

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
Ministère de l'enseignement supérieur et de la recherche scientifique

Université Constantine 1

Faculté des sciences de la technologie

N° d'ordre : Département d'électronique
Série :

Thèse
de Doctorat en sciences en Electronique
Option : Micro-ondes

Présentée Par:

Karima CHEMACHEMA

Thème

**ÉTUDE DES STRUCTURES MICROBANDES PAR
LA TECHNIQUE DES RESEAUX DE NEURONES
APPLICATION A DIFFÉRENTES EXCITATIONS**

Devant le jury:

Président:	Mr M. L. RIABI	Professeur	Université de Constantine
Rapporteur :	Mr A. BENGHALIA	Professeur	Université de Constantine
Examineurs:	Mr D. BENATIA	Professeur	Université de Batna
	Mr R. MAHAMDI	Professeur	Université de Batna
	Mr A. CHAABI	Professeur	Université de Constantine

Soutenance prévue pour Juin 2013

REMERCIEMENTS

- J'adresse mes remerciements en premier lieu, à *Dieu* tout puissant pour la volonté, la santé, le courage et surtout la patience qui m'a donné pour mener ce travail à terme.
- J'exprime toute ma gratitude à Monsieur *Abdelmadjid Benghalia* Professeur à l'université de Constantine pour m'avoir accueilli dans son laboratoire et pour avoir assuré la direction de cette thèse avec une grande compétence, pour ces conseils et son aide précieuse et efficace, et pour tout l'intérêt qu'il porte à la recherche scientifique, je tiens à lui exprimer tous mes respects.
- Je remercie très sincèrement, monsieur le Professeur *M. RIABI*, de l'université de Constantine, de m'avoir fait l'honneur d'accepter de présider le jury de cette thèse.
- Je remercie également monsieur le Professeur *D. BENATIA*, de l'université de Batna, monsieur le Professeur *R.MAHAMDI*, de l'université de Batna et monsieur le Professeur *A. CHAABI*, de l'université de Constantine, pour m'avoir fait l'honneur de faire part du jury de ce travail.

RÉSUMÉ

Dans ce travail une modélisation par les réseaux de neurones est proposée pour analyser trois structures microbandes à différentes excitations à partir d'un ensemble de données obtenues par deux méthodes différentes : cavité modifiée et méthode de la ligne de transmission.

L'impédance d'entrée d'une antenne rectangulaire imprimée sur un substrat isotrope avec ou sans gap d'air est calculée à partir des pertes par rayonnement, par conduction et par diélectrique. Le réseau MLP est choisi comme modèle neuronale et le calcul de l'impédance d'entrée est fait par l'application de dix algorithmes d'optimisation. Une comparaison faite entre ces algorithmes montre que l'algorithme Levenberg-Marquardt est le plus performant avec une bonne précision. Nous avons également montré l'efficacité de la modélisation neuronale inversée dans la détermination des paramètres géométriques du patch d'une antenne microruban à gap d'air pour une fréquence prédéfinie.

L'impédance d'entrée et le coefficient de réflexion d'une antenne microbande rectangulaire couplée par fente sont calculés en appliquant le perceptron multicouche. L'influence des différents paramètres d'une structure alimentée par couplage par ouverture a été détaillée. Les résultats obtenus sont comparés à ceux de la littérature.

Le modèle neuronal adopté dans notre propre démarche de modélisation (RBF, GRNN) est exposé ainsi que la base d'apprentissage qui est élaborée à partir des résultats fournis par la méthode TLM sur l'antenne microbande rectangulaire couplée par proximité. Une comparaison entre les modèles neuronaux MLP, RBF et GRNN montre que le RBF est caractérisé par son efficacité et sa performance au niveau de la vitesse de convergence.

La validation des résultats de simulation des modèles est faite sur le logiciel Simulink™ sous Matlab®, permettant de simuler le comportement du système dans le temps. La très bonne concordance entre les valeurs RNA de l'impédance d'entrée et celles calculées (TLM et cavité) confirme la validité du modèle neuronal.

Mots clés : Antenne microruban, méthode de la cavité, méthode TLM, réseaux de neurones MLP, les réseaux RBF.

ABSTRACT

● In this work a representative approach of the networks type of neurons is proposed to model three structures microbandes with various excitations starting from a unit of data obtained by two different methods: modified cavity and transmission line.

The input impedance of a rectangular microstrip antenna on an isotropic substrate with or without air gap is calculated starting from the losses by radiation, by conduction and by dielectric. Network MLP is selected like model neuronal and the calculation of the input impedance is made by the application of ten algorithms of optimization. A comparison made between these algorithms shows that the Levenberg-Marquardt algorithm is most powerful with a good precision. We also showed the effectiveness of the reversed neuronal modeling in the determination of the geometrical parameters of the microstrip antenna with air gap for a frequency predefined.

The input impedance and the reflection coefficient of an aperture coupled rectangular microstrip antenna are calculated by applying the multilayer perceptron. The influence of various parameters of a structure supplied with coupling and by opening was detailed. The results obtained are compared with those of the literature.

The neuronal model adopted in our own approach of modeling (RBF, GRNN) is exposed as well as the base of training which is elaborate starting from the results provided by TLM method on the rectangular antenna microbande coupled by proximity. A comparison between neuronal models MLP, RBF and GRNN shows that the RBF is characterized by its effectiveness and its performance on the speed level of convergence.

The validation of the simulation results of the models is made on the Simulink™ in Matlab®, which permits to simulate the behavior of the system in time. The very good agreement between neural network values of the input impedance and those calculated (TLM and cavity) confirms the validity of the neuronal model.

Key words: microstrip antenna, cavity method, TLM method, MLP neural networks, RBF networks.

ملخص

في هذا العمل تم تقديم اقتراح من نوع الشبكة العصبية لنمذجة ثلاث هوائيات دقيقة ذات تغذيات مختلفة التي تم الحصول عليها من طرق مختلفة : طريقة التجويف المعدلة وطريقة خط الانتقال.

تم حساب ممانعة الدخول لهوائي دقيق مستطيل بفجوة الهواء و بدونها عن طريق الفقدان في التوصيل والإشعاع والعازل. تم اختيار شبكة MLP كنموذج للشبكة العصبية وتم حساب ممانعة الدخول من تطبيق عشرة خوارزميات التحسين. المقارنة بين هذه الخوارزميات دلت على أن خوارزمية Levenberg-Marquardth هو الأكثر كفاءة مع دقة جيدة. أظهرنا أيضا فعالية النمذجة العكسية في الخلايا العصبية في تحديد الخصائص الهندسية للهوائي بفجوة الهواء لتردد معلوم مسبقا.

وقمنا بحساب ممانعة الدخول ومعامل انعكاس لهوائي ذو فتحة مستطيلة باستخدام العصبون متعدد الطبقات. ودرسنا تأثير العوامل المختلفة على هذا الهوائي. تمت مقارنة النتائج المتحصل عليها مع تلك الموجودة في المراجع.

نتعرض في هذا العمل أيضا للنموذج العصبي (RBF ، GRNN) المعتمد على النتائج المقدمة من طريقة TLM لهوائي دقيق مستطيل الذي غدي بطريقة الارتباط الكهرومغناطيسي . مقارنة بين النماذج العصبية MLP ، RBF و GRNN تبين أن RBF يتميز بالكفاءة من حيث السرعة والفعالية. المصادقة على النتائج تمت باستعمال برنامج SimulinkTM®. توافق جيد جدا بين قيم ممانعة الدخول المحسوبة بواسطة RNA وتلك المحسوبة (TLM والتجويف) يؤكد صحة النموذج العصبي.

الكلمات المفتاح: الهوائيات الدقيقة، طريقة التجويف ، طريقة خط الانتقال، الشبكة العصبية MLP، الشبكة العصبية RBF.

SOMMAIRE

INTRODUCTION GNERALE.....	5
---------------------------	---

CHAPITRE I :

Généralités sur les antennes microbandes

I.1 Introduction.....	10
I.2 Types d'antennes.....	10
I.2.1. Antennes filaires	10
I.2.2 Antennes à ouverture	11
I.2.3 Antennes réflecteur	12
I.2.4 Antennes à lentille	12
I.2.5 Antennes imprimées	13
I.2.6 Antenne PIFA (Planar Inverted F Antenna).....	13
I.2.7 Antenne fil-plaque monopolaire	14
I.2.8 Choix des antennes à étudier.....	15
I.3 Description de l'antenne microbande.....	15
I.3.1 Substrats.....	15
I.3.2 Techniques d'alimentation.....	16
a. Alimentation avec la ligne microruban	17
b. Alimentation par câble coaxiale.....	17
c. Alimentation couplée par ouverture	18
d. Alimentation couplée par proximité.....	19
I.3.3 Rayonnement.....	20
I.3.4 La mise en réseau d'antennes imprimées.....	21
I.4 Choix de la technologie des antennes microbandes.....	22
I.5 Conclusion	23
I.6 Références.....	23

CHAPITRE II :

Modélisation d'une antenne microbande avec gap d'air par cavité/RNA

II.1 Introduction.....	26
II.2 Modèle de la cavité (Wolff) d'une antenne avec gap d'air.....	26
II.3 Mise en œuvre d'une méthode neuronale.....	31
II.3.1 Principe de la méthode neuronale.....	31
II.3.2 Architectures de réseau.....	31
II.3.3 Perceptron multicouche.....	32
II.3.4 Apprentissage d'un réseau.....	33
II.4 Modélisation par RNA d'une antenne microbande sans gap d'air.....	36
II.5 Modélisation de l'impédance d'entrée de l'antenne avec gap d'air par RNA.....	40
II.6 Etude comparative	42
II.7 Modélisation des paramètres physiques de l'antenne sans gap d'air par RNA	46
II.8 Conclusion	51
II. 9 Références	51

CHAPITRE III :

Modélisation d'une antenne microbande couplée à une fente par TLM/RNA

III.1 Introduction.....	55
III.2 Application du modèle de la ligne de transmission sur l'antenne rectangulaire patch couplée à une fente	55
III.2.1 Description de l'antenne rectangulaire microbande couplée à une fente.....	55

III.2.2 Le modèle de la ligne de transmission d'une antenne microbande couplée à une fente.....	56
a. Modélisation de la plaque conductrice microbande.....	58
b. Modélisation de la fente dans le plan de masse et calcul de l'impédance d'entrée globale (Z_{in}).....	59
III.3 Modélisation neuronale de l'antenne couplée par une fente rectangulaire	60
III.3.1 Le modèle neuronale de l'impédance d'entrée.....	61
III.3.2 Influence des différents paramètres de la structure alimentée par fente Rectangulaire.....	63
III.4 Le modèle du coeficient de réflexion	72
III.5 Conclusion.....	75
III.6 Références.....	75

CHAPITRE IV :

Modélisation d'une antenne microbande couplée par proximité par TLM/RBF

IV.1 Introduction.....	79
IV.2 Modélisation d'une antenne alimentée (couplée) par proximité par la méthode de la ligne transmission (TLM) amélioré.....	79
IV.2.1 Description de l'antenne couplée par proximité.....	79
IV.2.2 Calcul de l'impédance d'entrée d'une antenne couplée par proximité	80
IV.3 Modélisation neuronale de l'antenne microbande rectangulaire couplée par proximité.....	86
IV.3.1 Définition d'un réseau RBF.....	86
IV.3.2 Apprentissage par RBF.....	88
IV.3.3 Modélisation de l'impédance d'entrée de l'antenne couplée par proximité par RBF	89

a. Influence du paramètre spread.....	91
b. L'effet de la distance de chevauchement L_2 de la ligne d'alimentation au patch...	93
c. L'effet de la largeur de la ligne d'alimentation W_f	94
IV.4 Comparaison des deux méthodes MLP et RBF.....	96
IV.5 Modélisation du coefficient de réflexion par réseaux de neurones GRNN.....	97
IV.5.1 Définition du réseau GRNN.....	97
IV.5.2 Application du réseau GRNN	98
IV. 6 Conclusion.....	100
IV.7 Références.....	101
CONCLUSION GENERALE	105
Annexe A	108
Annexe B	115

INTRODUCTION GENERALE

Dans un système de communication, les antennes sont des composants à part entière nécessitant une étude particulière. Tout en cherchant à améliorer les performances d'une antenne, on doit l'adapter aux applications les plus récentes. L'antenne doit également répondre aux contraintes de multiplication de bandes de fréquences et d'intégration dans l'architecture des terminaux. Enfin, les caractéristiques des antennes doivent être peu influençables par l'environnement. Compte tenu de la diversité des buts recherchés par les utilisateurs, on ne trouvera pas une méthode générale de synthèse applicable à tous les cas, mais plutôt un nombre important de méthodes propres à chaque type de problème. Cette diversité de solutions peut être exploitée pour constituer une base de données utile pour une approche générale de synthèse d'une antenne.

Dans ce domaine, des méthodes empiriques, analytiques et d'optimisation ont été utilisées pour étudier les antennes microbandes. Parmi les méthodes analytiques, on cite la méthode de la ligne de transmission, la méthode de la cavité, la méthode des éléments finis, la méthode des moments, etc. Pour les méthodes d'optimisation il existe les algorithmes génétiques et les réseaux de neurones.

Les réseaux de neurones artificiels (RNA) ont été le choix le plus populaire dans le domaine d'électronique pendant les deux dernières décennies. Ceci est peut être dû aux avancées faites dans les algorithmes d'apprentissages des RNA dans les années 80 leur donnant un niveau de classification comparable à ceux des approches déjà existantes et avec un temps de calcul nettement plus court [1]. Plusieurs architectures des RNA ont été employées, les plus utilisées sont le perceptron multicouche [2], les réseaux à fonction radiale [3], les cartes auto-organisatrices de Kohonen (SOM) [4], les réseaux de Hopfield [5] et les réseaux ART [6].

Le présent travail porte sur l'étude de trois antennes microbandes ayant des excitations différentes par deux méthodes : analytiques (cavité modifié et TLM) et d'optimisation RNA. Pour l'antenne microbande rectangulaire avec gap d'air nous calculons la fréquence de résonance et l'impédance d'entrée [7], [8] par le perceptron MLP avec différents algorithmes d'apprentissage.

La combinaison de modélisation rapide la méthode de la ligne de transmission (TLM) avec les réseaux de neurones est proposée pour la détermination de l'impédance d'entrée et le coefficient de réflexion des antennes: antenne couplée par fente et antenne couplée par proximité. Le choix des RNA réside dans le fait que ce sont des modèles comportementaux intéressants et dont les propriétés en font des approximateurs universels et parcimonieux. Dans cette approche, la modélisation par TLM sert à créer les bases de données nécessaires aux RNA. Le réseau neuronal comme technique rapide et meilleure en se basant sur *Neural Network Matlab Toolbox* est utilisé dans ce travail pour la détermination d'impédance d'entrée de l'antenne microbande.

Ce manuscrit de thèse est constitué de quatre chapitres, d'une conclusion générale et de deux annexes. Il est présenté comme suit:

Le premier chapitre donne une vue générale sur différents types d'antennes, ainsi qu'une description des antennes microbandes et les techniques d'alimentation.

Dans **le deuxième chapitre** nous déterminons la fréquence de résonance et l'impédance d'entrée d'une antenne microbande avec ou sans gap d'air utilisant la méthode de la cavité modifiée (Wolff) [8]. Nous décrivons alors les concepts fondamentaux et les notions liées aux réseaux neuronaux : (architectures de réseau, perceptrons multicouches, apprentissage d'un réseau). Pour réaliser une telle interpolation non-linéaire, un réseau de neurones multicouche est nécessaire, donc nous proposons d'utiliser les réseaux neuronaux pour évaluer l'impédance d'entrée à partir des valeurs connues calculées par la méthode de Wolff. Enfin, l'utilisation de la modélisation neuronale inversée est utilisée pour la détermination de la largeur, la longueur et l'épaisseur d'une antenne microbande rectangulaire avec ou sans gap d'air pour une fréquence de résonance donnée.

Dans **le troisième chapitre** nous calculons l'impédance d'entrée et le coefficient de réflexion d'une antenne microbande rectangulaire couplée par fente en utilisant la méthode de

la ligne de transmission [9]. Un modèle neuronal est élaboré permettant d'estimer l'impédance d'entrée et le coefficient de réflexion de cette antenne. Nous appliquons les étapes de conception de réseaux de neurones décrits à savoir l'élaboration des bases d'apprentissage et de test et le choix de la structure neuronale à utiliser pour obtenir de bonnes prédictions. La dernière partie est réservée aux résultats obtenus en vue de la validation du modèle développé.

Le dernier chapitre est réservé à l'application de la ligne de transmission améliorée [10] sur un autre type d'antenne qui est l'antenne microbande rectangulaire couplée par proximité à une ligne microruban. Nous définissons le réseau de neurones à fonction radial de base RBF, par sa simplicité et son usage dans l'approximation des fonctions et la capacité de résoudre des équations non- linéaires. Deux programmes ont été élaborés pour simuler le réseau neural RBF et la méthode de la ligne de transmission améliorée. Malgré l'absence de relations qui nous aident à créer un réseau optimal, nous avons pu choisir les paramètres du réseau de neurones (nombre des couches cachées, nombre de neurones dans chaque couche, ...) convenablement pour que notre réseau ait une performance acceptable. Les effets de la distance de chevauchement L_2 et la largeur de la ligne d'alimentation W_f sur l'impédance d'entrée sont étudiés aussi dans ce travail. Nous avons utilisé le réseau de neurones GRNN [11] qui permet de déterminer le coefficient de réflexion et de donner de meilleures précisions.

Les études comparatives des résultats obtenus à ceux donnés par d'autres auteurs, ont permis la validation de nos résultats.

Références bibliographiques :

[1] M.L. Minsky, S.A. Papert, *Perceptrons*, Cambridge, MIT Press, 1969.

[2] J. Moody, C. J. Darken, "*Fast learning in networks of locally-tuned processing units*," Neural Computation, 281–294, 1989.

- [3] T. Kohonen, "*Self-organized formation of topological correct feature maps*," Biological Cybernetics, 59–69, 1982.
- [4] J. J. Hopfield, "*Neural networks and physical systems with emergent collective computational abilities*," Proc. Nat. Acad. Sci., 2554–2558, 1982.
- [5] G. A. Carpenter, S. Grossberg, "*Art2: Self-organization of stable category recognition codes for analog input patterns*," Appl. Opt., 4919, 1987.
- [6] G.A. Carpenter, S. Grossberg, "*The ART of adaptive pattern recognition by a self-organizing neural network*," Computer, 77–88, 1988.
- [7] F. Abboud, J.P. Damiano, A. Papierink, "*Simple model for the input impedance of coax-fed rectangular microstrip patch antenna for C.A.D.*," Proc.IEE, 135, pp.323-326, 1988.
- [8] I. Wolff, N. Knoppik, "*Rectangular and circular microstrip disk capacitors and resonators*," *IEEE Trans*, MIT-22, pp.857-864, 1974.
- [9] C. BALANIS "*Antenna theory – Analysis and synthesis*," John Wiley & Sons, INC., 1997.
- [10] B. Belentepe, "*Modeling and design of electromagnetically coupled microstrip-patch antennas and antenna arrays*," IEEE Antennas Propag. Mag. 37, (1), pp. 31–39, 1995.
- [11] R. Battiti, A. Villani, T. L. Nhat, "*Neural Network Models for Intelligent Networks: Deriving the Location from Signal Patterns*," Autonomous Intelligent Networks and Systems, UCLA, Los Angelos, May 2002.

CHAPITRE I

GENERALITES SUR LES ANTENNES

MICROBANDES

1.1 Introduction

Les antennes microbandes sont de plus en plus utilisées dans des applications sans fil, ceci est dû à leur structure miniaturisée. Donc elles sont extrêmement compatibles pour les incorporer dans les dispositifs sans fil portatifs tels que les téléphones cellulaires ... etc. Pour l'utilisation des antennes microbandes dans la télémétrie et sur les missiles, elles doivent être très minces et conformes. Un autre secteur où elles ont été employées avec succès est la communication par satellite.

Ce chapitre résume un comparatif de différentes antennes : antennes filaires, antennes à ouverture, antennes réflecteurs, antennes à lentille, antennes imprimées, antenne PIFA (Planar Inverted F Antenna) et antenne fil-plaque monopolaire en montrant leurs avantages et leurs inconvénients. Nous avons mis le point sur les antennes microrubans, en donnant les différentes caractéristiques et les substrats exploités dans la conception de ces antennes. Nous examinons ensuite le type et l'endroit de l'alimentation qui jouent un rôle important dans l'étude du couplage. Enfin, nous présentons la description et le mécanisme de rayonnement et la mise en réseau d'antennes imprimées, leurs avantages ainsi que leurs inconvénients.

1.2 Types d'antennes

Nous classons habituellement les antennes en plusieurs types, tels que les antennes filaires, antennes à ouverture, antennes réflecteurs, antennes à lentille, antennes imprimées etc.

1.2.1 Antennes filaires

Les antennes filaires sont d'usage très courant (Figure I.1). Nous pouvons les rencontrer quotidiennement sur les automobiles, les bâtiments, les bateaux, les avions, ... Il existe différentes formes comme le dipôle, la boucle, l'hélice, ...



Figure I.1 Antenne filaire de forme boucle résonante.

I.2.2 Antennes à ouverture

Les antennes à ouverture, très développées, sont plus utilisées actuellement que par le passé, en raison de nombreuses demandes de caractéristiques sophistiquées et d'utilisation en très hautes fréquences (Figure I.2). Ces antennes sont très utiles pour les applications aériennes (aviation ou domaine spatial).




Figure I.2 Antenne à ouverture.

1.2.3 Antennes réflecteurs

Le succès dans l'exploration de l'espace intersidéral a eu comme conséquence l'avancement de la théorie des antennes. Du fait du besoin de communiquer sur de grandes distances, des formes sophistiquées d'antennes ont été utilisées afin de transmettre ou recevoir les signaux qui doivent traverser des millions de kilomètres (Figure I.3). Le réflecteur parabolique est l'antenne la plus commune pour ce type de communication. Il peut être appliqué dans le domaine de la transmission de données multimédias de télédiffusion ou de radiodiffusion.




Figure I.3 Antenne réflecteur.

1.2.4 Antennes à lentille

Les lentilles sont essentiellement utilisées pour concentrer les énergies divergentes du rayon incident afin de prévenir la dispersion dans les directions non désirées (Figure I.4). La forme géométrique et le choix du matériel permettent à ces antennes de transformer les diverses formes d'énergie divergentes en ondes planes. Les antennes à lentilles peuvent être utilisées dans le même domaine que les réflecteurs paraboliques. Elles sont classées selon le matériau avec lequel elles sont construites, ou selon leur forme géométrique [1].




Figure I.4 Antenne à lentille.

I.2.5 Antennes imprimées (antennes microrubans)

Ce type d'antenne a suscité beaucoup d'intérêts à partir des années 70, bien que les premières idées sur l'antenne imprimée aient été formulées dès l'année 1953 [1]. Une antenne microruban est composée d'une plaque de substrat diélectrique d'épaisseur h caractérisée par sa permittivité relative ϵ_r et sa tangente de perte $\text{tg}\delta$ (Figure I.3). La face inférieure est entièrement métallisée, on l'appelle le plan de masse de l'antenne. Sur la face supérieure, on dispose une couche de métal très fine qui peut être de forme variable (rectangle, carré, ellipse, disque, triangle...). Cette structure rayonnante peut être alimentée de différentes façons : par sonde coaxiale, par ligne micro-ruban ou coplanaire...

I.2.6 Antenne PIFA (Planar Inverted F Antenna)

L'antenne quart d'onde présente des dimensions réduites [2] par rapport à l'antenne demi-onde. La diminution de la taille est réalisée par un court-circuit placé le long de la ligne où le champ électrique entre la plaque rayonnante et le plan de masse est nul pour le mode fondamental de l'antenne imprimée. L'antenne PIFA est obtenue par une réduction de la largeur du court-circuit plan de l'antenne quart d'onde (Figure I.5). Cette antenne présente donc des dimensions inférieures à celles de l'antenne quart d'onde. La largeur du pavé rayonnant permet d'ajuster la fréquence de résonance ainsi que la forme du diagramme de rayonnement.

Dans les applications telles que les systèmes mobiles, le plan de masse de ce type d'antenne est considérablement réduit et a pour effet de rendre le diagramme de rayonnement plus omnidirectionnel [2].




