

République Algérienne Démocratique et Populaire  
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



**Université de Batna 2**  
**Faculté de Technologie**  
**Département d'Électronique**



## **THÈSE**

**Présentée pour l'obtention du diplôme de**  
**DOCTORAT en SCIENCES**  
**Spécialité: Électronique**

### **OPTION**

**Contrôle**

**Par**

**AOUICHE Abdelaziz**

### **Thème**

---

# **Contribution à l'Etude des Structures Microruban Cylindriques par la Méthode Neuro-Spectrale**

---

Soutenue le : 06/06/2016

**Devant le jury composé de :**

Mr. Abdelmadjid BENGHALIA	Prof.	Université de Constantine 1	Président
Mr. Farid BOUTTOUT	Prof.	Université de Bordj Bou Arréridj	Rapporteur
Mr. Tarek FORTAKI	Prof.	Université de Batna 2	Co-Rapporteur
Mr. Djamel BENATIA	Prof.	Université de Batna 2	Examineur
Mme. Fatiha BENABDELAZIZ	Prof.	Université de Constantine 1	Examineur
Mr. Kheiredine CHAFAA	Prof.	Université de Batna 2	Examineur

## Dédicaces

*Je dédie cette thèse  
à mes parents.*

*Spécialement à mon père BOUZID, décédé depuis deux ans, qui m'a toujours poussé et motivé dans mes études. J'espère que, du monde qui est sien maintenant, il apprécie cet humble geste comme preuve de reconnaissance de la part d'un fils qui a toujours prié pour le salut de son âme. Puisse Dieu, le tout puissant, l'avoir en sa sainte miséricorde !*

*Je tiens à présenter mes reconnaissances et mes remerciements à mon grand frère BOUBAKEUR Qui n'a jamais cessé de me soutenir pour que je puisse finir mes études et avoir une bonne formation et surtout être le meilleur et à qui je voudrais exprimer mes affections et mes gratitude.*

*Merci aussi à tous ceux qui ont consacré du temps, de l'énergie et de la patience.*

*“ La théorie, c'est quand on sait tout et que rien ne fonctionne. La pratique, c'est quand tout fonctionne et que personne ne sait pourquoi. Ici, nous avons réuni théorie et pratique : Rien ne fonctionne... et personne ne sait pourquoi ! ”*

*(Albert Einstein)*

## Remerciements

Je tiens tout d'abord à remercier le professeur BOUTTOUT Farid, mon directeur de thèse, qui durant ces années de cette thèse a toujours été présent pour m'encadrer, me diriger, et me soutenir. Pour ses multiples conseils et pour toutes les heures qu'il a consacrées à diriger cette recherche. J'aimerais également lui dire à quel point j'ai apprécié sa grande disponibilité et son respect sans faille des délais serrés de relecture des documents que je lui ai adressés.

En particulier, je tiens à remercier mon Co-encadreur du thèse, Monsieur le professeur FORTAKI Tarek pour la confiance qu'il m'a accordée en acceptant d'encadrer ce travail doctoral comme un co-encadreur . J'ai été extrêmement sensible à ses qualités humaines d'écoute et de compréhension tout au long de ce travail doctoral.

Je remercie également mon enseignant préféré CHAFAA Khierredine d'avoir accepté d'être examinateur de jury de cette thèse.

J'aimerais aussi remercier madame BENABDELAZIZ Fatiha et le professeur BENATIA Djamel, d'être venus assister à ma soutenance en qualité d'examineurs.

Je voudrais remercier le professeur BENGHALIA Abdelmadjid, en tant que président du jury de ma thèse.

Je remercie également toutes les personnes avec qui j'ai eu la chance de collaborer et surtout : DJELLID asmaa enseignante à l'université de BOUIRA avec qui j'ai effectué toutes les données expérimentales.

J'exprime ma profonde gratitude à monsieur MEZAACHE salah , pour l'intérêt qu'il a porté à notre collaboration et les nombreuses assistance qu'il a effectués dans ce cadre. Je le remercie également pour m'avoir fourni toutes les facilités, me permettant ainsi de mieux terminer ce travail.

Je remercie également tous ceux qui ont contribué de près ou loin au parachèvement de ce travail de thèse, soit par leur savoir scientifique ou par leur amitié.

Et enfin je voudrais remercier mes amis et mes proches. Et je dédie cette thèse à ma famille.

# SOMMAIRE

<b>INTRODUCTION GÉNÉRALE.....</b>	<b>01</b>
<b>Références bibliographiques.....</b>	<b>06</b>
<b>CHAPITRE I - ANALYSE ET IDENTIFICATION DES LIGNES COPLANAIRES MULTICOUCHES ELLIPTIQUES CYLINDRIQUES ET PLANAIRES PAR LA TECHNIQUE DE LA TRANSFORMÉE CONFORME</b>	<b>09</b>
<b>I.1 Introduction.....</b>	<b>10</b>
<b>I.2. Technologies planaires .....</b>	<b>10</b>
<i>I.2.1. Présentation de la ligne microruban.....</i>	<i>10</i>
<i>I.2.2. Equations d'analyse d'une ligne microstrip.....</i>	<i>11</i>
<b>I.3. Technologie guide d'onde coplanaire.....</b>	<b>13</b>
<b>I.4. Technologie coplanaire stripline (CPS) .....</b>	<b>13</b>
<b>I.5. Technologie ligne à fente ou slotline.....</b>	<b>14</b>
<b>I.6. Technologie multi-couche.....</b>	<b>15</b>
<b>I.7. Méthodes d'analyse des structures planaires.....</b>	<b>15</b>
<i>I.7.1. Méthode des moments.....</i>	<i>16</i>
<i>I.7.2. Méthode quasi- statique.....</i>	<i>16</i>
<b>I.8. Analyse des lignes coplanaires multicouches elliptiques (MECPS) Cylindriques (MCCPS), et asymétriques (MACPS) avec dimensions diélectriques finis par la technique de transformation conforme (CMT) .....</b>	<b>17</b>
<i>I.8.1. La Transformation des structures elliptiques et cylindriques à une Structure     planaire.....</i>	<i>19</i>
<b>I.9. Permittivité diélectrique effective et impédance caractéristique de la structure planaire .....</b>	<b>20</b>
<i>I.9.1. Calcul de la capacité de l'air <math>C_0</math> .....</i>	<i>21</i>
<i>I.9.2. Calcul des capacités des diélectriques <math>C_{di}</math> .....</i>	<i>22</i>

<b>I.10. Modélisation d'un processus .....</b>	25
<b>I.11. Caractérisation .....</b>	26
<b>I.12. Principe de la modélisation et l'estimation.....</b>	26
<b>I.13. Identification.....</b>	27
<b>I.14. Méthodes d'identification .....</b>	27
<b>I.15. Conclusion.....</b>	28
<i>Références bibliographiques.....</i>	29

**CHAPITRE II - IDENTIFICATION DES PARAMETRES QUASI-STATIQUES  
DES LIGNES DE TRANSMISSION PAR LES RESEAUX DE NEURONES (ANNs)** 32

<b>II.1. Introduction.....</b>	33
<b>II.2. Historique.....</b>	33
<b>II.3. Neurone biologique.....</b>	34
<b>II.4. Modèle mathématique.....</b>	35
<b>II.5. Neurone formel.....</b>	36
<b>II.6. Réseaux de neurones artificiels (ANN).....</b>	39
<b>II.7. Architecture des réseaux de neurones.....</b>	40
<i>II.7.1. Les réseaux de neurones non bouclés (Statiques) .....</i>	40
<i>II.7.2. Les réseaux de neurones bouclés (Dynamiques) .....</i>	41
<i>II.7.3. Réseau à connexions récurrentes (Feed back) .....</i>	42
<b>II.8. Perceptron multicouche (MLP).....</b>	42
<b>II.9. Apprentissage des réseaux MLP.....</b>	45
<i>II.9.1. Algorithme de rétro-propagation .....</i>	45
<i>II.9.2. Algorithme de Levenberg-Marquardt.....</i>	48
<b>II.10. Réseaux de neurones à fonctions de base radiales (RBF).....</b>	50
<b>II.11. Un réseau de neurone artificiel pour le calcul des paramètres quasi-statiques des lignes de transmission coplanaires (MACPS), (MCCPS) et MECPS).....</b>	52

<b>II.12. Organigramme d'apprentissage d'ANN pour calculer les paramètres quasi-statiques des lignes MECPS, MCCPS, et MACPS .....</b>	<b>54</b>
<b>II.13. Conclusion.....</b>	<b>55</b>
<i>Références bibliographiques.....</i>	<i>56</i>
<b>CHAPITRE III - IDENTIFICATION DES PARAMETRES QUASI-STATIQUES DES LIGNES DE TRANSMISSION PAR LES SYSTEMES FLOUS (FSs)</b>	<b>59</b>
<b>III.1. Introduction.....</b>	<b>60</b>
<b>III.2. Modélisation floue de systèmes.....</b>	<b>60</b>
<b>III.3. Systèmes d'Inférence Floue.....</b>	<b>61</b>
<b>III.4. Ensembles flous.....</b>	<b>61</b>
<i>III.4.1 Variable linguistique.....</i>	<i>62</i>
<i>III.4.2. Fonction d'appartenance.....</i>	<i>63</i>
<i>III.4.3. Propositions floues .....</i>	<i>65</i>
<i>III.4.4. Implications floues .....</i>	<i>66</i>
<b>III.5. Structure interne d'un système d'inférence floue (SIF) .....</b>	<b>67</b>
III.5.1. La Fuzzification.....	68
<i>III.5.1.1. Fuzzification numérique.....</i>	<i>68</i>
<i>III.5.1.2. Fuzzification singleton .....</i>	<i>68</i>
<i>III.5.1.3.Fuzzification non-singleton.....</i>	<i>68</i>
<i>III.5.1.4. Fuzzification symbolique.....</i>	<i>69</i>
III.5.2.Différentes méthodes d'inférences floues.....	70
<i>III.5.2.1. Inférence floue de type Mamdani.....</i>	<i>72</i>
<i>III.5.2.2 . Inférence floue de type Takagi-Sugeno-Kang (TSK).....</i>	<i>72</i>
III.5.3. Défuzzification.....	74
<b>III.6. Construction des modèles TSK à partir des données.....</b>	<b>74</b>
<b>III.7. Algorithme de rétro-propagation à l'identification floue .....</b>	<b>74</b>

<b>III.8. Structure de système d'inférence floue pour calculer les paramètres quasi-statiques des lignes de transmission.....</b>	<b>79</b>
<b>III.9. Organigramme d'apprentissage de FS pour calculer les paramètres quasi-statiques des lignes MECPS, MCCPS, et MACPS .....</b>	<b>80</b>
<b>III.10. Conclusion.....</b>	<b>81</b>
<i>Références bibliographiques.....</i>	<i>82</i>
 <b>CHAPITRE IV - RÉSULTATS DE SIMULATION ET DISCUSSION</b>	<b>85</b>
 <b>IV.1. Introduction.....</b>	<b>86</b>
<b>IV.2. Résultats Numériques.....</b>	<b>86</b>
<i>IV.2. 1. Comparaison des paramètres quasi-statiques des MECPS, MCCPS et MACPS avec la littérature.....</i>	<i>86</i>
<b>IV.3. Identification des paramètres quasi-statiques des MECPS, MCCPS et MACPS par les réseaux de neurones et la logique floue.....</b>	<b>97</b>
<i>IV.3.1. Détermination de l'architecture convenable du modèle neuronal et flou.....</i>	<i>98</i>
<i>IV.3.2. Différents cas de validation des modèles suggérés.....</i>	<i>99</i>
<i>IV.3.3. Les courbes de comparaison entre ANN, FS et CMT.....</i>	<i>105</i>
<b>IV.4. Conclusion.....</b>	<b>135</b>
<i>Références bibliographiques.....</i>	<i>136</i>
 <b>CONCLUSION GÉNÉRALE .....</b>	<b>138</b>

---

## CONTRIBUTION A L'ETUDE DES STRUCTURES MICRORUBAN CYLINDRIQUES PAR LA METHODE NEURO-SPECTRALE

---

### Résumé

Dans ce travail, les expressions analytiques exactes compactes sont présentées pour calculer les paramètres quasi-statiques des micro-rubans symétriques/asymétriques multicouches planaires coplanaires (MACPS), cylindriques (MCCP), et elliptiques (MECPS) utilisant la technique de la transformation conforme (CMT). La forme générale des expressions développées peut prendre en compte un nombre arbitraire de couches diélectriques en dessus/ ou en dessous de l'interface des rubans. Les modèles basés sur les réseaux de neurones artificiels (ANNs) et les systèmes flous (FSs) sont mis en œuvre où la CMT étant la référence dans le processus d'apprentissage. Les ANNs et les FSs sont entraînés en utilisant l'algorithme de rétro-propagation en conjonction avec les méthodes de Levenberg-Marquardt (LM) et Takagi-Sugeno-Kang (TSK), respectivement. Par l'écriture de codes efficaces en Matlab®R13 pour l'implémentation des ANNs et des FSs et en effectuant un échantillonnage adéquat des variables d'entrée, la taille de la matrice d'apprentissage d'entrée peut atteindre 10000 par 14, ce qui assure une grande précision des deux modèles. Les résultats des ANNs et FSs entraînés par leurs algorithmes respectifs pour les paramètres quasi-statiques des MACPS, MCCPS et MECPS sont très bon accord avec les résultats disponibles dans la littérature.

