\mathbf{n})}{\partial w_{ji}(\mathbf{n})} = -y_j(\mathbf{n})[1 - y_j(\mathbf{n})] \left[\sum_{k \in C} \delta_k(\mathbf{n}) w_{kj}(\mathbf{n}) \right] y_i(\mathbf{n}) \quad (4.13)$$

Et :

$$\Delta w_{ji}(\mathbf{n}) = -\eta \frac{\partial E(\mathbf{n})}{\partial w_{ji}(\mathbf{n})} = \eta \delta_j(\mathbf{n})y_i(\mathbf{n}) \quad (4.14)$$

Avec :
$$\delta_j(\mathbf{n}) = y_j(\mathbf{n})[1 - y_j(\mathbf{n})] \sum_{k \in \mathcal{C}} \delta_k(\mathbf{n}) w_{kj}(\mathbf{n}) \quad (4.15)$$

Les équations (4.14) et (4.15) sont valides pour toutes les couches cachées.

Nous résumons la méthode rétropropagation dans l'algorithme suivant :

1. Initialiser tous les poids à de petites valeurs aléatoires dans l'intervalle [-0.5, 0.5];
2. Normaliser les données d'entraînement ;
3. Permuter aléatoirement les données d'entraînement;
4. Pour chaque donnée d'entraînement n :
 - a. Calculer les sorties observées en propageant les entrées vers l'avant;
 - b. Ajuster les poids en rétropropageant l'erreur observée :

$$w_{ji}(\mathbf{n}) = w_{ji}(\mathbf{n} - 1) + \Delta w_{ji}(\mathbf{n}) = w_{ji}(\mathbf{n} - 1) + \eta \delta_j(\mathbf{n}) y_i(\mathbf{n}) \quad (4.16)$$

Où le « gradient local » est défini par :

$$\delta_j(\mathbf{n}) = \begin{cases} e_j(\mathbf{n}) y_j(\mathbf{n}) [1 - y_j(\mathbf{n})] & \text{si } j \in \text{couche de sortie} \\ y_j(\mathbf{n}) [1 - y_j(\mathbf{n})] \sum_k \delta_k(\mathbf{n}) w_{kj}(\mathbf{n}) & \text{si } j \in \text{couche cachée} \end{cases} \quad (4.17)$$

Avec $0 \leq \eta \leq 1$ représentant, le taux d'apprentissage et $y_i(\mathbf{n})$ représentant soit la sortie du neurone i sur la couche précédente, si celui-ci existe, soit l'entrée i autrement.

5. Répéter les étapes 3 et 4 jusqu'à un nombre maximum d'itérations ou jusqu'à ce que la racine de l'erreur quadratique moyenne (EQM) soit inférieure à un certain seuil.

4.3 Les mesures utilisées :

Les mesures que nous utilisons pour tester et évaluer notre réseau sont des mesures du canal de propagation à UWB, elles ont été effectuées dans divers endroits de deux galeries souterraines qui se trouvent à 70 mètres et 40 mètres dans la mine CAMNET de Val d'Or [28].

Le canal de propagation a été maintenu stationnaire, afin de caractériser statistiquement le canal de propagation à petites échelles, le récepteur est déplacé sur une grille de forme carrée 9 point (3x3) dont la distance entre chaque point adjacent est égale à 1 cm.

D'autre part, pour caractériser les statistiques du canal de propagation à grande échelle, le récepteur a été déplacé, indépendamment de la position fixe de l'émetteur, avec un pas de 1 m sur une distance allant de 1 m à 10 m dans la galerie en LOS et de 4 m à 10 m dans la galerie en NLOS (voir la figure 4.3))




FIGURE 4.3 — Plan de la mine au niveau 70m.

Dans notre projet nous nous sommes intéressés aux mesures de galerie LOS et aussi par les mesures au niveau de 40 mètres, ces dernières ont été prises de la même façon avec les mêmes équipements (voir le tableau 4.1)

Équipements de mesure	Description
Analyseur de réseau PNA	Agilent E8363B 10 MHz à 40 GHz
Antennes omnidirectionnelles	Electro-EM6116 bande de 2 GHz à 10GHz
Antennes directionnelles	DRG-118/A 1GHz à 18GHz
Câbles	Câbles RF 'Storm'
Unité d'acquisition des données	PC pour enregistrer les données de mesures via l'interface GPIB

Tableau 4.1 — Équipements utilisés dans les mesures.

L'analyseur de réseau Agilent E8362B est de la plateforme d'analyseurs de réseaux de la série de PNA. Ce dispositif destiné à la caractérisation de la propagation des ondes électromagnétiques a été choisi pour effectuer les mesures [28] pour son fonctionnement sur une plage de fréquence de 10 MHz à 40 GHz. Il a l'avantage d'être rapide et offre une grande précision en fréquence.

En effet, sa gamme dynamique atteint 110 dB et la vitesse de mesure peut aller jusqu'à 26 µsec/point. En ce qui concerne les antennes, l'antenne omnidirectionnelle EM-6116 utilisée dans ces mesures possède un diagramme de rayonnement omnidirectionnel sur le plan horizontal et couvre une bande de fréquence de 2 GHz à 10 GHz. L'antenne directionnelle DRG-118/A, est une antenne cornet possédant un lobe nettement plus important que les autres lobes dont la bande de fréquence est de 1 GHz à 18 GHz.

Toutes les mesures du canal de propagation que nous utilisons sont prises dans le domaine fréquentiel en « paramètres-S » S21.

4.4 Réseau et Apprentissage:

4.4.1 Architecture de réseau :

Notre réseau est de type perceptron multicouche d'architecture feedforward utilise l'apprentissage supervisé par la méthode de rétropropagation. Nous utilisons la fonction hyperbolique tangente sigmoïde (Tansig) dans les couches cachées et la fonction linéaire (purelin) dans la couche de sortie (voir chapitre2).

Au début nous avons commencé par un perceptron de trois couches, deux couches cachées et une couche de sortie comme présente la figure (3.4), nous avons varié le nombre de neurones par couche jusqu'à améliorer les résultats.

Afin d'obtenir de bons résultats nous avons utilisé plusieurs moyens, l'un de ces derniers est de diminuer le nombre de couches dans le réseau, car une architecture avec plusieurs couches cachées augmentera la précision des estimations. Cependant, le nombre de connexions sera plus élevé et le temps d'apprentissage sera plus lent.

L'un des problèmes que nous avons rencontrés est de montrer que le modèle est réaliste et d'identifier les entrées de notre modèle, car dans le cas de l'UWB, la puissance reçue variée en fonction de deux variables et nous avons un très grand nombre de mesures qu'il faut bien les arranger pour qu'elles puissent devenir utilisables. Nous sommes passés par plusieurs

expériences et plusieurs modèles afin d'identifier les entrées réalistes que nous présenterons en détail aux paragraphes suivants.




FIGURE 4. 4 — Modèle de réseau de neurones avec trois couches.

Nous avons utilisé l'apprentissage avec une seule couche cachée (figure (4.4)) avec différent nombre de neurones. Nous avons constaté qu'avec un nombre de neurones égal à quatre-vingts, nous obtenons l'erreur quadratique moyenne (EQM) la plus faible.




FIGURE 4. 5 — Modèle de réseau de neurones avec deux couches.

4.4.2 Apprentissage :

L'apprentissage cherche à trouver le vecteur de poids qui minimise l'erreur quadratique sur l'ensemble des données d'apprentissage. Il se fait en présentant un fichier d'exemplaire au réseau. Le nombre de neurones d'entrées et de neurones de sortie est fixe. Plusieurs paramètres ont une influence sur la recherche de ce vecteur poids. En effet, la règle utilisée pour la mise à jour du vecteur poids repose sur ces paramètres. Le tableau (4.2) présente un exemple de fichier qui contient toutes les informations nécessaires à l'apprentissage de notre réseau de neurones.

Paramètres	valeurs
nbre_entrées	2
nbre_couches_cachées	1
nbre_neurones_c_cachées	80
nbre_sorties	1
erreur_arret	0.0001
nbre_cycles	500

Tableau 4.2 — Paramètres décrivant le réseau de neurones.

4.5 Organisation et construction de fichiers de données :

La figure (4.6) montre comment nous avons regroupé l'ensemble de fichiers dans un fichier global qui contient toutes les données dont nous avons besoin, nous avons neuf fichiers de type S2p pour chaque distance de un à dix mètres c'est-à-dire quatre-vingt-dix fichiers au total.

Alors le fichier de donnée globale que nous avons construite contient les valeurs de la fréquence variée de 3 GHz à 10 GHz (la première colonne figure (4.7) et (4.8)) et pour chaque distance entre antennes émission et réception, nous avons l'amplitude et la phase de paramètre-S (S21). Dans notre modélisation, nous sommes intéressés par l'amplitude de S21 qui va nous donner la variation de puissance reçue et qui sera la sortie désirée de notre réseau et par la fréquence et la distance qui seront les entrées de notre réseau. Nous avons suivi la même procédure pour les données de mesure au niveau 70 mètres et au niveau 40

mètres afin de construire de fichier matrice01 pour les mesures 70 m et matrice02 pour les mesures de 40 m.

Voir les figure (4.7) et figure (4.8) montrent une partie de fichiers de données.