Figure I.5 Configuration de l'antenne PIFA (plaque rayonnante suspendu dans l'air)

1.2.7 Antenne fil-plaque monopolaire

L'antenne fil-plaque monopolaire peut être à la fois considérée comme une antenne imprimée originale ou alors comme un monopôle particulier, chargé par un toit capacitif. Sous sa forme simple, la structure de l'antenne fil-plaque est montrée sur la Figure I.6. Elle est constituée d'un plan métallique de forme à priori arbitraire placé sur la face supérieure d'une lame électrique. Ce plan métallique est appelé toit de l'antenne. La face inférieure de cette lame est généralement entièrement métallisée et constitue le plan de masse de l'antenne. L'alimentation est réalisée par une sonde coaxiale qui traverse le plan de masse et le substrat diélectrique afin d'être connectée au toit métallique. La particularité de l'antenne est de posséder des fils connectant le plateau supérieur au plan de masse. Ces fils sont souvent appelés fils de masse, fils de retour ou fils de court-circuit [3]. Deux fils de masse sont placés près de la sonde coaxiale qui alimente la plaque en son centre.




Figure I.6 Antenne fil-plaque monopolaire vue latérale.

1.2.8 Choix des antennes à étudier

Les différentes antennes présentées ne réunissent cependant pas de façon entièrement satisfaisante l'ensemble des propriétés requises pour une antenne miniature utilisable dans les divers systèmes modernes de communication mobile. Il est en effet rare de trouver une antenne qui présente à la fois des caractéristiques de fonctionnement (bande passante, efficacité de rayonnement, diagramme de rayonnement, polarisation, etc) et un encombrement compatible avec les besoins exigés dans les différents systèmes actuels ou futurs. Si bien qu'en général, un compromis doit être réalisé entre toutes ces caractéristiques de sorte à utiliser l'antenne la moins "mauvaise".

Concernant notre recherche, cette thèse sera limitée à l'étude des antennes microbandes classiques.

1.3 Description de l'antenne microbande

La Figure I.7 expose la topologie d'une structure métallique de fine épaisseur et de forme quelconque. L'élément rayonnant est positionné sur un diélectrique métallisé sur sa face inférieure afin de réaliser le plan de masse.




Figure I.7 Structure d'une antenne microbande.

1.3.1 Substrats

Dans la pratique, les formes des éléments rayonnants les plus souvent utilisées sont le carré, le rectangle, le disque et l'anneau. Des géométries plus élaborées sont toutefois employées pour répondre à des contraintes spécifiques sur l'antenne (en particulier pour générer de la polarisation circulaire).

Les substrats exploités dans la conception des antennes imprimées sont nombreux. Leurs permittivités relatives varient de 1 à 12 ($1 < \epsilon_r < 12$) [4].

Parfois, il est préférable d'utiliser des substrats diélectriques de grande épaisseur et de basse permittivité dans le but d'avoir une grande efficacité, une large bande passante. Mais dans ce cas la perte par onde de surface augmente et l'antenne devient de plus en plus encombrante.

Au contraire, l'utilisation de minces substrats de permittivités élevées est conseillée pour les circuits micro-ondes parce qu'elle minimise les ondes de surfaces, les radiations non désirées et le volume de l'antenne. Toutefois, l'efficacité et la bande passante diminuent à cause de la grande perte dans le substrat [5], [6].

1.3.2 Techniques d'alimentation

Les quatre techniques d'alimentation les plus populaires utilisées sont la ligne microruban, la sonde coaxiale (techniques avec contact), le couplage par ouverture et le couplage par proximité (technique sans contact).

a. Alimentation avec la ligne microruban

Dans ce type de technique d'alimentation, un ruban conducteur est connecté directement au bord du patch rayonnant comme il est montré dans la (Figure I.8). La longueur de la bande conductrice est plus petite par rapport au patch et ce genre d'alimentation a l'avantage qu'elle peut être gravée sur le même substrat pour fournir une structure planaire.

Le but de l'encart couplé dans le patch est d'adapter l'impédance de la ligne d'alimentation au patch sans avoir besoin d'un élément d'adaptation additionnel. Ceci est achevé par un contrôle correct de la position de l'encart. Par conséquent c'est une technique d'alimentation facile, puisqu'elle fournit la facilité de fabrication et la simplicité de modélisation, ainsi que l'adaptation d'impédance. Cependant, certaines applications nécessitent un substrat épais, ce qui engendre l'augmentation des ondes de surface et le rayonnement parasite, entraînant une dégradation de la bande passante [1].




Figure I.8 Alimentation par ligne microruban.

b. Alimentation par câble coaxiale

L'alimentation coaxiale ou l'alimentation par sonde, utilisée pour alimenter les antennes plaques est une technique très connue. Le conducteur intérieur du connecteur coaxial s'étend

à travers le diélectrique et il est soudé au patch, alors que le conducteur extérieur est relié au plan de masse (Figure I.9).




Figure I.9 Antenne microbande alimentée par sonde.

L'avantage principal de ce type d'alimentation est qu'elle peut être placée à n'importe quel endroit désiré du patch afin d'assurer l'adaptation d'impédance. Cette méthode d'alimentation est facile à fabriquer et a un rayonnement parasite faible. Cependant, son inconvénient principal est qu'elle fournit une bande passante étroite et elle est difficile à modéliser puisqu'un trou doit être foré dans le substrat et le connecteur sort en dehors du plan de masse, cela ne la rend pas complètement plane pour les substrats épais ($h > 0.002 \lambda_0$).

En outre, pour des substrats plus épais, l'accroissement de la longueur de sonde rend l'impédance d'entrée plus inductive, menant aux problèmes d'adaptation [5]. Il est clair, à partir de ce qu'on a vu, qu'avec un substrat diélectrique épais, ce qui fournit une large bande passante, les alimentations, par lignes microrubans et par câble coaxial, souffrent de plusieurs inconvénients. Les techniques d'alimentation sans contact, qui seront discutés ci-dessous, résolvent ces problèmes.

c. Alimentation couplée par ouverture

Dans ce type d'alimentation, le patch rayonnant et la ligne microruban d'alimentation sont séparés par le plan de masse comme représentée dans la (Figure I.10). Le couplage entre le patch et la ligne d'alimentation est assuré par une fente ou une ouverture dans le plan de masse. L'ouverture de couplage est habituellement centrée sous le patch. Puisque le plan de masse sépare le patch et la ligne d'alimentation, le rayonnement parasite est minimisé. D'une façon générale, un matériau ayant une constante diélectrique élevée est employé pour le

substrat inférieur, alors qu'un matériau épais et ayant une constante diélectrique faible est employé pour le substrat supérieur afin d'optimiser le rayonnement du patch [4].




Figure I.10 Alimentation couplée par ouverture.

L'inconvénient majeur de cette technique d'alimentation est qu'elle présente des difficultés au niveau de la fabrication en raison des couches multiples qui augmentent également l'épaisseur d'antenne. Cette technique d'alimentation fournit aussi une largeur de bande étroite.

d. Alimentation couplée par proximité

Cette technique d'alimentation est connue également sous le nom de couplage électromagnétique. Deux substrats diélectriques sont employés de sorte que la ligne d'alimentation soit située entre les deux substrats et le patch soit imprimé sur le substrat supérieur comme il est montré dans la (Figure I.11). L'avantage principal de cette technique d'alimentation est qu'elle élimine le rayonnement parasite dû à l'alimentation et fournit une largeur de bande très élevée (plus que 13%) [4], en raison de l'augmentation globale de l'épaisseur de l'antenne microbande. Cette technique fournit également des choix entre deux milieux diélectriques différents, un pour le patch et un pour la ligne d'alimentation pour optimiser les performances de l'antenne.




Figure I.11 Alimentation couplée par proximité.

L'adaptation peut être réalisée en contrôlant la longueur de la ligne d'alimentation. L'inconvénient principal de cette technique d'alimentation est qu'elle est difficile à fabriquer en raison des deux couches diélectriques qui nécessitent un alignement approprié. En outre, il y a une augmentation de l'épaisseur globale de l'antenne.

I.3.3 Rayonnement

Le diagramme de rayonnement de l'antenne caractérise la variation de la puissance rayonnée à grande distance dans les différentes directions de l'espace.

Lorsque la polarisation de l'antenne est linéaire, le diagramme de rayonnement est celui d'un dipôle magnétique [1], [7], il est généralement représenté dans deux plans de coupe particuliers (Figure I.12) [6] :

- le plan E,
- le plan H.

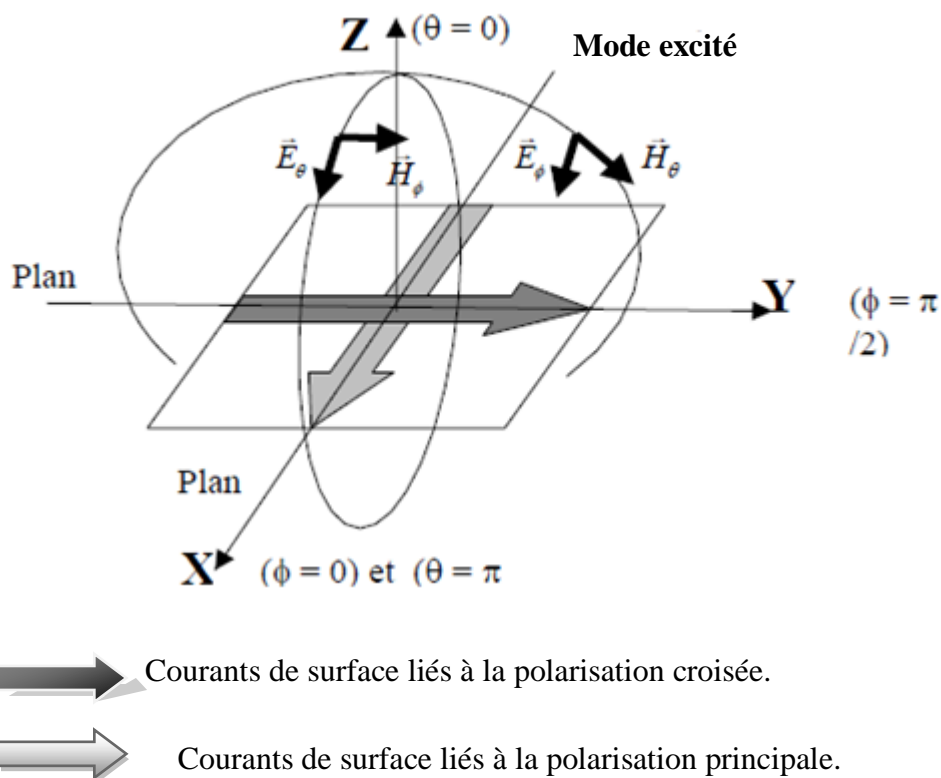


Figure I.12 Représentation des courants surfaciques dans le plan E et le plan H d'une antenne patch.

1.3.4 La mise en réseau d'antennes imprimées

L'utilisation d'une antenne unitaire s'avère souvent insuffisante pour répondre aux contraintes de rayonnement imposées. Des caractéristiques spécifiques, un gain élevé, un lobe formé ne peuvent généralement être obtenus que par le regroupement de plusieurs sources rayonnantes pour former un **réseau d'antennes** [8].

On forme ainsi des réseaux linéaires et des réseaux plans (Figure I.13).

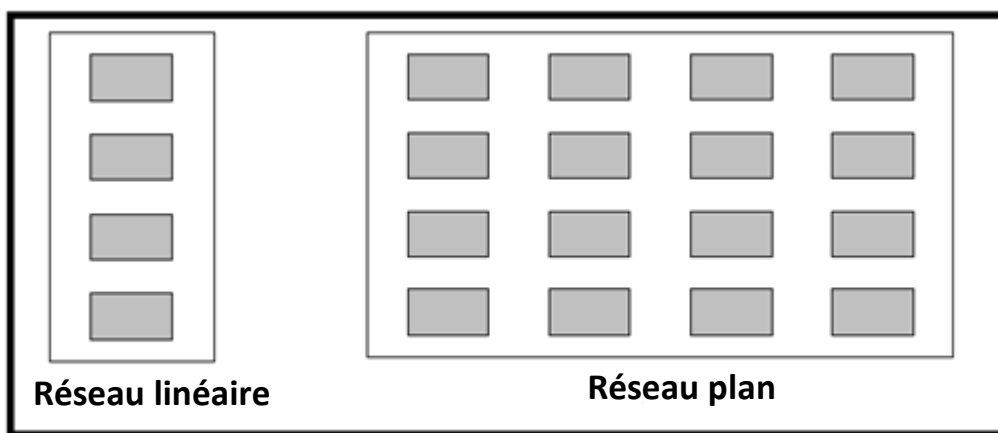


Figure I.13 Architecture de base des réseaux.

Cette mise en réseau des sources crée des rayonnements parasites (Figure I.14) qui sont dus au débordement des champs magnétiques, à l'épaisseur du substrat utilisé, à l'orientation et à la distance entre les sources.




Figure I.14 Mécanisme des rayonnements parasites.

1.4 Choix de la technologie des antennes microbandes

Actuellement, les antennes imprimées deviennent de plus en plus importantes en raison de la grande variété des formes géométriques qu'elles peuvent prendre et qui les rendent applicables aux différentes situations d'intégration [9], [10].

Parmi les avantages de cette technologie d'antennes, on peut citer : le faible poids, leur volume réduit, la conformabilité et la possibilité d'intégrer les circuits micro-ondes au niveau des antennes [8]. De plus la simplicité de leurs structures fait que ce type d'antenne est adapté au faible coût de fabrication. Ceci est une propriété clé qui explique l'introduction des antennes imprimées dans les applications de la communication mobile.

D'une façon générale, les avantages des antennes microbandes sont [1], [11]:

- + Simples,
- + Robustes,
- + non encombrantes,
- + adaptées aux surfaces planes et non planes,
- + à faible coût.

Les antennes microbandes ont également des limitations [1]:

- + faible efficacité,
- + faible puissance,
- + impureté de la polarisation,
- + bande relativement étroite.

Ces limitations sont connues depuis plusieurs années et des progrès considérables ont été réalisés pour améliorer les performances des antennes microbandes. Notamment, leur bande passante peut être augmentée jusqu'à 70 % en utilisant une configuration multicouche et leur gain peut s'accroître de 30 % en mettant en réseau plusieurs antennes.

1.5 Conclusion

Dans ce chapitre, nous avons présenté différents types d'antennes, différentes méthodes d'alimentation des antennes microbandes, ainsi que différents matériaux et substrats utilisés. Nous avons également cité les avantages et les inconvénients, les principales contraintes imposées à la réalisation de ces structures d'alimentation et leurs applications.

Cette étude concernant les caractéristiques de base des antennes imprimées, sera élargie dans le chapitre suivant à la modélisation d'une antenne avec gap d'air par les deux méthodes : la méthode de la cavité et la méthode neuronale et finalement les résultats de simulation obtenus.

I.6 Références

- [1] C. A. Balanis, "*Antenna theory analysis and design*", John Wiley & Sons, INC, 1997.

- [2] C. R. Rowell, R. D. Murch, "*A capacity loaded PIFA for compact mobile telephone handsets*", " IEEE Trans., Ant. Propag., Vol. 45, No. 5, pp. 837-842, May 1997.

- [3] C. Delaveaud, P. Leveque, B. Jecko, "*New kind of microstrip antenna : The monopolar wire-patch Antenna*", " Electron. Lett., Vol. 30, No. 1, pp. 1-2, 1994.

- [4] D. M. Pozar, "*Microstrip Antennas*, " Proc. IEEE, Vol. 80, No. 1, pp. 79-80, January 1992.

- [5] C.M. Krowne, "*Cylindrical-Rectangular Microstrip Antenna*," IEEE Trans. Antennas Propagat., Vol. AP-31, No. , pp. 194-199, January 1983.

- [6] I. Lier, K. R. Jakobsen, "*Rectangular Microstrip Patch Antennas with Infinite and Finte Ground Plane Dimensions*," IEEE Trans. Antennas Propagat., Vol. AP-31, No.6, pp.978-984, Nov 1983.

- [7] F.T. Ulaby, "*Fundamentals of applied electromagnetics*, " Prentice Hall, 1999.

- [8] P. Versin Rapport de Stage : *Conception d'un Réseau d'Antennes Imprimées pour un Sondeur Multicapteurs et Optimisation des Phénomènes de Couplage*. INSA de Rennes – Juin 2001.

[9] **Antenne** – Cours Universitaire Préparé par Dr Youssef Daher Université Libanaise – Faculté de Génie – Branche 1.

[10] J. R. James, P. S. Hall and C. Wood "*Microstrip Antenna: Theory and Design,*" London, U.K: Peter Peregrinus, 1981.

[11] A. Kuchar, Rapport de Thèse "*Aperture-Coupled Microstrip Patch Antenna Array,*" Technic University of Wien, March 1996.

CHAPITRE II

MODÉLISATION D'UNE ANTENNE MICROBANDE AVEC GAPD'AIR PAR CAVITÉ/RNA

II.1 Introduction

Dans la première partie de ce chapitre, nous présentons la méthode de la cavité modifiée (Wolff) pour calculer la fréquence de résonance et l'impédance d'entrée de l'antenne microbande avec gap d'air. Ensuite, nous attacherons à détailler le type de réseaux de neurones utilisé dans ce chapitre (MLP), et plus particulièrement ses propriétés et sa mise en œuvre. Un réseau neuronal artificiel a des caractéristiques privilégiées représentées par sa capacité à apprendre des informations, à généraliser et à identifier des fonctions non linéaires multidimensionnelles.

Dans la deuxième partie, nous exposons le réseau neuronal multicouche de type Feed-Forward avec l'algorithme de Back-Propagation, et la base d'apprentissage qui est élaborée à partir des résultats fournis par la méthode de la cavité. Les résultats obtenus pour une antenne avec gap d'air seront comparés à ceux d'une antenne sans gap d'air.

II.2 Modèle de la cavité modifiée (Wolff) d'une antenne microbande rectangulaire avec gap d'air

Une antenne rectangulaire microbande avec gap d'air peut être assimilée à une cavité fermée par deux murs électriques en $z = 0$, et plan de masse en $z = H = H_A + H_D$, le conducteur métallique supérieur, et par des murs magnétiques verticaux. Une longueur et une largeur effectives sont introduites pour prendre en compte les débordements des champs sur les bords de l'antenne. Le patch est alimenté par un courant électrique J parallèle à l'axe oz (Figure II.1-a) et répartie uniformément. Le choix d'une antenne avec gap d'air a été proposé par Lee et al [1] dans le but de changer les fréquences de résonance sans avoir recours à un autre modèle d'antenne. La fréquence de résonance de ce type d'antennes peut être modifiée par un ajustement convenable de la hauteur d'air existant entre le substrat et le plan de masse. Cette méthode appelée la méthode de Wolff modifiée vue l'introduction de donnée par Chew [2] dans les formules de Wolff, donne des résultats avec une bonne précision y compris pour le substrat électriquement épais.

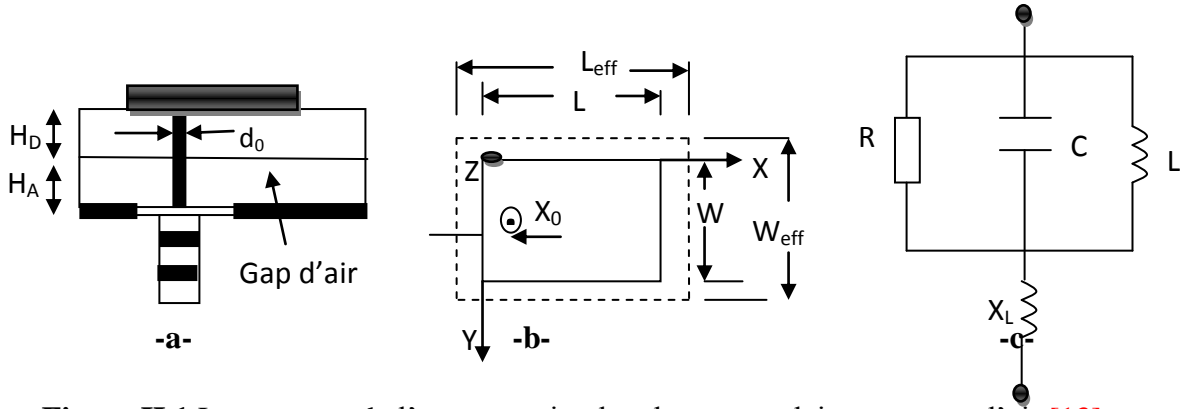


Figure II.1 La structure de l'antenne microbande rectangulaire avec gap d'air [13].

➤ *Calcul de la fréquence de résonance*

Les caractéristiques de la structure ont été étudiées par Lee et al en utilisant le modèle de la cavité. Aboud et al [3] ont proposé un circuit équivalent R-L-C parallèle (Figure II.1-c) pour analyser une telle structure.

La fréquence de résonance pour le mode (m, n) est donnée par :

$$f_R = f_{mn} = \frac{V_0}{2\sqrt{\epsilon_{dyn}}} \sqrt{\left[\left(\frac{m}{W_{eff}}\right)^2 + \left(\frac{n}{L_{eff}}\right)^2\right]} \quad (II. 1)$$

Où V_0 la vitesse de la lumière, W_{eff} et L_{eff} sont les dimensions effectives de l'antenne, dans le but de rendre les résultats théoriques obtenus comparables aux mesures. Pour le calcul de la longueur effective, on utilise la relation suivante [6], [7] :

$$L_{eff} = L + \left(\frac{W_{eq} - W}{2}\right) \frac{\epsilon_{eff}(W) + 0.3}{\epsilon_{eff}(W) - 0.258} \quad (II. 2)$$

Les expressions de la largeur équivalente W_{eq} , et la permittivité effective ϵ_{eff} en fonction de la largeur et la longueur du patch sont données par les équations suivantes :

$$\epsilon_{eff}(W) = \left[\frac{Z_0(W, H, \epsilon_r = 1)}{Z(W, H, \epsilon_r)}\right]^2 \quad (II. 3)$$

$$W_{eq} = \frac{120\pi H}{Z(W)\sqrt{\epsilon_{eff}}} \quad (\text{II. 4})$$

Pour calculer le coefficient W_{eq} , on utilise l'impédance d'une ligne microruban de la façon suivante [4]:

$$Z(W) = \frac{60\pi}{\sqrt{\epsilon_{eff}}} \left\{ \frac{W}{2H} + 0.441 + 0.082 \left[\frac{\epsilon_{eff} - 1}{\epsilon_{eff}^2} \right] + \frac{(\epsilon_{eff} + 1)}{2\pi\epsilon_{eff}} \left[1.451 + \ln \left(\frac{W}{2H} + 0.94 \right) \right] \right\}^{-1} \quad \text{pour } W/H > 1 \quad (\text{II. 5})$$

ϵ_{dyn} est la permittivité dynamique elle est en fonction de W , L , H et ϵ_r [3].

Pour calculer la permittivité dynamique on utilise la méthode de Wolff [8]:

$$\epsilon_{dyn} = \frac{C_{dyn}(W, L, H, \epsilon_r)}{C_{dyn}(W, L, H, \epsilon_r = 1)} \quad (\text{II. 6})$$

$\epsilon_{dyn}(W, L, H, \epsilon_r)$ représente la capacité dynamique totale du patch en présence d'un diélectrique.