**Mots clés :** Ruban Multicouche, Ruban elliptique, Ruban cylindrique, Ruban coplanaire, Transformée conforme, Réseau de neurones, Logique floue.

---

## FUZZY NEUROCONFORMAL ANALYSIS OF MULTILAYER ELLIPTICAL CYLINDRICAL AND ASSYMETRICAL COPLANAR STRIPLINES

---

### **Abstract**

In this work, accurate and compact analytic closed-form expressions are presented in order to calculate the quasi-static parameters of symmetric / asymmetric multilayer planar coplanar stripline (MACPS), multilayer cylindrical (MCCPS), and multilayer elliptical (MECPS) by using the conformal mapping technique (CMT). The general form of the developed expressions can take into account an arbitrarily number of dielectric layers above and / or below the strips interface. Models based on artificial neural networks (ANNs) and fuzzy systems (FSs) are implemented where the CMT being the reference in training process. The ANNs and FSs are trained using the back-propagation algorithm together with Levenberg–Marquardt (LM) and Takagi–Sugeno–Kang (TSK) methods, respectively. By writing efficient Matlab®R13 coding for implementation of the ANNs and FSs and performing adequate sampling of the input variables, the size of the input training matrix reaches 10,000 by 14 which ensures high accuracy of the two models. The results of the ANNs and FSs trained with their respective algorithms for the quasi-static parameters of the MACPS, MCCPS, and MECPS are in very good agreement with the results available in the literature.

**Keywords:** Multilayer Strip, Elliptical strip, Cylindrical strip, Coplanar strip, Conformal mapping, Neural network, Fuzzy logic.

## ***ABREVIATIONS ET SYMBOLES***

Adaline : Adaptive Linear Element (Élément adaptatif linéaire)

ANN: Artificial neural network (Les réseaux de neurones artificiels)

ANFIS: Adaptive-network-based fuzzy inference system (Les systèmes d'inférence neuro-floue adaptatifs)

CMT: Conformal mapping technique (Technique de transformation conforme)

CPS: Coplanar stripline (Ligne coplanaire à microruban)

CPW: Conventional coplanar waveguide (Guide d'ondes coplanaire)

FDTD: Finite-Difference Time-Domain method (La technique des différences finies)

FEM : Finite elements method (La méthode des éléments finis)

FET : Field Effect Transistor (Transistor à effet de champ)

FS: Fuzzy system (système flou)

LM: Levenberg-Marquardt

LSBRM: The method of least squares (La méthode des moindres carrés)

LTCC: Low-Temperature Cofired Ceramic (Céramique co-frittée à basse température)

MACPS: Asymmetric multilayer planar coplanar stripline (Ligne de transmission coplanaire multicouche asymétrique)

MCCPS: Multilayer cylindrical coplanar stripline (Ligne de transmission coplanaire multicouche cylindrique)

MECPS: Multilayer elliptical coplanar stripline (Ligne de transmission coplanaire multicouche elliptique)

MoM: Method of Moments (Méthode des Moments)

MLP: Multilayer Perceptron (Le Perception multicouche)

MMIC :Monolithic MIC (Circuits intégrés micro-ondes monolithiques)

MMT: Mode-Matching Technique

MIC: Microwave Integrated Circuits (Circuits intégrés micro-ondes)

RBF: Radial basic Function (Les réseaux de neurones à fonctions de base radiales)

SIF: Fuzzy Inference System (Système d'inférence flou)

TEM : Transversal electromagnetic mode (Transverse Electromagnétique)

TLM: Transmission-line matrix method (La méthode de la matrice des lignes de transmission)

TM: Transversal magnetic (Traverse magnétique)

TRM: Transverse Resonance Method (Méthode de résonance transversale)

TSK: Takagi-Sugeno-Kang

VCOs : Voltage-controlled oscillators (Oscillateurs commandés en tension)

$AR$ : Axial ratio (Rapport des axes)

$h$ : Hauteur du substrat diélectrique (The dielectric material's height )

$r$ : Radius of the substrate interface (Rayon d'interface du substrat)

$T$ : Thickness of the strip (Épaisseur du ruban)

$W$ : Width of metal strip (Largeur du ruban)

$Z_0$ : Characteristic impedance (Impédance caractéristique)

$\epsilon_{eff}$ : Effective permittivity (Permittivité effective)

$\epsilon_r$ : Relative permittivity (Permittivité relative)

$\theta$ : Opening angle of the strips (Angle d'ouverture des rubans)

$2\phi$ : Gap between the two strips (Écart entre les deux rubans)

---

# ***INTRODUCTION GÉNÉRALE***

## ***INTRODUCTION GÉNÉRALE***

Depuis les dernières décennies, le domaine des micro-ondes qui sont basées sur les structures planaires et coplanaires se prêtent particulièrement bien à la réalisation et à la miniaturisation des circuits passifs et actifs. Le développement de ces technologies a débouché sur la production industrielle de dispositifs en technologie hybride et de composants MIC (Microwave Integrated Circuits) ou MMIC (Monolithic MIC), dans lesquels les circuits passifs (type lignes de transmission) et les éléments semi-conducteurs (transistors et diodes) sont intégrés sur le même substrat semi-conducteur, principalement en Silicium ou en Arséniure de Gallium [1].

La modélisation électromagnétique des structures coplanaires CPS telles que les discontinuités régulières et irrégulières, les résonateurs et les filtres, s'effectue par trois techniques différentes. La première, dite quasi-statique, ne fournit que des solutions approchées pour les paramètres de la structure, valables uniquement aux basses fréquences. La deuxième est basée sur le modèle des guides d'ondes équivalents. Elle peut nous renseigner sur la dispersion et ses effets aux hautes fréquences, cependant elle ne tient pas compte des pertes dues aux rayonnements et aux excitations des ondes de surface au niveau de la surface de la structure. La troisième approche dite onde complète (full-wave), tient compte aussi bien du rayonnement des ondes de surface que des ondes d'espace [2].

Les paramètres quasi-statiques de CPS avec un seul/multiples substrats diélectriques ont été analysés en utilisant la technique de la transformation conforme (CMT) qui est la transformation d'une région définie dans un plan complexe à une région distincte dans un plan de référence d'une autre variable complexe [3]-[4]. La CMT a été appliquée pour l'analyse des antennes et des circuits micro-ondes. Lambert et al. ont utilisé la CMT pour calculer l'impédance caractéristique de l'antennes cornet TEM [5]. Dans la référence [6], la CMT a été utilisée pour convertir une structure microbande en un guide d'ondes clos pour lequel la technique FDTD est utilisée pour calculer les coefficients de dispersion du guide d'onde discontinu. Zhu et al. ont utilisé la CMT pour dériver des expressions analytiques pour les distributions de champ dans la CPS à support [7]. Les fonctions de Green pour les structures périodiques ondulées ont été calculées en utilisant la CMT [8]. Récemment, la

CMT a été utilisée pour estimer les paramètres quasi-statiques de guide d'ondes coplanaire [9]-[10].

L'un des défis du chercheur au cours de la dernière décennie, est de copier la nature et de reproduire des modes de raisonnement et de comportement qui lui sont propres. Les réseaux de neurones artificiels (ANNs), sont nés de cette envie. Ils réalisent facilement un certain nombre d'applications telles que la reconnaissance des formes, le traitement du signal, l'apprentissage, la mémorisation et la généralisation. Ces applications sont pourtant, malgré tout les efforts déployés en algorithmique et en intelligence artificielle, à la limite des possibilités actuelles c'est à partir de l'hypothèse que le comportement intelligent émerge de la structure et du comportement des éléments de base du cerveau que les réseaux de neurones artificiels se sont développés. Les ANNs sont des systèmes de traitement d'information dont la conception est inspirée par les études de la capacité du cerveau humain à apprendre à partir des observations et de généraliser par abstraction. Ils peuvent être entraînés pour apprendre des relations arbitraires d'entrée-sortie à partir de données correspondantes. Suntives et al. ont utilisé les ANNs pour modéliser les éléments RF linéaires ainsi que les sous-circuits non linéaires tels que les amplificateurs, les mélangeurs et les Oscillateurs Commandés en tension (VCOs) [11].

Sur la base des réseaux à perceptrons multicouches; une méthode généralisée pour la détermination précise des fréquences de résonance des antennes microrubans de géométries régulières a été présentée dans [12]. Dans la référence [13], Guney et Sarikaya ont calculé la résistance d'entrée des antennes microrubans circulaires utilisant l'approche ANN.

Une approche basée sur les ANNs a été introduite pour déterminer les paramètres caractéristiques de guide d'ondes coplanaire (CPW) intercalée entre deux substrats diélectriques [14]. Pascual Garcia et al ont présenté une technique basée sur les ANNs pour la conception des filtres micro-ondes de la technologie imprimée blindée [15]. Une méthode basée sur les systèmes d'inférence neuro-floue adaptatif (ANFIS) a été présentée pour l'analyse de CPWs asymétrique avec conducteur en arrière, où quatre algorithmes d'optimisation ont été utilisés pour concevoir les paramètres de l'ANFIS [16].

En outre, il a été démontré que les systèmes flous sont capables d'approximer toute fonction réelle continue sur un ensemble compact pour une précision arbitraire. Dans [17], une méthode basée sur des systèmes d'inférence floue (FISs) pour calculer la fréquence de résonance d'éléments d'antenne microruban rectangulaire électriquement mince et épais a été présentée. Dans [18], Guney et Sarikaya ont présenté une méthode de calcul de la résistance d'entrée de l'antenne microruban circulaire utilisant ANFIS. Cette méthode fût aussi utilisée pour la synthèse des antennes microrubans rectangulaires avec des substrats minces et épais [19]. Gaoua et. al ont développé des techniques neuronales et neurones-floues robustes pour modéliser des transistors à effet de champ (FETs) et des transistors bipolaires à hétérojonction [20].

L'intérêt de ces approches neuronales et floues réside dans leurs capacités à réagir automatiquement à un environnement complexe tel que les systèmes de télécommunication. Dans ce travail, nous étudions trois modèles de lignes de transmission coplanaires multicouches asymétriques (MACPS), cylindriques (MCCPS) et elliptiques (MECPS) par la technique de la transformation conforme (CMT) en conjonction avec les réseaux de neurones (ANNs) et les systèmes flous (FSs). Les formules de l'analyse des paramètres quasi-statiques pour calculer l'impédance caractéristique ( $Z_0$ ) et la constante diélectrique effective ( $\epsilon_{eff}$ ) de ces modèles de lignes de transmission sont présentées. Les données de l'apprentissage du réseau neuronal et du système flou sont obtenues à partir des simulations numériques utilisant la technique CMT.

Nous choisissons dans ce travail la technique CMT comme une base de référence comme présentée par Volkan Akan [4] et nos résultats obtenus s'accordent bien avec ceux de cette dernière référence citée. Premièrement, les données de l'apprentissage sont préparées, les ANN et FS sont ainsi prêts pour l'entraînement. Deuxièmement, l'algorithme standard de la rétro-propagation du gradient basé sur l'approche de Levenberg-Marquardt (LM) est utilisé pour l'entraînement de l'ANN, alors que l'algorithme de rétro-propagation est aussi choisi pour l'entraînement du FS, utilisant l'approche de Takagi-Sugeno-Kang (TSK). Les approches LM et TSK sont choisies en raison de leur convergence garantie et de leur robustesse numérique. Troisièmement, l'ANN et le FS sont appliqués pour prédire les paramètres quasi-statiques des lignes de transmission. Il est nécessaire de les tester sur une base de données différente de celle utilisée pour l'apprentissage.