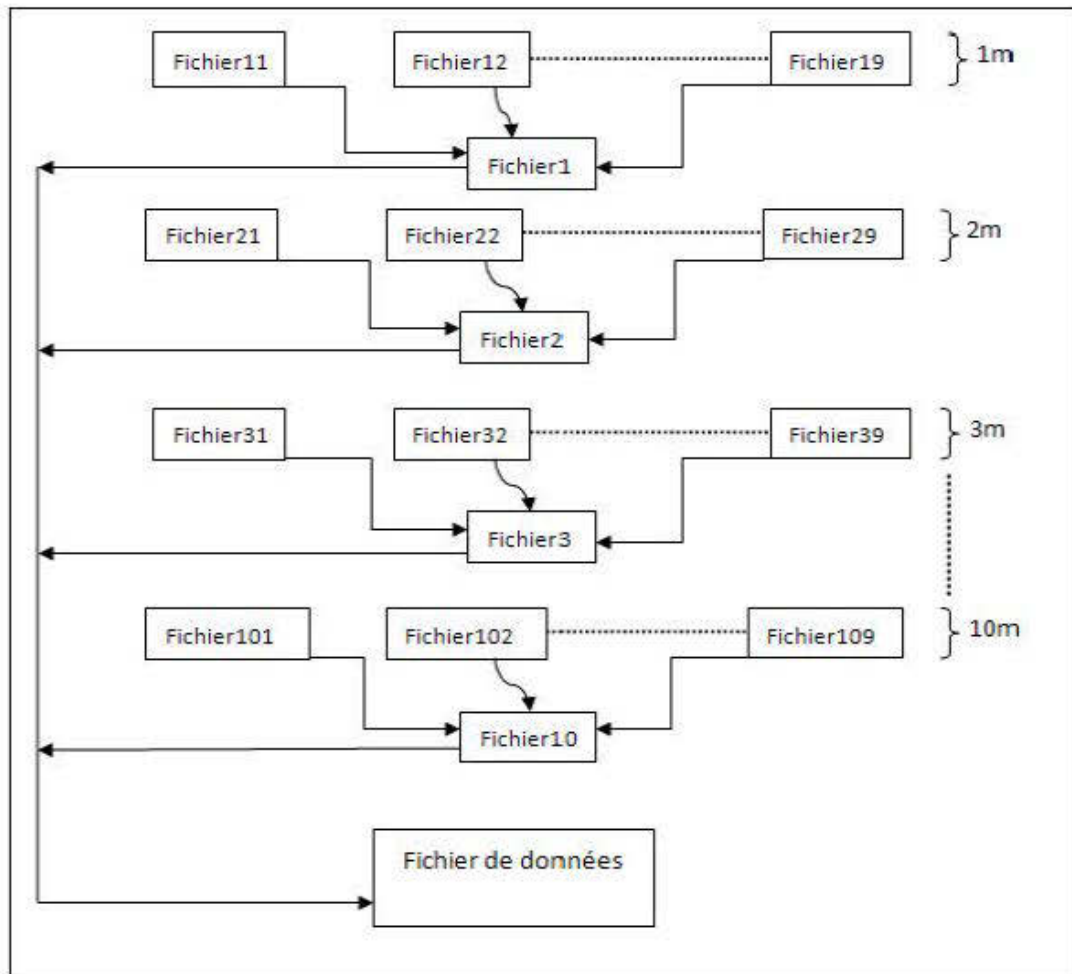


FIGURE 4. 6 — Organisation de données.



matrice01 <16001x31 double>													
	1	2	3	4	5	6	7	8	9	10	11	12	13
14	3.0057e+09	1	8.5475	56.6387	2	3.0748	-13.9682	3	1.3793	84.2276	4	-3.5217	15.4602
15	3.0061e+09	1	8.5422	54.5864	2	3.0509	-16.4701	3	1.3847	81.0569	4	-3.5589	11.9678
16	3.0066e+09	1	8.5300	52.4880	2	3.0206	-19.0062	3	1.3850	117.8189	4	-3.5978	8.4248
17	3.0070e+09	1	8.5250	50.4548	2	2.9922	-21.5001	3	1.3909	114.6093	4	-3.6345	4.9202
18	3.0074e+09	1	8.5243	48.3928	2	2.9696	-23.9732	3	1.4007	111.4201	4	-3.6559	81.4458
19	3.0079e+09	1	8.5226	46.2875	2	2.9553	-26.5141	3	1.4100	108.1556	4	-3.6837	77.8945
20	3.0083e+09	1	8.5272	44.1897	2	2.9421	-29.0879	3	1.4216	104.8844	4	-3.7023	114.3659
21	3.0088e+09	1	8.5266	42.0721	2	2.9254	-31.6163	3	1.4358	101.6166	4	-3.7246	110.8477
22	3.0092e+09	1	8.5289	40.0138	2	2.9036	-34.1403	3	1.4405	98.3699	4	-3.7508	107.3694
23	3.0096e+09	1	8.5283	37.9163	2	2.8815	-36.6201	3	1.4487	95.1324	4	-3.7779	103.8745
24	3.0101e+09	1	8.5361	35.8428	2	2.8832	-39.1127	3	1.4642	91.8973	4	-3.7876	100.4809
25	3.0105e+09	1	8.5405	33.6962	2	2.8726	-41.7148	3	1.4734	88.6113	4	-3.7982	96.9821
26	3.0109e+09	1	8.5455	31.6513	2	2.8659	-44.1966	3	1.4876	85.4401	4	-3.8032	93.5634
27	3.0114e+09	1	8.5539	29.5249	2	2.8539	-46.8126	3	1.4978	82.1630	4	-3.8076	90.0892
28	3.0118e+09	1	8.5720	27.4335	2	2.8534	-49.3131	3	1.5252	78.9383	4	-3.8051	86.6486
29	3.0123e+09	1	8.5922	25.3430	2	2.8628	-51.8230	3	1.5470	75.7139	4	-3.7904	83.2196
30	3.0127e+09	1	8.6174	23.2514	2	2.8732	-54.5183	3	1.5772	72.3652	4	-3.7760	79.6545
31	3.0131e+09	1	8.6270	21.1603	2	2.8711	-57.1746	3	1.5963	69.0452	4	-3.7620	76.1101
32	3.0136e+09	1	8.6453	19.0679	2	2.8705	-60.1049	3	1.6167	65.6856	4	-3.7389	72.4731
33	3.0140e+09	1	8.6512	17.0000	2	2.8614	-63.4326	3	1.6352	62.3348	4	-3.7347	68.8615
34	3.0144e+09	1	8.6583	15.0082	2	2.8569	-66.6763	3	1.6549	58.9461	4	-3.7247	65.2534
35	3.0149e+09	1	8.6536	13.18248	2	2.8458	-70.0344	3	1.6627	55.5934	4	-3.7166	61.6036
36	3.0153e+09	1	8.6504	11.42058	2	2.8349	-73.4354	3	1.6814	52.2699	4	-3.7037	57.9970
37	3.0158e+09	1	8.6299	12.74108	2	2.8034	-76.6763	3	1.6743	48.9440	4	-3.7168	54.3723
38	3.0162e+09	1	8.6112	125.2081	2	2.7669	44.0394	3	1.6709	45.6073	4	-3.7217	50.7416
39	3.0166e+09	1	8.6031	123.1109	2	2.7516	41.5157	3	1.6772	42.3771	4	-3.7231	47.2491
40	3.0171e+09	1	8.5919	120.9598	2	2.7305	38.8884	3	1.6809	39.1175	4	-3.7225	43.6642
41	3.0175e+09	1	8.5791	118.9103	2	2.7051	36.3530	3	1.6831	35.9119	4	-3.7249	40.1856
42	3.0179e+09	1	8.5795	116.8473	2	2.6893	33.8008	3	1.6990	32.6918	4	-3.7072	36.6592
43	3.0184e+09	1	8.5747	114.8211	2	2.6599	31.3202	3	1.7062	29.5214	4	-3.7075	33.1905
44	3.0188e+09	1	8.5933	112.7715	2	2.6628	28.8494	3	1.7329	26.3492	4	-3.6859	29.7196

FIGURE 4. 7 — Partie du fichier des données de mesures minières au niveau 70 m.

matrice02 <16001x31 double>													
	1	2	3	4	5	6	7	8	9	10	11	12	13
1	3.0000e+09	1	9.9041	-60.5466	2	5.0384	53.9602	3	3.3655	104.6209	4	-3.8585	-39.2728
2	3.0004e+09	1	9.8734	-22.8870	2	4.9956	51.1075	3	3.3211	100.8810	4	-3.8675	-103.0694
3	3.0009e+09	1	9.8585	54.9140	2	4.9737	48.3891	3	3.2967	97.3320	4	-3.8450	-26.6971
4	3.0013e+09	1	9.8384	52.6921	2	4.9476	45.6971	3	3.2679	93.7794	4	-3.8315	-30.3903
5	3.0018e+09	1	9.8161	50.4710	2	4.9240	42.9712	3	3.2300	90.1823	4	-3.8191	-34.1304
6	3.0022e+09	1	9.7913	-8.3495	2	4.8899	40.3655	3	3.1819	86.7171	4	-3.8247	-37.7722
7	3.0026e+09	1	9.7698	-6.2246	2	4.8654	37.7276	3	3.1314	83.2423	4	-3.8366	-41.4920
8	3.0031e+09	1	9.7492	-4.0805	2	4.8327	35.0662	3	3.0796	79.8011	4	-3.8553	-45.1810
9	3.0035e+09	1	9.7333	-2.0115	2	4.7963	32.5175	3	3.0269	76.4563	4	-3.8785	-48.7804
10	3.0039e+09	1	9.7242	39.9107	2	4.7706	69.9496	3	2.9807	73.0633	4	-3.9081	-52.3264
11	3.0044e+09	1	9.7232	37.8455	2	4.7463	67.4002	3	2.9364	69.7846	4	-3.9238	-55.7476
12	3.0048e+09	1	9.7182	35.7404	2	4.7249	64.9393	3	2.8937	66.4862	4	-3.9467	-59.1304
13	3.0053e+09	1	9.7185	33.5988	2	4.7100	102.3977	3	2.8490	63.2024	4	-3.9468	-22.4899
14	3.0057e+09	1	9.7258	31.4540	2	4.7027	99.8887	3	2.8180	59.9099	4	-3.9262	14.1574
15	3.0061e+09	1	9.7244	29.2892	2	4.6923	137.3331	3	2.7842	56.6077	4	-3.8930	50.7204
16	3.0066e+09	1	9.7319	27.1322	2	4.6872	134.8047	3	2.7551	53.3143	4	-3.8614	47.2124
17	3.0070e+09	1	9.7273	24.9541	2	4.6784	132.2594	3	2.7147	50.0122	4	-3.8255	43.6414
18	3.0074e+09	1	9.7156	62.7885	2	4.6579	129.7114	3	2.6667	46.7086	4	-3.8026	80.0269
19	3.0079e+09	1	9.7136	60.6265	2	4.6464	127.2034	3	2.6241	43.4542	4	-3.7662	76.3010
20	3.0083e+09	1	9.7061	98.4427	2	4.6320	124.6595	3	2.5778	40.1438	4	-3.7446	72.4301
21	3.0088e+09	1	9.6914	136.3195	2	4.6072	122.2192	3	2.5147	36.9901	4	-3.7470	68.6723
22	3.0092e+09	1	9.6880	134.2422	2	4.6038	119.8338	3	2.4720	33.9019	4	-3.7494	64.9007
23	3.0096e+09	1	9.6864	132.1597	2	4.6038	117.4442	3	2.4367	30.8575	4	-3.7551	61.2411
24	3.0101e+09	1	9.6887	130.1292	2	4.6116	115.1087	3	2.4150	27.8441	4	-3.7485	57.5775
25	3.0105e+09	1	9.6982	128.0346	2	4.6239	112.6855	3	2.3953	24.7046	4	-3.7453	53.8022
26	3.0109e+09	1	9.7079	125.9665	2	4.6402	110.3023	3	2.3747	21.6037	4	-3.7610	50.0501
27	3.0114e+09	1	9.7283	123.8941	2	4.6776	107.9172	3	2.3587	18.5777	4	-3.7757	46.3430
28	3.0118e+09	1	9.7480	121.7925	2	4.7114	105.4315	3	2.3469	15.5224	4	-3.7982	42.6703
29	3.0123e+09	1	9.7638	119.6556	2	4.7437	102.9436	3	2.3421	12.4634	4	-3.8235	39.0311
30	3.0127e+09	1	9.7810	117.5342	2	4.7758	100.4118	3	2.3364	9.3643	4	-3.8504	35.3822