$\epsilon_{dyn}(W, L, H, \epsilon_r=1)$ représente la capacité dynamique totale du patch en présence de l'air.

$$C_{dyn}(W, L, H, \epsilon_r) = C_{0,dyn}(W, L, H, \epsilon_r) + 2C_{e1,dyn}(W, L, H, \epsilon_r) + 2C_{e2,dyn}(W, L, H, \epsilon_r) \quad (\text{II. 7})$$

La capacité dynamique du patch $C_{0,dyn}$ et les capacités marginales dynamiques $C_{e1,dyn}$ et $C_{e2,dyn}$ sont définies respectivement comme suit [8]:

$$C_{0,dyn}(\epsilon_r) = \frac{C_{0,stat}(\epsilon_r)}{\gamma_n \gamma_m} \quad (\text{II. 8})$$

et

$$C_{0,stat}(\epsilon_r) = \frac{\epsilon_{r0}\epsilon_r LW}{H} \quad (\text{II. 9})$$

$$i = n, m; \quad \gamma_i = \begin{cases} 1 & \text{pour } i = 0 \\ 2 & \text{pour } i \neq 0 \end{cases}$$

Avec

$$C_{e1,dyn}(\epsilon_r) = \frac{C_{e1,stat}(W, L, H, \epsilon_r)}{\gamma_n} \quad (\text{II. 10})$$

$$C_{e2,dyn}(\epsilon_r) = \frac{C_{e2,stat}(W, L, H, \epsilon_r)}{\gamma_m} \quad (\text{II. 11})$$

La capacité statique est obtenue en soustrayant la capacité centrale du patch de toute la capacité obtenue à partir de l'expression variationnelle comme suit:

$$C_{e1,stat}(W, L, H, \epsilon_r) = \frac{1}{2} [CL - C_{0,stat}(\epsilon_r)] \quad (\text{II. 12})$$

$$C = \frac{Z_0}{V_0 Z^2} \quad (\text{II. 13})$$

$$\epsilon_{eff}(W) = \frac{\epsilon_{re} + 1}{2} + \frac{\epsilon_{re} - 1}{2} \left(1 + \frac{10}{W/H}\right)^{-1/2} \quad (\text{II. 14})$$

Avec

$$\epsilon_{re} = \frac{\epsilon_r(H_D + H_A)}{(H_D + H_A \epsilon_r)} \quad (\text{II. 15})$$

➤ *Calcul de l'impédance d'entrée*

On peut modéliser l'antenne microbande avec gap d'air dans le mode fondamentale par un circuit parallèle RLC (Figure II.1-c). Notre objectif est principalement la détermination de l'impédance d'entrée. Donc il nous manque l'équation qui relie le facteur de qualité et l'impédance de l'antenne ayant un gap d'air. Celle-ci est donnée par l'expression suivante :

$$Z_{in}(f) = \frac{R}{1 + Q_T^2 \left[\frac{f}{f_R} - \frac{f_R}{f} \right]^2} + j \left[X_L - \frac{RQ_T \left[\frac{f}{f_R} - \frac{f_R}{f} \right]}{1 + Q_T^2 \left[\frac{f}{f_R} - \frac{f_R}{f} \right]^2} \right] \quad (\text{II. 16})$$

R est la résistance résonnante du circuit parallèle RLC [5] :

$$R = \frac{Q_T H}{\pi f_R \varepsilon_{dyn} \varepsilon_0 L W} \cos^2 \left(\frac{\pi X_0}{L} \right) \quad (\text{II. 17})$$

$$X_L = \frac{377 f H}{c_0} \text{Ln} \left(\frac{c_0}{\pi f d_0 \sqrt{\varepsilon_r}} \right) \quad (\text{II. 18})$$

Q_T est le facteur de qualité total. Il est exprimé en termes de facteur de qualité associé à la radiation, à la conduction et la perte diélectrique par l'équation suivante:

$$Q_T = \left[\frac{1}{Q_R} + \frac{1}{Q_c} + \frac{1}{Q_D} \right]^{-1} \quad (\text{II. 19})$$

Avec

Q_R : le facteur de qualité dû au rayonnement. Il est donné par :

$$Q_R = \frac{c_0 \sqrt{\varepsilon_{dyn}}}{4 f_R H} \quad (\text{II. 20})$$

Où ε_{dyn} est donné par la formule (II.6).

Les autres contributions dans le facteur de qualité de l'antenne sont les pertes du diélectrique et des conducteurs. Ces pertes sont indépendantes de la forme de l'antenne si le substrat est fin.

$$Q_D = \frac{1}{\text{tg} \delta} \quad (\text{II. 21})$$

$\tan(\delta)$ est la tangente des pertes dans le diélectrique.

L'antenne présente également des pertes par radiation qui doivent être incorporées pour compléter l'analogie entre la cavité et l'antenne microbande. L'antenne microbande est supposée rayonner par ses bordures. Dans ce cas, on considère tous les bords puisque les champs sont déterminés partout dans l'antenne.

$$Q_c = \frac{0.786 Z_{ao}(W) \cdot H \cdot \sqrt{f_R}}{P_a} \quad (\text{II. 22})$$

$$P_a(W) = \frac{2\pi \left[\frac{W}{H} + \frac{\frac{W}{\pi H}}{\frac{W}{2H} + 0.94} \right] \left[1 + \frac{H}{W} \right]}{\left\{ \frac{W}{H} + \frac{2}{\pi} \ln \left[2\pi \exp \left(\frac{W}{2H} + 0.94 \right) \right] \right\}^2} \quad \text{pour } W/H \geq 2 \quad (\text{II. 23})$$

$Z_{ao}(W)$: est l'impédance d'une ligne microruban de largeur W et d'épaisseur H , on substitue ϵ_r dans la formule (II.5) on trouve Z_{ao} .

Les formules de Q_D et Q_C montrent que Q_D est indépendant de l'épaisseur du substrat, tandis que Q_C est proportionnel à l'épaisseur électrique H du substrat. Alors pour un substrat mince, les pertes dans le conducteur dominent les pertes dans le diélectrique [13].

Avant d'appliquer la méthode neuronale, nous présentons des notions de base sur les réseaux de neurones afin de prouver l'efficacité et la souplesse de cet outil numérique.

II.3 Mise en œuvre d'une méthode neuronale

II.3.1 Principe de la méthode neuronale

Les réseaux de neurones formels sont constitués d'éléments de base appelés neurones. Le concept est fortement inspiré par le système nerveux biologique. De la même manière que les neurones naturels, le fonctionnement du réseau de neurones formel est caractérisé par les degrés d'affinité qui lient les neurones entre eux. Cette affinité est matérialisée par des connections pondérées. Le réseau peut être entraîné pour une tâche spécifique (reproduction d'un comportement par exemple) en ajustant les valeurs des poids des connections entre les neurones.

II.3.2 Architectures de réseau

Un réseau bouclé est un réseau récurrent ou dynamique où l'information suit un cycle tel qu'il puisse revenir à son point de départ. Il convient bien pour la modélisation dynamique de processus non linéaires où la notion du temps est un élément essentiel [9]. Ceci n'est pas le cas dans notre technique de mesure car le temps n'est pas un paramètre de la méthode.

Un seul neurone ne peut approximer qu'une allure très simple. Dans un réseau, on met à contribution les actions de plusieurs neurones en les interconnectant entre eux pour implémenter ces approximations.

Naturellement, on peut imaginer des interconnexions tous azimuts entre les entrées et les neurones comme illustrées dans la Figure II.2. Il s'agit dans ce cas d'un *réseau complètement connecté*. Le réseau comporte donc des entrées et des sorties. Les neurones situés en bout de chaîne donnant les valeurs de sortie du réseau sont appelés neurones de sortie. Les neurones situés entre l'entrée du réseau et les neurones de sortie sont appelés neurones cachés.

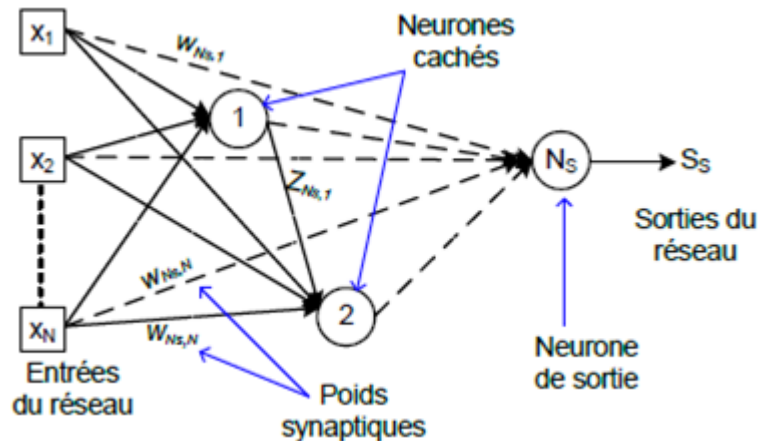


Figure II.2 Réseau complètement connecté.

Dans un réseau non bouclé, dit aussi statique, l'information circule dans un seul sens, de l'entrée vers la sortie et le temps n'intervient pas. Il réalise des calculs algébriques complexes sur ses entrées. Les sorties sont obtenues par composition des fonctions élémentaires opérées par chaque neurone.

II.3.3 Perceptron multicouche

Le perceptron multicouche PMC (MLP en anglais) est le type de réseau le plus connu et le plus utilisé pour des problèmes d'approximation, de classification et de prédiction. Il est utilisé donc comme approximateur ou classifieur parcimonieux.

Il appartient à la famille générale des réseaux statiques. Les neurones qui le constituent sont répartis par couche. Il est habituellement constitué de deux ou trois couches de neurones mais avec la particularité de ne pas disposer de connexions entre les neurones d'une même couche. Ce qui fait que deux neurones d'une même couche fonctionnent en parallèle et deux neurones de couches différentes obéissent à un fonctionnement séquentiel. Les neurones de la première couche recevant les entrées (informations extérieures) constituent la couche d'entrée du réseau. La dernière couche est celle qui fournit le résultat ; elle est appelée la couche de sortie. Toutes les couches entre cette dernière et la couche d'entrée sont des couches cachées. De manière générale le PMC a une structure comme celle de la Figure II.3. Cependant, Cybenko [10] et Funuhashi [11] ont démontré que «toute fonction bornée suffisamment régulière peut être approchée uniformément, avec une précision arbitraire, dans un domaine fini de l'espace de ses variables, par un réseau de neurones comportant une couche de neurones cachés en nombre fini, possédant tous la même fonction d'activation, et un neurone de sortie linéaire».

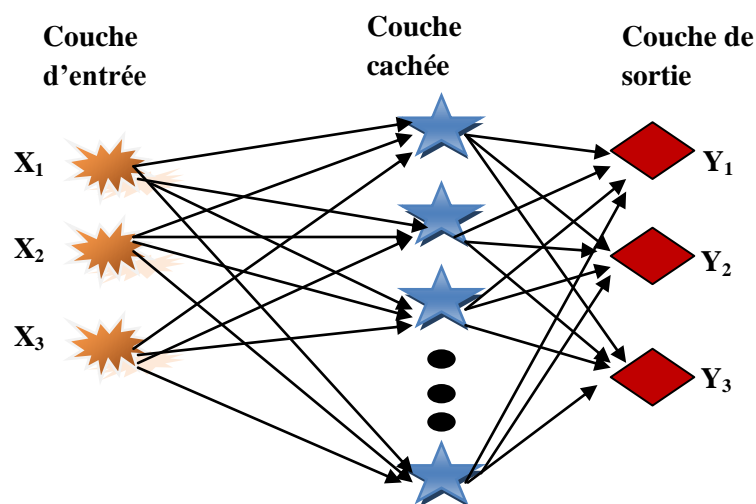


Figure II.3 Exemple d'un réseau multicouche de type

Perceptron (3 entrées, 3 sorties).

II.3. 4 Apprentissage d'un réseau

L'apprentissage est une phase du développement d'un réseau de neurones au cours de laquelle son comportement est réajusté jusqu'à l'obtention du comportement désiré (Figure II.4). Ceci est réalisé grâce à un algorithme d'apprentissage. Il en existe deux catégories : apprentissage supervisé et apprentissage non supervisé. Dans l'apprentissage supervisé, il est nécessaire de disposer d'une base de données appelée corpus que nous désignons par (X, Y) . Le corpus est un ensemble formé d'un nombre fini de couples assez représentatifs du comportement du processus physique à modéliser. L'apprentissage consiste en fait à modifier l'ensemble des poids w_{ckj} de telle manière que pour toute(s) entrée(s) x incluse(s) dans l'ensemble contenant les données X , les sorties S du réseau approchent au mieux les observations Y .

X est une matrice de dimensions $N \times N_t$ et Y une matrice de dimension $N_s \times N_t$, où N est le nombre des entrées, N_t le nombre de couples, et N_s le nombre des sorties du réseau. Le nombre des sorties est de fait égal au nombre de neurones de sortie. Par contre dans l'apprentissage non supervisé, on ne dispose pas de base d'exemples connus à priori pour fournir au réseau. Même la manière de présenter les données d'entraînement au réseau peut se faire de deux manières. On parle d'*entraînement adaptatif* si les poids sont modifiés après chaque passage de couple du corpus et d'*entraînement non-adaptatif* lorsqu'ils sont modifiés après le passage de l'ensemble du corpus. Nous utilisons dans le cadre de notre étude l'entraînement non adaptatif.

Algébriquement parlant et dans le cas d'apprentissage supervisé, l'apprentissage revient à optimiser la somme des erreurs quadratiques entre les vecteurs y_q et s_q sur l'ensemble des N_t données utilisées pour l'apprentissage. Cette erreur définie par l'équation II.24 est la suivante :

$$E(W) = \sum_{q=1}^{N_t} \left[\sum_{l=1}^{N_s} (y_l^q - S_l^q)^2 \right] \quad (\text{II. 24})$$

Un réseau de neurones, lorsqu'il est bien entraîné, doit avoir une capacité de généralisation et non se comporter juste comme une mémoire. Pour ce faire, il faut trouver un équilibre entre le

biais et la variance du modèle. En effet, on a un biais trop élevé lorsque le modèle est trop simple (très peu de neurones cachés), ce qui entraîne un écart important avec le modèle idéal. Par contre on a une variance importante lorsque le modèle est trop complexe (trop de neurones cachés), il passe donc par tous les points utilisés pour l'entraînement du réseau. Pour s'assurer que le réseau entraîné est capable de généraliser les résultats, nous effectuons des tests avec des données non utilisées pendant l'entraînement. Nous évaluons l'erreur quadratique moyenne E_{test}^q puis la comparons avec celle E_{entr}^q obtenue avec les données ayant servi à l'entraînement. Ces erreurs quadratiques moyennes au niveau d'une sortie q se calculent grâce aux expressions suivantes :

$$E_{test}^q = \sqrt{\frac{1}{n_{test}} \sum_{q=1}^{n_{test}} (y_1^q - S_1^q)^2} \quad (\text{II. 25})$$

$$E_{entr}^q = \sqrt{\frac{1}{n_{entr}} \sum_{q=1}^{n_{entr}} (y_1^q - S_1^q)^2} \quad (\text{II. 26})$$

On reprend l'entraînement plusieurs fois et on retient le réseau qui donne les erreurs E_{test}^q et E_{entr}^q du même ordre de grandeur. Pour éviter le surajustement, il existe plusieurs techniques de régularisation comme la régularisation bayésienne qui a été utilisée avec succès pour la caractérisation de matériaux diélectriques [12]. La technique de l'arrêt prématuré (*early stopping* en anglais) de l'entraînement consiste à arrêter l'apprentissage avant que l'algorithme ne s'ajuste trop finement aux données fournies pour l'apprentissage et surtout lorsque les capacités de généralisation sont optimales.

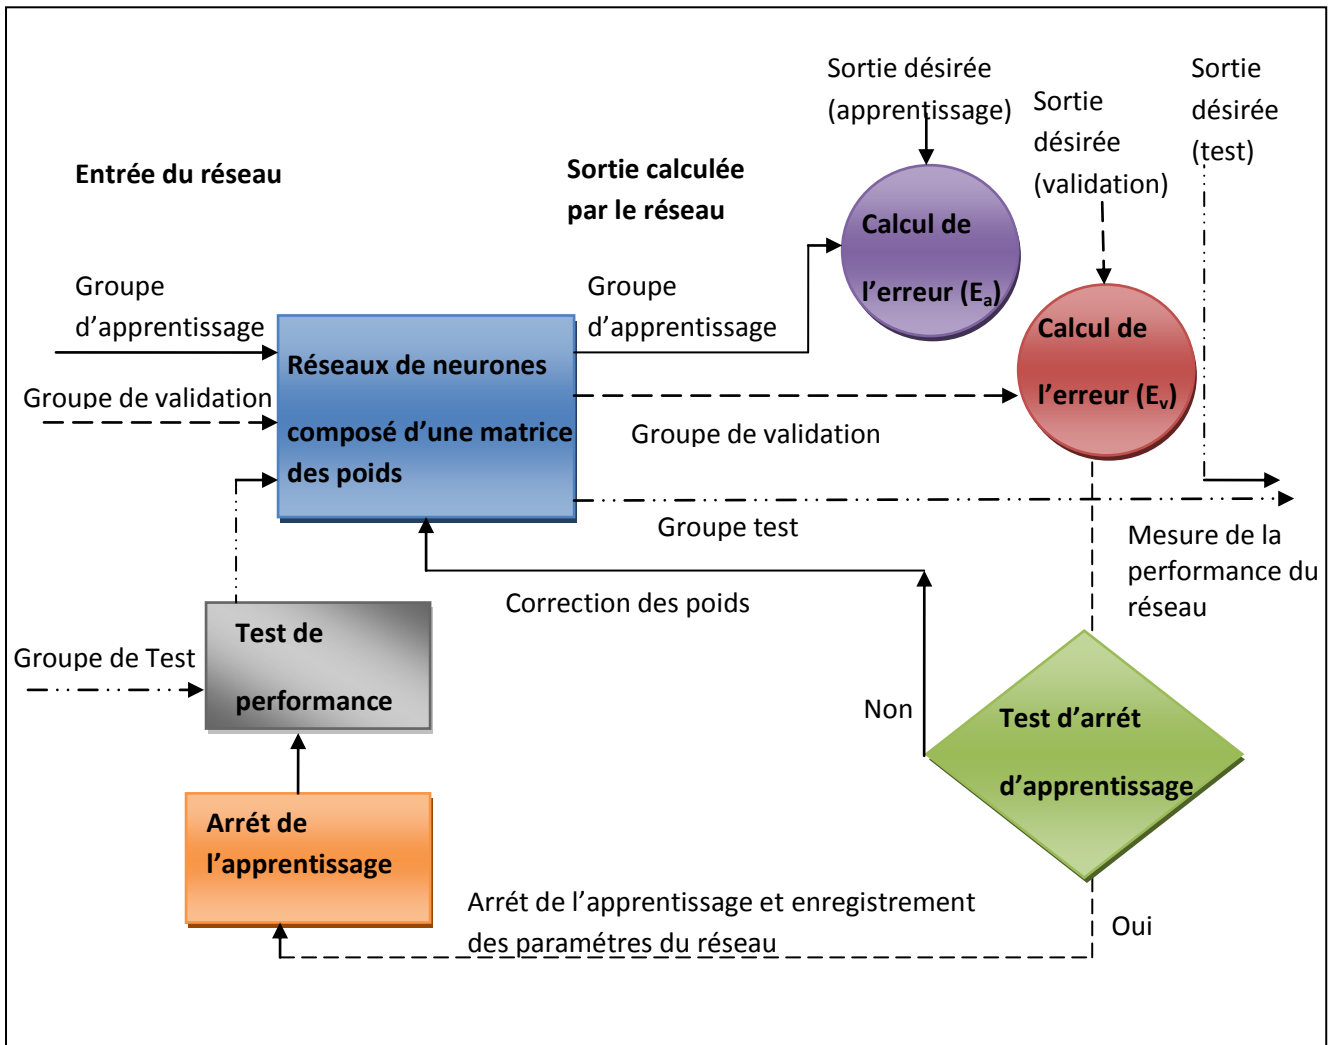


Figure II.4 Description schématique de la phase d'apprentissage.

II.4 Modélisation par RNA d'une antenne microbande sans gap d'air

Dans notre étude, nous utilisons le modèle de la cavité modifiée pour générer les matrices d'entraînement et de validation du réseau de neurones.

🔴 Développement d'un PMC pour la modélisation

Le calcul de l'impédance d'entrée normalisée à Z_0 (50Ω) en fonction de la fréquence nous mène à former un réseau neuronal constitué de 5 neurones d'entrée et de 2 neurones à la sortie Figure II.5. Plusieurs simulations ont été faites, le réseau optimal obtenu après l'ajustement des différents paramètres : seuil = 0.001 ; le coefficient d'apprentissage = 0.02 et momentum = 0.9. La qualité du résultat est évaluée par les erreurs d'apprentissage et de test. Cela conduit au Tableau II.1 qui regroupe les erreurs quadratiques moyennes **mse** ; et somme des carrés des erreurs **sse** à partir des paramètres du corpus de test.

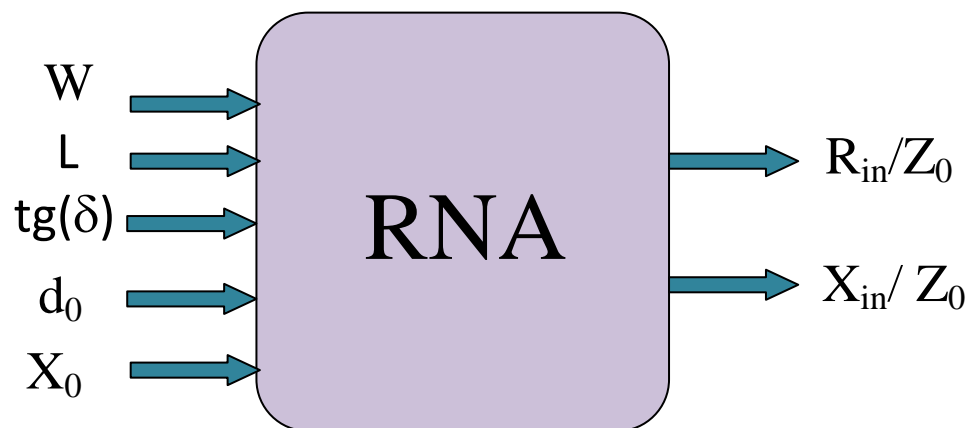


Figure II.5 Modèle neuronale de l'impédance d'entrée.

L'impédance d'entrée est simulée pour différents paramètres physique de l'antenne microruban sans gap d'air : La longueur $L \in [2\text{cm} ; 4\text{cm}]$, la largeur $W \in [3.1\text{cm} ; 6.1\text{cm}]$, $\text{tg}(\delta) \in [0.001 ; 0.003]$, $d_0 \in [0.055\text{cm} ; 0.15\text{cm}]$ et $X_0 \in [0.1\text{cm} ; 0.65\text{cm}]$.

Le réseau, avant d'être utilisé, doit tout d'abord être entraîné sur un corpus d'entraînement ayant un nombre assez représentatif du comportement système à modéliser. Pour chaque perceptron que nous avons développé, nous avons constitué 200 exemples de couples de vecteurs entrées/sorties.

Algorithmes d'apprentissage	Nombre de neurone dans la couche cachée	Erreur d'apprentissage	Erreur de test	SSE	MSE
LM (Levenberg-Marquardt)	13 × 5	9.8478e-4	0.2301	0.000958 /43 itérations	0.000906 /35 itérations
OSS (One-Step Secant)	10 × 15	0.0252	0.3247	0.000959 /584 itérations	0.000966 /178 itérations
BFG (Quasi-newton)	8 × 17	0.0034	0.2891	0.000915 /76 itérations	0.000880 /44 itérations
SCG (Conjugué du gradient d'échelle)	18 × 9	0.0037	0.1824	0.000998 /337 itérations	0.000987 /180 itérations
CGF (Fletcher-Reeves)	10 × 15	0.0035	0.3783	0.000997 /3679 itérations	0.000990 /447 itérations

Tableau II.1 Performances obtenues dans les algorithmes d'apprentissage.



Les valeurs des éléments du vecteur d'entrée et de celles du vecteur de sortie doivent chacune appartenir à une plage définissant le domaine de validité du réseau de neurones. A l'issue des erreurs estimées par le perceptron multicouche PMC sur le corpus de test, on peut conclure que le réseau fonctionne bien dans le domaine choisi. Il assure donc la généralisation.

Le neurone utilisé dans ce réseau est le neurone linéaire continu dont les fonctions d'activation sont les fonctions : tansig, logsig, tansig, et purelin respectivement.


Une fois le réseau de neurones entraîné (après apprentissage), il est nécessaire de le tester sur une base de données différente de celle utilisée pour l'apprentissage. Ce test permet à la fois d'apprécier les performances du système neuronal et de détecter le type de données qui pose un problème. Si les performances ne sont pas satisfaisantes, il faudra soit modifier l'architecture du réseau, soit modifier la base d'apprentissage.

Pour calculer l'impédance d'entrée de l'antenne rectangulaire microbande sans gap d'air par l'intermédiaire de l'architecture de MLP ; on a utilisé six algorithmes différents LM [13], OSS[14], BFG[15], SCG[16], CGF[17] et RP[18] (Annexe A).


L'évolution de la fonction d'erreur pendant la phase d'apprentissage pour chaque algorithme se visualise par l'intermédiaire d'un graphe (Figure II.6 a, b, c, d, e, f). Il illustre la convergence du réseau de neurones par rapport au fichier d'apprentissage. Il se dégage que l'algorithme LM a montré d'excellentes performances en termes de robustesse et présente l'avantage d'effectuer une recherche multipoints de la solution optimale, ce qui permet de réduire considérablement le temps de calcul.

a-trainlm**b-trainoss**


c-trainbfg



d-trainscg



f-traincgf



e-trainrp




Figure II.6 Evolution de la fonction d'erreur pendant la phase d'apprentissage pour 6 algorithmes pour un seuil de 0.001.