L'utilisation des ANN et FS avec des algorithmes d'apprentissage appropriés présentent les avantages suivants :1) Le nombre de variables d'entrée peut être augmenté. En effet, pour les lignes de transmission étudiées, nous utilisons 10 entrées pour le MACPS et MCCPS alors que le nombre des entrées est de 14 pour MECPS. 2) L'entraînement de l'ANN et du FS est capable de prédire les paramètres quasi-statiques des lignes de transmission sans utiliser des fonctions spéciales de Jacobi qui consomment beaucoup de temps de simulation.

Ce travail consiste en quatre chapitres, organisés comme suit :

- Dans le premier chapitre, nous présentons les structures géométriques des lignes de transmission étudiées avec la formulation mathématique du problème utilisant la CMT. L'utilisation appropriée des transformations complexes, les structures coplanaires multicouches, elliptiques et cylindriques sont transformées en lignes coplanaires microrubans dont les formules quasi-statiques sont bien établies.
- Dans le deuxième chapitre, nous décrivons les différents concepts théoriques de l'identification par ANN. Une synthèse de quelques approches des réseaux de neurones artificiels est donnée, accent mis sur *le Perceptron Multicouches (MLP)* par laquelle nous avons réalisé ce travail. Les différentes étapes de l'identification des paramètres caractéristiques des lignes de transmission sont expliquées et présentées sous forme d'organigramme afin d'aider à la mise en œuvre numérique.
- Dans le troisième chapitre, nous décrivons l'approche d'identification des données par les modèles flous de TSK, moyennant un ensemble de règles *Si-Alors*. Cette approche a été testée sur des cas de simulation des lignes de transmission et a prouvé une grande efficacité de point de vue analyse et interprétation sans avoir recours au jugement d'un expert humain.
- Dans le quatrième chapitre, nos résultats de simulation obtenus par les réseaux de neurones artificiels (ANN) et les systèmes flous (FS) sont comparés avec les données disponibles dans la littérature. L'application des méthodes citées précédemment sous forme des résultats est présentée et interprétée dans ce chapitre pour démontrer l'efficacité des techniques de formation suggérées.

***Références bibliographiques***

- [1] M. Le Roy, «Analyse et optimisation de lignes de transmission à variation continue d'impédance: application au filtrage », *Thèse de Doctorat*, Université de Bretagne occidentale, Brest, 1999.
- [2] M. Laib, «Caractérisation de la ligne coplanaire à microruban volumique et ses discontinuités par l'approche Full-wave basée sur la technique MPIE dans le domaine spatial», *Thèse de Doctorat*, Université Ferhat Abbas, Sétif, 07 mai 2012.
- [3] V. Akan and E. Yazgan, “A Simple Formulation for Quasi-static Solutions of Elliptical, Cylindrical and Asymmetrical Coplanar Strip Lines”, *Microwave and Optical Technology Letters*, vol. 41, n° 1, pp. 18–21, 5th April 2004.
- [4] V. Akan and E. Yazgan, “Quasi-Static Solutions of Multilayer Elliptical, Cylindrical Coplanar Striplines and Multilayer Coplanar Striplines with Finite Dielectric Dimensions Asymmetrical Case”, *IEEE Transactions on Microwave Theory and Techniques*, vol. 53, n° 12, pp. 3681–3686, December 2005.
- [5] A. P. Lambert, S. M. Booker and P. D. Smith, “Calculation of the Characteristic Impedance of TEM Horn Antennas using the Conformal Mapping Approach”, *IEEE Transactions on Antennas and Propagation*, vol. 43, n° 1, pp. 47–53, January 1995.
- [6] S. Kapoor and J. B. Schneider, “Characterization of Microstrip Discontinuities using Conformal Mapping and the Finite-Difference Time-Domain Method”, *IEEE Transactions on Microwave Theory and Techniques*, vol. 43, n° 11, pp. 2636–2639. November 1995.
- [7] N. H. Zhu, E. Y.B. Pun and P. S. Chung, “Field Distributions in Supported Coplanar Lines using Conformal Mapping Techniques”, *IEEE Transactions on Microwave Theory and Techniques*, vol. 44, n° 8, pp. 1493–1496, August 1996.
- [8] Y. A. Tsarin, “Conformal Mapping Technique in the Theory of Periodic Structures”, *Microwave and Optical Technology Letters*, vol. 26, n° 1, pp. 57–61, 5<sup>th</sup> July 2000.
- [9] M. Kumar, R. Saxena, A. Kumar, P. Kala, and R. Pant, “Theoretical Characterization of Coplanar Waveguide using Conformal Mapping”, *International Journal of Advanced Research in Computer Science and Electronics Engineering (IJARCSEE)*, vol. 1, issue 4, pp. 48-51, June 2012.

- [10] N. Boothalingam and P. Karantharaj, “A Conformal Mapping Approach to Various Coplanar Waveguide Structures”, *Australian Journal of Basic and Applied Sciences*, 8(3), pp. 173-178, March 2014.
- [11] A. Suntives, M. S. Hossain, J. Ma, R. Mittra, and V. Veremey, “Application of Artificial Neural Network Models to Linear and Nonlinear RF Circuit Modeling”, *International Journal of RF and Microwave Computer-Aided Engineering*, vol. 11, n° 4, pp. 231–247, July 2001.
- [12] K. Guney, S. Sagiroglu, and M. Erler, “Generalized Neural Method to Determine Resonant Frequencies of Various Microstrip Antennas”, *International Journal of RF and Microwave Computer-Aided Engineering*, vol. 12, n° 1, pp.131–139, January 2002.
- [13] K. Guney and N. Sarikaya, “Artificial Neural Networks for Calculating the Input Resistance of Circular Microstrip Antennas”, *Microwave and Optical Technology Letters*, vol. 37, n° 2, pp. 107–111, 20<sup>th</sup> April 2003.
- [14] C. Yildiz, S. Sagiroglu, and M. Turkmen, “Neural model for coplanar wave guides and wiced between two dielectric substrates”, *IEE Proceedings on Microwave Antennas and Propagation*, Vol. 151, n° 1, February 2004.
- [15] J. P. Garcia, F. Q. Pereira, D. C. Rebenaque, J. S. G. Diaz, A. A. Melcon, “A New Neural Network Technique for the Design of Multilayered Microwave Shielded Bandpass Filters”, *International Journal of RF and Microwave Computer-Aided Engineering*, vol. 19, n° 3, pp.405–415, May 2009.
- [16] S. Kaya, K. Guney, C. Yildiz, and M. Turkmen, “ANFIS Models for Synthesis of Micro-Coplanar Stripline and Asymmetric Coplanar Stripline with an Infinitely Wide Strip”, *Microwave and Optical Technology Letters*, vol. 54, n° 2, pp. 460–467, February 2012.
- [17] S. Ozer, K. Guney and A. Kaplan, “Computation of the Resonant Frequency of Electrically Thin and Thick Rectangular Microstrip Antennas with the Use of Fuzzy Inference Systems”, *International Journal of RF and Microwave Computer-Aided Engineering*, vol. 10, n° 2, pp.108–119, March 2000.

- [18] K. Guney and N. Sarikaya, “Adaptive-Network-Based Fuzzy Inference System Models for Input Resistance Computation of Circular Microstrip Antennas”, *Microwave and Optical Technology Letters*, vol. 50, n° 5, pp. 1253–1261, May 2008.
- [19] K. Guney and N. Sarikaya, “Multiple Adaptive-Network-Based Fuzzy Inference System for the Synthesis of Rectangular Microstrip Antennas with Thin and Thick Substrates”, *International Journal of RF and Microwave Computer-Aided Engineering*, vol. 18, n° 4, pp.359–375, July 2008.
- [20] S. Gaoua, L. Ji, Z. Cheng, F. A. Mohammadi, and M. C. E. Yagoub, “Fuzzy Neural-Based Approaches for Efficient RF/Microwave Transistor Modeling”, *International Journal of RF and Microwave Computer-Aided Engineering*, vol. 19, n° 1, pp.128–139, January 2009.

---

# *CHAPITRE I*

## *ANALYSE ET IDENTIFICATION DES LIGNES COPLANAIRES MULTICOUCHES ELLIPTIQUES CYLINDRIQUES ET PLANAIRES PAR LA TECHNIQUE DE LA TRANSFORMEE CONFORME*

## **I.1. Introduction**

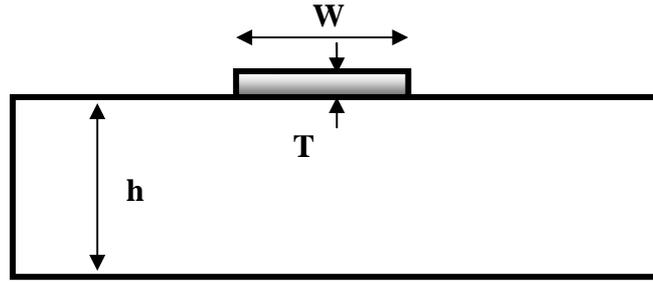
Depuis de nombreuses années, le domaine des hyperfréquences connaît une évolution constante. L'une des tendances les plus importantes est le passage, amorcé au début des années 60, des technologies "classiques" type guide d'onde aux technologies plaquées à microruban [1]. Dans ce chapitre, nous présentons la modélisation du structure simplifiée des lignes microrubans ses avantages et ses inconvénients ainsi que les différentes techniques son analyses existantes, le présent chapitre illustre les méthodes d'identification des processus et celle utilisée dans ce travail. Ce chapitre présente aussi les méthodes d'analyse les plus répandues de nos lignes de transmission choisies.

## **I.2. Technologie planaire**

Compte tenu des contraintes de poids et de taille des circuits liées aux nouvelles applications, on parle alors de technologie planaire. Cette technologie présente de nombreux avantages parmi lesquelles une grande souplesse de réalisation et de réglage ainsi que des faibles coûts de réalisation [2].

### **I.2.1. Présentation de la ligne microruban**

La ligne microruban est la plus utilisée parmi toutes les lignes de transmission planaires. Cette technologie de ligne offre à la fois la simplicité et la facilité de réalisation et d'intégration dans les dispositifs micro-ondes. La géométrie d'une ligne microruban est décrite par la Figure (I.1). Un ruban métallique de largeur  $W$  est déposé sur un diélectrique d'épaisseur  $h$  et de permittivité relative  $\epsilon_r$ . L'autre face du diélectrique, totalement métallisée, constitue le plan de masse. La ligne microruban assure une bonne gamme d'impédances caractéristiques réalisables. L'impédance caractéristique de la ligne, pour une permittivité donnée, est déterminée par le rapport  $W/h$ . Le mode dominant qui se propage sur la ligne microruban est un mode hybride. Cependant, compte tenu de la faible amplitude des composantes longitudinales  $E_z$  et  $H_z$  par rapport aux composantes transverses  $E_t$  et  $H_t$ , le mode dominant sur une ligne microruban est considéré comme un mode quasi-TEM (Transverse Electro-Magnetic). Les équations décrivant ces lignes ont été établies avec une variété de techniques analytiques et numériques [3].



**Figure I.1.** Coupe transversale d'une ligne microruban.

L'exemple le plus connu de ligne microruban est le circuit imprimé double face dont l'une des faces est entièrement cuivrée. De nombreuses études ont montré qu'une telle ligne de transmission est le siège d'une onde se propageant en mode quasi-TEM, c'est à dire que les champs électrique et magnétique sont perpendiculaires à l'axe de la ligne selon lequel s'effectue la propagation.

L'impédance caractéristique et la constante diélectrique effective d'un microruban dépendent de ses dimensions et de la nature du matériau isolant. On trouve dans la littérature plusieurs équations empiriques complexes permettant de calculer ces paramètres à partir des données géométriques (analyse) ou inversement de déterminer les dimensions  $W/h$  permettant d'obtenir une ligne d'impédance caractéristique donnée (conception, design) [4].