FIGURE 4. 8 — Partie du fichier de données des mesures minières au niveau 40 m.

4.6 Les étapes de fonctionnement du modèle

Lors de l'apprentissage, nous présentons au réseau de neurones un ensemble de données similaires. Nous entraînons le modèle en effectuant un nombre suffisant d'expériences pour vérifier la validité des résultats et du modèle. Lors de la phase de prédiction, nous testons le modèle en estimant sa précision à prédire correctement les valeurs de la puissance reçue. Si la précision est acceptable, on peut utiliser le modèle sinon il faut recommencer le cycle de construction du modèle. Enfin, ce modèle de prédiction sera utilisé pour d'autres données sans connaître à priori les sorties correspondantes aux entrées. La figure (4.9) montre les deux phases de l'estimation de réseau de neurones, la phase d'apprentissage et la phase de prédiction ou de test.




FIGURE 4.9 — Les phases d'estimation de réseau.

Les étapes de fonctionnement de notre modèle sont présentées Figure (3.10), nous décrivons les étapes comme suite:

- Normalisation des données à partir du fichier de données, le fichier de données contient toutes les entrées, les sorties désirées qui sont les valeurs de fréquences, de distances et de puissances reçues.
- Division des données en deux ensembles, l'un servira à l'apprentissage et l'autre au test. Dans cette étape, nous avons essayé par plusieurs pourcentages de division, nous allons détailler cela au chapitre suivant. En général, l'ensemble d'apprentissage est toujours le plus grand.
- Nous construisons le réseau de neurones à partir des paramètres d'architecture et d'apprentissage, nous spécifions le nombre de neurones en entrées, le nombre de couches cachées, le nombre de neurones dans chaque couche et les fonctions de transfert dans chaque couche.
- Apprentissage du réseau : après la construction du réseau, nous lui présentons les données d'apprentissage. Les données seront présentées au réseau une à la fois. L'entrée permet de calculer la sortie produite par le réseau. Nous comparons celle-ci à la sortie de données mesurées. Une mise à jour des poids est faite selon la règle du delta, deux critères d'arrêt sont possibles pour l'apprentissage, lorsque l'on a atteint soit une erreur acceptable, soit un nombre de cycles jugé suffisant à l'apprentissage des données. Nous produisons deux fichiers de résultats l'un contient l'erreur quadratique moyenne, le deuxième sert à sauvegarder les valeurs de poids de tous les liens à la fin de l'apprentissage.
- Une fois que l'architecture de réseau a été entraînée, les données de test lui sont présentées une à une en utilisant les valeurs de poids d'apprentissage. Nous calculons la sortie produite par le réseau, puis on la compare avec la sortie désirée. Dans cette étape nous calculons aussi l'erreur quadratique moyenne qui sera un critère pour savoir la performance du réseau.

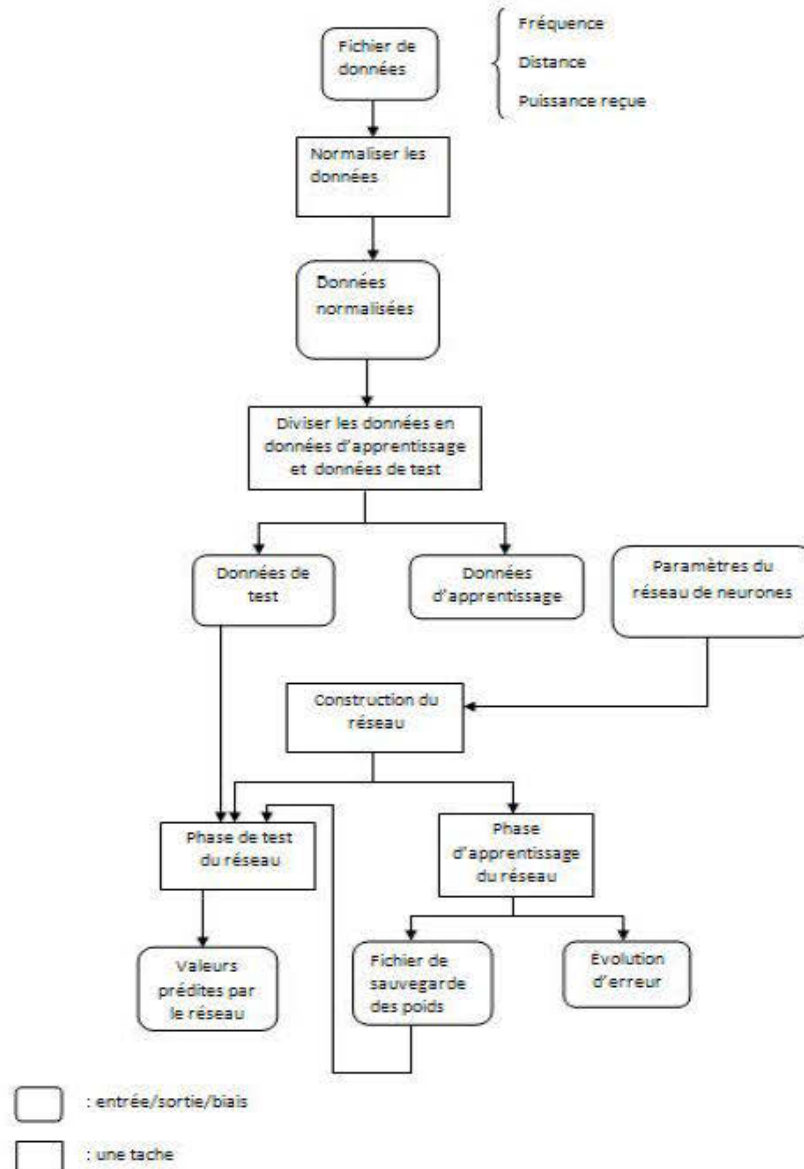


FIGURE 4.10 — Les étapes de fonctionnement de modèle.

4.7 Conclusion :

Dans ce chapitre, nous nous sommes intéressés à la modélisation par réseaux de neurones du canal minier, nous avons présenté le type de réseau utilisé. Ainsi, nous avons décrit les mesures minières et les étapes qu'on a faites pour les organiser et la génération du fichier de données utilisé dans l'apprentissage et le test du réseau, puis nous avons construit notre modèle de réseau de neurones en considérant plusieurs critères, enfin nous avons présenté un algorithme global du fonctionnement de notre modèle.

Chapitre 5

Analyse des résultats

5.1 Introduction

Dans ce chapitre, nous présentons les résultats que nous avons obtenus, tout d'abord nous commençons par le cas idéal d'espace libre, ensuite nous exposons les résultats de canal UWB au niveau de 70 mètres sous terrain avec les différents pourcentages de données d'apprentissage et de test, nous montrons enfin les résultats d'évaluation de notre modèle au niveau de 40 mètres c'est-à-dire dans un environnement différent et nous les comparerons avec données de 70 m.

5.2 Cas d'espace libre

La figure (4.1) montre la variation de puissance reçue en fonction de la distance, nous avons calculé la puissance reçue par l'utilisation de l'équation (2.3) que nous avons détaillée dans le chapitre 2, nous avons considéré que la fréquence est constante.




FIGURE 5. 1 — Puissance reçue en fonction de distance.

D'après la figure 5.1, nous remarquons que la puissance estimée par le réseau de neurones et la puissance calculée sont identiques.

5.3 Modélisation de canal UWB au niveau 70 mètres sous terrain

5.3.1 Modèle neuronal avec une seule entrée

Comme nous l'avons expliqué au chapitre 4, nous avons passé par plusieurs étapes avant d'identifier les entrées (fréquence, distance), nous avons rencontré des difficultés pour présenter les dimensions des vecteurs entrées, car nous avons pour chaque distance 16 001 valeurs discrètes de fréquences. Par conséquent, nous avons construit au début des modèles par une seule entrée, nous présentons les résultats de ces modèles dans les deux sections suivants.