● Résultats de simulation

Nous avons utilisé les fonctions disponibles sur Matlab Toolbox permettant de donner une grande variété d'algorithmes. Certains sont du premier ordre d'autres sont du deuxième ordre permettant l'accélération de l'apprentissage en utilisant la dérivée du second ordre de la fonction de coût. Notre choix a été porté après plusieurs tests sur l'algorithme du deuxième ordre de Levenberg-Macquardt, vue le temps d'apprentissage très court et la précision des résultats obtenus. La Figure II.7 montre les résultats de simulations des méthodes d'analyses concernant la méthode de la cavité modifiée (Wolff), et la méthode RNA d'une antenne microbande sans gap d'air.

Cette figure montre également la correspondance existante entre nos résultats (RNA) et les résultats obtenus par la méthode de Wolff, ce qui donne une certaine crédibilité à nos résultats.

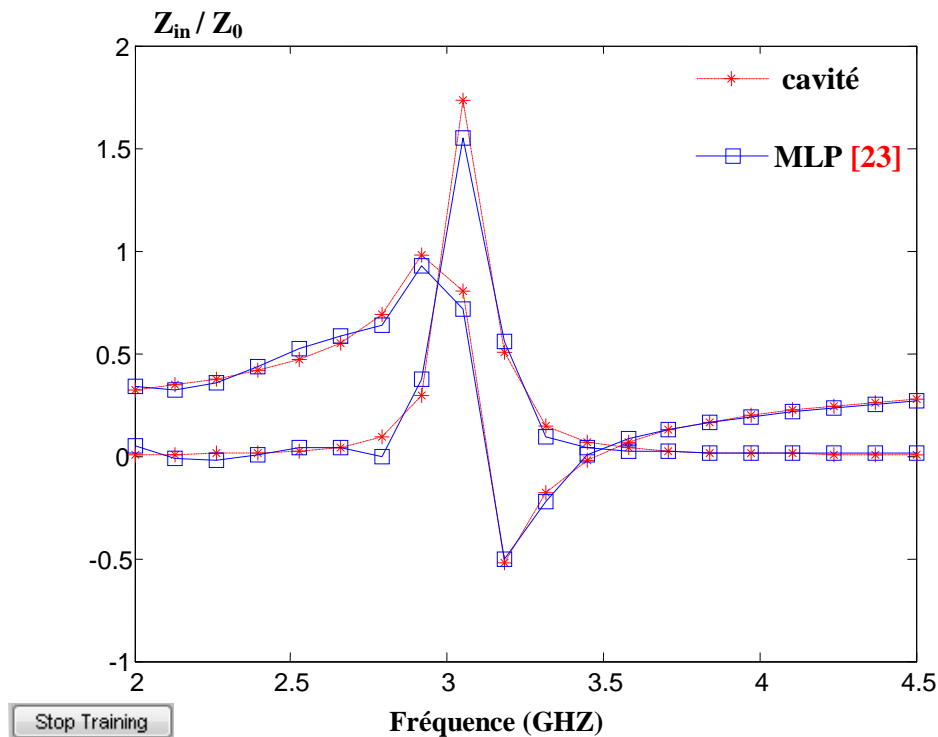


Figure II.7 Variation de l'impédance d'entrée normalisée d'une antenne microbande sans gap d'air en fonction de la fréquence. ($L=3.05\text{cm}$, $W=4.55\text{cm}$, $\text{tg}\delta = 0.001$, $d_0 = 0.127\text{cm}$, $H_D=0.14\text{cm}$, $X_0=0.54\text{cm}$ et $\epsilon_r = 2.33$).

II.5 Modélisation de l'antenne microbande avec gap d'air par RNA

Développement d'un PMC pour la modélisation

Nous prenons la même structure de la Figure II.4, avec la base de données différente. Notre choix d'apprentissage s'est porté sur un apprentissage supervisé. Pour cette phase d'apprentissage, nous présentons le domaine d'apprentissage qui est utilisé comme paramètre d'entrée du réseau dans le Tableau II.2. Cinq algorithmes d'apprentissage différents (LM, CGP[20], CGB[20], GDX[21], GDM[21]) décrits dans le Tableau II.3 sont utilisés. Pour le nombre d'itérations il faut choisir un nombre important permettant au réseau de bien s'organiser et d'adapter de mieux en mieux ses poids, dans notre cas il est de 500000 itérations.

W(cm)		L(cm)		tg δ		d ₀ (cm)		X ₀ (cm)	
MIN	MAX	MIN	MAX	MIN	MAX	MIN	MAX	MIN	MAX
2.7	20.45	1.7	13.8	0.001	0.003	0.03	0.13	0.12	0.71

Tableau II.2 Domaine de variation des entrées du réseau de neurones.

Le Tableau II.3 montre la variation de l'erreur d'apprentissage et de test du MLP en changeant l'algorithme d'apprentissage et le nombre de neurones dans la couche cachée. Nous remarquons que le changement de ces deux paramètres entraîne un changement de l'erreur. Par exemple, l'augmentation de l'erreur de test dans les deux bases de données est due à l'utilisation de l'algorithme GDX. Contrairement à l'algorithme LM, l'emploi de cette dernière implique une diminution remarquable des taux (d'apprentissage et de test), ceci est clairement vu dans le Tableau.


Algorithmes d'apprentissage	Nombre de neurone de la couche cachée	Erreur d'apprentissage	Erreur de test	Nombre d'itérations
LM (Levenberg-Marquardt)	11×8	0.0022	0.9037	26
CGP (Polak-Ribière)	15×20	0.0037	1.0812	476
CGB (Redémarrage Powell-Beale)	17×22	0.0035	1.0694	298
GDX (A pas variable)	19×25	0.0037	1.4538	5149
GDM (Descente de gradient par lot)	17×20	0.0032	1.0213	28528

Tableau II.3 Erreur d'apprentissage et de test pour les cinq algorithmes d'apprentissage.

● Résultats de simulation

Dans ce cas un gap d'air de hauteur $H_A = 0.5\text{mm}$ est choisi pour tracer l'impédance d'entrée normalisée en fonction de la fréquence. La Figure II.8 est tracée toujours par l'algorithme LM, car il présente des erreurs d'apprentissage et de test inférieures que les autres

algorithmes. Nous remarquons bien d'après la Figure II.8 la concordance entre le résultat obtenu par les deux méthodes : cavité et RNA.



Stop Training

Figure II.8 Variation de l'impédance d'entrée normalisée d'une antenne microbande avec gap d'air en fonction de la fréquence. ($L=4.14\text{cm}$, $W=6.858\text{cm}$, $\text{tg}\delta = 0.003$, $H_D= 0.1524\text{cm}$, $d_0 = 0.127\text{cm}$, $X_0=0\text{ cm}$ et $\epsilon_r = 2.5$).

II.6 Etude comparative

Dans ce paragraphe, nous gardons la même structure neuronale, pour comparer les résultats des impédances d'entrée obtenus par RNA avec ceux obtenus par la méthode de cavité modifiée pour une antenne sans gap d'air et avec gap d'air. L'impédance d'entrée est représentée en fonction de l'épaisseur du gap d'air pour trois valeurs $H_A=0\text{mm} - 0.5\text{mm} - 1\text{mm}$. La Figure II.9 montre qu'on peut ajuster l'épaisseur en air incluse pour avoir une


fréquence de résonance maximum de la structure. Nous avons trouvé que l'impédance d'entrée croît avec l'accroissement de la couche en air.

L'impédance d'entrée est représentée en fonction de l'épaisseur du gap d'air pour trois valeurs $H_A=0\text{mm} - 0.5\text{mm} - 1\text{mm}$. La Figure II.9 montre qu'on peut ajuster l'épaisseur en air incluse pour avoir une fréquence de résonance maximum de la structure. Nous avons trouvé que l'impédance d'entrée croît avec l'accroissement de la couche en air.


Un réseau neurologique est développé pour l'évaluation de la résistance résonante d'une antenne rectangulaire microruban à une alimentation coaxiale en fonction de la position d'alimentation. Un corpus d'entraînement : $L \in [11\text{cm}; 14\text{cm}]$, $W \in [18; 21]$, $\text{tg}(\delta) \in [0.001; 0.0035]$, $d_0 \in [0.065\text{cm}; 0.2\text{cm}]$ et $X_0 \in [0\text{cm}; 8\text{cm}]$, le nombre de neurones dans la couche cachée est 18×15 , seuil = 10^{-4} , momentum = 0.7. Le corpus de test est $L=13.97\text{cm}$, $W=20.45\text{cm}$, $H_D=0.1588\text{cm}$, $\text{tg}(\delta) = 0.003$, $d_0= 0.127\text{cm}$, $\epsilon_r = 2.3$.

D'après la Figure II.10 quand l'endroit d'alimentation augmente à partir du bord de rayonnement vers le centre de la plaque conductrice, la première crête de résonance (le maximum R_{in}) diminue jusqu'à ce qu'il atteigne des valeurs minimum au centre du patch, On constate cependant, que nos résultats sont en accord avec ceux publiés par [22]. L'effet de l'épaisseur du substrat sur la résistance résonante en fonction de la position d'alimentation est étudié. On constate que la résistance augmente lorsque H_A augmente.

La Figure II.11 montre la résistance résonante normalisée en fonction de la position d'excitation pour différentes valeurs de ϵ_r . Plus la permittivité ϵ_r est grande, plus la résistance résonante est haute. On a comme résultat après l'entraînement : erreur d'apprentissage = $6.3164e-4$, erreur de test = 0.9528.



-a-



-b-

Figure II.9 Variation de l'imp dance d'entr e normalis e d'une antenne microbande avec gap d'air en fonction de la fr quence. a- la partie r elle ; b- la partie imaginaire.




Figure II.10 Variation de la résistance résonante normalisée d'une antenne microbande avec gap d'air en fonction de la fréquence pour différentes valeurs de H_A en fonction de la position d'alimentation X_0 , mode (0,1).

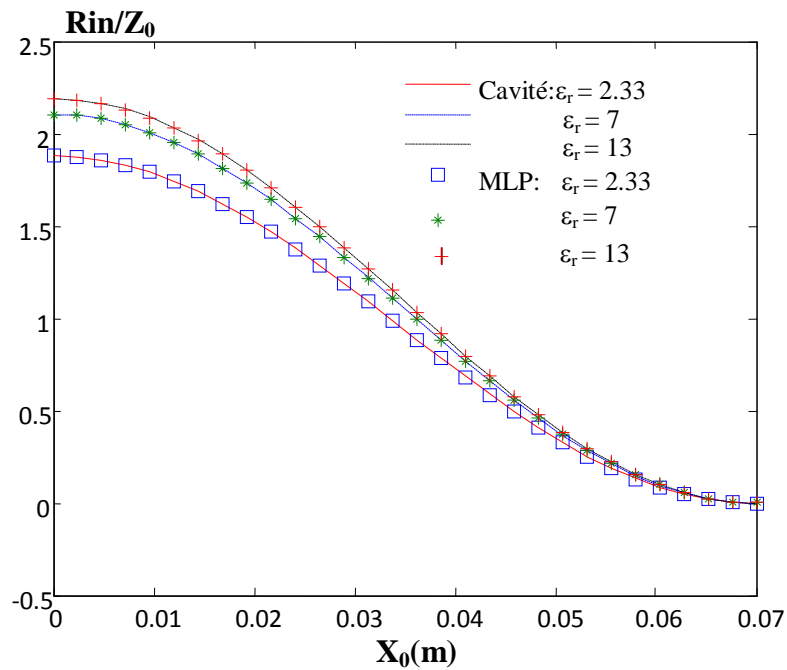


Figure II.11 Variation de la résistance résonante normalisée pour une antenne sans gap d'air pour différentes valeurs de ϵ_r en fonction de la position d'alimentation X_0 .

II.7 Modélisation des paramètres physiques de l'antenne sans gap d'air par RNA

Nous proposons une modification pour le modèle neuronal décrit dans la section précédente. Elle consiste à utiliser des paramètres dans le réseau qui n'ont pas été considérés dans le modèle précédent. Les sorties du réseau sont les paramètres géométriques (W , L , H), et l'entrée est la fréquence de résonance (Figure II.12). Les données d'entraînement sont générées grâce au calcul direct, soit 720 échantillons tirés de manière aléatoire dans ces plages de valeurs.




Figure II.12 Modèle neuronal des paramètres géométriques.

Il est évidemment possible de visualiser les performances du réseau pendant l'entraînement. De ce fait, on peut observer les courbes d'erreurs sur la Figure II.13 en fonction du nombre d'itérations. Sur cette figure, on peut distinguer les courbes d'erreur quadratique moyenne appelée aussi l'erreur d'apprentissage normalisée (MSE) sur les données d'entraînement (Train), de validation (Validation) et de test (Test). Différentes simulations ont été effectuées pour choisir les neurones cachés. On a constaté que 17×9 neurones étaient optimisés pour réaliser le minimum de l'erreur quadratique moyenne qui est 0.00015 sur les données d'entraînement, validation et de test comme le montre la Figure II.13-a, dans 2 époques avec le 'tansig' 'logsig' 'purelin' en tant que fonctions d'activation. La Figure (II.13-b) illustre l'EQM tracée en fonction du nombre des itérations. L'algorithme d'apprentissage est l'algorithme de Levenberg-Maquardt. L'apprentissage ne dure que quelques secondes.

Les paramètres statistiques pour évaluer les résultats obtenus dans les étapes d'apprentissage, de test et de validation du modèle neuronal sont montrés dans le Tableau II.4.

Nous avons aussi constaté qu'on avait en simulation des meilleures performances (E_{test} de l'ordre de 0.0086 pour un entraînement avec des données bruitées), c'est sur la base de cet exemple que nous procédons pour développer un réseau spécifique approprié à chaque domaine de validité.

De plus le Tableau II.4 donne une comparaison entre les paramètres géométriques calculés par RNA pour différentes valeurs de fréquences de résonances et celles données par la référence Aboud [13]. On peut dire que la performance globale de l'algorithme trainlm est satisfaisante.

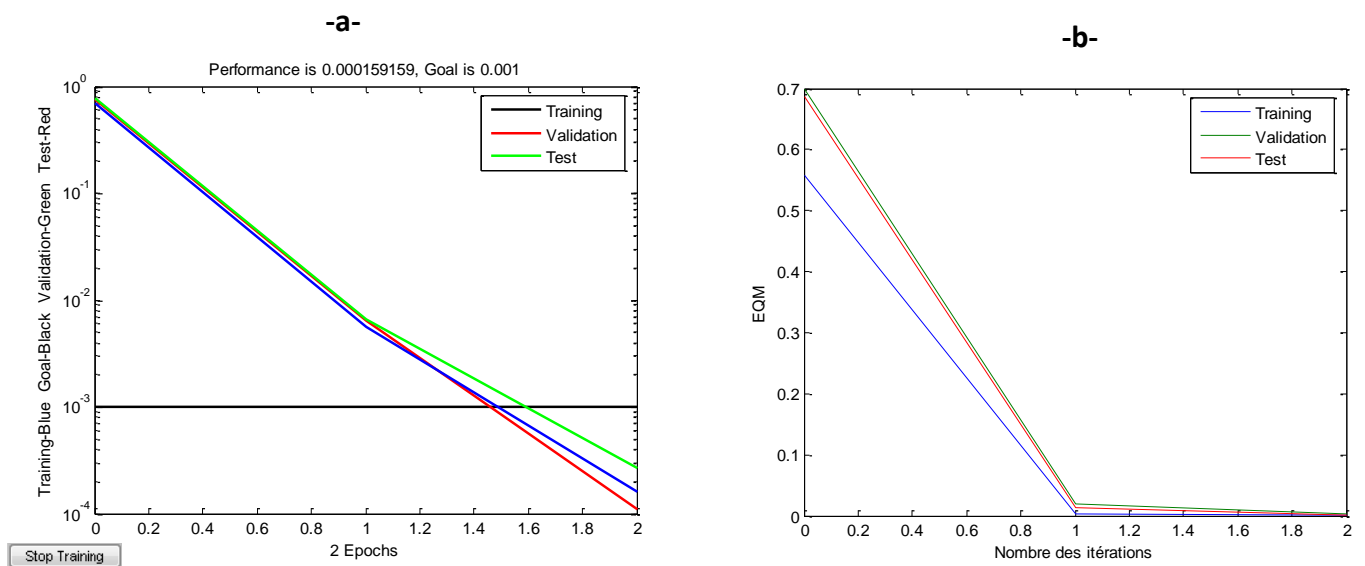


Figure II.13 Évolution de l'erreur quadratique moyenne au cours de l'apprentissage évaluée sur les corpus d'entraînement, de validation et de test jusqu'à l'arrêt de l'algorithme d'apprentissage par la méthode d'arrêt prématuré (algorithme LM).

La fréquence de résonance f_R (GHZ)	Performances		MLP (Nos Résultats)			Aboud [13]		
	Erreur d'apprentiss- age	Erreur de test	W (cm)	L (cm)	H (cm)	W (cm)	L (cm)	H (cm)
2.38	1.832e-4	0.198	5.74	3.82	0.3	5.7	3.8	0.3175
2.91	2.938e-4	0.194	4.56	3.09	0.82	4.55	3.05	0.1375
4.29	7.320e-6	0.197	2.95	1.95	0.32	2.95	1.95	0.3175
5.96	2.989e-4	0.201	1.88	1.29	0.32	1.95	1.3	0.3175
6.76	2.478e-4	0.202	1.72	1.09	0.3	1.7	1.1	0.3175
7.82	2.89e-4	0.203	1.42	0.96	0.33	1.4	0.9	0.3175
8.5	4.900e-5	0.204	1.2	0.8	0.32	1.2	0.8	0.3175
9.3	2.614e-4	0.205	1.08	0.72	0.28	1.05	0.7	0.3175
10.27	4.034e-4	0.206	0.88	0.54	0.27	0.9	0.6	0.3175
7.79	4.517e-5	0.202	1.7	1.11	0.14	1.7	1.1	0.1524

Tableau II.4 Comparaison des résultats obtenus par RNA et Aboud [13].

Pour l'antenne microbande avec gap d'air, on garde la même structure neuronale c-à-d le même nombre de couches, fonction d'activation,...etc. Le minimum de la valeur d'erreur moyenne est de 0.00061 sur les données d'entraînement, de validation et de test comme le montre la Figure II.14-a dans 9 époques.

La Figure (II.14-b) montre l'erreur quadratique moyenne en fonction du nombre d'itérations. Ces valeurs sont acceptables pour l'EQM en apprentissage, de validation et en test. Donc on peut conclure que la vitesse d'apprentissage dans le premier cas (2 époques) est due à l'utilisation d'un algorithme du second ordre LM.

Compte tenu qu'il n'ya pas de formule explicite et directe calculant les paramètres géométriques de l'antenne avec une bonne précision et du fait que la relation entre la fréquence de résonance et ces paramètres est hautement non linéaire, la modélisation inversée s'avère nécessaire.

Nous avons déterminés les paramètres (W, L, H) par RNA d'une antenne microbande avec gap d'air ($H_A = 1\text{mm}$) pour une fréquence prédéfinie (Tableau II.5). Nous avons également montré l'efficacité de la modélisation neuronale inversée.

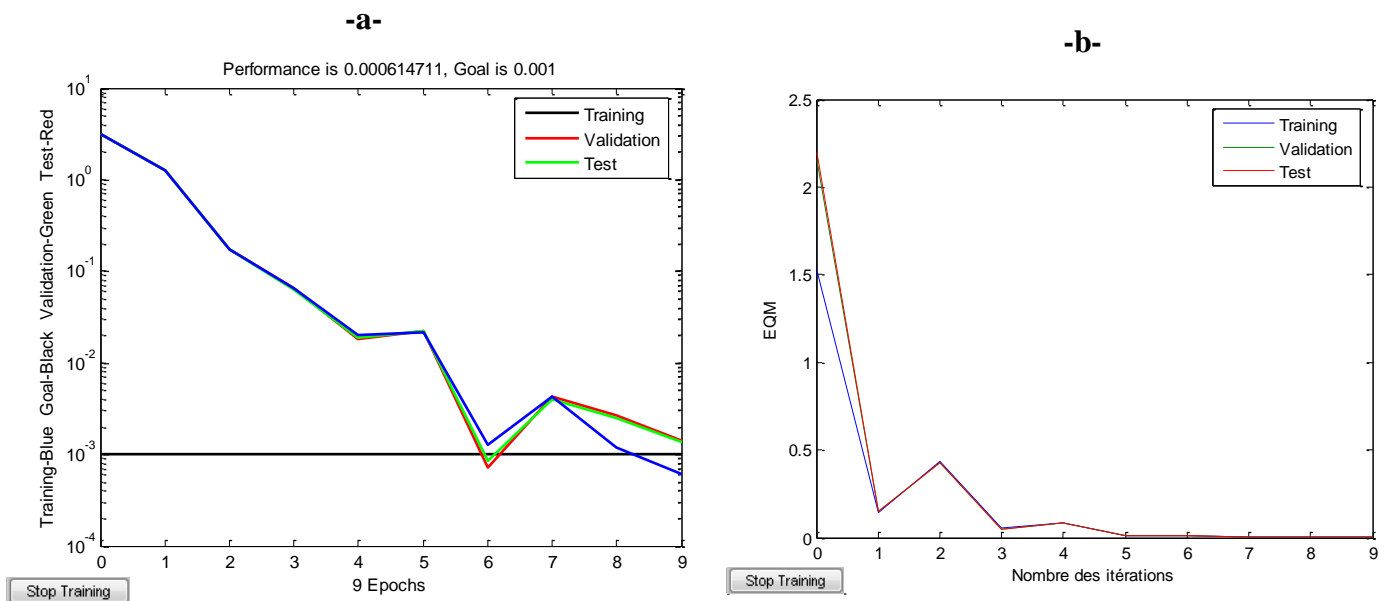


Figure II.14 Évolution de l'erreur quadratique moyenne au cours de l'apprentissage évaluée sur les corpus d'entraînement, de validation et de test jusqu'à l'arrêt de l'algorithme d'apprentissage par la méthode d'arrêt prématuré (algorithme RP).

La fréquence de résonance f_R (GHZ)	Performances		MLP (Nos Résultats)			Aboud [13]		
	Erreur d'apprentiss- age	Erreur de test	W (cm)	L (cm)	H (cm)	W (cm)	L (cm)	H (cm)
2.57	2.627e-4	0.016	5.57	3.82	0.39	5.7	3.8	0.3185
3.1	2.23e-19	0.012	4.55	3.05	0.32	4.55	3.05	0.3185
4.45	7.002e-4	0.012	2.83	2.04	0.35	2.95	1.95	0.3185
6.01	1.136e-5	0.014	1.95	1.3	0.32	1.95	1.3	0.3185
6.73	0.0026	0.015	1.6	1.15	0.61	1.7	1.1	0.3185
7.67	0.0026	0.016	1.3	0.95	0.61	1.4	0.9	0.3185
8.28	1.370e-5	0.016	1.2	0.8	0.32	1.2	0.8	0.3185
8.96	2.280e-4	0.017	1.04	0.7	0.32	1.05	0.7	0.3185
9.77	0.0014	0.018	0.92	0.79	0.57	0.9	0.6	0.3185
8.04	0.0046	0.015	2.01	1.4	0.18	1.7	1.1	0.1534

Tableau II.5 Comparaison des résultats obtenus par RNA et Aboud [13] de l'antenne avec gap d'air $H_A = 1$ mm.

II.8 Conclusion

Le modèle de la cavité modifiée (Wolff) d'une antenne avec gap d'air est présenté dans le but de calculer la fréquence de résonance et l'impédance d'entrée. Nous avons aussi donné le modèle de réseau de neurones artificiel (RNA), son fonctionnement et son utilisation dans l'apprentissage supervisé.

L'application de dix algorithmes d'optimisation sur les deux modèles neuronaux proposés dans ce chapitre, a conduit à une brève comparaison de ces algorithmes. Il apparaît que l'algorithme LM est plus performant en termes de précision. En plus, la précision obtenue dans les exemples a montré l'efficacité des RNA pour approcher des fonctions à partir des données d'apprentissage. Quand on compare les paramètres physiques donnés par [13] et ceux générés par le modèle neuronal on trouve un très bon accord entre les deux.

II. 9 Références

- [1] K.F. Lee, K. Y. Ho, J.S. Dahele, "*Circular-disk microstrip antenna with an air gap,*" IEEE Trans. Antennas Propat., vol.AP-32, pp.880-840, Aug. 1984.
- [2] W. C. Chew, Q. L. Liu, "*Resonance frequency of a rectangular microstrip patch,*" IEEE transactions on antennas and propagation, Vol. 36, No. 8, pp. 1045-1056, Aug. 1988.
- [3] F. Abboud, J.P. Damiano, A. Papierink, "*Simple model for the input impedance of coax-fed rectangular microstrip patch antenna for C.A.D,*" Proc.IEE, 135, pp.323-326, 1988.
- [4] J.R. James, A. Henderson, P. S. Hall, "*Microstrip antenna performance is determined by substrate constraints,*" Microwave System News, August, 73-84. 1982.
- [5] I.J. Bahl, P. Bhartia, "*Microstrip antennas,*" Ed. Artech House, 1980.
- [6] F. Abboud, J.P. Damiano, A. Papiernik, "*Rectangular microstrip antenna for CAD,*" IEEE Proceedings, Vol.135, Pt H, N°.5, pp. 323-326, October 1988.