### I.2.2. Equations d'analyse d'une ligne microstrip

Les équations ci-dessus permettent de calculer l'impédance caractéristique  $Z_0$  et la permittivité effective  $\epsilon_{eff}$  d'une ligne microstrip dont on connaît les dimensions. Pour une meilleure précision on utilise deux équations différentes selon la valeur de  $W/h$  [4] :

Pour  $W/h < 1$

$$Z_0 = \frac{60}{\sqrt{\epsilon_{eff}}} \ln \left( \frac{8h}{W} + \frac{W}{4h} \right) \quad (I.1)$$

avec

$$\epsilon_{eff} = \frac{\epsilon_r + 1}{2} + \frac{\epsilon_r - 1}{2} \left[ \left( 1 + 12 \frac{h}{W} \right)^{-1/2} + 0.04 \left( 1 - \frac{W}{h} \right)^2 \right] \quad (I.2)$$

pour  $W/h > 1$

$$Z_0 = \frac{120\pi/\varepsilon_{eff}}{\frac{W}{h} + 1.393 + 0.667 \ln\left(\frac{W}{h} + 1.444\right)} \quad (I.3)$$

avec

$$\varepsilon_{eff} = \frac{\varepsilon_r + 1}{2} + \frac{\varepsilon_r - 1}{2} \left[ \left(1 + 12 \frac{h}{W}\right)^{-1/2} \right] \quad (I.4)$$

Ces équations utilisent les paramètres suivants :

$Z_0$  : Impédance caractéristique de la ligne

$\varepsilon_{eff}$ : Constante diélectrique effective isolant (permittivité effective)

$W$  : Largeur de la piste

$T$  : Epaisseur de la piste

$H$  : Epaisseur du diélectrique

$\varepsilon_r$ : Constante diélectrique du matériau isolant (permittivité relative).

Plusieurs variantes de lignes microrubans existent, citons les lignes microrubans enterrées et les lignes microrubans suspendues ou “Stripline”.

Les relations précédentes ont été établies en supposant que l'épaisseur  $T$  du conducteur est très faible devant l'épaisseur  $h$  de l'isolant ( $T/h < 0.005$ ). Dans les autres cas, il faut apporter une correction, la plupart du temps négligeable [4].

Dans ce modèle les inconnus sont la permittivité effective et l'impédance caractéristique. Une fois déterminées, une ligne de transmission équivalente à l'antenne est obtenue. Le mode de propagation dominant est supposé être le mode TEM ou quasi-TEM avec une variation négligeable dans la direction transverse. C'est une approximation valide si l'épaisseur du substrat est maintenue négligeable devant la longueur d'onde. Ce modèle néglige quelques effets physiques comme l'excitation des ondes de surface, les variations du champ sur les bords rayonnant, le couplage mutuel entre les éléments voisins, les effets des modes d'ordre élevés, etc. Malgré l'existence d'un modèle de la ligne de transmission pouvant traiter les patches de forme arbitraire, ce modèle reste toujours limité en terme de précision à cause des inconvénients cités auparavant [5].

### I.3. Technologie guide d'onde coplanaire

La technologie guide d'onde coplanaire (CoPlanar Waveguide ; CPW) est constituée d'un ruban central métallique de largeur  $W$  et de deux plans de masse de largeur  $S$  situés sur la même face du substrat. Ces trois conducteurs sont séparés par deux fentes identiques de largeur  $G$  comme le montre la Figure (I.2). La symétrie de la ligne fait apparaître deux modes de propagation possibles, un mode TEM et un mode quasi TE. Cette topologie offre l'avantage de rassembler sur une même face tous les conducteurs, évitant ainsi l'usinage des trous métallisés et simplifiant donc l'insertion des composants et leur interconnexion.

Contrairement à la ligne microruban, les caractéristiques des lignes CPW sont relativement peu dépendantes de l'épaisseur du substrat. Les bibliothèques des modèles des lignes CPW sont par contre moins disponibles. Les inconvénients de cette technologie sont liés à la nécessité de l'utilisation de ponts à air lorsque des jonctions sont réalisées, afin de relier les masses [3].

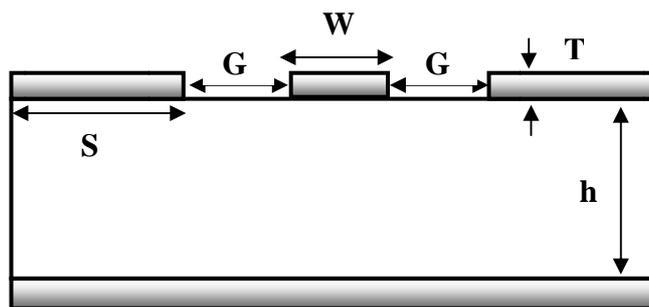


Figure I.2. Coupe transversale d'une ligne CPW.

### I.4. Technologie stripline coplanaire (CPS)

La technologie coplanaire stripline (CPS) présente un intérêt certain pour la conception des circuits intégrés radio-fréquences. La géométrie d'une ligne CPS, présentée dans la Figure (I.3), peut être vue comme la structure duale du guide d'onde coplanaire. Grâce à la disposition des deux rubans conducteurs sur la même face du substrat, la ligne CPS a tous les avantages de la ligne CPW, principalement la facilité de l'insertion des composants séries et parallèles sans avoir recours aux trous métallisés afin de les connecter au plan de masse [6].

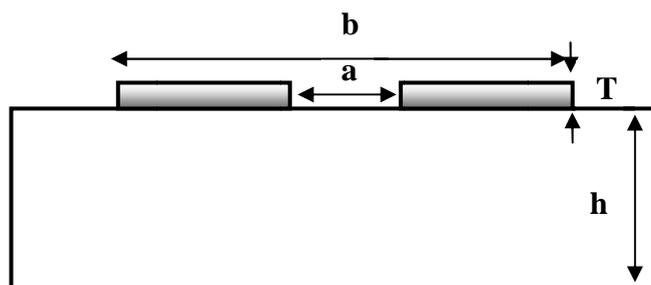


Figure I.3. Coupe transversale d'une ligne CPS.

### I.5. Technologie ligne à fente ou slotline

La configuration d'une ligne à fente est montrée dans la Figure (I.4). Elle consiste en un substrat avec une fente dans la métallisation d'une face unique du substrat.

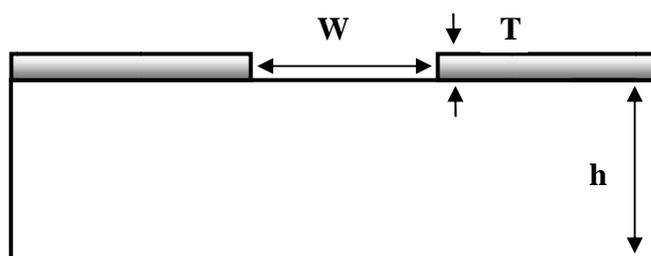


Figure I.4. Coupe transversale d'une ligne slotline.

Cette géométrie planaire est convenable pour les circuits intégrés. Dans une ligne à fente, le mode de propagation est principalement TE. La topologie de la ligne à fente offre l'avantage de la flexibilité du circuit en ce qui concerne l'insertion des composants en série et en parallèle, une gamme plus large des valeurs des impédances caractéristiques, l'élimination du couplage entre les lignes, assurant donc une meilleure intégration. Par contre, ce type de ligne souffre d'une forte dispersion en haute fréquence [7].

## **I.6. Technologie multi-couche**

La technologie récente LTCC (Low-Temperature Co-fired Ceramic) consiste en un empilement de couches diélectriques fines et de conducteurs métalliques [8]-[9]. Elle permet de réaliser une structure céramique multi-niveaux, où les niveaux de métallisation sont connectés entre eux par l'intermédiaire de trous métallisés. Elle offre une grande souplesse de réalisation et d'intégration, répondant aux soucis de miniaturisation et de réduction des pertes par connexions.

Cette technologie permet de réaliser des composants discrets (inductances, résistances, capacités) en technologie microruban, et d'intégrer des modules actifs en technologie MMIC.

En ce qui concerne les performances électriques de cette technologie. En pratique, les tolérances de fabrication sont trop grandes pour pouvoir contrôler les dimensions des gaps lors de la réalisation, ce qui peut poser problème aux fréquences millimétriques. Les principaux avantages de cette technologie résident donc dans des coûts de production attractifs et une grande intégrabilité dans un environnement MMIC [2].

## **I.7. Méthodes d'analyse des structures planaires**

Les lignes planaires usuelles sont difficiles à étudier en raison du non homogénéité du milieu qui les supporte (air et diélectrique), il en résulte des conditions aux limites complexes pour parvenir aux expressions caractéristiques de dispersion et des champs électromagnétiques dans une ligne plane, différentes méthodes approchées ont été proposées [10]:

- Méthode des différences finies : domaine temporel (FDTD).
- Méthode des éléments finis (FEM).
- Méthode des moments (MoM).
- Méthode de la matrice des lignes de transmission (TLM).
- Méthode de raccordement des modes (MMT).
- Méthode de la résonance transverse (TRM).
- Méthode des moindres carrés (LSBRM).
- L'Approche quasi-statique.

### **I.7.1. Méthode des moments**

C'est une méthode d'analyse intégrale qui sert à réduire une relation fonctionnelle en une relation matricielle pouvant être résolue par des techniques connues. Elle permet une étude systématique et peut s'adapter à des formes géométriques très complexes. Cette méthode est plus rigoureuse et fait appel à un formalisme plus compliqué conduisant à des développements numériques. Elle s'applique dans le cas où la ligne de transmission peut être décomposée en un ou plusieurs milieux homogènes : le champ électromagnétique peut alors s'exprimer sous forme d'une intégrale surfacique. Elle tient compte implicitement de tous les modes de rayonnement. De plus, la décomposition de courant surfacique en fonctions de base permet de simplifier énormément la résolution des équations intégrales ce qui rend la méthode simple à mettre en œuvre. Cette méthode est basée sur les 4 étapes suivantes [11] :

- Dérivation d'équation 'intégrale',
- Conversion de l'équation 'intégrale' en une équation matricielle,
- Evaluation du système matriciel,
- Résolution de l'équation matricielle.

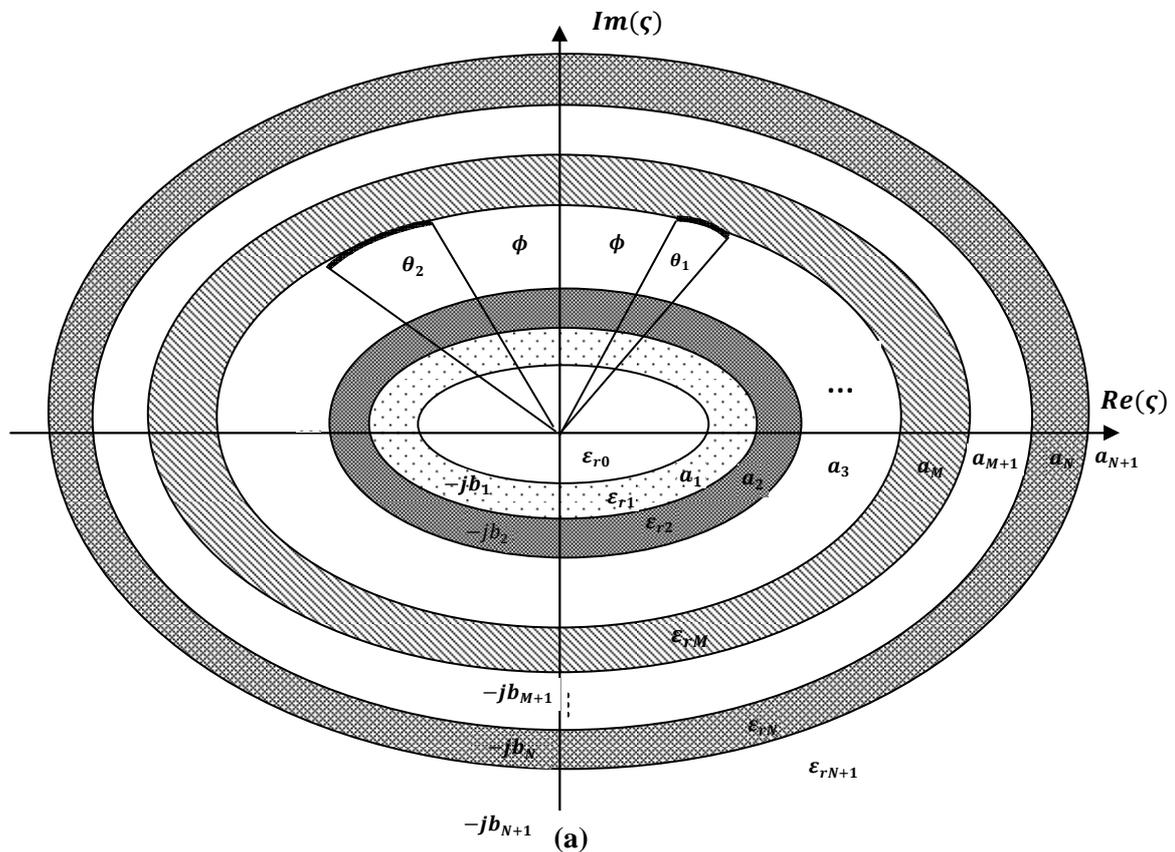
Cette méthode peut être appliquée dans le domaine spatial ou dans le domaine spectral [12]. La méthode des moments, qui est d'actualité, n'est pas limitée par les conditions classiques imposées sur le substrat, et permet d'analyser des lignes de formes très variées, des structures empilées, des patches conducteurs ou supraconducteurs imprimés sur des milieux multicouches.