5.3.1.1 Puissance reçue en fonction de distance

Dans cette partie, nous avons considéré la fréquence constante, alors la distance est devenue la seule entrée de notre réseau. La figure 5.2 montre la variation de puissance reçue en fonction de distance.




FIGURE 5. 2 — Puissance reçue en fonction de distance au niveau de 70m sous terre.

Nous avons obtenu une erreur quadratique moyenne très petite de valeur $2,13 \times 10^{-4}$ dBm qu'on considère négligeable. Alors nous pouvons conclure à partir de la figure et de l'erreur quadratique que le résultat est parfait.

5.3.1.2 Puissance reçue en fonction de la fréquence

À l'inverse du cas précédent, nous avons considéré que la distance est fixe c'est-à-dire que pour chaque distance nous estimons la puissance reçue en fonction de fréquence. La figure 5.3 présente la variation de puissance reçue en fonction de fréquence pour une distance de 1 mètre et la figure 5.4 est un zoom de la partie rouge dans la figure 5.3.

Nous avons obtenu une erreur quadratique égale à 0.1340 dBm qui est faible, et à partir de des deux figures nous remarquons que le résultat est très logique.

Grâce à ce que nous avons vu dans les derniers paragraphes, nous tirons comme conclusion que la modélisation en UWB en fonction de la fréquence et de la distance est réalisable, nous présenterons aux paragraphes suivants le modèle en fonction de deux paramètres.




FIGURE 5. 3 — Puissance reçue en fonction de fréquence pour une distance fixe =1m.

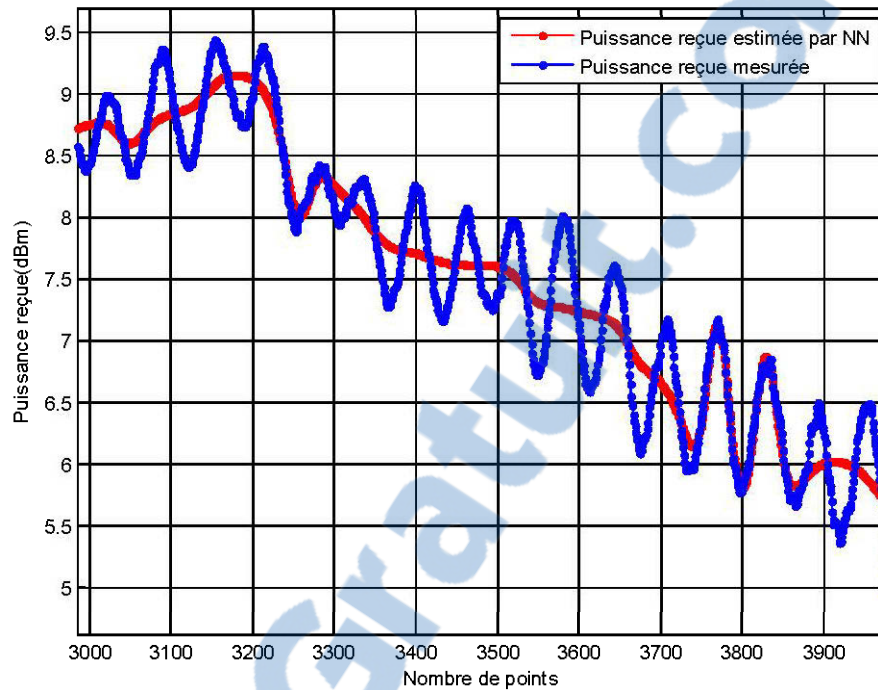


FIGURE 5.4 — Zoome de la partie rouge de figure (5.3).

5.3.2 Modèle neuronal avec deux entrées

Dans cette partie, nous présentons les différents pourcentages de données pour entraîner et tester notre réseau. À ce stade, nous avons besoin de figure 4.9 de chapitre 4 pour bien expliquer comment se passe la répartition de données pour les deux phases d'entraînement et de test. L'objectif de ce travail est de trouver la répartition la plus valide pour notre modèle et de valider la performance de notre modèle.

Dans toutes les figures suivantes, la fréquence varie de 3 à 10 GHz avec un pas qui dépend du nombre d'exemplaires du test et de la distance varie de 1 à 10 m.

- **Entraîner le réseau avec 50 % de mesures et tester avec 50 % de mesures :**

La figure 5.5 montre la division des données au niveau de la phase d'apprentissage et de la phase de prédiction :

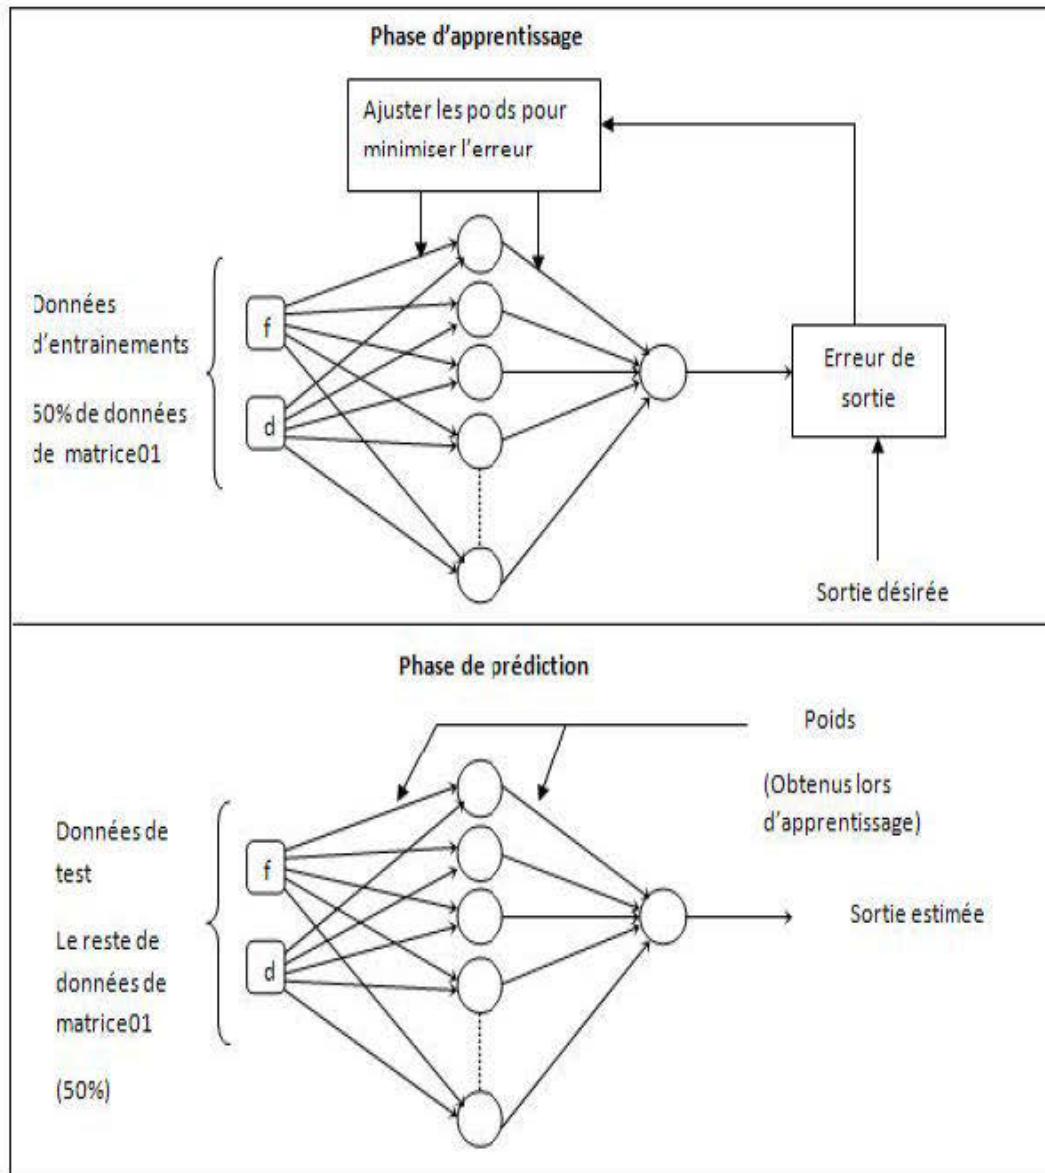


FIGURE 5.5 — Répartition des données dans les deux phases d'estimation.

Nous obtenons les résultats illustrés dans la figure 5.6 avec une erreur quadratique moyenne égale à 1,0359 dBm.




FIGURE 5. 6 — Puissance reçue en fonction de la distance et de la fréquence de canal UWB minier au niveau 70m.

La figure 5.7 montre une partie zoomée de la figure précédente pour la distance de 1 m :




FIGURE 5. 7 — Puissance reçue en fonction de fréquence à 1m.

Nous concluons que notre modèle est capable de prédire correctement la puissance reçue en fonction de fréquence et de distance.

► **Entraîner le réseau avec 10 % de mesures et tester avec 50 % de mesures :**

Dans cette partie, nous divisons les données en 10 % de données pour l'entraînement et 50 % pour tester le réseau. La figure 5.8 montre les résultats trouvés par le réseau de neurones avec une erreur quadratique de 1.0445dBm.




FIGURE 5.8 — Puissance reçue en fonction de la distance et de la fréquence du canal UWB minier à 70m sous terre.




FIGURE 5. 9 — Zoom de la figure (5.8) à 5m.

Nous remarquons que même si nous avons diminué le nombre d'exemplaires d'entraînement de notre modèle, ce dernier reste capable d'estimer correctement la variation de la puissance en fonction de la fréquence et de la distance.