- [7] E. H. Newman, P. Tylyathan, "*Analysis of microstrip antennas using moment methods*," IEEE Transaction on Antennas and Propagations, Vol. AP-29, N°. 1, pp. 47-53, January 1989.
- [8] I. Wolff, N. Knoppik, "*Rectangular and circular microstrip disk capacitors and resonators*," *IEEE Trans*, MIT-22, pp.857-864, 1974.
- [9] A. Aussem, "*Théorie et applications des réseaux de neurones récurrents et dynamiques à la prédiction, à la modélisation et au contrôle adaptatif des processus dynamiques*," Thèse de doctorat, Université de Paris 05, 1995.
- [10] G. Cybenko, "*Approximation by superpositions of sigmoidal function. Mathematics of Control, Signals and Systems*," 303–314, 1989.
- [11] K. Funuhashi, "*On the approximate realization of continuous mapping by neural networks*," *Neural Networks*, 2 :183–192, 1989.
- [12] H. Acikgoz, Y. Le Bihan, O. Meyer, L. Pichon. "*Microwave characterization of dielectric materials using bayesian neural networks*," *Progress in Electromagnetics Research*, C3:169–182, 2008.
- [13] F. Abboud, J.P. Damiano, A. Papiernik, "*Accurate Model For The Input Impedance Of Coax-Fed Rectangular Microstrip Antenna With And Without Airgaps*," pp.102-106, 1989.
- [14] R. Battiti, "*First and second order methods for learning: Between steepest descent and Newton's method*," *Neural Computation*, Vol. 4, No. 2, pp. 141–166, 1992.
- [15] J. E. Dennis, R. B. Schnabel, "*Numerical Methods for Unconstrained Optimization and Nonlinear Equations*," (Prentice-Hall, Englewood Cliffs, N.J., 1983; Mir, Moscow, 1988).

- [16] M. F. Moller, "A *scaled conjugate gradient algorithm for fast supervised learning*," *Neural Networks*, Vol. 6, pp. 525–533, 1993.
- [17] R. Fletcher, C. M. Reeves, "*Function minimization by conjugate gradients*," *Computer Journal*, Vol. 7, pp. 149–154, 1964.
- [18] M. Riedmiller, H. Braun, in Proc. IEEE Int. Conf. "*On Neural Networks*," San Francisco, March, Vol. 1, p. 586, 1993.
- [19] M. T. Hagan, H. B. Demuth, M. Beale, "*Neural Network Design*," (PWS Publish. Comp), Boston, 1996.
- [20] M. J. D. Powell, "*Restart procedures for the conjugate gradient method*," *Mathematical Programming*, Vol. 12, pp. 241–254, 1977.
- [21] E. M. L. Beale, "*A Derivation of Conjugate Gradients, Numerical Methods for Nonlinear Optimization*," Academic, London, 1972.
- [22] W.F. Richards, Y.T. Lo, D.D. Harrison, "*An improved theory for microstrip antennas and applications*," *IEEE Trans. Antennas Propag*, 29, (1), pp. 38–46, 1981.
- [23] K.Chemachema, A. Benghalia, "*Input Impedance of coax-fed Rectangular Microstrip Antenna with and without Airgaps Using Various Algorithm*," *PIERS 2011*, March 2011, Marrakesh-Morroco.

CHAPITRE III

MODÉLISATION D'UNE ANTENNE MICROBANDE COUPLÉE À UNE FENTE PAR TLM/RNA

III.1 Introduction


Dans ce chapitre nous présentons dans un premier temps l'outil d'analyse d'une antenne microbande rectangulaire couplée par fente, noté TLM. Nous analyserons le cas où le couplage s'effectue à l'aide d'une simple fente orientée de façon perpendiculaire à la ligne de transmission, ainsi qu'une étude de l'influence des différents paramètres géométriques sur ce couplage.

Dans un second temps, les perceptrons multicouches seront présentés, permettant de modéliser l'impédance et le coefficient de réflexion afin d'obtenir des résultats satisfaisants.

III.2 Application du modèle de la ligne de transmission sur l'antenne rectangulaire patch couplée à une fente

III.2.1 Description de l'antenne rectangulaire microbande couplée à une fente

Au lieu d'alimenter l'antenne directement au moyen d'une ligne micro-ruban ou d'un câble coaxial, on effectue un couplage électromagnétique à l'aide d'une fente Figure III.1 [1]. Ce qui est très avantageux pour les conceptions à hautes fréquences. La fente est couplée à une ligne micro-ruban située sur un substrat différent de celui de l'antenne. La quantité de ce couplage est déterminée par la forme, la taille et l'emplacement de l'ouverture; le rayonnement parasite est minimisé. Cette fente est généralement centrée par rapport au patch où le champ magnétique est maximum. Comme une antenne et une ligne micro-ruban requièrent des caractéristiques de substrats différents [2], on peut choisir un substrat optimal pour chacun des deux. Le substrat d'antenne doit être de faible permittivité et de grande épaisseur pour obtenir une bonne largeur de bande. Pour avoir une bonne performance du mode guidé, le substrat de la ligne doit être mince et posséder une grande permittivité.



a- fente rectangulaire

b- fente de forme H

Figure III.1 Antenne microbande couplée par fente.

Deux mécanismes de couplage très semblables sont créés, l'un entre la ligne d'alimentation et la fente et l'autre entre la fente et l'élément rayonnant. Les inconvénients majeurs de cette technique sont les difficultés rencontrées lors de sa réalisation, et sa largeur étroite de bande [3].

III.2.2 Le modèle de la ligne de transmission d'une antenne microbande couplée par fente

L'antenne couplée par fente peut être modélisée à l'aide d'impédances, de transformateurs et de lignes de transmission [4]. La Figure III.2 nous montre le schéma complet de cette modélisation. L'antenne microbande est modélisée par deux lignes d'impédance caractéristique Z_0 terminées par une capacité de bout de ligne (B) et d'une conductance de rayonnement (G). Le couplage entre la fente et l'antenne ainsi que celui entre la ligne et la

fente sont représentés respectivement par les rapports de transformation n_1 et n_2 . La fente rectangulaire est modélisée par une simple impédance Z_{ap} et la ligne micro-ruban par un bout de ligne d'impédance caractéristique Z_{om} terminée par un circuit-ouvert.




Figure III.2 Modèle en ligne de transmission d'une antenne microbande couplée par fente [4].

La fente interrompt l'écoulement courant longitudinal dans la ligne d'alimentation et la pièce conductrice, ayant pour résultat un accouplement entre elles. L'accouplement entre la plaque conductrice, ouverture, et la ligne d'alimentation peut être décrit par deux transformateurs d'impédance. Le premier transformateur n_1 : représente le rapport de transformation entre l'antenne et la fente. Ce rapport est égal à la fraction du courant (dirigé principalement selon x) qui passe au-dessus de la fente (du plan de masse) par rapport à la largeur totale de l'antenne. Ce courant recueilli par la fente correspond au couplage entre les deux structures. Le rapport de transformation est donc donné par [5]:

$$n_1 = \frac{L_{ap}}{W} \quad (\text{III. 1})$$

Le deuxième transformateur n_2 est calculé [6] en utilisant la grandeur de la tension dans la fente (V_0) et la discontinuité de la tension sur la ligne microruban (ΔV) :

$$n_2 = \frac{\Delta V}{V_0} = \frac{J_0\left(\frac{k_{es} W_f}{2}\right) J_0\left(\frac{k_{em} W_{ap}}{2}\right)}{k_{es}^2 + k_{em}^2} \left[\frac{k_{em}^2 k_2 \epsilon_{rf}}{k_2 \epsilon_{rf} \cos k_1 d_p - k_1 \sin k_1 d_p} + \frac{k_{es}^2 k_1}{k_2 \cos k_1 d_p - k_1 \sin k_1 d_p} \right] \tag{III. 2}$$

$$k_1 = k_0 \sqrt{|\epsilon_{r1} - \epsilon_{effs} - \epsilon_{effm}|} \tag{III. 3}$$

$$k_2 = k_0 \sqrt{|\epsilon_{effs} + \epsilon_{effm} - 1|} \tag{III. 4}$$

$$k_{es} = k_0 \sqrt{\epsilon_{effs}} ; \quad k_{em} = k_0 \sqrt{\epsilon_{effm}} \tag{III. 5}$$

Avec : $k_0 = 2\pi/\lambda_0$; λ_0 est la longueur d'onde dans le vide.

Où ϵ_{effs} est la permittivité effective de la fente et ϵ_{effm} est la permittivité effective de la ligne d'alimentation. Elles sont calculées par l'équation :

$$\epsilon_{eff} = \frac{\epsilon_r + 1}{2} + \frac{\epsilon_r - 1}{2} \left(1 + 12 \frac{h}{W}\right)^{-1/2} \tag{III. 6}$$

La fréquence de résonance est donnée par :

$$f_0 = \frac{c}{2L_{eff} \sqrt{\epsilon_{eff}}} \tag{III. 7}$$

a) Modélisation de la plaque conductrice

Le circuit équivalent de la plaque conductrice est montré ci-dessous (Figure III.3):




Figure III.3 Circuit équivalent de la plaque conductrice.

L'impédance du patch est donnée par :

$$Z_{\text{patch}} = Z_1 + Z_2 = \frac{1}{Y_1} + \frac{1}{Y_2} \quad (\text{III. 8})$$

Où

$$Y_1 = Y_0 \frac{(G_s + jB_s) + jY_0 \tan(k_0 L_1)}{Y_0 + j(G_s + jB_s) \tan(k_0 L_1)} \quad (\text{III. 9})$$

$$Y_2 = Y_0 \frac{(G_s + jB_s) + jY_0 \tan(k_0 L_2)}{Y_0 + j(G_s + jB_s) \tan(k_0 L_2)} \quad (\text{III. 10})$$

La conductance G_s et la susceptance B_s sont calculées par :

$$G_s = \frac{W}{120\lambda_0} \left[1 - \frac{1}{24} (k_0 h)^2 \right] \quad (\text{III. 11})$$

$$B_s = \frac{W}{120\lambda_0} [1 - 0.636 \ln(k_0 h)] \quad (\text{III. 12})$$

Où λ_0 est la longueur d'onde dans le vide.

Y_0 est l'admittance caractéristique de la ligne :

$$Y_0 = \left[\frac{120\pi}{\epsilon_{\text{reff}}} \ln \left\{ \frac{W_{\text{feff}}}{h_1} + 1.393 + 0.667 \ln \left[\frac{W_{\text{feff}}}{h_1} + 1.44 \right] \right\}^{-1} \right]^{-1}$$

pour $W_f/h_1 \geq 1$ (III. 13)

b) Modélisation de la fente dans le plan de masse et calcul de l'impédance d'entrée globale (Z_{in})

La valeur de l'admittance de la fente (Y_{ap}) est obtenue par la mise en parallèle de deux lignes de transmission court-circuitées, pour la forme rectangulaire on a:

$$Y_{ap} = -2jY_{os} \cot\left(\frac{K_{es} L_{ap}}{2}\right) \quad (\text{III. 14})$$

Et l'impédance de la fente du forme H est donnée par:

$$Y_{ap} = 2jY_{os} \frac{-\frac{Y_{os}}{2} \cot\left(\frac{k_{es} L_h}{2}\right) + Y_{os} \tan\left(\frac{k_{es} L_{ap}}{2}\right)}{Y_{os} + \frac{Y_{os}}{2} \cot\left(\frac{k_{es} L_h}{2}\right) \tan\left(\frac{k_{es} L_{ap}}{2}\right)} \quad (\text{III. 15})$$

La valeur de l'admittance caractéristique de la fente (Y_{os}) est obtenue par la méthode de Cohn [7] (Annexe B).

L'impédance d'entrée est définie par la méthode de la ligne de transmission comme suit:

$$Z_{in} = \frac{n_2^2}{n_1^2 Y_{patch} + Y_{ap}} - jZ_{om} \cot(k_{em} L_s) \quad (\text{III. 17})$$

Le coefficient de réflexion est donné par :

$$S_{11} = 20 \log_{10} \left(\frac{Z_{in} - Z_{om}}{Z_{in} + Z_{om}} \right) \quad (\text{III. 18})$$

Où Z_{om} est l'impédance caractéristique de la ligne d'alimentation.

III.3 Modélisation neuronale de l'antenne microbande couplée par une fente rectangulaire

III.3.1 Le modèle neuronale de l'impédance d'entrée

Phase d'apprentissage et validation

Le modèle neuronale utilisé pour le calcul de l'impédance d'entrée de l'antenne microbande couplée par ouverture rectangulaire est illustré sur la Figure III.4. Les neurones dans la couche d'entrée sont les paramètres L , W , L_{ap} , W_{ap} , l_s , et W_f . Ils agissent seulement en tant qu'amortisseurs pour distribuer les signaux d'entrée aux neurones dans la couche cachée. Les neurones dans la couche de sortie sont les parties réelle et imaginaire de l'impédance d'entrée R_{in} et X_{in} .

Les fonctions de transfert des couches cachées utilisent la fonction de sigmoïde (SF) par contre, la couche de sortie se base sur la fonction de transfert linéaire (LF). Les algorithmes appliqués dans ce cas sont: LM Trainlm - Levenberg-Marquardt, BFG trainbfg - quasi-Newton backpropagation, RP trainrp - Resilient Backpropagation, SCG trainscg -

Scaled Conjugate Gradient, CGF traincgr - Fletcher-Powell Conjugate Gradient, CGP traincgp- conjugate gradient of Polak–Ribière (CGPR).




Figure III.4 Structure neuronale utilisée pour calculer l'impédance d'entrée d'une antenne microbande couplée par fente rectangulaire.

Le nombre de neurones dans la 1^{ère} couche cachée est 16 et 18 neurones dans la 2^{ème} couche cachée. Le réseau, avant d'être utilisé, doit tout d'abord être entraîné sur un corpus d'entraînement ayant un nombre assez représentatif du comportement système à modéliser. Pour chaque perceptron que nous avons développé, nous avons constitué 640 exemples de couples de vecteurs Entrées/Sorties. Le seuil est égal à 0.00001 et un nombre d'itérations est de l'ordre de 400000. La base d'apprentissage est donnée par le Tableau III.1.

Paramètres d'entrée	Valeurs minimum	Valeurs maximum
W (cm)	3.1	4.9
L (cm)	3.9	4.7
L_{ap} (cm)	1.22	2
W_{ap} (mm)	1.22	1.7
l_s (cm)	1.8	2.5
W_f (cm)	0.4	0.75

Tableau III.1 Domaine de variation des entrées du réseau de neurones.

Résultats de simulation

La Figure III.5 représente l'impédance d'entrée d'une antenne microbande couplée par fente rectangulaire pour les entrées de test respectives $W = 4\text{cm}$, $L = 3\text{cm}$, $W_{ap} = 1.55\text{ mm}$, $\epsilon_r = 2.54$, $W_f = 0.495\text{cm}$, $L_s = 2\text{cm}$. L'algorithme d'apprentissage est LM. Nous avons effectué une comparaison entre nos résultats et ceux de [8] calculés aussi par la méthode TLM. On constate un bon accord entre les deux.




Figure III.5 Variation de l'impédance d'entrée d'une antenne microbande couplée par fente rectangulaire en fonction de la fréquence.

L'un des paramètres essentiels qui permettent de juger sur la validation d'un réseau de neurone réalisé, est la corrélation entre les deux sorties: celle obtenue par le réseau et celle désirée et ceci pour les deux ensembles : l'ensemble d'apprentissage et l'ensemble de validation. Un moyen de faire cela est d'effectuer la *régression linéaire* (Annexe A).

La Figure III.6 montre cette caractéristique pour l'impédance d'entrée. Cette figure montre bien que les deux résultats (sorties) sont presque identiques soit pour l'ensemble d'apprentissage ou celui de validation.




Figure III.6 Corrélation de Z_{in} (RNA) et Z_{in} (désirée) pour l'ensemble d'apprentissage.

III.3.2 Influence des différents paramètres de la structure alimentée par fente rectangulaire

● La longueur de l'ouverture L_{ap}

Dans ce cas il est choisi cinq neurones dans la couche d'entrée (L , W , W_{ap} , l_s , et W_f) pour étudier l'influence du premier paramètre L_{ap} qui influe sur l'impédance d'entrée d'une antenne couplée à une fente rectangulaire. (13×19) neurones dans la couche cachée ont permis une bonne convergence de l'algorithme et une bonne précision du modèle neuronal.

Une base de données, composée de 280 exemples est subdivisée par la suite entre un ensemble de test et un autre d'apprentissage. Les deux bases de données, ainsi obtenues, doivent impérativement couvrir tout l'espace de fonctionnement.

La Figure III.7 représente l'évolution de fonction d'erreur pendant la phase d'apprentissage par l'algorithme BFG qui illustre la convergence du réseau de neurones par rapport au fichier d'apprentissage.






Figure III.7 Estimation de l'erreur durant la phase d'apprentissage (trainbfg).

Les courbes de la Figure III.8 sont tracées pour différentes longueurs de l'ouverture rectangulaire d'une antenne microruban décrite précédemment, et par les deux approches neuronales et TLM.

On constate que croître la longueur de l'ouverture a pour effet d'augmenter l'impédance d'entrée. On peut dire que la méthode numérique basée sur le réseau de neurones nous permet d'avoir dans la plupart des cas une solution qui s'approche de celle désirée avec un temps de calcul instantané.



-a-



-b-

Figure III.8 Variation de l'impédance d'entrée d'une antenne microbande couplée par fente rectangulaire en fonction de la fréquence pour différentes valeurs de L_{ap} ;
 a- la partie réelle, b-la partie imaginaire.

● Largeur de l'ouverture W_{ap}

Pour le cas de l'influence de la largeur de l'ouverture nous avons utilisé cinq neurones à l'entrée (L , W , L_{ap} , l_s , et W_f), (17×19) nombre de neurones dans la couche cachée et deux neurones à la sortie (R_{in} et X_{in}). Cette architecture a permis une bonne convergence de l'algorithme LM (Figure (III.9)) et une bonne précision du modèle neuronal. Les fonctions d'activation sont la fonction de sigmoïde (SF) pour l'entrée et la fonction linéaire (LF) pour la sortie. Le fichier d'apprentissage comprend 350 exemples cette fois ci.

Les courbes de la Figure III.10 représentent l'impédance d'entrée pour le même exemple de la section précédente, simulée par la ligne de transmission et les RNA. En changeant la largeur de l'ouverture W_{ap} , on constate dans ce cas aussi que l'augmentation de la largeur de l'ouverture augmente le couplage.


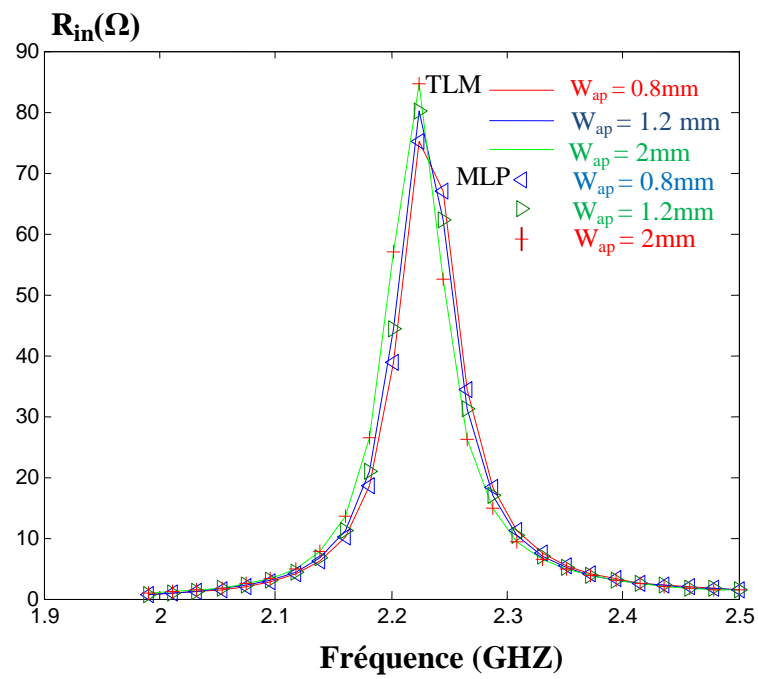



Figure III.9 Estimation de l'erreur durant la phase d'apprentissage (trainlm).



-a-



-b-

Figure III.10 Variation de l'impédance d'entrée d'une antenne microbande couplée par fente rectangulaire en fonction de la fréquence pour différentes valeurs de W_{ap} ;

a- la partie réelle, b- la partie imaginaire.

● La forme d'ouverture

Dans le cas de l'influence de la forme de l'ouverture cinq neurones à l'entrée (L , W , L_{ap} , l_s , et W_f), (13×10) nombre de neurones dans la couche cachée et deux neurones à la sortie (R_{in} et X_{in}), l'algorithme CGF (Figure III.11) est utilisé dans cette phase. Les fonctions d'activation sont la fonction de sigmoïde (SF) pour l'entrée et la fonction linéaire (LF) pour la sortie. Le corpus d'apprentissage comprend 320 exemples, le seuil est égale 0.01.

La forme de l'ouverture de couplage a un impact significatif sur le niveau de couplage entre l'alimentation et l'élément rayonnant.

L'ouverture rectangulaire est utilisée en général dans le couplage des antennes microrubans, et elle donne un bon couplage par rapport à l'ouverture circulaire. Depuis la première proposition de l'alimentation d'une antenne microruban par couplage à travers une ouverture, il y a eu plusieurs formes géométriques qui ont été suggérées.

En général les ouvertures qui existent dans ce types d'antennes sont: « os de chien » (dogbone), nœud de papillon (bowtie), la forme « H », la forme « L », ou la forme « U », et elles peuvent améliorer le couplage et diminuer les parasites pour une antenne microruban rectangulaire [10], [11], [12].






Figure III.11 Performance du réseau RNA avec la fonction traincgf.

La Figure (III.12) montre une parfaite concordance entre la sortie des RNA et la sortie désirée, et on remarque aussi que l'ouverture de forme « H » donne un meilleur couplage par rapport à la forme rectangulaire.



-a-



-b-

Figure III.12 Variation de l'impédance d'entrée d'une antenne microbande couplée par fente rectangulaire en fonction de la fréquence pour différentes formes d'ouverture ; a-la partie réelle, b-la partie imaginaire.

● Largeur de la ligne d'alimentation W_f

Pour ce cas il est utilisée l'algorithme SCG (Figure III.13) qui présente 146143 itérations pendant la phase d'apprentissage, pour un seuil de 0.001 et (14×11) neurones dans la couche cachée. La largeur de la ligne d'alimentation affecte le couplage par ouverture. On remarque d'après la Figure III.14 que plus la ligne est moins large, plus le couplage de l'ouverture est plus efficace [13].


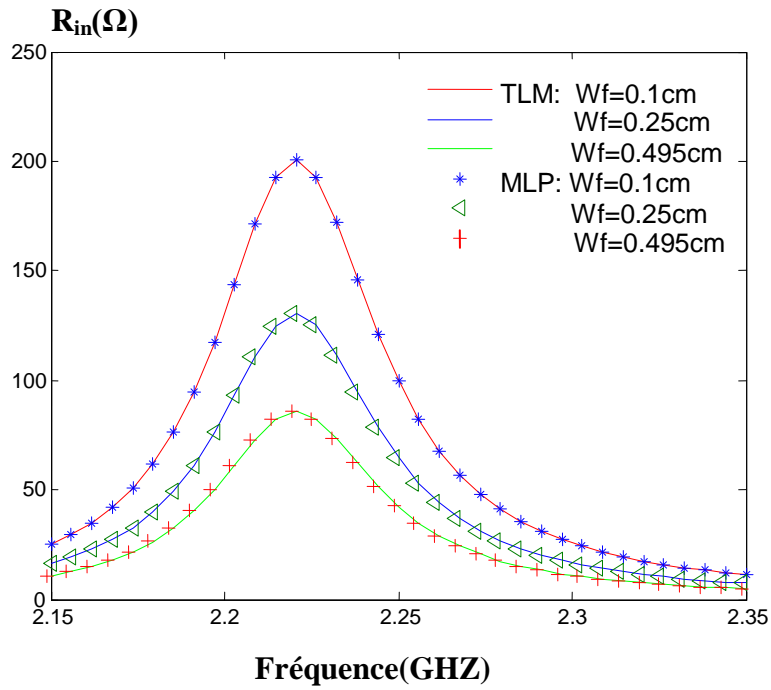



Figure III.13 Performance du réseau RNA avec la fonction trainscg.