### **I.7.2. Méthode quasi-statique**

La méthode quasi-statique, qui réduit le champ électromagnétique et la densité de courant au mode zéro, permet de résoudre les problèmes électromagnétiques par des méthodes propres à l'électrostatique, c'est à dire aux méthodes de résolution de l'équation de Poisson. Ceci a donné une tendance à formaliser la fonction de Green et à la technique de la transformée conforme CMT. Cette méthode a été utilisée comme un moyen de calcul rapide dans une certaine mesure, mais elle ne peut donner lieu qu'à des résultats qualitatifs [13].

**I.8. Analyse des lignes coplanaires multicouches elliptiques (MECPS), cylindriques (MCCPS), et asymétriques (MACPS) avec dimensions diélectriques finies par la technique de transformation conforme (CMT)**

La coupe transversale du MECPS à analyser est présentée dans la Figure (I.5(a)). Il existe  $N$  substrats diélectriques elliptiques de constantes diélectriques relatives  $\epsilon_{r1}, \epsilon_{r2} \dots \epsilon_{rN}$ , respectivement. Les cylindres elliptiques ont des axes semi-majeurs et semi-mineurs  $a_i$  et  $b_i$  respectivement ( $i = 1, 2, \dots, N + 1$ ). Les angles d'ouverture des strips sont  $\theta_1$  et  $\theta_2$  et  $2\phi$  est l'écart entre les deux strips. Le rapport axial est défini par  $AR = \theta_1/\theta_2$ . Les strips sont implantés sur le substrat avec les axes semi-majeurs et semi-mineurs  $a_M$  et  $b_M$  respectivement.



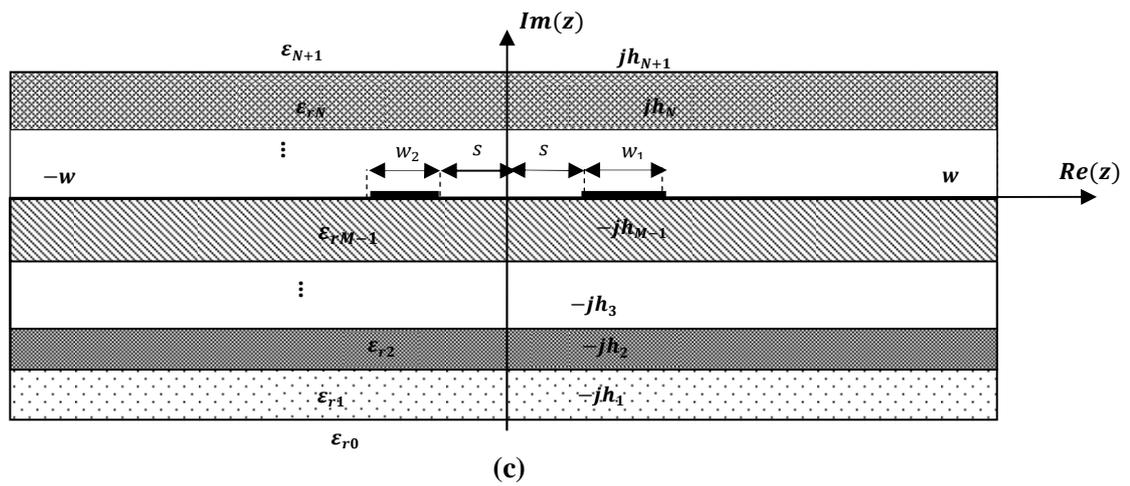
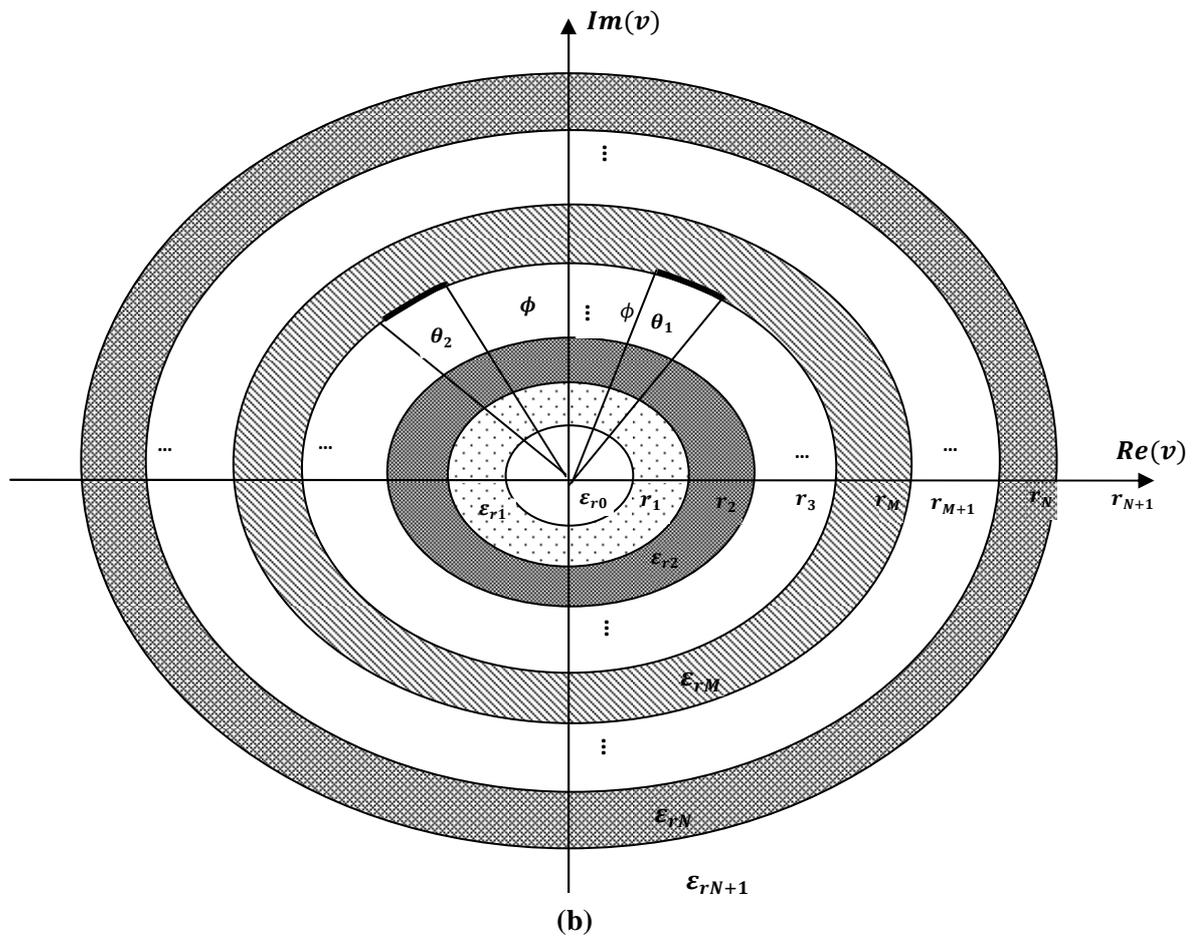


Figure I.5. Coupe transversale de: (a) MECPS, (b) MCCPS, (c) MACPS.

### **I.8.1. La Transformation des structures elliptiques et cylindriques à une Structure planaire**

Dans ce paragraphe, nous allons utiliser la technique de transformation conforme pour transformer la structure elliptique présentée par la Figure (I.5(a)) à une structure cylindrique comme présentée dans la Figure (I.5(b)) et la structure cylindrique à une structure planaire illustrée dans la Figure (I.5(c)). Tout d'abord, nous considérons la transformation elliptique-cylindrique [14], cette transformation peut être accomplie en utilisant l'image:

$$v = \frac{1}{f} \left( \zeta \pm \sqrt{\zeta^2 - f^2} \right) \quad (I.5)$$

où

$$f = \sqrt{a_i^2 - b_i^2} \text{ est la distance focale de l'ellipse.}$$

Ainsi, les ellipses confocales dans le plan- $\zeta$  sont transformées en cercles dans le plan- $v$  de la structure cylindrique avec rayons

$$r_i = \sqrt{\frac{a_i + b_i}{a_i - b_i}} \quad (I.6)$$

Ces structures peuvent être transformées dans le plan- $z$  du MACPS avec un plan de masse fini présenté par la Figure (I.5(c)) en utilisant la transformation.

$$z = j \ln \frac{v}{r_M} + \frac{\pi}{2} \quad (I.7)$$

Où  $r_M$  est le rayon de l'interface du substrat où les strips sont implantées. Les épaisseurs des substrats diélectriques du MACPS peuvent alors être écrites comme :

$$\begin{cases} h_{i<} = \ln(r_M/r_i) & i = 1, 2, \dots, M \\ h_{i>} = \ln(r_i/r_M) & i = M, \dots, N \end{cases} \quad \text{et} \quad \begin{cases} w_1 = \theta_1 \\ w_2 = \theta_2 \\ s = \phi \end{cases} \quad (I.8)$$

- $h_{i<}$  : hauteur du substrat diélectrique de constante diélectrique  $\epsilon_{ri}$  ( $i = 1 \dots M - 1$ ).
- $h_{i>}$  : hauteur du substrat diélectrique de constante diélectrique  $\epsilon_{ri}$  ( $i = M \dots N$ ).

Comme le montre la Figure (I.5(c)), le MACPS se compose de  $(M - 1)$  couches diélectriques avec des constantes diélectriques  $\varepsilon_{r1}, \varepsilon_{r2}, \dots, \varepsilon_{rM-1}$ , respectivement, et les hauteurs diélectriques  $h_{<1}, h_{<2}, \dots, h_{<M-1}$ . Il existe également  $(N - M + 1)$  substrats diélectriques ayant des constantes diélectriques  $\varepsilon_{rM}, \varepsilon_{rM+1}, \dots, \varepsilon_{rN}$ , respectivement et des hauteurs diélectriques  $h_{>M}, h_{>M+1}, \dots, h_{>N}$ . La largeur totale de la configuration est  $2w$  et les largeurs de strips métalliques sont  $w_1$  et  $w_2$ .

### **I.9. Permittivité diélectrique effective et impédance caractéristique de la structure planaire**

En utilisant les approximations quasi-statiques, la permittivité diélectrique effective  $\varepsilon_{eff}$  et l'impédance caractéristique  $Z_0$  de lignes de transmission sont données par [15]

$$\varepsilon_{eff} = \frac{C}{C_0} \quad (I.9)$$

$$Z_0 = \frac{\sqrt{\varepsilon_{eff}}}{Cv_0} \quad (I.10)$$

Où  $v_0$  est la vitesse de la lumière,  $C$  est la capacité totale de la ligne de transmission,  $C_0$  est la capacité de l'air de la ligne correspondante, où tous les diélectriques remplacés par l'air. La capacité totale de la ligne par unité de longueur du MACPS avec des dimensions diélectriques finies peut être exprimée par l'expression :

$$C = C_{<} + C_0 + C_{>} \quad (I.11)$$

- $C_0$  : capacité de l'air après avoir enlever le matériau diélectrique global.
- $C_{<}$  : somme de toutes les capacités des couches diélectriques d'épaisseurs  $h_{i<}$  avec les constantes diélectriques équivalentes  $(\varepsilon_{ri} - \varepsilon_{r(i-1)})$ ,  $i = 1, 2, \dots, M - 1$  et  $\varepsilon_{r0} = 1$ .
- $C_{>}$  : somme des capacités des couches diélectriques d'épaisseurs  $h_{i>}$ , ayant les constantes diélectriques  $(\varepsilon_{ri} - \varepsilon_{r(i+1)})$ ,  $i = M, \dots, N$  et  $\varepsilon_{r(N+1)} = 1$ .