➤ **Entraîner le réseau avec 1 % de mesures et tester avec 50 %**

Nous avons diminué les données d'entraînement jusqu'à 1 %, nous obtenons les résultats présentés dans la figure (4.10), avec une erreur quadratique moyenne de 3.8692dBm

Nous voyons que l'erreur a augmenté par rapport aux cas précédents. Pourtant, cette augmentation de l'erreur, le réseau a estimé correctement la variation de puissance reçue en fonction de fréquence et de distance.




FIGURE 5.10 — Puissance reçue en fonction de la distance et de la fréquence du canal UWB minier à 70m sous terre.




FIGURE 5.11 — Partie marquée en rouge de la figure précédente zoomée.

► **Entraîner le réseau avec 10 % de mesures et tester avec 1 %**

Dans cette partie nous faisons le contraire du paragraphe précédent, nous augmentons le nombre d'exemplaires d'entraînement et nous diminuons le nombre d'exemplaires de test. La figure 5.12 montre la variation de la puissance reçue en fonction toujours de la fréquence et de la distance avec une erreur quadratique moyenne plus faible égale à (1.1194dBm).

Nous remarquons que les résultats sont plus ponctuels, car le nombre de mesures est devenu plus faible comparée aux étapes précédentes.




FIGURE 5.12 — Puissance reçue en fonction de la distance et de la fréquence

du canal UWB minier à 70m sous terre.

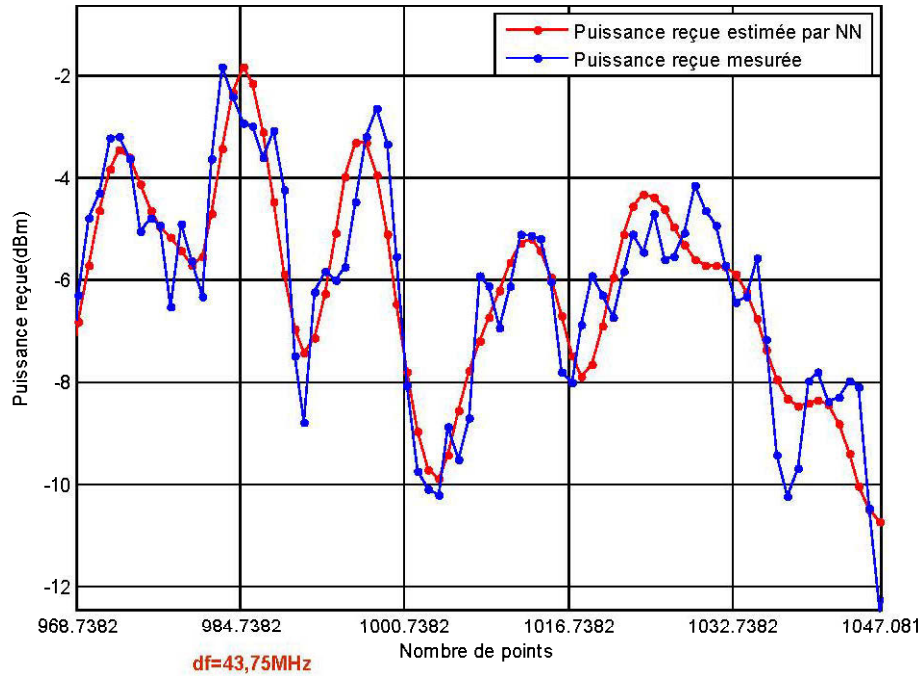


FIGURE 5. 13 — Partie de figure (5.12) zoomée à 6 m.

5.4 Évaluation de réseau par les mesures d'un canal différent au 40 m sous terrain

Après que nous avons montré la performance de notre réseau pour la modélisation de canal minier au niveau de 70 m, nous évaluons notre réseau par les exemplaires de canal minier à 40 m sous terrain. La figure 5.14 montre la répartition des entrées du canal minier à 70 m dans la phase d'apprentissage et les entrées de canal à 40 m dans la phase de prédiction ou de test.

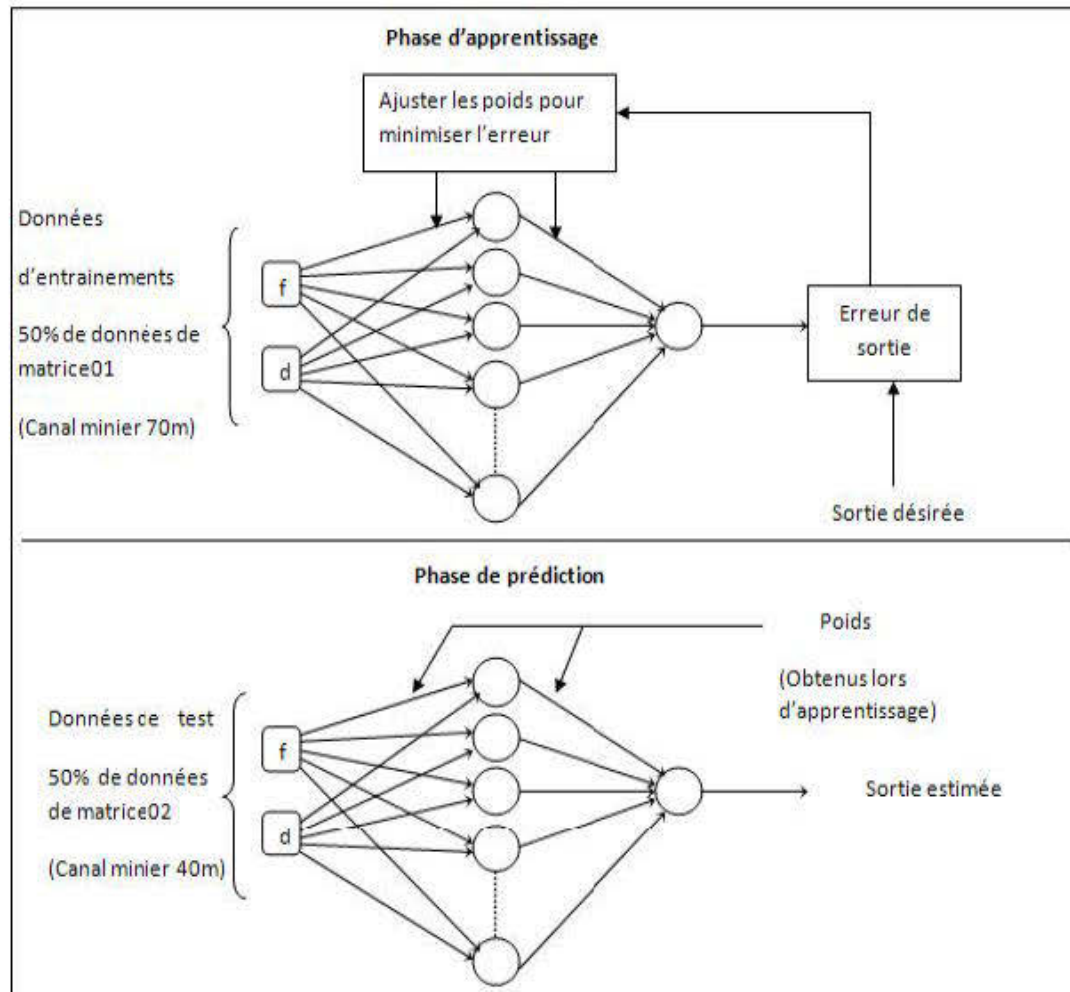


FIGURE 5. 14 — Identification des entrées d'apprentissage et de prédiction.

Afin de valider la performance de notre réseau pour un autre canal, nous avons utilisé 50 % de mesures de canal minier à 70 m pour l'entraînement de réseau et 50 % de mesures de canal minier à 40 m pour tester le réseau.

Nous avons obtenu les résultats illustrés dans la figure (4.15), avec une erreur quadratique moyenne égale à 6.7561dBm, nous remarquons que l'erreur quadratique est devenue plus grande, mais même si elle a augmentée, nous voyons d'après la figure que le réseau est encore capable de nous prédire correctement l'évolution de la puissance reçue en fonction la fréquence et de la distance.

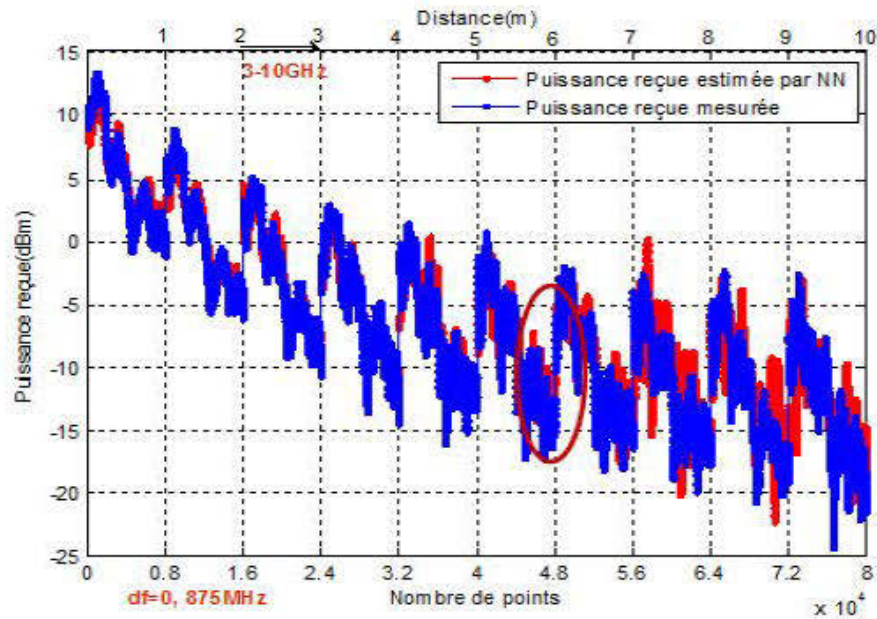


FIGURE 5. 15 — Puissance reçue en fonction de distance et fréquence du canal UWB minier à 40m sous terre.