-a-



-b-

Figure III.14 Variation de l'impédance d'entrée d'une antenne microbande couplée par fente rectangulaire en fonction de la fréquence pour différentes valeurs de W_f ; a- la partie réelle, b- la partie imaginaire.

III.4 Le modèle neuronale du coefficient de réflexion

● Elaboration des données, algorithme et paramètres d'apprentissage

Pour la synthèse du coefficient de réflexion nous avons utilisé cinq neurones à l'entrée et un neurone à la sortie (Figure III.15). Cette architecture a permis une bonne convergence de l'algorithme LM et une bonne précision du modèle neuronal. Le neurone utilisé dans ce réseau est le neurone non linéaire continu dont la fonction d'activation est une fonction sigmoïde.




Figure III.15 Modèle neuronal du coefficient de réflexion.

L'ensemble d'entraînement est 480, et permet de couvrir l'ensemble du domaine de variation des entrées et des sorties du réseau (Tableau III.2).

Paramètres d'entrée	Valeurs minimum	Valeurs maximum
f/f_r	1.07	1.8
h_1 (cm)	0.09	0.17
h_2 (cm)	0.08	0.18
ϵ_{r1}	1	4
ϵ_{r2}	2	6

Tableau III.2 Domaine de variation des variables.

● Résultats de simulation

Le coefficient de réflexion en fonction de la longueur de fente est présenté par la Figure III.16, Il est observé pour chaque largeur de fente qu'il y a une longueur optimum pour l'accouplement. La longueur optimum de fente diminue lorsque la largeur de fente augmente. Pour la gamme considérée de la longueur de fente, le coefficient de réflexion change entre ~ 0 dB et ~ -10.39 dB. Pour la largeur $W_{ap} \geq 0.6$ mm, l'accouplement maximum se produit à la longueur de fente de 10.5 mm. Par conséquent, l'accouplement optimum peut être obtenu en ajustant la longueur de fente. Les trois courbes montrent bien que les deux résultats (TLM et RNA) sont presque identiques.




Figure III.16 Variation du coefficient de réflexion en fonction de la longueur L_{ap} pour différentes valeurs de W_{ap} .

L'apprentissage ne dure que 2 secondes. Il est 65 fois inférieur au temps enregistré par les autres algorithmes. Dans le cas de 17×9 et 22×10 neurones le temps nécessaire à l'apprentissage est de 7 et 10 secondes respectivement. Un bon apprentissage est atteint lorsque l'erreur d'apprentissage et celle de test sont petites (Tableau III.3).

Algorithmes d'apprentissage	Nombre de neurone de la couche cachée	mse	Erreur D'apprentissage	Erreur de test	Nombre d'itérations
LM	15×5	7.846e-5	2.2287e-5	0.2079	56
OSS	11×19	9.994e-5	0.0011	0.5388	217209
BFG	18×12	9.734e-5	0.0012	0.2390	471
SCG	22×25	9.999e-5	0.0013	0.7995	5512
RP	25×17	9.998e-5	0.0011	0.4283	5023
CGB	26×20	9.955e-5	0.0012	0.8779	3825

Tableaux III.3 La comparaison de l'effet d'apprentissage dans différents algorithmes.

Nous avons également représenté la variation de l'erreur d'apprentissage en fonction du nombre d'itération (algorithme LM) sur la Figure III.17.




Figure III.17 Performance du réseau RNA avec la fonction trainlm.

III.5 Conclusion

Dans ce chapitre, nous avons étudié l'influence des différents paramètres de l'alimentation par ouverture sur l'impédance d'entrée, et nous avons conclu que : les dimensions de l'ouverture, la forme de l'ouverture et la largeur de la ligne d'alimentation ont une grande influence sur le couplage. Après l'analyse de l'impédance d'entrée et le coefficient de réflexion par la méthode neuronale et TLM nous constatons que la différence entre les résultats obtenus est relativement négligeable.

Cette efficacité a été prouvée via la modélisation des modèles neuronaux issus de différents algorithmes d'apprentissage en occurrence ceux mis à disposition par les concepteurs de matlab toolbox.

Les résultats concernant l'impédance d'entrée et le coefficient de réflexion obtenus sont comparés à ceux publiés dans la littérature [8].

III. 6 Références

- [1] D. M. Pozar, "*Microstrip Antenna Aperture-Coupled to a Microstripline*," Electronics Letters. 2, 49-50, 1985 Janvier.
- [2] J.F. Zgrcher, F.E. Gardiol, "*Broadband Patch Antennas*," Artech House, Norwood, MA, 1995.
- [3] Jean-François Blain, Thèse de doctorat, "*Conception et Fabrication d'antennes microrunas couplées par fentes permettant une polarisation circulaire variable*," Université de Montréal 1999.
- [4] M. Himidi, J.P. Daniel, C.Terret, "*Transmission Line Analysis of Aperture-Coupled Microstrip Antenna*", Electron. Lett., Vol. 25, 1989.
- [5] B.N. Das, K.K. Joshi, "*Impedance of a Radiating Slot in the Ground Plane of a Microstripline*," IEEE Trans. Antenna and Propagation, Vol. AP-30, 1982.
- [6] D.M. Pozar, "*A Reciprocity Method of the Analysis for Printed Slot and Slot-Coupled Microstrip antennas. Microstripline*,". IEEE Transactions on Antennas and Propagation, AP-34, 1439-1446,1986.

- [7] S.B. Cohn, "*Slot Line on a Dielectric Substrate*," IEEE Transactions on microwave Theory and Techniques, MTT-17, 768-778, 1969.
- [8] J. P. Daniel, G Dubost, C. Terret, J. Citerne, M. Driss, "*Research on planar antennas and arrays*," IEEE Antennas and Propagation Magazine, 35, pp. 14-38, February 1993.
- [9] K. Chemachema, A. Benghalia, "*Neural models for Input Impedance of Aperture Coupled Rectangular Patch Antenna*," International Review of Aerospace Engineering, Vol. 5, N. 3, June 2012.
- [10] Z. Aijaz, S.C. Shrivastava, "*An Introduction of Aperture Coupled Microstrip Slot Antenna*," International Journal of Engineering Science and Technology, vol.2(1), pp.36-39, 2010.
- [11] D.M. Pozar, S.D. Targonski, "*Improved coupling for aperture coupled microstrip antennas*," Electronics Letters, vol.27, n°13, pp. 1129-1130, 1991.
- [12] Ke. Shyh-Yeong, Mil. Acad, Kaohsiung, "*Broadband proximity-coupled microstrip antennas with an H-shaped slot in the ground plane*,"; Antennas and Propagation Society International Symposium, vol.2, pp.530-533, 2002.
- [13] M. D. Pozar, "*A review of aperture coupled microstrip antenna : history, operation, development, and Applications*," Electrical and Computer Engineering, University of Massachusetts at Amherst, MA 01003, 1996.

CHAPITRE IV

MODÉLISATION D'UNE ANTENNE MICROBANDE COUPLÉE PAR PROXIMITÉ PAR TLM/RBF

IV.1 Introduction

Dans ce chapitre, nous détaillons la méthode d'analyse TLM améliorée [1] utilisée pour déterminer l'impédance d'entrée et le coefficient de réflexion d'une antenne couplée par proximité à une ligne microruban. Cette phase d'analyse est une étape primordiale pour offrir des données aux réseaux RBF comme étape d'apprentissage.

Deux programmes de simulation ont été développés afin de pouvoir comparer le modèle théorique TLM et RBF. Nous présentons l'ensemble des résultats issus de la simulation afin de permettre une comparaison claire entre le perceptron MLP et RBF.

Enfin, nous exposons le modèle neuronal adopté dans nos propres démarches de modélisation, qui est le réseau GRNN dans le calcul du coefficient de réflexion d'une antenne microbande couplée par proximité.

IV.2 Modélisation d'une antenne alimentée (couplée) par proximité par la méthode de la ligne de transmission (TLM) améliorée

IV.2.1 Description de l'antenne couplée par proximité

L'antenne microbande couplée par proximité se compose de deux couches: la couche d'alimentation qui est une ligne microruban de 50Ω avec un plan de masse et la couche supérieure qui contient le patch rayonnant (Figure IV.1). La ligne d'alimentation est encastrée par la distance L_2 de l'extrémité du patch. C'est ce chevauchement (les modes d'expansion) qui fournit la continuité du flux du courant de la ligne d'alimentation au patch.

Le niveau du couplage peut être ajusté en changeant la longueur de la distance L_2 de chevauchement G . Splitt et al, [2]. L'antenne microbande peut être analysée sans tenir compte du couplage qui a lieu, par la méthode de la ligne de transmission [3],[4]. Cependant,

des améliorations doivent être apportées, pour déterminer l'impédance d'entrée de l'antenne en appliquant le modèle de la ligne de transmission améliorée qui a été proposé dans [5],[6].




Figure IV. 1 Antenne microbande rectangulaire alimentée par proximité à une ligne de transmission.

Ce modèle est basé sur le concept de l'effet de fente équivalente ouverte, en utilisant des expressions liées à la fréquence. Le mécanisme de rayonnement dans le patch est expliqué par une paire de fentes de rayonnement (Figure IV.2.a).

Le patch est représenté par une ligne de transmission de longueur L séparée par deux fentes de rayonnement, qui sont représentées par deux admittances self Y_s dans le circuit équivalent. Les sources de courant sont ajoutées dans le circuit pour contribuer dans les admittances Y_m entre les fentes. Une autre manière d'inclure l'effet du couplage mutuel est de placer l'admittance mutuel Y_m en parallèle avec Y_s à chaque extrémité de façon à remplacer l'admittance self par $(Y_s - Y_m)$. Ce genre de circuit équivalent est donné dans [7], et fournit de bonnes comparaisons.

IV.2.2 Calcul de l'impédance d'entrée d'une antenne couplée par proximité

Un circuit de trois ports est ainsi considéré comme dans la Figure IV.2.b. L'admittance caractéristique Y_c et la constante de propagation γ_p de chaque section de la ligne est différente quand le couplage électromagnétique se produit au port 3.




Figure IV.2 Circuit équivalent d'une antenne rectangulaire microbande [5].

Les paramètres de la ligne de transmission sont [5]:

$$Z_c = \frac{120\pi \cdot h}{\sqrt{\epsilon_{ref}} W_{eff}} \tag{IV.1}$$

$$\beta = k_0 \sqrt{\epsilon_{ref}} ; \alpha = 0.5\beta \tan \delta \tag{IV.2}$$

Les suppositions suivantes sont nécessaires pour simplifier le modèle mathématique du circuit équivalent de la Figure IV.2.b :

- En mode fondamental, la source de rayonnement est limitée à la fente principale le long des extrémités ouvertes du patch.
- Le rayonnement qui provient de la composante tangentielle du champ électrique uniforme entre les fentes principales peut être considéré infini.

Basé sur la deuxième supposition, le concept d'une fente infini est employé pour déterminer les admittances mutuelles et selfs, ainsi que les paramètres de la ligne.

$$I_1 = (Y_s + Y_{c1} \coth \theta_1) V_1 - Y_m V_2 - Y_{c1} \operatorname{csch} \theta_1 V_3 \quad (\text{IV. 3})$$

$$I_2 = -Y_m V_1 + (Y_s + Y_{c2} \coth \theta_2) V_2 - Y_{c2} \operatorname{csch} \theta_2 V_3 \quad (\text{IV. 4})$$

$$I_3 = -Y_{c1} \operatorname{csch} \theta_1 V_1 - Y_{c2} \operatorname{csch} \theta_2 V_2 + (Y_{c1} \coth \theta_1 + Y_{c2} \operatorname{csch} \theta_2) V_3 \quad (\text{IV. 5})$$

Où $\theta_1 = \beta L_1$ et $\theta_2 = \beta L_2$, avec β la constante de propagation.

Dans le cas où $I_1 = I_2 = 0$ et $I_3 \neq 0$, le courant est divisé par V_3 nous obtenons :

$$\frac{I_1}{V_3} = (Y_s + Y_{c1} \coth \theta_1) \frac{V_1}{V_3} - Y_m \frac{V_2}{V_3} - Y_{c1} \operatorname{csch} \theta_1 = 0 \quad (\text{IV. 6})$$

$$\frac{I_2}{V_3} = -Y_m \frac{V_1}{V_3} + (Y_s + Y_{c2} \coth \theta_2) \frac{V_2}{V_3} - Y_{c2} \operatorname{csch} \theta_2 = 0 \quad (\text{IV. 7})$$

L'admittance d'entrée Y_{in1} concernant le circuit de la Figure IV.2.b s'écrit:

$$Y_{in1} = \frac{I_3}{V_3} = -Y_{c1} \operatorname{csch} \theta_1 \frac{V_1}{V_3} - Y_{c2} \operatorname{csch} \theta_2 \frac{V_2}{V_3} + (Y_{c1} \coth \theta_1 + Y_{c2} \operatorname{csch} \theta_2) \quad (\text{IV. 8})$$

Les rapports V_1/V_3 et V_2/V_3 sont déterminés à partir des équations (IV.6) et (IV.7).

Les expressions de Y_s et Y_m sont calculées par [5], [6] :

$$Y_s = G_s + jB_s \quad (\text{IV. 9})$$

$$G_s = \frac{1}{\pi \eta_0} \left\{ \left(w_1 \operatorname{Si}(w_1) + \frac{\sin w_1}{w_1} + \cos w_1 - 2 \right) \left(1 - \frac{s^2}{24} \right) + \frac{s^2}{12} \left(\frac{1}{3} + \frac{\cos w_1}{w_1^2} - \frac{\sin w_1}{w_1^3} \right) \right\} \quad (\text{IV. 10})$$

$$B_s = Y_c \tan(\beta \Delta l) \quad (\text{IV. 11})$$

$$Y_m = G_m + jB_m \quad (\text{IV. 12})$$

$$G_m = G_s F_g K_g \quad (IV.13)$$

$$B_m = B_s F_b K_b \quad (IV.14)$$

$$F_g = J_0(l) + \frac{s^2}{24 - s^2} J_2(l) \quad (IV.15)$$

$$F_b = \frac{\pi}{2} \frac{Y_0(l) + \frac{s^2}{24 - s^2} Y_2(l)}{\ln\left(\frac{s}{2}\right) + C^e - \frac{3}{2} + \frac{s^2/12}{24 - s^2}} \quad (IV.16)$$

K_g , K_b sont les fonctions de correction, J et Y sont les fonctions de Bessel 1^{er} ordre et 2^{eme} ordre respectivement.

Les paramètres W_1 , S , Y_c , Δl , C^e , l , sont donnés par [5].

Y_{c1} est l'impédance caractéristique de la section de la ligne découplée. Elle est calculée en utilisant les formules quasi-statiques [10], [11].

$$Y_{c1} = \frac{376.7}{\sqrt{\epsilon_r}} \left\{ \frac{W}{h} + 0.88825 + 0.1645 \left(\frac{\epsilon_r - 1}{\epsilon_r^2} \right) + \frac{\epsilon_r + 1}{\pi \epsilon_r} \left(1.4516 + \ln \left(\frac{W}{2h} + 0.94 \right) \right) \right\} \quad (IV.17)$$

Cependant, La détermination de Y_{c2} est plus compliquée, parce qu'elle implique la section couplée. La théorie des lignes couplées présentée dans [12], [18] est employée. Le circuit équivalent de la ligne de transmission donné dans [20] pour des lignes couplées est modifié ici pour représenter la fin de la section de la ligne couplée, comme représenté sur le schéma IV.3. Les lignes sont représentées en modes d'impédances paire et impair Z_{oo} , Z_{oe} , correspondant aux deux modes orthogonaux TEM.




Figure IV.3 La section de la ligne couplée.

Avec une approche approximée et dans la théorie de ligne couplée, deux suppositions simples peuvent être faites, comme suit :

- Puisque W_f est trop petit, pratiquement, une fois comparé avec W , la distribution du champ électrique autour de la ligne d'alimentation est confinée à sa proximité très étroite.
- Puisque le superstrat n'existe pas, en raison de la micro structure du patch, la distribution de champ pour les modes impairs seulement est possible. Négligeant la perturbation causée par la ligne microruban, cette distribution du champ sur le patch sera tout à fait semblable au mode quasi TEM.

En se basant sur ces deux hypothèses, la distribution du champ dans la structure peut être illustrée sur le schéma IV.4, avec les conclusions suivantes :

1. Quand l'effet de la ligne microruban est négligé, l'impédance caractéristique du patch peut être simulée par celle de l'extrémité du microruban sur un substrat du plan de masse, comme déterminé par le modèle du guide planaire.
2. Les impédances de mode pour le couplage de la ligne microruban peuvent être déterminées à partir des résultats de la méthode variationnelle [20].

$$Y_{c2} = \frac{1}{Z_{00}^f} \quad (\text{IV. 18})$$

$$Y_{c3} = \frac{2}{(Z_{0e}^f - Z_{00}^f)} \quad (\text{IV. 19})$$

$$Z_{oe} = \frac{188.3/\sqrt{\epsilon_r}}{\frac{w_f/b}{1-h_1/b} + \frac{C_{fe}'}{\epsilon}} \quad (IV.20)$$

$$Z_{oo} = \frac{188.3/\sqrt{\epsilon_r}}{\frac{w_f/b}{1-h_1/b} + \frac{w_f}{h_1} + \frac{C_{fo}'}{\epsilon}} \quad (IV.21)$$

Les capacités de mode pair et impair sont obtenues par :

$$\frac{C_{fe}'}{\epsilon} = 0.4413 + \frac{1}{\pi} \left[\log \left(\frac{1}{1-h_1/b} \right) + \frac{h_1/b}{1-h_1/b} \log \frac{b}{h_1} \right] \quad (IV.22)$$

$$\frac{C_{fo}'}{\epsilon} = \frac{b/h_1}{\pi} \left[\log \left(\frac{1}{1-h_1/b} \right) + \frac{h_1/b}{1-h_1/b} \log \frac{b}{h_1} \right] \quad (IV.23)$$

$b = h_1 + h$ est la hauteur totale.




Figure IV.4 la distribution du champ.

a- mode pair ; b-mode impair.

Comme une représentation appropriée de la section électromagnétiquement couplée a été obtenue, la prochaine étape doit l'incorporer au modèle de la ligne de transmission améliorée.

Ceci est fait au port 3 sur le plan BB' , et le circuit équivalent final donné par la Figure IV.5.

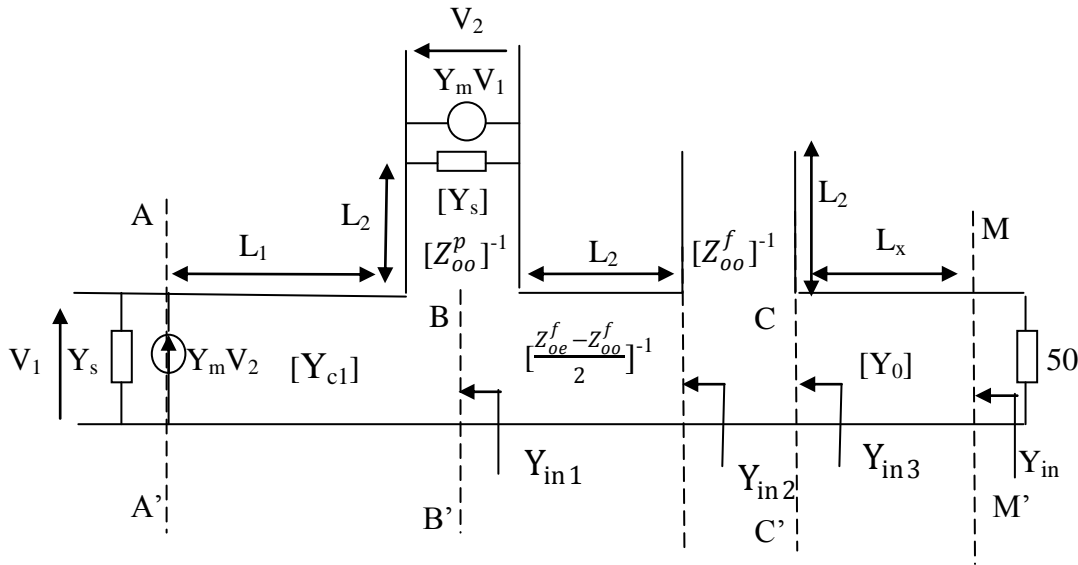


Figure IV.5 Circuit final de l'antenne microbande couplée par proximité [1].

L'admittance caractéristique, Y_{in1} vue au port 3, est donnée par l'équation (IV.8), et l'admittance caractéristique finale Y_{in} vue à l'entrée, est calculée par une transformation simple de l'impédance. Les étapes de transformation sont :

$$Y_{in2} = Y_{c3} \frac{Y_{in1} + jY_{c3} \tan \theta_2}{Y_{c3} + jY_{in1} \tan \theta_2} \tag{IV.24}$$

$$[Y_{in3}]^{-1} = [Y_{in2}]^{-1} + [-jZ_{o0}^f \cot(\theta_2)] \tag{IV.25}$$

$$Y_{in} = Y_0 \frac{Y_{in3} + jY_{c3} \tan(\beta L_x)}{Y_0 + jY_{in3} \tan(\beta L_x)} \tag{IV.26}$$

Où $L_x = L_f - L_2$.

IV.3 Modélisation neuronale de l'antenne microbande rectangulaire couplée par proximité

IV.3.1 Définition d'un réseau RBF

Introduit par Powell et Broomhead [15], le réseau RBF (Radial Basis Functions) fait partie des réseaux de neurones supervisés. Il est constitué de trois couches (Figure IV.6): une couche

d'entrée qui retransmet les entrées sans distorsion, une seule couche cachée qui contient les neurones RBF qui sont généralement des gaussiennes [15], [16], [17] et une couche de sortie dont les neurones sont généralement animés par une fonction d'activation linéaire. Chaque couche est complètement connectée à la suivante et il n'y a pas de connexions à l'intérieur d'une même couche.

IV.3 Modélisation neuronale de l'antenne microbande rectangulaire couplée par proximité

IV.3.1 Définition d'un réseau RBF

Introduit par Powell et Broomhead [15], le réseau RBF (Radial Basis Functions) fait partie des réseaux de neurones supervisés. Il est constitué de trois couches (Figure IV.6): une couche d'entrée qui retransmet les entrées sans distorsion, une seule couche cachée qui contient les neurones RBF qui sont généralement des gaussiennes [15], [16], [17] et une couche de sortie dont les neurones sont généralement animés par une fonction d'activation linéaire. Chaque couche est complètement connectée à la suivante et il n'y a pas de connexions à l'intérieur d'une même couche.




Figure IV.6 Présentation schématique d'un réseau RBF.

Ce réseau est constitué de N neurones d'entrée, M neurones cachés et J neurones de sortie.

La sortie du $m^{\text{ième}}$ neurone de la couche cachée est donnée par :

$$y_m^{(q)} = \exp \left[-\frac{\|x^{(q)} - v_m\|^2}{2\sigma_m^2} \right] \quad (\text{IV. 27})$$

v_m est le centre du $m^{\text{ième}}$ neurone de la couche cachée où du $m^{\text{ième}}$ neurone gaussien et σ_m est la largeur du $m^{\text{ième}}$ gaussienne.

La sortie du $j^{\text{ième}}$ neurone de la couche de sortie est donnée par:

$$z_j^{(q)} = \left(\frac{1}{M} \right) \cdot \left[\sum_{(m=1,M)} w_{mj} y_m^{(q)} \right] \quad (\text{IV. 28})$$

$m=1, \dots, M$ et $j=1, \dots, J$.

w_{mj} sont les poids reliant la couche cachée à celle de la sortie.

L'apprentissage du réseau RBF a été présenté la première fois par Moody et Darken [16]. Il consiste à régler quatre paramètres principaux: le nombre de neurones dans l'unique couche cachée ou le nombre des gaussiennes, la position des centres de ces gaussiennes, la largeur de ces gaussiennes et les poids de connexions entre les neurones cachés et le(s) neurone(s) de sortie. L'avantage le plus important de cette méthode est le fait que l'entraînement est fait une seule fois, c'est-à-dire qu'on présente les données une seule fois à l'entrée. Ce qui réduit considérablement le temps d'apprentissage. La particularité de cette méthode est qu'elle tire profit du parallélisme du réseau pour faire l'approximation des fonctions de densité de probabilité de chaque classe.