Maintenant, nous dérivons les expressions des capacités introduites dans l'équation (I.11).

**I.9.1. Calcul de la capacité de l'air  $C_0$**

Premièrement, toutes les couches diélectriques de la structure de la Figure (I.5(c)) sont remplacées par l'air. Utilisant la transformation de Schwarz-Christoffel donnée par l'équation (I.12) ci-dessous

$$W = \int_{u_0}^u \frac{du}{\sqrt{(u - u_3)(u - u_4)(u - u_5)(u - u_6)}} \quad (I.12)$$

La structure de la Figure (I.5(c)) est transformée à la Figure (I.6).

La capacité  $C_0$  en espace libre est donnée par [16]

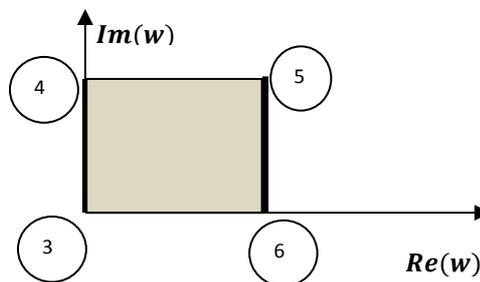
$$C_0 = 2\epsilon_0 \frac{K(k'_0)}{K(k_0)} \quad (I.13)$$

et le module  $k_0$  s'écrit

$$k_0 = \left[ \frac{2s(2s + w_1 + w_2)}{(2s + w_1)(2s + w_2)} \right]^{\frac{1}{2}} \quad (I.14)$$

$K(k_0)$  est l'intégrale elliptique complète du premier espèce avec module  $k_0$  et son complémentaire

$$k'_0 = (1 - k_0^2)^{1/2} \quad (I.15)$$



**Figure I.6.** Transformation en un condensateur à plaque-parallèle.

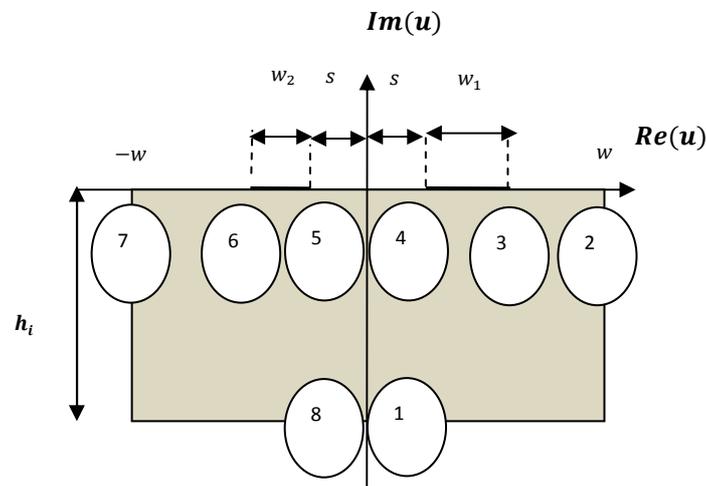
**I.9.2. Calcul des capacités des diélectriques  $C_{di}$**

Afin de calculer la capacité diélectrique  $C_{di}$  ( $i = 1, 2, \dots, N$ ). La région diélectrique dans la Figure (I.7) est transformée dans la moitié inférieure de la région de la Figure (I.8) en utilisant la fonction elliptique de Jacobi.

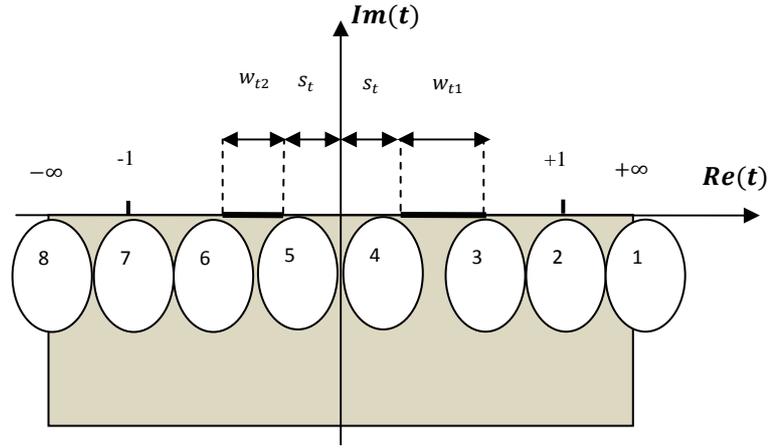
$$t = sn\left(\left(\frac{K(m_i)}{w}\right)z, m_i\right) \quad i = 1, 2, \dots, N \tag{I.16}$$

Pour simplifier le calcul, des expressions donnant d'excellentes approximations de  $m_i$  sont données par :

$$m_i = \begin{cases} \frac{\left[ \frac{\exp\left(\frac{\pi w}{h_i}\right) - 2}{\exp\left(\frac{\pi w}{h_i}\right) + 2} \right]^2}{\sqrt{1 - \left[ \frac{\exp\left(\frac{\pi h_i}{w}\right) - 2}{\exp\left(\frac{\pi h_i}{w}\right) + 2} \right]^4}} & \text{pour } 1 \leq \frac{w}{h_i} < \infty \\ \sqrt{1 - \left[ \frac{\exp\left(\frac{\pi h_i}{w}\right) - 2}{\exp\left(\frac{\pi h_i}{w}\right) + 2} \right]^4} & \text{pour } 0 < \frac{w}{h_i} < 1 \end{cases} \tag{I.17}$$



**Figure I.7.** Coupe transversale de l'ACPS.



**Figure I.8.** Transformation intermédiaire de la région diélectrique.

Ensuite, la structure obtenue par la Figure (I.8) est transformée encore dans la zone rectangulaire dans la Figure (I.6), utilisant la transformation Schwarz-Christoffel

$$W = \int_{t_0}^t \frac{dt}{\sqrt{(t-t_3)(t-t_4)(t-t_5)(t-t_6)}} \quad (\text{I. 18})$$

où  $t_3 = s_t + w_{t1}$ ,  $t_4 = s_t$ ,  $t_5 = -s_t$ ,  $t_6 = -s_t - w_{t2}$

et

$$C_d = \varepsilon_0 \varepsilon_d \frac{K(k'_i)}{K(k_i)} \quad (\text{I. 19})$$

où

$$\varepsilon_d = \begin{cases} \varepsilon_{ri} - \varepsilon_{r(i-1)} & \text{pour } i = 1, 2, \dots, M-1 \\ \varepsilon_{ri} - \varepsilon_{r(i+1)} & \text{pour } i = M, \dots, N \end{cases} \quad (\text{I. 20})$$

et

$$k_i = \left[ \frac{2t_4^{(i)}(t_3^{(i)} - t_6^{(i)})}{(t_3^{(i)} + t_4^{(i)})(t_4^{(i)} - t_6^{(i)})} \right]^{\frac{1}{2}} \text{ pour } i = 1, 2, \dots, N \quad (\text{I. 21})$$

$$\begin{cases} t_4^{(0)} = s \\ t_3^{(0)} = s + w_1 \\ t_6^{(0)} = -(s + w_2) \end{cases} \quad (I.22)$$

Par conséquent, la capacité totale de la ligne est donnée par :

$$C = 2\varepsilon_0 \frac{K(k'_0)}{K(k_0)} + \varepsilon_0 \sum_{i=1}^{M-1} (\varepsilon_{ri} - \varepsilon_{r(i-1)}) \frac{K(k'_i)}{K(k_i)} + \varepsilon_0 \sum_{i=M}^N (\varepsilon_{ri} - \varepsilon_{r(i+1)}) \frac{K(k'_i)}{K(k_i)} \quad (I.23)$$

La permittivité effective  $\varepsilon_{eff}$  et l'impédance caractéristique  $Z_0$  par unité de longueur sont obtenues comme :

$$\varepsilon_{eff} = 1 + \frac{1}{2} \left[ \sum_{i=1}^{M-1} (\varepsilon_{ri} - \varepsilon_{r(i-1)}) q_i + \sum_{i=M}^N (\varepsilon_{ri} - \varepsilon_{r(i+1)}) q_i \right] \quad (I.24)$$

et

$$q_i = \frac{K(k'_i) K(k_0)}{K(k_i) K(k'_0)} \quad \text{où } i = 1, 2, \dots, N. \quad (I.25)$$

$$Z_0 = \frac{60\pi}{\sqrt{\varepsilon_{eff}}} \frac{K(k_0)}{K(k'_0)} \quad (I.26)$$

Les formules obtenues sont utilisées pour étudier l'effet de  $w, s, h$  sur  $\varepsilon_{eff}$  et  $Z_0$  d'un MACPS. Pour le cas de MECPS et MCCPS, les variations de  $\varepsilon_{eff}$  et  $Z_0$  sont explorées en termes des angles  $\theta_1, \theta_2$  et  $\phi$ .

### **I.10. Modélisation d'un processus**

On dit qu'on a modélisé un processus physique, si on est capable de prédire quel était son comportement (sortie) lorsqu'on le soumet à une sollicitation (entrée) connus.

Un modèle est une représentation mathématique entre les entrées et les sorties d'un système. Il peut être statique ou dynamique et est caractérisé par son domaine de validité.

Un modèle peut être utilisé pour simuler un système dans le but, par exemple, d'améliorer la compréhension, la sûreté de fonctionnement, le diagnostic de pannes.

Selon les informations à disposition sur les différents systèmes à étudier, on peut distinguer trois grands types de modèles :

- Les modèles dits « boîte blanche » sont construits à partir d'une analyse physique en appliquant soit les lois générales, fondées notamment sur des principes mécaniques, électromagnétiques, thermodynamiques, quantiques, etc. Dans la pratique, il est toujours souhaitable d'établir un modèle de ce type. Néanmoins, il arrive fréquemment que le système soit trop complexe ou que les phénomènes qui le régissent soient trop mal connus pour qu'il soit possible d'établir un modèle suffisamment précis pour l'application considérée.
- Les modèles dits « boîte noire » sont construits essentiellement sur la base de mesures effectuées sur les entrées et les sorties du système à modéliser. La modélisation consiste alors à utiliser des équations (algébriques, différentielles, récurrentes) pouvant être linéaires ou non linéaires et à estimer les paramètres du modèle à partir des mesures disponibles sans connaissances a priori sur la représentation physique du modèle.
- Les modèles dits « boîte grise » sont une forme intermédiaire entre les deux précédentes. On les utilise généralement lorsque certaines connaissances du système pouvant s'exprimer sous forme d'équations sont disponibles, en prenant en considération à la fois des connaissances physiques et des mesures expérimentales. Une telle démarche permet de réaliser un compromis entre la finesse du modèle de connaissance établi et sa complexité afin de pouvoir identifier ses paramètres [17].

### I.11. Caractérisation

La première étape du processus de modélisation consiste à faire une hypothèse sur la structure du système, c'est-à-dire à choisir un type de relation mathématique  $f$  liant les entrées et les sorties. Les paramètres structuraux, au départ inconnus, seront déterminés numériquement dans l'étape suivante dite l'identification. Dans ce choix de structure, on peut être guidé par:

- Une analyse physique conventionnelle du processus.
- Les expériences et le résultat qualitatif de tests simples.
- Des contraintes de calcul ou des contraintes économiques...

Cette étape, essentiellement qualitative, n'est éclairée et validée que par le reste de la procédure. C'est souvent la plus difficile ; elle fait appel à l'expérience [18].