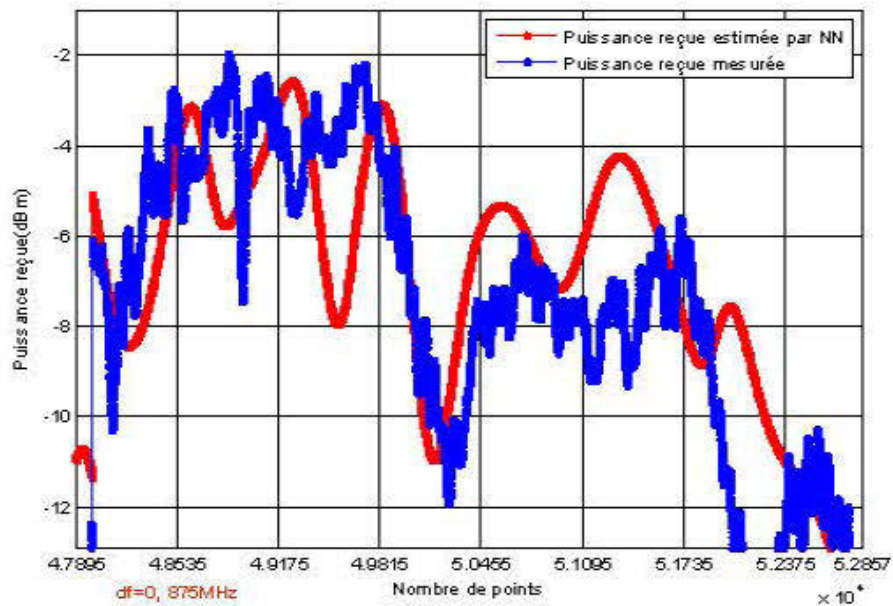


FIGURE 5. 16 — Un zoom de la partie marquée en rouge de la Figure (5. 15).

5.5 Conclusion

Dans ce chapitre, nous avons analysé les résultats obtenus. Au début, on a commencé par le cas d'espace libre qui est un cas idéal, on a trouvé que la puissance reçue estimée par le réseau de neurones est la même que la puissance calculée, ce résultat est très logique, car qu'il n'y a pas des obstacles, au contraire dans le cas réel de canal minier, il y a les obstacles et plusieurs mécanismes qu'a l'influence sur la propagation de signal. Ensuite, nous avons traité les résultats de canal minier UWB au niveau 70m sous terrains, on a entraîné le modèle neuronal par des pourcentages différents de mesures d'entrées et de sorties, par conséquent, on a trouvé que notre modèle est capable de prédire la variation de puissance reçue correctement avec une faible erreur quadratique moyenne. À la fin, nous avons évalué notre modèle dans un nouveau canal, au niveau 40m sous terrains, on a remarqué que le modèle est encore capable de prédire correctement la variation de puissance reçue avec une augmentation d'erreur quadratique moyenne.

Chapitre 6

Conclusion

6.1 Introduction :

Ce projet de maîtrise a été consacré à l'application des réseaux de neurones dans la modélisation de canal radio UWB minier, dans ce mémoire nous avons utilisé sur les mesures faites par le laboratoire LRTCS dans la mine CANMET de Val-d'Or.

Depuis la régulation de son spectre d'émission par l'autorité américaine FCC en 2002, l'intérêt de l'UWB a cessé de croître. Dans le milieu industriel et scientifique, cet engouement se manifeste par un débat intensif concernant la normalisation des systèmes UWB et par de nombreuses propositions pour la conception d'équipements performants. Par ses caractéristiques uniques, la technologie UWB peut utiliser dans le milieu minier pour atteindre plusieurs objectifs, comme la télésurveillance, la transmission vidéo avec une très haute vitesse et l'utilisation des téléphones cellulaires avec possibilité d'interconnexions directe entre les ouvriers de la mine et leurs centres d'exploitation. Pour le développement de tels systèmes de communication, le laboratoire LRTCS a lancé plusieurs travaux dans ce sens, notre travail sera un complément de ces recherches et un ajout d'une nouvelle méthode d'études.

Les réseaux de neurones sont déjà largement exploités dans plusieurs sujets de télécommunication, nous l'appliquons également ici à la modélisation de canal minier UWB. En effet, le point fort de réseaux de neurones qu'on peut découvrir la forme de la fonction qui lie les variables d'entrées aux variables de sorties à l'aide de mise à jour, des valeurs de ses poids à l'apprentissage, l'étude de canal UWB minier par les réseaux de neurones est plus difficile par rapport aux autres technologies de communication à cause de la largeur de bande passante qui varie de 3 GHz à 10 GHz.

Ce mémoire a été organisé de telle manière qu'il présente en premier le contexte et la motivation de notre recherche, puis le milieu de travail et la technologie UWB utilisée pour bien comprendre notre sujet. Avant de présenter la méthode de modélisation de canal radio que nous avons utilisé dans notre recherche, une connaissance du canal de propagation radio

est obligatoire, pour cette raison, le deuxième chapitre a été consacré à la caractérisation de canal de propagation radio, nous avons présenté en premier temps les différentes caractéristiques de canal, ensuite, les notions de base de modélisation. À la fin, nous avons présenté l'application pour un canal UWB minier.

Dans le chapitre 3, nous avons présenté les réseaux de neurones, au début on a commencé par l'historique et le fonctionnement. Puis, on a exposé les différents types de réseaux de neurones et les applications de ces derniers.

Le chapitre 4 a montré le modèle neuronal qu'on a élaboré pour la modélisation de canal minier UWB, dans ce stade nous avons détaillé au début la méthode de rétropropagation utilisée dans l'apprentissage, cette technique est se basé sur le calcul des dérivées de gradient qui peut être appliquée à n'importe qu'elle structure de fonctions dérivables. De telles façons l'erreur commise en sortie du réseau sera rétropropagée vers les couches cachées d'où le nom de rétropropagation. Ensuite, nous avons présenté les mesures qu'on a utilisées et les étapes qu'on a passées pour organiser ces mesures et déterminer les entrées de réseau. À la fin, nous avons montré l'algorithme de fonctionnement de modèle neuronal.

Nous analysons les résultats que nous avons obtenus dans le chapitre 5, nous avons présenté les résultats sur trois niveaux, tout d'abord on a commencé par l'état idéal d'un canal de propagation en espace libre, nous avons trouvé un excellent résultat. Ensuite, nous avons travaillé sur le canal minier UWB au niveau 70m sous terrain, dans ce cas, on a évalué le modèle neuronal par des différents pourcentages de mesures dans l'apprentissage et la prédiction, nous valorisons les résultats par la comparaison de l'erreur quadratique moyenne, ainsi on a trouvé des bons résultats avec une faible erreur quadratique moyenne. À la fin, nous avons évalué notre modèle neuronal par les mesures de canal minier UWB au niveau 40m sous terrain et on a trouvé que le modèle est capable de nous prédire la variation de la puissance reçue correctement.

On a publié un article sur les résultats de notre travail dans la conférence Vehicular Technology Conference(VTC Spring), 2012 IEEE, Yokohama. On présente une copie de l'article dans l'annexe.

6.2 Suggestion de travaux futurs

Nous avons basé notre travail sur la prédiction de la variation de puissance reçue à l'aide de l'amplitude de paramètre S_{21} , ainsi nous avons utilisé un perceptron multicouche. Nous proposons comme continuité de travail d'étudier d'autres paramètres de caractérisation de canal propagation radio à l'aide d'études des autres paramètres S et aussi, utiliser d'autres types des réseaux de neurones. En fin, il y a des travaux lancés dans laboratoire LRTCS pour étudier le canal 60 GHz par les méthodes classiques, on peut utiliser les réseaux de neurones pour modéliser ce canal.

Bibliographies

- [1] M. Boutin, A. Benzakour, C. Despins and S. Affes, “Radio wave characterization and modeling in underground mine tunnels”, IEEE Trans. on Antennas and Propag., vol. 56, n°2, pp. 540-549, Feb. 2008.
- [2] A. Chehri, P. Fortier, P. Tardif “Frequency Domain Analysis of UWB Channel Propagation in Underground Mines”, IEEE VTC'06-Fall, September 25-28, 2006, Montreal, Canada.
- [3] T. W. BARRETT, « History of ultrawideband (UWB) radar & communications : pioneers and innovators », in Progress in Electromagnetics Symposium, Cambridge, MA, USA, July 2000.
- [4] J. D. TAYLOR, Introduction to Ultra-Wideband Radar Systems, Boca Raton : CRC Press, 1995.
- [5] F.T CHOFFO-TALOM, B. UGUEN, E. PLOUHINEC, et al., « A sitespecific tool for UWB channel modeling », in IEEE International Workshop on Ultra Wideband Systems joint with Conference on Ultra Wideband Systems and Technologies, Kyoto, Japan, pages 61–65, May 2004.
- [6] FCC, « First report and order, revision of Part 15 of the Commission’s rules regarding ultra-wideband transmission systems », Document technique ET Docket 98-153, FCC, April 2002.
- [7] J. FOERSTER et Q. LI, « UWB channel modeling contribution from Intel », Document technique IEEE 802.15-02/287, IEEE P802.15 Working Group for Wireless Personal Area Networks (WPANs), July 2003.
- [8] L. YANG et G. B. GIANNAKIS, « Ultra-wideband communications : an idea whose time has come », IEEE Signal Processing Magazine, vol. 21, no 6, pages 26–54, november 2004.
- [9] D. PORCINO et W. HIRT, « Ultra-wideband radio technology : potential and challenges ahead », IEEE Communications Magazine, vol. 41, no 7, pages 66–74, July 2003.