IV.3.2 Apprentissage par RBF

L'apprentissage des RBF consiste à déterminer les poids des connexions et les paramètres des fonctions de base. Comme les sorties dépendent linéairement des poids de connexions, la détermination de ces derniers est simplement un problème d'optimisation linéaire [21]. La plus part des algorithmes d'apprentissage des réseaux RBF procèdent à une sélection aléatoire d'un certain nombre d'échantillons de l'espace d'entrée comme étant les centres des fonctions de base. Cependant, dans la plus part des cas, il est évident qu'une sélection aléatoire des centres n'est pas

satisfaisante. Pour remédier à cet inconvénient, d'autres algorithmes ont été utilisés dans lesquels la procédure d'apprentissage est divisée en deux étapes :

Un entraînement non supervisé pour l'ajustement des centres des fonctions de base dans la couche cachée, suivi par un entraînement supervisé pour l'ajustement des poids des connexions entre la couche cachée et la couche de sortie.

La modélisation des réseaux RBF est généralement composée de deux étapes distinctes : la paramétrisation des fonctions-noyaux et l'apprentissage des poids de la couche de sortie. Cette dernière étape ne concerne qu'une seule couche de connexions et peut être réalisée par des techniques d'apprentissage simples telles que la règle Delta ou de Widrow-Hoff. Avec une seule couche cachée, les réseaux RBF se comportent comme des approximateurs universels. Les réseaux RBF obtiennent des performances comparables ou supérieures à celles des réseaux MLP dans l'approximation de fonctions. Une particularité intéressante est la rapidité et la simplicité dans l'apprentissage faisant de ces réseaux des outils de choix pour des systèmes de classification de signaux. D'un point de vue pratique, les réseaux RBF sont moins sensibles aux pertes de mémoire résultant de la destruction de leurs poids. Dans la configuration de base, ce type de réseau est constitué de deux couches dont une agit comme la couche cachée. La première couche qui n'est pas comptabilisée est la couche d'entrée dont les fonctions d'activation sont linéaires, telle que la fonction « purelin ». La couche cachée est constituée de fonctions de type gaussien telle que la fonction « radbas » fournie par MATLAB. Finalement, la couche de sortie comporte des fonctions d'activation non-linéaires telles que la fonction « tansig ».

IV.3.3 Modélisation de l'impédance d'entrée de l'antenne couplée par proximité par RBF

L'architecture d'un réseau RBF est présentée en Figure IV.7. Il se compose d'une couche d'entrée, une couche cachée et une couche de sortie. La couche d'entrée se compose des paramètres physiques de l'antenne couplée par proximité (W , L , W_f , b , ϵ_r). Toutes les cellules de la couche d'entrée sont connectées aux I neurones de la couche cachée qui eux même sont connectés à ceux de la couche de sortie (R_{in} , X_{in}).

Nous avons élaboré alors un programme qui permet de calculer les composantes de l'impédance d'entrée pour tous les vecteurs cités précédemment à partir de la fonction newrb crée un RBF de façon itérative en ajoutant un (ou plusieurs) neurone(s) par itération.

Les neurones sont ajoutés jusqu'à ce que l'erreur soit inférieure à une valeur souhaitée ou que le nombre de neurones a atteint une valeur maximale.

L'appel de cette fonction se fait par :

Net = newrb (P, T, GOAL, SPREAD)

Où P est la matrice des entrées et T est le vecteur cible.

A chaque itération le vecteur d'entrée qui résulte de la minimisation de l'erreur du réseau est utilisé pour créer un neurone radbas.

Il est important que le paramètre spread (l'étendue de la gaussienne) soit grand pour que les neurones radbas aient des régions de réponse qui se chevauchent et couvrent tout l'espace, mais pas trop grand pour que tous les neurones ne répondent pas de la même manière.

Dans cette simulation le domaine d'opération est limité dans les intervalles : [37.5mm ; 43.5mm] ; [36mm ; 42.5mm] ; [3.9 mm ; 5.2mm] ; [1 ; 8] ; [3.1mm ; 5.2mm] pour W , L , W_f , ϵ_r , b , respectivement, pour un ensemble d'apprentissage de 3000.

Les paramètres de l'algorithme newrb sont fixés comme suit : goal=0.1 ; spread = 1.




Figure IV.7 Modèle neuronale RBF de l'impédance d'entrée.

La Figure IV.8 montre la variation de l'impédance d'entrée en fonction de la fréquence ainsi que celle générée par le réseau RBF. Les résultats obtenus comparés à ceux de la littérature sont en accord.




Figure IV.8 Variation de l'impédance d'entrée en fonction de la fréquence. ($L = 40\text{mm}$; $h_1 = 1.575\text{mm}$; $W = 40\text{ mm}$; $W_f = 4.8\text{ mm}$; $h_2 = 1.575\text{mm}$; $\epsilon_r = 2.2$; $L_2 = 28.4\text{mm}$; $L_f = 86.6\text{mm}$).




Figure IV.9 Performance du réseau RBF avec la fonction newrb.

a. Influence du paramètre spread

La Figure IV.9 montre l'influence du paramètre spread : paramètre d'étendue des gaussiennes sur les courbes de l'impédance d'entrée.

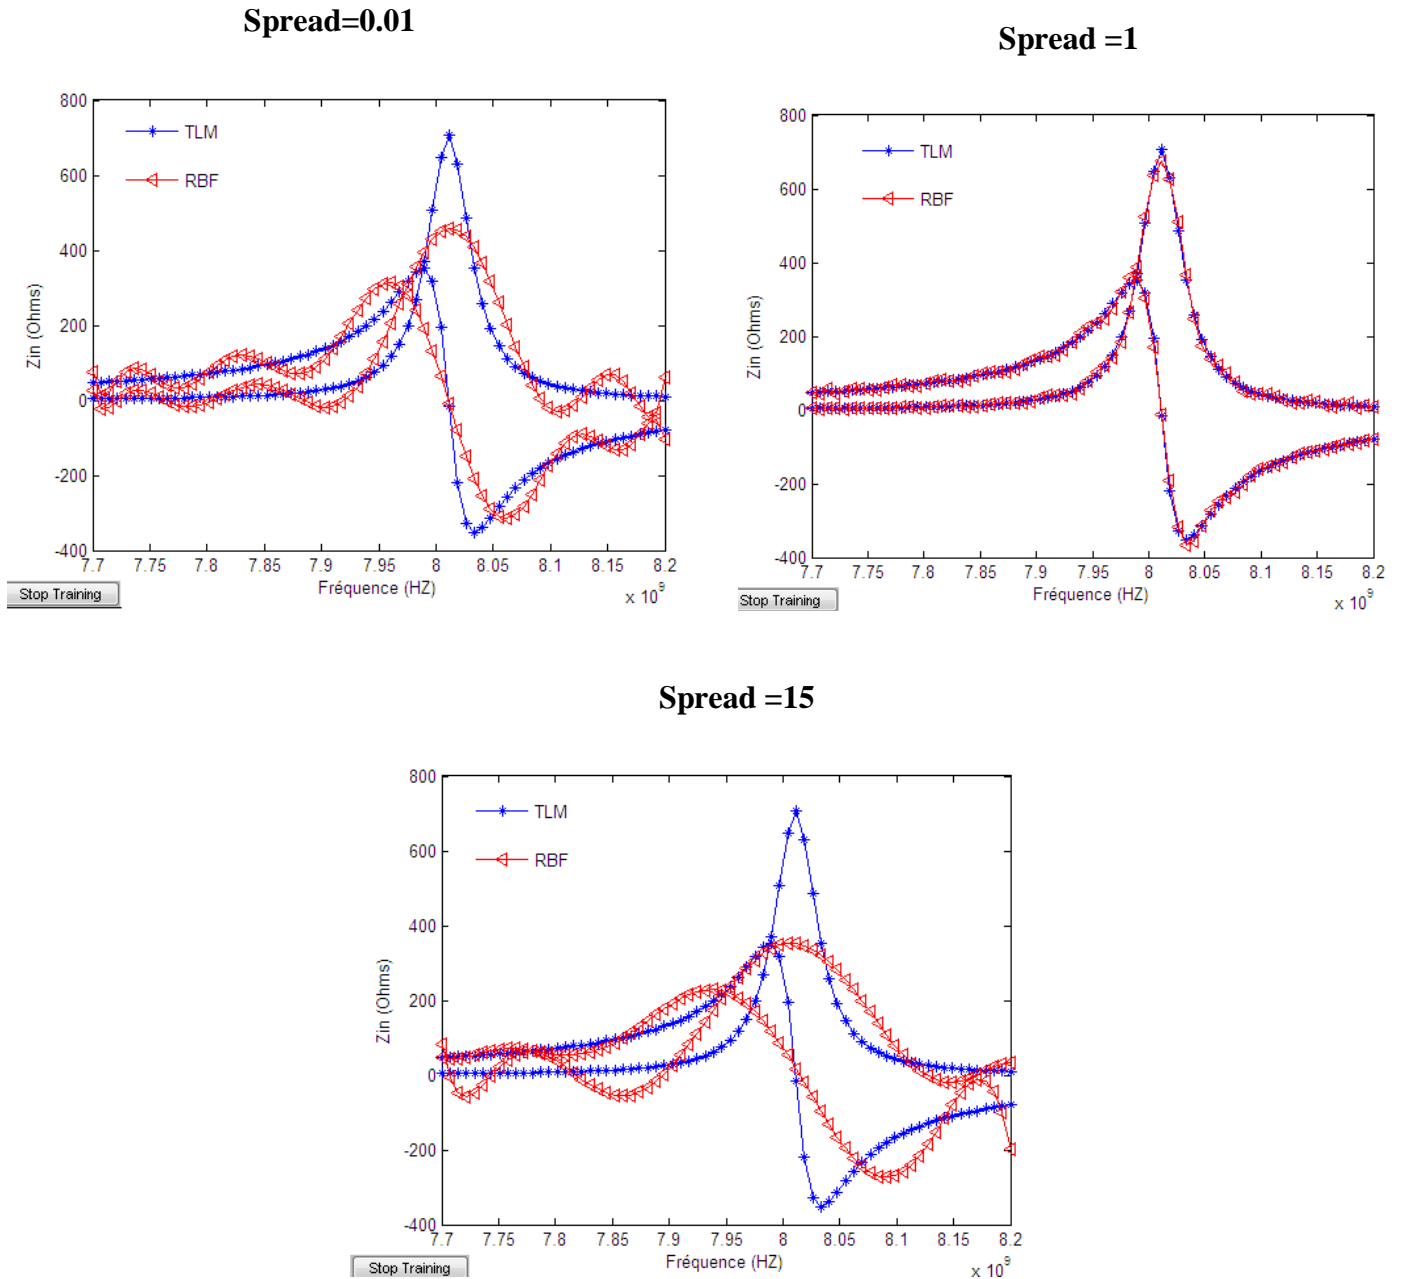


Figure IV.10 Influence du paramètre spread sur la courbe de l'impédance d'entrée pour $L=11\text{mm}$; $h_1=0.8\text{mm}$; $W=9\text{mm}$; $W_f=2.2\text{mm}$; $h=1.6\text{mm}$; $\epsilon_r=2.17$.

Ces trois exemples montrent l'influence de l'étendue de la gaussienne dans l'application d'approximation. Ils utilisent la fonction *newrb*, qui crée un réseau à 2 couches :

- une couche de sortie qui comporte deux neurones dans cette application d'approximation de fonction ;
 - cinq neurones dans la couche d'entrée, dont le nombre de neurones va être déterminé par l'algorithme en fonction du paramètre d'erreur (un seuil) passé en argument : l'algorithme ajoutera des neurones successivement dans cette couche jusqu'à ce que le taux d'erreur passe en dessous de ce seuil.
- ✚ Si cette étendue est petite ($\text{spread} = 0.01$), la courbe ne peut pas être approximée correctement car les centres des gaussiennes sont trop éloignés entre eux par rapport à l'étendue de ces dernières. Aux endroits des creux de la somme des gaussiennes, des points d'entrée ne tomberont pas sur la fonction approximée quand ils seront présentés au réseau.
- ✚ Si l'étendue est grande ($\text{spread} = 15$), les variations de la somme des gaussiennes sont trop douces et donc cette courbe ne peut pas suivre les variations rapides de la fonction à approximer.
- ✚ Dans le cas $\text{spread}=1$, l'étendue des gaussiennes est bien choisie et la courbe est bien approximée.

b. Effet de la distance de chevauchement L_2 de la ligne d'alimentation au patch

Nous choisissons une antenne microbande rectangulaire couplée par proximité de dimension $L = 11\text{mm}$, $W = 9\text{mm}$, imprimée sur un substrat isotrope de permittivité relative $\epsilon_r = 2.17$ et d'épaisseur $h = 1.6\text{mm}$, avec une ligne d'alimentation centrée le long du bord de rayonnement pour différentes valeurs de chevauchement, nous avons représenté la variation de l'impédance d'entrée en fonction de la fréquence (Figure IV.11). D'après la Figure IV.11 on voit bien que l'impédance d'entrée diminue avec l'augmentation de L_2 . On remarque aussi que l'impédance d'entrée et la fréquence de résonance peuvent être ajustées par l'ajustement de la longueur de la ligne d'alimentation sous la plaque conductrice.

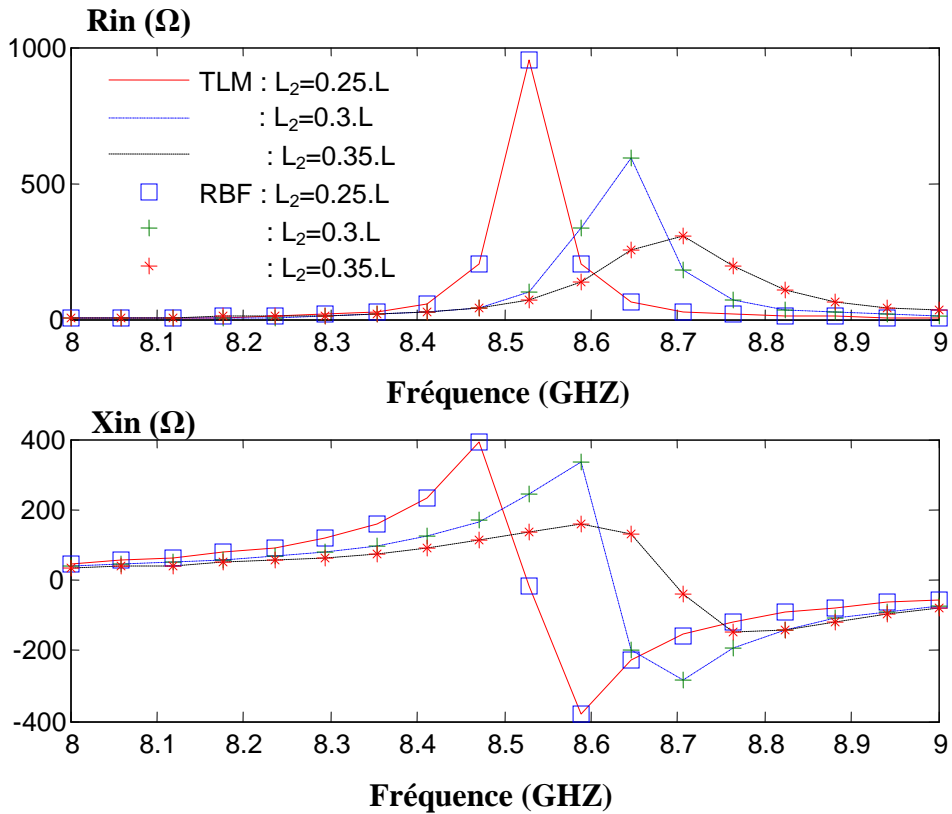


Figure IV.11 Variation de l'impédance d'entrée en fonction de la fréquence pour différentes valeurs de chevauchement L_2 .

c. Effet de la largeur de la ligne d'alimentation W_f

Pour un vecteur d'apprentissage contenant 250 données (W , L , b , ϵ_r , R_{in} , X_{in}), le réseau RBF calcule l'impédance d'entrée pour différentes valeurs de W_f . Les valeurs minimales et maximales qui sont utilisées comme paramètres d'entrée du réseau sont données par le Tableau IV.1.

La Figure IV.12 montre la variation de l'impédance d'entrée pour différentes valeurs de la largeur W_f , on note que l'impédance d'entrée diminue lorsque W_f est grande. Les exercices de simulation effectués par réseau RBF ont montré les bonnes performances de stabilité de la structure proposée pour un spread = 3 et un seuil égal à 0.

W(cm)		L(cm)		ϵ_r		b(mm)	
MIN	MAX	MIN	MAX	MIN	MAX	MIN	MAX
1.7	2	4.1	6	1	5	0.2	2.2

Tableau IV.1 Domaine de variation des entrées du réseau de neurones.




Figure IV.12 Variation de l'impédance d'entrée en fonction de la fréquence pour différentes valeurs de la largeur de la ligne d'alimentation W_f .

IV.4 Comparaison des deux méthodes MLP et RBF

Le Tableau IV.2 résume les résultats de comparaison entre l'apprentissage dans différents algorithmes et indique clairement, que la structure RBF proposée et identifiée est la meilleur c.-à-d. une erreur d'apprentissage plus petite et un temps plus court.

La Figure IV.13 illustre la performance du réseau de neurones. La performance d'apprentissage atteint une erreur de $2.07176e-5$. On remarque que le réseau converge au bout de 550 itérations ceci confirme l'efficacité de l'algorithme "newrb" utilisé dans cette modélisation ainsi que sa généralisation.

Algorithmes d'apprentissage	Nombre d'itérations	Nombre de neurone de la couche cachée	MSE	Erreur d'apprentissage
LM	2017	13×19	9.98411e-5	0.0054
BFG	5960	11×18	9.99108e-5	0.0066
RP	65258	9×17	9.99996e-5	0.0059
SCG	191482	15×8	9.99789e-5	0.0066
RBF	550	25	2.07176e-5	7.4976e-5

Tableau IV.2 La comparaison de l'effet d'apprentissage dans différents algorithmes.




Figure IV.13 Performance du réseau RBF avec la fonction newrb.

IV.5 Modélisation du coefficient de réflexion par réseaux de neurones GRNN

IV.5.1 Définition du réseau GRNN

Le réseau de neurones GRNN (*Generalized Regression Neural Network*) [22] a une architecture assez semblable à celle des réseaux de neurones à base radiale (*Radial Basis Networks ou RBF*). Il possède deux couches de neurones. Les neurones de la couche cachée ont une fonction de transfert à base radiale ($a = e^{-n^2}$) et les deux neurones de la couche de sortie ont une fonction de transfert linéaire ($a = n$).

Tout comme le réseau MLP, le réseau GRNN doit être entraîné avant d'être utilisé. Pour l'entraîner, il faut fixer seulement le paramètre : « spread ». Plus le paramètre « spread » est faible, plus le neurone mémorise bien l'entrée qui lui a été assignée. Le réseau GRNN donne alors une excellente précision et une bonne capacité à mémoriser.

L'algorithme utilisé pour l'apprentissage du réseau GRNN est beaucoup plus simple que celui utilisé pour l'apprentissage du réseau MLP; il s'ensuit donc un temps d'apprentissage beaucoup moins long pour le réseau GRNN. Celui-ci dépend aussi du nombre de données d'apprentissage. La précision donnée par le réseau GRNN, contrairement au réseau MLP, n'est pas fonction des valeurs initiales de ses poids et biais.

IV.5.2 Application du réseau GRNN

La base de données utilisée pour la mise en œuvre du RNA est constituée de 120 exemples. 60 sont utilisés pour l'apprentissage du réseau et 60 pour le test (validation). Le RNA mis en œuvre est constitué d'une couche d'entrée composée de cinq neurones (W , L , W_f , b , ϵ_r) et d'une couche de sortie composée d'un neurone (S_{11}) Figure IV.14.

Nous avons élaboré alors un programme qui permet de calculer le coefficient de réflexion pour tous les vecteurs cités précédemment à partir de la fonction newgrnn.

L'appel de cette fonction se fait par :

Net = newgrnn (P, T, SPREAD)

le paramètre spread dans ce cas égale est égale à 0.2.



Figure IV.14 structure du réseau GRNN.

🔴 Résultats de simulation

La courbe d'apprentissage de la Figure IV.15 atteint rapidement la convergence désirée avec l'algorithme newgrnn. Ceci est très court comparativement à d'autres méthodes d'apprentissage. Comme la quantité de patrons (base de données) n'est pas élevée, le temps d'apprentissage total ne dépasse pas une seconde.

Le coefficient de réflexion est simulé par la méthode TLM, les valeurs sont relevées dans la bande de fréquence [7–8.4] GHz. Les résultats de la littérature [23] et de simulation à la fréquence de résonance 8.1 GHz sont de l'ordre de -15 dB.




Figure IV.15 Variation du coefficient de réflexion en fonction de la fréquence. ($L=1$ mm; $h_1=0.8$ mm; $W=9$ mm; $W_f=2.2$ mm; $h=1.6$ mm; $\epsilon_r=2.17$).

La Figure IV.16 présente la variation du coefficient de réflexion S_{11} à l'entrée de l'antenne en fonction de la fréquence pour trois valeurs de la profondeur de pénétration. Nous trouvons des coefficients S_{11} variant de -14 à -37 dB. Il apparaît dans cette figure que le coefficient S_{11} de l'antenne s'améliore pour des valeurs de L_2 plus élevées.




Figure IV.16 Le coefficient de réflexion pour différentes valeurs de chevauchement L_2 .
($L=11\text{mm}$; $h_1=0.8\text{mm}$; $W=9\text{mm}$; $W_f=2.2\text{mm}$; $h=1.6\text{mm}$; $\epsilon_r=2.17$).

IV. 6 Conclusion

L'alimentation d'une antenne patch rectangulaire par le couplage électromagnétique et par la ligne microruban a été étudiée dans ce chapitre. Une analyse par la méthode de la ligne de transmission améliorée est menée. L'effet de la largeur de la ligne d'alimentation ainsi que le chevauchement sur l'impédance d'entrée sont présentés.

La Toolbox Neural Network de Matlab nous permet de construire, simplement et rapidement, des réseaux dont les fonctions de transfert sont des RBF. L'avantage des fonctions Matlab est qu'elles optimisent le nombre de RBF nécessaires à l'interpolation ainsi que leur emplacement. Il se dégage que le réseau de neurones GRNN permet de déterminer le coefficient de réflexion de l'antenne microbande couplée par proximité et donne des meilleures précisions. L'inconvénient est qu'il n'y a qu'une fonction de transfert par couche du

réseau et que l'on ne peut pas adapter ses paramètres à la variable de sortie. Il sera donc nécessaire d'avoir un réseau par sortie, ce qui limite alors l'intérêt des réseaux. Cependant, les fonctions Matlab restent très avantageuses du fait de leur rapidité.

IV.7 Références

- [1] B. Belentepe, "*Modeling and design of electromagnetically coupled microstrip-patch antennas and antenna arrays*," IEEE Antennas Propag. Mag. 37, (1), pp. 31–39, 1995.
- [2] P. Bartia, K. V. S. Rao, R. S. Tomar, "*Millimeter wave microstrip and printed circuit antennas*," . Artech House, Boston, London. 1991.
- [3] R. E. Munson, "*Conformal microstrip antennas and microstrip phased arrays*," IEEE Transactions on Antennas and Propagation, AP-22., pp 6 1-65, 1974.
- [4] A. G. Derneryd, "*A theoretical investigation of the rectangular microstrip antenna element*," IEEE Transactiotis on Antennas and Propagation, AP-26, 4, pp. 532-35, July 1978.
- [5] H. Pues, A Van de Capelle, "*Accurate transmission line model for the rectangular microstrip antenna*," IEE Proceedings, 131H, pp 334-340, 1984.
- [6] J. R James, P S Hall, "*Handbook of Microstrip Antennas*," Volume 1, (IEE Edition), Peter Peregrinus, 1989, Chapter 10.
- [7] A. Bhattacharyya, Garg, "*Generalized Transmission Line Model for Microstrip Patches*," Proceedings of the IEE, 132 part H, pp 93-98, April 1985.
- [8] G. Kompas, A. Mehran, "*Planar waveguide model for calculating microstrip components*," Electronics Letters, 11, 19, pp. 459-460 Sep1975.