### I.12.Principe de la modélisation et l'estimation

- L'Automatique pour laquelle la connaissance du modèle est indispensable pour synthétiser une loi de commande.
- Les Sciences Expérimentales, lorsque la validation d'une théorie se fait par des manipulations expérimentales (physique atomique, microélectronique...).
- La Biologie, l'Economie, les Statistiques.
- Partout où des observations sont validées par un principe de fonctionnement (Règle mathématique) [19].

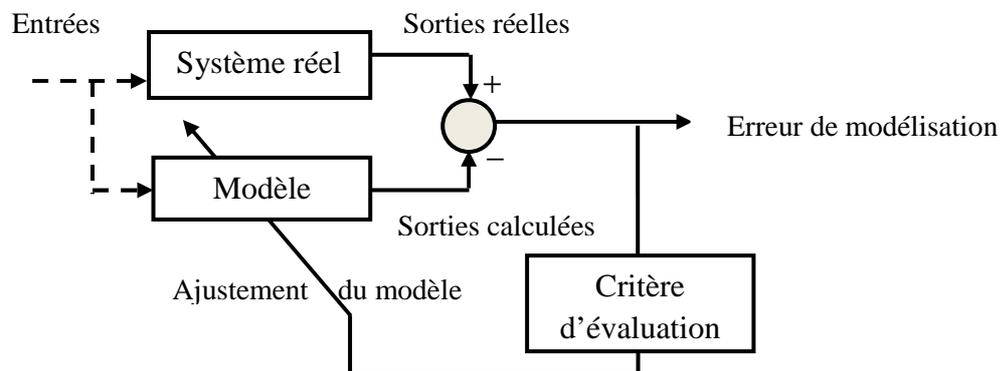


Figure I.9. Principe de la modélisation et l'estimation

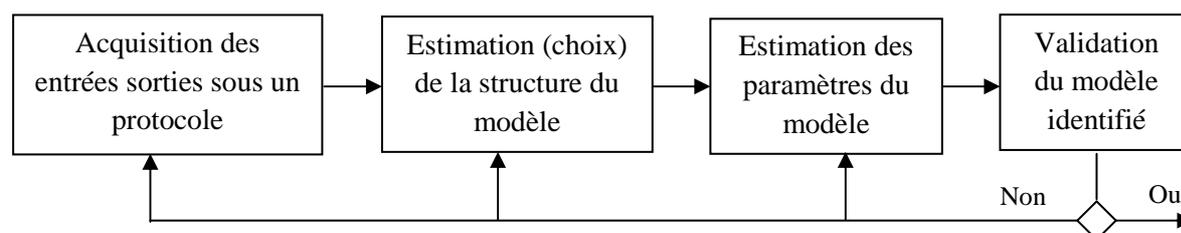
### I.13. Identification

L'identification d'un procédé est définie comme la détermination, basée sur la connaissance des entrées et des sorties du procédé, d'un modèle appartenant à une classe spécifiée, équivalente au procédé. C'est la détermination de son modèle mathématique sur la base des observations expérimentales entrées sorties. Le traitement mathématique des réponses graphiques du système est appelé identification [20].

### I.14. Méthodes d'identification

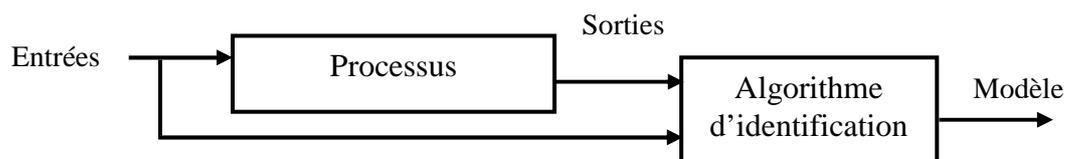
Dans la plupart des cas, le but de l'identification est de permettre la mise en œuvre d'une bonne régulation du procédé à étudier. Afin de mener à bien cette identification, un minimum de connaissances sur le système est indispensable [21].

Cette approche peut être décomposée en quatre étapes :

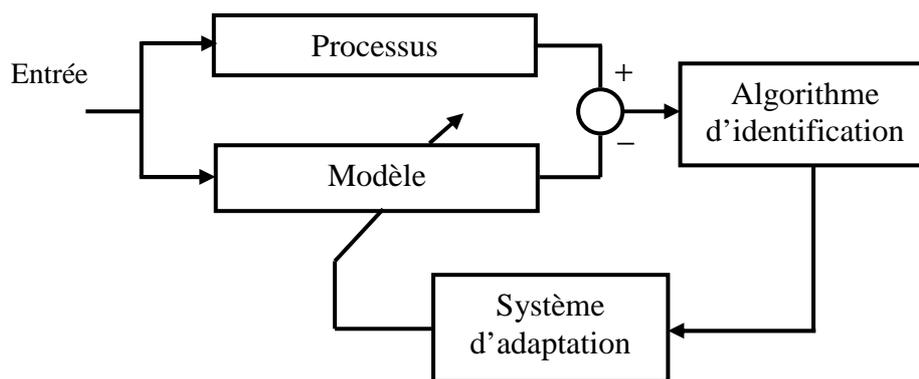


**Figure I.10.** Procédure d'identification d'un modèle de système

L'identification constitue une phase importante dans la définition du modèle, c'est par elle que le choix de la classe de modèles à adopter puis les valeurs des paramètres qui le caractérisent vont se préciser. Le plus souvent l'identification s'effectue en optimisant un caractère de qualité qui caractérise l'écart entre le comportement du processus (repéré par un ensemble de mesures), et celui de son modèle (étudié par simulation) pour un ensemble de sollicitations données. De nombreuses méthodes d'identification ont été précisées le plus souvent à l'un des schémas des Figures (I.11) et (I.12) [22].



**Figure I.11.** Identification à partir du comportement entrée-sortie



**Figure I.12.** Identification de type paramétrique

Lorsque la complexité des problèmes électromagnétiques demande des conceptions de modélisation très efficaces et des outils d'analyses sensibles, ce qui peut être réalisé par des méthodes intelligentes comme les réseaux de neurones ou la logique floue.

Deux approches d'identification, basées sur les réseaux de neurones et la logique floue, seront appliquées aux Chapitres II et III pour trois types de lignes de transmission de forme elliptique, cylindrique et planaire.

### I.15. Conclusion

Dans ce chapitre, la technologie des circuits planaires a été présentée ainsi que les différentes méthodes d'analyse de ces circuits. Ensuite, les formules mathématiques nécessaires pour obtenir les paramètres quasi-statiques pour des lignes de transmission (MECPS), (MCCPS), et (MACPS) par la technique de transformation conforme (CMT) ont été développées. Finalement, le principe de la modélisation et l'identification des processus a été exposé et le schéma des étapes a été présenté et détaillé. L'identification par les réseaux de neurones et la logique floue sera appliquée dans les chapitres suivants pour l'analyse des structures des lignes mentionnées et les résultats numériques seront présentés et commentés.

***Références bibliographiques***

- [1] M. Laib, «Caractérisation de la ligne coplanaire à microruban volumique et ses discontinuités par l’approche Full-wave basée sur la technique MPIE dans le domaine spatial», *Thèse de Doctorat*, Université Ferhat Abbas, Sétif, 07 mai 2012.
- [2] D. Kaddour. «Conception et réalisation de filtres RF passe-bas à structures périodiques et filtres Ultra Large Bande, semi localisés en technologie planaire», *Thèse de Doctorat*, Université Joseph Fourier, France, le 11 juillet 2007.
- [3] K. Gupta, R. Gang, and J. Bahl, “Microstrip Lines and Slotlines”. *Debhamn, MA: Artech House*, 1996.
- [4] J. R. Fisk W1HR , “Microstrip transmission line” *Ham Radio* janvier 1978.
- [5] M.A. Belhedri,«Influence de la supraconductivité à haute température de transition sur la résonance d’une plaque rectangulaire réalisée sur un substrat à anisotropie de type électrique et magnétique», *Mémoire de Magister* , Université Kasdi Merbah ,Ouargla.
- [6] F. Boukchiche, «Contribution à la Modélisation des Structures Coplanaires pour Application aux Composants Passifs et Actifs», *Mémoire de magistère*, Université de Mentouri, Constantine, 2005.
- [7] N. Aouabdia, «Caracterisation et Modelisation d’un Capteur Micro-onde», *Mémoire de Magistère*, Université de Mentouri , Constantine, 2002.
- [8] Y. Rong, K. Zaki, M. Hageman, D. Stevens, and J. Grippich, “Low temperature cofired ceramic (LTCC) ridge waveguide bandpass chip filters,” *IEEE Transactions on Microwave Theory and Techniques*, vol. 47, no. 12, pp. 2317–2324, December 1999.
- [9] Y. Rong, K. Zaki, J. Grippich, M. Hageman, and D. Stevens, “LTCC wide-band ridge-waveguide bandpass filters,” *IEEE Transactions on Microwave Theory and Techniques*, vol. 47, no. 9, pp. 1836–1840, September 1999.
- [10] C. Zebiri, «Effet de l’Anisotropie Tensorielle sur les paramètres des structures planaires», *Thèse de Doctorat*, Université de Mentouri , Constantine, 2011.
- [11] H. B. Gaha ,«Analyse et Conception des Antennes Fractales Applications aux Télécommunications Large Bande », *Thèse de Doctorat*, L’institut National Polytechnique De Toulouse , France, 18 Juillet 2007

- [12] F. Chebbara, «Etudes des Caractéristiques de Résonance et de Rayonnement des Antennes Microbandes Réalisées avec des Matériaux ayant une Anisotropie de Type Electrique et Magnétique », *Thèse de Doctorat*, Université El-Hadj Lakhdar, Batna, 2011.
- [13] D.Z. Sidi Ali Mebarek, “Support de transmission et composants micro-ondes”, *OPU* , 1995.
- [14] V. Akan and E Yazgan, “Quasi-Static Solutions of Multilayer Elliptical, Cylindrical Coplanar Striplines and Multilayer Coplanar Striplines with Finite Dielectric Dimensions - Asymmetrical Case,” *IEEE Transactions on Microwave Theory and Techniques*, vol. 53, n° 12, pp. 3681–3686, December 2005.
- [15] C. Yildiz and M. Turkmen, “Quasi-Static Models Based on Artificial Neural Networks for Calculating the Characteristic Parameters of Multilayer Cylindrical Coplanar Waveguide and Strip Line”, *Progress In Electromagnetics Research B*, Vol. 3, pp. 1–22, 2008.
- [16] F. Gunes and N. Turker, “Artificial Neural Networks in their Simplest Forms for Analysis and Synthesis of RF/Microwave Planar Transmission Lines,” *International Journal of RF and Microwave Computer-Aided Engineering*, vol. 15, n° 6, pp.587–600 , January 2005.
- [17] B. Huard, «Contribution à la modélisation non-linéaire et à la commande d’un actionneur robotique intégré pour la manipulation », *Thèse de Doctorat*, École nationale supérieure d’ingénieurs, Poitiers, 07 juin 2013.
- [18] O. Bennia et L. Mohamadi,“ identification des systèmes non linéaires par les réseaux de neurones” , *Mémoire d’ingéniorat*, Université Mohamed Boudiaf , M’sila (2002).
- [19] P. Bonnet, “Modélisation et identification des processus” *cours* Université de Lille 1, *Master ASE1*, IEEA. 2010-2011.
- [20] B. Ould Bouamama, “Identification des Systèmes” ,*cours* ,Laboratoire d’Automatique, Génie Informatique et Signal (LAGIS - UMR CNRS 8219), École Polytechnique de Lille (Poltech’ lille), 2012.

- [21] P. Borne, J-P. Richard, “Modélisation et identification des processus”, *Livre* ,  
Volume 1, Editions Technip, page 33, 1992.
- [22] M. Villain ,“Automatique 2 Systèmes asservis linéaires” *Livre*, Editions Ellipses,  
Décembre 1996 .

---

## **CHAPITRE II**

### ***IDENTIFICATION DES PARAMETRES QUASI- STATIQUES DES LIGNES DE TRANSMISSION PAR LES RESEAUX DE NEURONES (ANNs)***

## **II.1. Introduction**

Les systèmes réels sont difficiles à étudier, donc on est amené à les représenter mathématiquement pour pouvoir les conduire. Le problème posé est: comment obtient-on ce modèle mathématique ? Ce modèle sera utilisé pour effectuer des prédictions de la sortie du processus, ou pour l'apprentissage d'un correcteur, ou encore pour simuler le processus au sein d'un système [1]. Par ailleurs, dans certains cas, ce modèle est quasiment impossible à obtenir.