- [10] J. D. PARSONS, *The Mobile Radio Propagation Channel*, Chichester, 2nd edition 2000.
- [11] P. Pagani, F. Tchoffo Talom, P. Pajusco, B. Uguen « Ultra-Wideband Radio propagation channels a practical approach », ISTE Ltd, John Wiley & Sons Inc., 2008, 352 p. ISBN 978-1848210844.
- [12] J. D. Parsons. *The Mobile Radio Propagation Channel*. John Wiley, 2000.
- [13] Inés Kammoun-Jemal, « Codage spatio-temporel sans connaissance à priori du canal ». Thèse à l'Ecole Nationale Supérieure des Télécommunications de Paris, France 2004.
- [14] P. A. Bello, “ Characterisation of Randomly Time Variant Linear Channels “, *IEEE Transactions in Communication and Systems*, vol. CS-11,no12, pages 360–393, dec 1963.
- [15] Tchoffo Talom F., *Modélisation déterministe du canal de propagation indoor dans un contexte UWB*, PhD Thesis, Institut National des Sciences Appliquées de Rennes, France, 2005.
- [16] S. Haykin, *Neural Networks: A Comprehensive Foundation*, New York: Macmillan College Publishing Company Inc, 1994.
- [17] J. M. Zurada, *Introduction to Artificial Neural Systems*, Boston: PWS Publishing Company, 1992.
- [18] L. Qiu , D. Jiang, and L. Hanlen, *Neural Network Prediction of Radio Propagation*, *Proceedings 6th Australian Communications Theory Workshop*, 2-4 February 2005, Brisbane, pp. 272-277. ISBN 0-7803-9007-5 (2005)
- [19] Ivan Vilovic, *An Approach to Propagation Modeling for Indoor WLAN Applications Using Neural Networks*, *IEEE*, 10.1109/ICCOM.2005.204929 . ISBN 953-6037-44-0.
- [20] M. Ibnkahla, J. Sombrin, F. Castanié, and N. J.Bershad, "Neural networks for modeling non linear memoryless channels", *IEEE Trans. on Communications*, Vol. 45, No. 7, pp. 768-771, July 1997.

- [21] Shehadi Dayekh, Sofiene Affes, Nahi Kandil, Chahé Nerguizian, «Radio-localization in underground narrow-vein mines using neural networks with in-built tracking and time diversity » WCNC 2011 :1788-1793
- [22] N. Kandil, V. K. Sood, and M. Saad, "Use of ANNs for Short-Term Load Forecasting", the Canadian Conference on Electrical and Computer Engineering, CCECE'99, May 1999, Edmonton, Alberta, Canada.
- [23] M. Isaksson, D. Wisell, and D. Rönnow, "Wideband dynamic modeling of power amplifiers using radial-basis function neural networks," IEEE Trans. Microwave Theory Tech., vol. 53, pp.3422-3428, 2005.
- [24] M. Ibnkahla, "Neural Network Modeling and Identification of Nonlinear Channels with Memory: Algorithms, Applications and Analytic Models", IEEE Trans. On Signal processing, vol 46, no. 5, pp.1208-1220, 1998.
- [25] T. Moazzeni, "A Wireless Propagation Channel Model with Meteorological Quantities Using Neural Networks", GCC Conference, 2006 IEEE. ISBN 978-0-7803-9590-9.
- [26] M. Ibnkahla, "Neural Network Modeling and Identification of Nonlinear MIMO Channels", IEEE, Signal Processing and Its Applications, 2007. ISSPA 2007. 9th International Symposium on, ISBN 978-1-4244-0778-1.
- [27] Meijuan Gao, Jingwen Tian, Shiru Zhou, "Modeling for Mobile Communication Fading Channel Based on Wavelet Neural Network", IEEE, Information and Automation, 2008. ICIA 2008. International Conference, ISBN 978-1-4244-2183-1.
- [28] B.Nkakanou, N.Hakem, G.Y.Delisle, "Experimental Evaluation of the Ultra-Wideband Propagation Channel in an Underground Mine", Antennas and Propagation Society International Symposium (APS/URSI), Jul 2011, pp. 2781-2784, 2011.
- [29] J. C. Principe, N. R. Euliano, W. C. Lefebvre, «Neural and Adaptive Systems: Fundamentals through Simulations», Wiley, 2000.
- [30] Howard Demuth, and Mark Beale, Neural networks Toolbox for use with MATLAB, 2004.

Neural networks model of an UWB channel path loss in a mine environment

M. Kalakh, N. Kandil, *Member, IEEE*, and N. Hakem, *Member, IEEE*

Abstract— this paper aims to present an UWB propagation channel modeling with neural networks in a mine environment, focusing on the change in the path loss attenuation as a function of distance and frequency.

A trained neural network can be used for high-level design, providing fast and accurate answers to the task it has learned. Neural networks are effective alternatives methods to conventional methods such as statistical and stochastic modeling methods, which could be computationally expensive, or to analytical methods which could be difficult to obtain for new environments, or to empirical modeling solutions which range and accuracy may be limited.

Index Terms—ultra-wide-band (UWB); neural networks (NN); modeling an UWB channel; underground mine environment; multi-layer perceptron (MLP).

I. INTRODUCTION

Prediction of the propagation channel model in a Mine Environment with an ultra-Wideband technology is known to be a difficult problem, due to diffractions, reflections and scatterings of radio signal.

Ultra-wideband technology offers many advantages, mainly, the high-speed data transmissions, the short duration pulse, and the low power communication compared to wideband wireless systems. A modern exploitation of mineral resources, particularly in an underground mine, requires remote control and high speed audio/video data transmission be available. To achieve these objectives, the characterizations of the UWB channel are conducted in a typical underground environment [11].

Numerous wideband propagation measurements in an underground mine were taken by researchers of the Underground Communications Research Laboratory (LRCS) as a part of a collaborative research effort, in CANMET, (Canadian Center for Minerals and Energy Technology), experimental mine in Val d’Or, Canada.

We apply a neural network learning algorithm to predict the received power of a radio signal as a function of distance d and frequency f based on UWB measurements in a mine.

A neural network (NN) is a natural choice for modeling linear and nonlinear dynamic systems, since it can approximate any continuous function arbitrarily well [5].

Many works on neural networks have been published in the literature. NN have, hence, been used for modeling communication system [6] like satellite channels [7] or

localization in mines [2]. Also they have been used for modeling UWB channels [4]. But there are no publications for the modeling of an UWB channel in a mine environment using neural networks.

Consequently, it is important to present a work which studies the propagation channel measurements in an underground environment applying neural networks, since it presents a new application in such environment.

The remainder of this paper is arranged as follows: in section II we present the UWB channel modeling. In section III we present a description of the underground mine environment and measurements done in this environment. The neural network learning algorithm is discussed in section IV. In Section V we show results. The last section is devoted to the conclusion and to the discussion of future work.

II. UWB CHANNEL MODELING

The ultimate performance limits of any communication system are determined by the channel it operates in. For an UWB system, this is the UWB propagation channel, which differs from conventional (narrowband) propagation in many aspects. The performance of a system thus can only be evaluated when realistic channel models are available. For any channel model, we must make a trade-off between the prediction reliability with computation expense, as with the measurement resolution. In our case, we are limited to signal envelope measurements.

The simplest UWB channel model is the stochastic delay line model given by:

$$h(t, \tau) = \sum_{l=1}^L a_l(t) \delta(t - \tau_l(t)) \quad (1)$$

$h(t, \tau)$ is the channel impulse response at time t , δ is the Dirac function, L is the number of multipath components, a_l and τ_l are the fading amplitude and the time of arrival of the l path [11].

III. MINE ENVIRONNEMENT

The measurements are performed in various galleries in an old gold mine at a level of 70 meters underground. The environment consists mainly of very rough walls and non flat floor containing puddles. The size of the corridors of the mine varies between 2.5 m and 3 m wide and about 3 m high. Measurements were taken in both line of sight (LOS) and non line of sight (NLOS) scenarios. Fig 1 shows the photograph of the underground tunnel.

The CANMET gallery at 40 m depth, in which the previous wideband measurements were performed, was quite different than the one at 70 m depth, as it was characterized by a width and height of both approximately 5 m [8].



Fig.1 Photograph of the underground gallery.

The UWB measurements were performed in frequency domain using the frequency channel sounding technique based on the module of the S21 scattering parameter obtained by a vector network analyzer.

In fact, the system measurement setup consists of E8363B network analyzer (PNA) and two different kinds of antennas, with directional and unidirectional radiation patterns, respectively. There are no amplifiers used during the measurements because the distance between the transmitter and the receiver was just 10 meters. The transmitting port of the PNA swept 16001 discrete frequencies ranging from 3 GHz to 10 GHz uniformly distributed over the bandwidth, and the receiving port measured the magnitude and the phase of each frequency component. (In our work we were limited to the magnitude)[12].

IV. NEURAL NETWORKS

A. Model description

Neural networks (NN) are composed of simple elements operating in parallel. These elements are inspired by biological nervous systems. As in nature, the connections between elements largely determine the network function. You can train a neural network to perform a particular function by adjusting the values of the connections (weights) between elements. Typically, neural networks are adjusted, or trained, so that a particular input leads to a specific target output. The next figure illustrates such situation. There, the network is adjusted, based on a comparison of the output and the target, until the network output matches the target. Typically, many such input/target pairs are needed to train a network. NN have been trained to perform complex functions in various fields, including pattern recognition, identification, classification, speech, vision, and control systems. NN can also be trained to

solve problems that are difficult for conventional computers or human beings [10].




Fig. 2 Operation of the neural network

Neural networks can learn from the given cases and summarize the internal principles of data even without knowing the potential data principles ahead. And it can adapt its own behavior to the new environment.

There is no good way to determine the number of hidden layers of neural network and the number of hidden nodes in each layer currently. In order to overcome the problem, we determine the hidden layers and nodes in each hidden layer by training the system. Through the operation of neural network, we select a neural network model with smaller average error [9].

The most important work in building a NN power forecasting model is the selection of input variables. There is no general rule that can be followed in this process. It depends on engineering judgment and experience and is carried out almost entirely by trial and error [3].