- [9] H. Pues, A. Van de Capelle, "*Approximate formulas for frequency dependence of microstrip parameters*," Electronics Letters, 16, 23, pp. 870-871, Nov 1980.
- [10] T. Edwards, "*Foundations for microstrip circuit design*," (Second Edition), New York, John Wiley & Sons, 1991.
- [11] E. H. Fooks, R. A. Zakarevicious, "*Microwave engineering using microstrip circuits*," New York, Prentice Hall, 1990.
- [12] P. Bhartia, P. Pramanick, "*Computer-aided design models for broadside coupled striplines and mm-wave suspended substrate microstrip lines*," IEEE Transactions on Microwave Theory and Techniques, MTT-36, 1, pp. 1476-1481, Nov 1988.
- [13] Q. Zhang, Y. Fukuoka, T. Itoh, "*Analysis of a suspended patch antenna excited by an electromagnetically coupled inverted microstrip feed*," IEEE Trans. Antennas Propagat, Vol. 33, pp. 895-899, Aug 1985.
- [14] E. Hammerstad, I. Melhus, O. Jensen, F. Bekkadal, "*Simulation of microwave components*," ELAB Report STF 44 F80127, Trondheim, Norway, Dec 1980.
- [15] D.S Broomhead, D. Lowe, "*Multivariate functional interpolation and adaptive networks*," Complex Systems, vol 2, p.321-355, 1988.
- [16] J. Moody, C.J. Darken, "*Fast Learning in Network for Locally Tuned Processing Units*," Neural Computation, vol.1, p.281-294, 1989.
- [17] T. Poggio, F. Girosi, "*Network for approximation and learning*," Proc. IEEE, vol 78, no. 9, pp. 1481 -1497, 1990.
- [18] I.J. Bahl, P. Bhartia, "*The design of broadside coupled stripline circuits*," IEEE Transactions on Microwave Theory and Techniques, MTT-29, 2, pp 165-68, February 1981.

- [19] G. Matthaei, L. Young, E.M.T. Jones, "*Microwave filters, impedance matching networks and coupling structures*," Norwood, MA, Artech House, pp 226, 1980.
- [20] E. Yamashita, "*Variational method for the analysis of microstrip-like transmission lines*," IEEE Transactions on Microwave Theory and Techniques, MTT-16, 8, pp 529-35, August 1968.
- [21] S. Haykin, "*Neural Networks, A Comprehensive Foundation*," Prentice-Hall, 1994.
- [22] D. F. Specht, "*A general regression neural network*," IEEE Trans. Neural Networks 2(6), 568–576, 1991.
- [23] J. P. Daniel, G Dubost, C. Terret, J. Citerne, M. Driss, "*Research on planar antennas and arrays*," IEEE Antennas and Propagation Magazine, 35, pp. 14-38, February 1993.
- [24] Vicente D. Costa, I. Bianchi, J. C. da S. Lacava, L. Cividanes "*Analysis of Rectangular Electromagnetically Coupled Microstrip Antennas with Anisotropic Substrates*,"

CONCLUSION GENERALE

Dans ce modeste travail, le modèle neuronale et en particulier les perceptrons multicouches (MLP) et les RBF sont appliqués sur les structures de type antenne microbande avec gap d'air, antenne microbande couplée par fente et antenne microbande couplée par proximité. Ils sont utilisés en conjonction avec les méthodes analytiques cavité modifiée et TLM.

La méthode de la cavité modifiée (Wolff) à été utilisée dans le cas de l'antenne avec gap d'air permettant le calcul de la fréquence de résonance et l'impédance d'entrée. Ceci montre l'effet d'un gap d'air sur l'amélioration de ces paramètres. Le premier modèle neuronale est basé sur dix algorithmes par la boite à outils *matlab toolbox*, qui sont très faciles à implémenter et à utiliser. Ils sont très rapides et très précis. Une comparaison est faite entre tous les algorithmes d'apprentissage utilisés. A cet effet il se dégage que l'algorithme Levenberg-Marquardt a montré d'excellentes performances en terme de robustesse. Il présente l'avantage d'effectuer une recherche multipoints de la solution optimale permettant de réduire considérablement le temps de calcul.

L'antenne microbande rectangulaire couplée par ouverture, est modélisée par la méthode TLM, à l'aide des impédances, des transformateurs et des lignes de transmission. Dans ce cas la quantité du couplage est déterminée par la forme, la taille et l'emplacement de l'ouverture. Lors de l'application du modèle neuronale l'impédance d'entrée est utilisée sous forme de matrices issues de la méthode TLM tenant compte des différents paramètres géométriques tels que : les dimensions et la forme de fente aussi que la largeur de la ligne d'alimentation. Il se dégage que l'ouverture ne doit pas être très grande, ce qui est nécessaire pour l'adaptation de l'impédance, et de plus on constate que la forme « H » donne un meilleur couplage par rapport à la forme rectangulaire [2], [3], [4], et la largeur doit être petite pour un couplage parfait. Un autre modèle neuronale sert à estimer le coefficient de réflexion où il est introduit la fréquence normalisée par rapport à la fréquence de résonance. Nous concluons que le modèle neuronale permet d'avoir dans la plupart des cas une solution qui s'approche de celle désirée avec un temps de calcul instantané.

Un autre réseau de neurone RBF est utilisé pour modéliser l'antenne couplée par proximité, qui possède des performances comparables ou supérieurs à celles des réseaux MLP

dans l'approximation de fonction. L'influence du paramètre d'étendue des gaussiennes **spread** sur les courbes d'impédance a été mentionné, on trouve que plus ce paramètre est faible, plus le neurone mémorise bien les entrées qui lui ont été assignées.

La formulation théorique de l'alimentation par proximité a été effectuée avec la méthode TLM améliorée. Nous avons présenté les effets de chevauchement et de la largeur d'alimentation sur l'impédance d'entrée. Nous constatons que l'augmentation de ces paramètres diminue l'impédance d'entrée. La comparaison entre les algorithmes de perceptron MLP et le réseau RBF montre que ce dernier est le plus performant.

L'efficacité du réseau à régression généralisée GRNN a été prouvée via la modélisation du coefficient de réflexion d'une antenne microbande couplée par proximité. Des résultats théoriques et numériques concernant l'impédance d'entrée, le coefficient de réflexion de chaque structure ont été présentés, discutés et comparés avec les résultats théoriques reportés en littérature.

Les perspectives portent notamment sur l'application de la procédure (RNA) développée à des antennes de forme circulaires, annulaires. Ceci pourra impliquer un travail sur l'architecture des RNA et sur la structure de la base d'apprentissage. En effet, en tenant compte du type d'approximation réalisé par un RNA, différentes méthodes d'optimisation de la base d'apprentissage peuvent être considérées.

Nous devons aussi continuer l'application de la procédure pour la détermination d'autres paramètres caractérisant l'antenne microruban couplée par fente. Les paramètres sont : l'efficacité, le gain et le champ rayonné, en tenant compte aussi de différentes formes de fentes cités dans le chapitre III.

Enfin, Le coefficient de réflexion du réseau d'antenne couplée par proximité est doit faire l'objet de nos perspectives afin de confronter les résultats expérimentaux avec nos résultats simulés.

ANNEXES

ANNEXE A

Les algorithmes d'apprentissage

On sait que le MLP fait son apprentissage grâce à un algorithme à propagation arrière afin de modifier ses poids synaptiques. Cependant, il existe plusieurs algorithmes d'apprentissages que l'on peut séparer en trois catégories distinctes. Une catégorie constituée d'algorithmes non applicables à des problèmes réels vue leur extrême lenteur (Descente du Gradient et Descente du Gradient avec Momentum). La deuxième catégorie regroupe des algorithmes rapides et qui utilisent une technique heuristique pour modifier le « learning rate » et le momentum (variable learning rate et resilient backpropagation). Enfin, la dernière catégorie rassemble des algorithmes rapides et qui font appel à deux optimisations particulières : l'optimisation de la Descente du Gradient Conjugué et la Méthode de Newton. La méthode développée par Levenberg-Marquardt est astucieuse car elle fait justement appel aux avantages de deux algorithmes : l'optimisation de Newton de la 3^e catégorie et la Descente du Gradient de la 1^{er} catégorie. Mais qu'elle est l'intérêt d'utiliser des algorithmes lent et rapide en même temps ? La réponse vient en analysant la méthode de Levenberg-Marquardt.

A.1 Principe des algorithmes

La fonction de coût $J(w)$ la plus utilisée est l'erreur quadratique sur la base d'apprentissage. Elle consiste à minimiser la somme des carrés des erreurs entre la sortie du réseau et la valeur réelle de la sortie.

$$J(w) = \frac{1}{2} \sum_{i=1}^N (y_i(w) - t_i)^2 \quad (\text{A. 1})$$

Pour les problèmes de régression, l'ensemble d'apprentissage est constitué d'exemples pour lesquels la sortie désirée t est une variable continue.

Cette fonction de coût est issue du principe de maximum de vraisemblance avec une hypothèse gaussienne sur la distribution des sorties. Pour les problèmes de classification à

deux classes, la sortie désirée est une variable binaire codée 1 ou 0 selon que l'exemple appartient respectivement à C_1 ou C_0 .

L'hypothèse gaussienne sur la distribution des sorties n'est alors clairement plus vérifiée. Cependant, si l'apprentissage est effectué en minimisant l'erreur quadratique, la sortie du réseau de neurones peut être interprétée comme la probabilité a posteriori, au sens du théorème de Bayes, d'appartenance à la classe C_1 [1].

Les algorithmes utilisés nécessitent que $J(w)$ soit dérivable par rapport aux poids. Le principe de ces méthodes est de se placer en un point initial, de trouver une direction de descente du coût dans l'espace des paramètres w , puis de se déplacer d'un pas dans cette direction. On atteint un nouveau point et l'on fait l'itération de la procédure jusqu'à satisfaction d'un critère d'arrêt. Ainsi, à l'itération k , on calcule :

$$w_k = w_{k-1} + \alpha_{k-1} \cdot d_{k-1} \quad (\text{A. 2})$$

α_k est le pas de la descente et d_k est la direction de descente : les différents algorithmes se distinguent par le choix de ces deux quantités.

A.2 Descente de gradient

L'algorithme le plus simple consiste à choisir comme direction de descente l'opposé du gradient de la fonction de coût $d_k = -\nabla J(w) = -\text{Grad}(J(w_k))$. Cette méthode est efficace loin du minimum et permet uniquement de s'en approcher. Pour cette raison, la détermination du pas n'est pas cruciale : loin du minimum, il faut seulement vérifier que le pas n'est ni trop petit ni trop grand. En pratique, on utilise, selon les cas, deux méthodes :

soit un asservissement par la norme du gradient :

$$\alpha_k = \frac{\alpha_0}{1 + \|\nabla J(w_k)\|} \quad (\text{A. 3})$$

où α_0 est une constante qui vaut typiquement 0,01.

soit la méthode de Goldstein pour laquelle le pas est adapté afin de satisfaire deux conditions :

$$1. J(w_k + \alpha_k \cdot d_k) < J(w_k) + m_1 \alpha_k \nabla J^T(w_k) d_k \quad (\text{A. 4})$$

$$2. J(w_k + \alpha_k \cdot d_k) > J(w_k) + m_2 \alpha_k \nabla J^T(w_k) d_k \quad (\text{A. 5})$$

La première condition s'assure que le pas choisi n'est pas trop grand (sinon l'algorithme risque d'avoir un comportement oscillatoire), alors que la deuxième s'assure qu'il n'est pas trop petit (sinon l'algorithme a une convergence très lente). Les valeurs habituelles pour les deux paramètres m_1 et m_2 sont respectivement 0,1 et 0,7.

A. 3 La méthode de Newton

La méthode de Newton utilise la courbure (dérivée seconde) de la fonction de coût pour atteindre le minimum. La modification des paramètres s'écrit ainsi :

$$w_k = w_{k-1} - H_{k-1}^{-1} \cdot \nabla J(w_{k-1}) \quad (\text{A. 6})$$

La direction de descente est $-H_{k-1}^{-1} \cdot \nabla J(w_{k-1})$ où H_{k-1}^{-1} est l'inverse du Hessien de la fonction de coût, et le pas est constant fixé à un.

Cet algorithme converge en une seule itération pour une fonction quadratique. C'est donc un algorithme qui est inefficace loin du minimum de la fonction et très efficace près du minimum. Dans la pratique, le calcul du Hessien et surtout de son inverse est à la fois complexe et source d'instabilités numériques ; on utilise de préférence une méthode de "quasi-Newton".

A.4 La méthode de quasi-Newton

Les méthodes de quasi-Newton consistent à approcher l'inverse du Hessien plutôt que de calculer sa valeur exacte. La modification des paramètres s'écrit :

$$w_k = w_{k-1} - \alpha_{k-1} \cdot M_{k-1} \cdot \nabla J(w_{k-1}) \quad (\text{A. 7})$$

La suite M_k est construite de façon à converger vers l'inverse du Hessien avec M_0 égale à la matrice identité. Cette suite est construite grâce à la méthode dite BFGS [2], dont la vitesse de convergence est beaucoup plus grande que celle de la méthode du gradient.

A.6 Utilisation de la Boîte à outils Matlab Réseaux de Neurones-(Neural Network Toolbox nntool)

Il s'agit d'une structure hiérarchique (certains membres de la structure de base sont eux mêmes des structures) relativement complexe. Elle peut être visualisée lors de la création du réseaux ou plus tard.

A.6.1 Création d'un réseau

La fonction de création d'un réseau est spécifique au modèle de réseau utilisé (newc, newlvq, etc).

Pour les réseaux multicouches, la création du réseau est commandée par la fonction newff :

Réseau = newff (PR, [S1 S2.....SN1] , {TF1 TF2.....TFN1}, BTF , BLF , PF) ;

avec :

PR : Plage des variations des entrées (affichage par minmax (p)).

Si : nombre des neurones dans la couche i, pour N1 couches.

TFi : fonction d'activation dans la couche i, par défaut la fonction d'activation est 'tansig', elle peut être :

- **Hardlim** : fonctions Heaviside ; **hardlims**: fonctions signe ; **logsig** : fonction logarithme sigmoïde ; **tansig** : fonction tangente sigmoïde ; **pureline** : fonction linéaire ; **satlins** : Fonction linéaire a seuil.

BTF : l'algorithme d'apprentissage par paquets du réseau, la fonction BTF peut être :

- trainlm ; trainbfg ; trainoss ;

BLF : l'algorithme d'apprentissage incrémental du réseau, la fonction BLF peut être :

- **Learngd** : L'algorithme d'apprentissage sera la descente de gradient à taux d'apprentissage fixe ; **Learngdm** : version de learngd avec moment.

PF : fonction du coût.

- **mae** : erreur absolu moyen ; **mse** : erreur quadratique moyen ; **msereg** : version de mse avec modérations des poids ; **sse** : somme des carrés des erreurs.

A.6.2 Apprentissage

Il existe 2 types d'apprentissage :

- Incrémental : fonction adapt ; Par paquets : fonction train.

Apprentissage incrémental (en-ligne, *on-line*) : les poids sont modifiés à chaque présentation d'une entrée.

Apprentissage par paquets (hors-ligne, *off-line, batch mode*) : les poids sont modifiés uniquement après présentation de toutes les entrées.

L'efficacité de l'apprentissage dépend essentiellement des paramètres d'apprentissage suivants :

- Taux d'apprentissage (η) : Ce paramètre détermine la vitesse de la convergence en réglant la taille d'étape.
- Momentum (α) : Le terme α (Momentum) doit empêcher l'algorithme d'apprentissage de se ranger et de se trouver bloqué dans des minimums locaux. Il augmente également la vitesse de la convergence. Ce paramètre est habituellement placé à une valeur positive moins de 1.
- Tolérance d'apprentissage (E) : Ce paramètre critique détermine l'exactitude des sorties du réseau neurologique. Une tolérance de plus petites valeurs augmente habituellement l'exactitude mais peut avoir comme conséquence une moindre possibilité de généralisation aussi bien qu'un plus long temps d'apprentissage [3].

A.6.3 Simulation (ou activation) d'un réseau

$A = \text{sim}(\text{net}, p)$;

où net est le pointeur retourné par une fonction de création de réseau.

A.7 La régression

Dans un problème de régression, les caractères ne sont pas considérés de la même façon. L'un d'eux est le caractère "à expliquer", les autres sont "explicatifs". Nous considérons d'abord le cas de deux caractères x (explicatif) et y (à expliquer). "Expliquer" signifie ici exprimer une dépendance fonctionnelle (comme fonction de x), de manière à prévoir la valeur de y connaissant celle de x . Si pour tout individu i , $y_i = f(x_i)$ et si on observe une valeur x_{n+1} du caractère x sur un nouvel individu, on donnera $f(x_{n+1})$ comme prédiction du caractère sur ce même individu. La situation idéale n'est jamais rencontrée en pratique. On cherchera plutôt, dans une famille fixée de fonctions, quelle est celle pour laquelle ils sont les plus proches des observations. La proximité se mesure en général comme une erreur quadratique moyenne. On

parle alors de régression au sens des moindres carrés. Les différences entre les valeurs observées et les valeurs prédites par le modèle s'appellent les résidus. Si le modèle est ajusté de sorte que la série des résidus soit centrée (de moyenne nulle), alors l'erreur quadratique est la variance des résidus.

La régression linéaire simple permet de mettre en relation deux variables continues : la variable cible Y et la variable explicative X.

Quelles que soient les variables continues X et Y, on a :

$$y_i = a x_i + b + R_i \quad (\text{A. 8})$$

avec :

- y_i : valeur de Y pour l'individu i.
- x_i : valeur de X pour l'individu i.
- a et b : coefficients de l'équation de régression linéaire.
- R_i : résidu pour l'individu i.

La partie « $a x_i + b$ » est la composante déterministe du modèle.

La partie R_i est la composante stochastique appelée «erreur» ou «résidu».

Remarque : des individus ayant la même valeur de X peuvent avoir des valeurs de Y différentes.

La droite $Y = aX + b$ est la droite de corrélation linéaire. On dit qu'elle «ajuste» le nuage de points.




Figure A.1 Régression linéaire.

Références

- [1] R. P. Lippman *"An Introduction to Computing with Neural Nets,"* IEEE ASSP magazine, pp.4-22, 1987.
- [2] C.G. BROYDEN, *"The convergence of a class of double-rank minimization algorithms 2: the new algorithm,"* Journal of the institute of Mathematics and its applications, 6, p. 222-231, .1970
- [3] A. H Zaabab, Q. J Zhang, M. Nakhla, *"A Neural Network Modeling Approach To Circuit Optimization And Statistical Design"* IEEE Transactions On Microwave Theory and Techniques, Vol. 43, no. 6, June 1995.

ANNEXE B

Méthode de la résonance transverse

Cohn [1] introduit successivement de part et d'autre de la fente des murs électriques et magnétiques faisant apparaître une structure de guide d'onde.

Considérons une fente excitée entre ses bords, de manière à créer deux ondes de même fréquence f et de même amplitude et de directions opposées. Il existe alors des plans transverses à la fente (plans normaux à l'axe Ox) séparés de $\lambda_g/2$ dans lesquels, le champ transverse électrique et le champ normal magnétique sont nuls. On obtient de plus un régime d'onde stationnaire. Ainsi on peut considérer deux murs électriques distants de $W = \lambda_g/2$ dans des plans pour lesquels E transverse est nul. Ces murs ainsi placés n'influencent pas sur l'onde stationnaire.




Figure B.1 Onde stationnaire sur la fente entre deux murs électriques.

De plus, on considère que lorsque $y = \pm L/2$ on a deux murs électriques ou magnétiques dans le plan normal à l'axe Oy . L est choisi suffisamment grand pour ne pas influencer sur l'onde [2]. Ainsi on obtient une structure de guide d'onde de longueur infinie selon l'axe Oz dont W et L sont les dimensions de la section.




Figure B.2 Section du guide d'onde rectangulaire




Figure B.3 Vue en coupe du guide d'onde

Dans le guide d'onde ainsi réalisé, on distingue trois régions, les régions I et III représentent une structure semi-infinie remplie d'air de guide d'onde rectangulaire de largeur $W = \lambda_g/2$ et de hauteur L , la région II représente un guide d'onde de même section de longueur d rempli de diélectrique de constante ϵ_r . La ligne à fente dans une telle structure se comporte comme un iris capacitif de largeur W_f . En tenant compte d'une infinité de modes discrets $TE_{1,2n}$ et $TM_{1,2n}$ satisfaisant le raccord des champs dans le plan de la fente $z = 0$, on obtient la susceptance totale ramenée par les régions I, II et III mises en parallèle. En se plaçant à la première résonance de la fente $W = \lambda_g/2$, la susceptance totale B_t s'annule. Il s'agit de la résonance transverse.

En posant les changements de variables :

$$\eta B_t = \frac{W}{2L} \left[-\alpha + v \tan \left(\frac{\pi d v}{W P} - \operatorname{arctg} \frac{\alpha}{v} \right) \right. \\ \left. + \frac{1}{P} \left\{ \left(\frac{\varepsilon_r + 1}{2} - P^2 \right) \ln \frac{2}{\pi \rho} \right. \right. \\ \left. \left. + \frac{1}{2} \sum_{n=1,2,3} \left[\alpha^2 \left(1 - \frac{1}{F_n} \right) + D_n \right] \frac{\sin^2(\pi n \rho)}{n(\pi n \rho)^2} \right\} \right] \quad (\text{B.1})$$

avec

$$\rho = \frac{W_f}{L}, \quad v = \sqrt{\varepsilon_r - P^2}, \quad \alpha = \sqrt{P^2 - 1}, \quad F_n = \sqrt{1 + \left(\frac{\alpha L}{2W_n P} \right)^2},$$

$$F_{n1} = \sqrt{1 - \left(\frac{\alpha L}{2W_n P} \right)^2}$$

➤ Pour F_{n1} réelle, l'expression de D_n est :

$$D_n = \frac{\varepsilon_r \operatorname{tanh} r_n - P^2 F_n \operatorname{coth} q_n}{\left[1 + \left(\frac{L}{2W_n} \right)^2 \right] F_{n1}} - v^2 \quad (\text{B.2})$$

Où

$$r_n = \frac{2\pi n d F_{n1}}{L} + \operatorname{tanh}^{-1} \left(\frac{F_{n1}}{\varepsilon_r F_n} \right); \quad q_n = \frac{2\pi n d F_{n1}}{L} + \operatorname{coth}^{-1} \left(\frac{F_n}{F_{n1}} \right)$$

➤ Pour F_{n1} imaginaire, l'expression de D_n devient:

$$D_n = \frac{\varepsilon_r \operatorname{tan} r'_n - P^2 F_n \operatorname{cot} q'_n}{\left[1 + \left(\frac{L}{2W_n} \right)^2 \right] |F_{n1}|} - v^2 \quad (\text{B.3})$$

Où

$$r'_n = \frac{2\pi n d |F_{n1}|}{L} + \operatorname{tanh}^{-1} \left(\frac{|F_{n1}|}{\varepsilon_r F_n} \right); \quad q'_n = \frac{2\pi n d |F_{n1}|}{L} + \operatorname{cot}^{-1} \left(\frac{F_n}{|F_{n1}|} \right)$$

L'expression de la susceptance qui vient d'être présentée permet de calculer les paramètres caractéristiques de la ligne à fente. En effet, le calcul du rapport entre la vitesse de phase et la vitesse de groupe se fait comme suit.

Soit une fréquence de travail f_0 , la longueur d'onde dans le vide est alors λ_0 fixe, on cherche P_0 la valeur de P qui annule la susceptance. Cela revient à chercher la valeur de λ_g pour laquelle la susceptance s'annule ; P ayant pour expression λ/λ_g . Pour les fréquences :

$f_1 = f_0 - \varepsilon$ et $f_2 = f_0 + \varepsilon$ voisines de f_0 , la susceptance s'annule respectivement λ_{g1} et λ_{g2} le rapport entre la vitesse de phase et la vitesse de groupe est alors :

$$\frac{v_\varphi}{v_g} = 1 + \frac{f_0}{\lambda_0/\lambda_g} \frac{\Delta(\lambda_0/\lambda_g)}{\Delta f} ; \Delta f = f_2 - f_1 \quad (\text{B. 4})$$

Le calcul de ηB_t pour $P_1 = P_0 - \varepsilon$ et $P_2 = P_0 + \varepsilon$ donne l'expression de l'impédance caractéristique suivante :

$$Z_{ca} = 376.7 \left[\frac{v_\varphi}{v_g} \right] \frac{\pi \Delta P}{P \Delta(\eta B_t)} \quad (\text{B. 5})$$

Ainsi, la méthode de la résonance transverse permet de déterminer les paramètres caractéristiques d'une ligne à fente à partir de sa largeur, de l'épaisseur et la constante diélectrique du substrat ainsi que la fréquence de travail.

Références

[1] S.B. Cohn, "*Slot Line on a Dielectric Substrate*," IEEE Transactions on microwave Theory and Techniques, MTT-17, 768-778, 1969.

[2] P. Gouget "*Etude de circuits hyperfréquences utilisant la jonction inhomogène ligne à fente-ligne microruban. Application à l'intégration de filtres et de iplexeurs*," Thèse de doctorat, Université de Bordeaux I, 2004.