Our network is multi-layer perceptron (MLP) type feed forward architecture. It is based on a supervised training using the method of back propagation. We use hyperbolic tangent sigmoid function (Tansig) in the hidden layers and linear function (Purline) in the output layer.

At the beginning we started with a perceptron of three layers, two hidden layers and one output layer, we varied the number of neurons per layer to improve performance and that by using several ways: one of them is by reducing the number of layers in the network since an architecture with multiple hidden layers will increase the precision of estimates. However, the number of connections will be higher and the learning curve will be slower. One problem we encountered is showing the realism of our model and identifying its inputs because in the case of UWB, the received power varies with frequency and distance and in our study we set to work a very large number of measures which must be arranged to be used by the network. We went through several experiments and models to identify realistic entries. Then we tried learning with a single hidden layer (figure 3) with different number of neurons. We found that with a number of neurons equal to eighty the mean square error (MSE) obtained is the lowest.

In this system, we use a neural network model that consists of an input layer which contains two inputs, frequency f and distance d , a single hidden layer of 80 neurons and an output which is the path loss attenuation (L) in the output layer. The

changing of the learning rate used in the phase of training is related to the number of training data (input data).




Fig.3. NN with two input nodes, 80 hidden nodes, and one output node, the two input nodes correspond to frequency and distance. The Output node corresponds to the Power. W presents weights.

B. Operating Model

When training, we present the neural network a set of similar data. We train the model by performing a sufficient number of experiments to verify the validity of results and the model. During the prediction phase, we test the model by estimating its accuracy to predict correctly the values of the received power. If the accuracy is acceptable then we can use the model, else we have to repeat the cycle of the model construction. Finally for a new environment, presenting other data without knowing a priori the relation linking the inputs to the outputs, this model can be used

V. RESULTS

A. UWB channel modeling in a mine at 70m depth

The objective of this part is to find the most accurate NN parameters and evaluate mismatching between measurements and NN model.

1) Training the network with 50% of measures and testing with 50% of measures:

In this step we use the half of measures to train the network and half to test. We obtain the results shown in Fig.4 with MSE equal to 1.0359 dB. This error can be considered a very low error.

As it shown, the blue curve shows path loss attenuation measured in terms of distance and frequency, such that for each distance the frequency varies from 3 to 10 GHz with a step of 0.875MHz where the red curve showing NN model path loss is fully under blue one which shows a perfect fitting. Fig.5 shows a zoom in of red circle on Fig.4 and red curve path loss. Therefore, we conclude that our model is able to correctly predict path loss as a function of frequency and distance.




Fig.4: Path loss as a function of distance and frequency with 50% measurement for training process




Fig.5: Zooming of red circle in Fig.4

2) Training the network with 10% of measures and testing with 50% of measures:

In this part we reduce the number of training process input to 10% of measures, then as it shown in the fig.6, we get a result of 1.0445dB MSE error, which is as small as previous result with 50% training process.




Fig. 6 Path loss as a function of distance and frequency with 10% measurement for training process




Fig.7: Zooming of red circle in fig.6

Although we reduced the measurements used for training process in our model, this latter is able to accurately estimate the change in power as a function of frequency and distance.

3) Training the network with 1% of measures and testing with 50% of measures:

In the same way to previous subsection, the measurements used in training process are reduced to 1% and results are plotted in Fig.8 and Fig.9. The obtained MSE error is slightly small than 4 dB.




Fig.8: Path loss as a function of distance and frequency with 1% measurement for training process




Fig.9: Zooming of red circle in Fig.8

Although the training process uses only 1% of the measurements, the accuracy of NN path loss model is reduced but, it remains very moderate and the model predict correctly path loss as a function of frequency and distance.

4) Training the network with 10% of measures and testing with 1% of measures:

In opposite way, we increase the number of measurements in training process and reduce them in testing one.

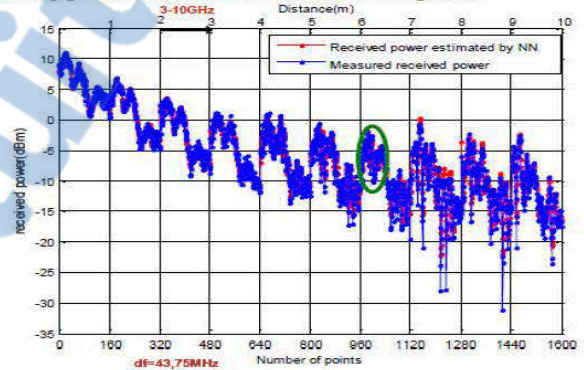


Fig.10: Path loss as a function of distance and frequency with 10% measurement for training process and 1% for testing process

Fig.10. and the corresponding zoom in Fig.11 show path loss attenuations as function of the frequency and distance with a 1.12 dB MSE fitting error. We can note that the results are clearer because the measurements used for testing process are lower compared to the previous subsections.

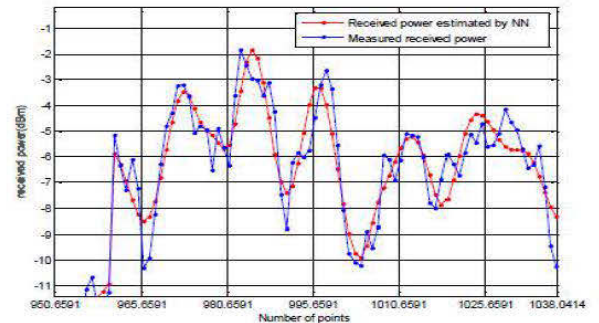


Fig.11: Zooming of green circle in Fig.10

B. Evaluation of NN model in other mine gallery

After showing the performance of our neural network in modeling path loss attenuation in a mine tunnel at 70m depth, we evaluate fitting of our model with experimental measurement coming from another tunnel located at 40 m of depth in the same mine environment.

The fitting results are plotted in the Fig.12. The MSE error is 6.7561dB, this latter has increased but even so, we can see in the Fig.13 that the model is still able to correctly predict the

evolution of the path loss attenuations as function of frequency and distance. Therefore, use of one tunnel measurement to predict the path loss behavior of another tunnel in the same mine is viable with a less accuracy, about 6 dB in our scenario.




Fig.12: Path loss as a function of distance and frequency with measurement coming from tunnel 40m depth




Fig.13: Zoom of green circle in fig.12

VI. CONCLUSION

The neural networks allow the modeling of complex problems in various fields. Unlike statistical models, the NN can discover the form of the function linking the input variables to output variables to support the update of the values of its weights to learn. During our work we are interested precisely by the variation in path loss attenuation of UWB signal in underground harsh mine environment as a function of distance and frequency. However, the frequency varies between 3GHz and 10 GHz, and the distance varies from 1 to 10 meters. We build a NN model using multilayer perceptron based on the method of backpropagation for learning network. Indeed, the most important phase in building a neural model is to determine the inputs and outputs of the network. Then, by comparing the results obtained by the neural model and the experimental measured values, we note that our model is able to correctly predict the variation of path loss attenuation in a UWB channel in a mine environment for

two different galleries and give an acceptable accuracy with very few experimental measurements. Therefore, we show in this work that neural network is a feasible solution for the channel modeling in a mine considered as harsh environment. Finally our work can be considered as the beginning of other work that can be run in this area, for example we can work on other parameters of the UWB channel, and we can also choose other types of neural networks for modeling.

REFERENCES

- [1] L Qiu, D Jiang, and L Hanlen, "Neural Network Prediction of Radio Propagation," Proceedings 6th Australian Communications Theory Workshop, 2-4 February 2005, Brisbane, pp. 272-277. ISBN 0-7803-9007-5, 2005.
- [2] Anthony Taok, Nahi Kandil, Sofiene Affes, "Neural Networks for Fingerprinting-Based Indoor Localization Using Ultra-Wideband," JCM 4(4): 267-275, 2009.
- [3] N. Kandil, V.K. Sood, and M. Saad, "Use of ANNs for Short-Term Load Forecasting," the Canadian Conference on Electrical and Computer Engineering, CCECE'99, Edmonton, Alberta, Canada, Mai 1999.
- [4] M. Isaksson, D. Wisell, and D. Rönnow, "Wideband dynamic modeling of power amplifiers using radial-basis function neural networks," IEEE Trans. Microwave Theory Tech., vol. 53, pp.3422-3428, 2005.
- [5] M. Ibnkahla, "Neural Network Modeling and Identification of Nonlinear Channels with Memory: Algorithms, Applications and Analytic Models," IEEE Trans. On Signal processing, vol 46, no. 5, pp.1208-1220, 1998.
- [6] S. Haykin, Neural Networks, 2nd ed. Upper Saddle River, NJ: Prentice-Hall, 1999.
- [7] M. Ibnkahla, "Applications of neural networks to digital communications—A survey," J. Signal Process., vol. 80, pp. 1185-1215, 2000.
- [8] M. Boutin, A. Benzakour, Charles L. Despins, and S. Affes, "Radio Wave Characterization and Modeling in Underground Mine Tunnels," IEEE transaction on antennas and propagation, Vol.56, No. 2, February 2008.
- [9] T. Guo, Gui-Yang Li, "NEURAL DATA MINING FOR CREDIT CARD FRAUD DETECTION," Machine Learning and Cybernetics, 2008 International Conference on, pp. 3630 - 3634, 2008.
- [10] Howard Demuth, and Mark Beale, Neural networks Toolbox for use with MATLAB, 2004.
- [11] A. Chehri, P. Fortier, P. -M Tardif "Frequency Domain Analysis of UWB Channel Propagation in Underground Mines," IEEE VTC'06-fall, September 25-28, 2006, Montreal, Canada.
- [12] B. Nkakanou, N. Hakem, G. Y. Delisle, "Experimental Evaluation of the Ultra-Wideband Propagation Channel in an Underground Mine," Antennas and Propagation Society International Symposium (APS/URSD), Jul 2011, pp. 2781-2784, 2011.