Les réseaux de neurones ANN peuvent fournir une solution pour les problèmes de la modélisation et l'identification. Leur capacité de mémorisation, d'apprentissage et d'adaptation sont des fonctions utiles pour tout système non linéaire.

Le présent chapitre clarifie l'idée de base des réseaux de neurones qui est inspirée des propriétés biologiques du cerveau, pour construire des modèles de calcul mieux adaptés et capables de résoudre les problèmes d'identification. L'approche neuronale consiste à ajuster les poids (coefficient synaptique) d'un réseau neuronal selon des lois d'apprentissage jusqu'à ce que la sortie s'accorde avec celles calculée. Ce chapitre présente aussi quelques algorithmes et architectures des réseaux de neurones utilisées dans la littérature et de comprendre comment l'utiliser pour l'apprentissage et l'identification des paramètres quasi-statistiques des lignes de transmission MECPS, MCCPS, et MACPS étudiées dans ce travail.

## **II.2. Historique**

L'origine de l'inspiration des réseaux de neurones artificiels remonte à 1890 lorsque *James* introduit le concept de mémoire associative. Il propose ce qui deviendra une loi de fonctionnement pour l'apprentissage des réseaux de neurones, connue plus tard sous le nom de loi de *Hebb*. En 1949 *Culloch* et *Pitts* montrent que des réseaux de neurones formels simples peuvent réaliser des fonctions logiques arithmétiques et symboliques complexes.

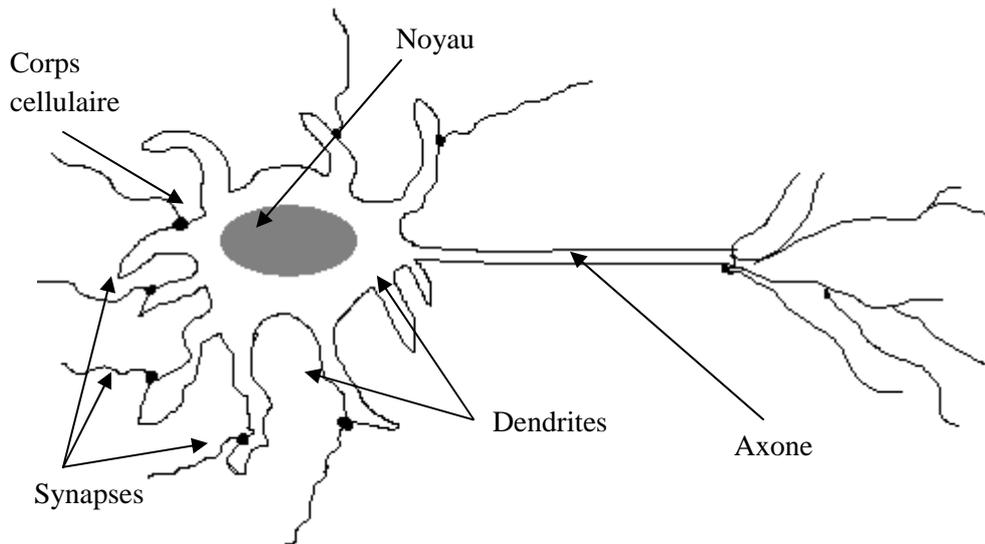
C'est ensuite que *Hebb* physiologiste américain, présente en 1949 la propriété des neurones par le conditionnement chez l'animal. Ainsi, un conditionnement de type *pavlovien* tel que, nourrir tous les jours à la même heure un chien, entraîne chez cet animal la sécrétion de salive à cette heure précise même en l'absence de nourriture. La loi de modification des propriétés des connexions entre neurones qu'il propose, explique en partie ce type de résultats expérimentaux.

Les premiers succès de cette discipline remontent à 1957, lorsque *Rosenblatt* développe le modèle du *Perceptron*. Il construit le premier neuro-ordinateur basé sur ce modèle et l'applique au domaine de la reconnaissance des formes. En 1960, l'automaticien *Widrow* développe le modèle *Adaline* (Adaptative Linear Element). Dans sa structure, le modèle ressemble au Perceptron, cependant la loi d'apprentissage est différente.

Celle-ci est à l'origine de l'algorithme de rétro-propagation de gradient très utilisé aujourd'hui. C'est un algorithme d'apprentissage adapté au Perceptron Multicouche. Grâce à cette découverte, nous avons la possibilité de réaliser une fonction non linéaire d'entrée/sortie sur un réseau, en décomposant cette fonction en une suite d'étapes linéairement séparables. En 1989, *Moody* et *Darken* exploitent quelques résultats de l'interpolation multivariables pour proposer le Réseau à Fonctions de base Radiales (RBF). Ce type de réseau se distingue par sa représentation locale [2].

### **II.3. Neurone biologique**

L'élément de base du système nerveux central est le neurone. Le cerveau se compose d'environ mille milliards de neurones, avec 1000 à 10000 synapses (connexions) par neurone. Le neurone est une cellule composée d'un corps cellulaire et d'un noyau comme le montre la Figure (II.1). Le corps cellulaire se ramifie pour former ce que l'on nomme les dendrites. Celles-ci sont parfois si nombreuses que l'on parle alors de chevelure dendritique ou d'arborisation dendritique. C'est par les dendrites que l'information est acheminée de l'extérieur vers le soma (corps du neurone). L'information est traitée alors par le corps cellulaire. Si le potentiel d'action dépasse un certain seuil, le corps cellulaire répond par un stimuli. Le signal transmis par le neurone chemine ensuite le long de l'axone (unique) pour être transmis aux autres neurones. La transmission entre deux neurones n'est pas directe. En fait, il existe un espace intercellulaire de quelques dizaines d'Angströms entre l'axone du neurone afférent et les dendrites du neurone efférent. La jonction entre deux neurones est appelée synapse [3].



**Figure II.1.** Neurone biologique

Le neurone formel que nous allons étudier par la suite rappelle beaucoup le neurone biologique que nous venons de présenter. Pour cette raison, le vocabulaire utilisé dans la littérature pour décrire un neurone formel est largement emprunté à la biologie. Le formalisme mathématique du réseau de neurones artificiels, se trouve une inspiration biologique de plus en plus présente dans les méthodes d'apprentissage [4].

#### **II.4. Modèle mathématique**

Les réseaux de neurones biologiques réalisent facilement un certain nombre d'applications telles que la reconnaissance des formes, le traitement du signal, l'apprentissage par l'exemple, la mémorisation et la généralisation. C'est à partir de l'hypothèse que le comportement intelligent émerge de la structure et du comportement des éléments de base du cerveau, que les réseaux de neurones artificiels se sont développés. La Figure (II.2) montre la structure d'un neurone artificiel. Chaque neurone artificiel est un processeur élémentaire. Il reçoit un nombre variable d'entrées en provenance de neurones amont. A chacune de ces entrées est associée un poids  $w$ , abréviation de *weight* (poids en anglais), représentatif de la force de la connexion.

Chaque processeur élémentaire est doté d'une sortie unique, qui se ramifie ensuite pour alimenter un nombre variable de neurones aval. A chaque connexion est associée un poids [5] .

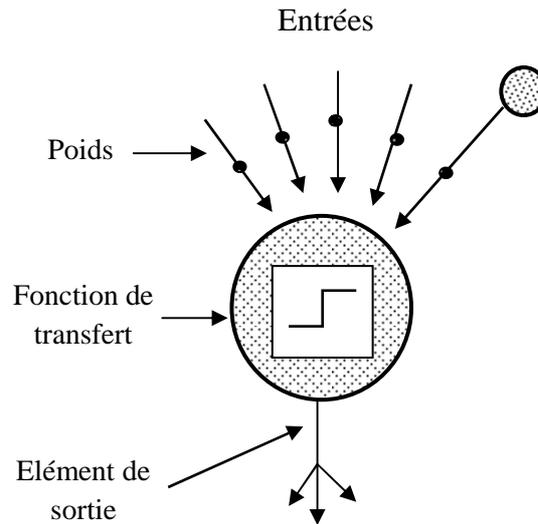


Figure II.2. Neurone artificiel

### II.5. Neurone formel

Par analogie avec le neurone biologique, le neurone formel est une approximation très grossière de l'opération du neurone biologique. Le neurone formel est un élément de traitement qui fait une sommation pondérée de  $n$  entrées  $x_1, x_2 \dots x_n$ , (qui sont les sortie d'autre neurone ou des informations prônent de l'extérieure) [6]. Le modèle couramment utilisé du neurone formel est le suivant : un neurone est une unité de calcul élémentaire recevant ses entrées du milieu extérieur et/ou d'autres neurones et transmettant sa sortie à d'autres neurones et/ou au milieu extérieur. Ces entrées sont pondérées par un poids synaptique qui modélise l'intensité des connexions (synapses) entre les neurones. Chaque neurone additionne ses entrées, préalablement multipliées par les poids associées, et génère la sortie correspondante à travers une fonction non-linéaire appelée fonction d'activation comme présentée dans la Figure (II.3) [7].

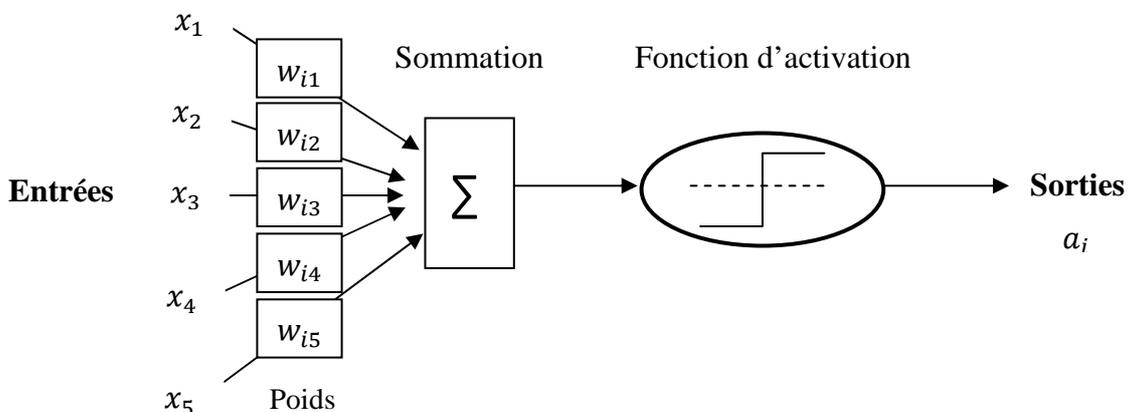
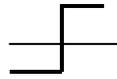


Figure II.3. Neurone formel le modèle Mc Culloch et Pitts

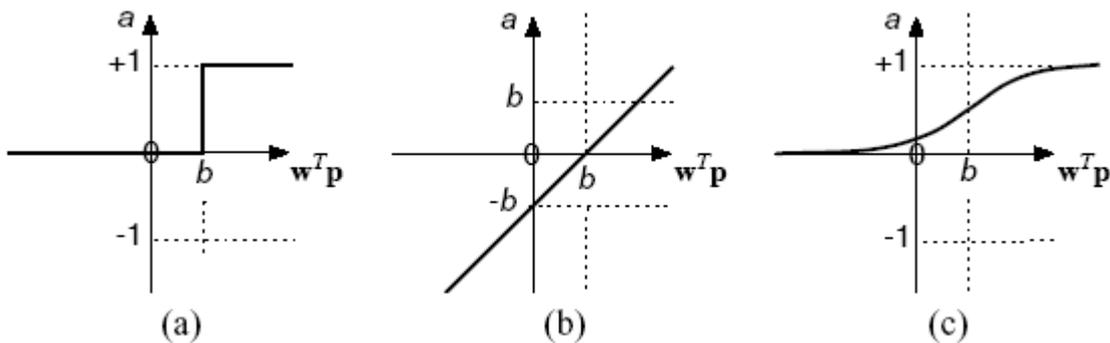
Il est émulé de manière logicielle ou implanté matériellement, comprend donc les éléments suivants :

- 1) L'ensemble des connexions (synapses) permettant la réception des signaux d'entrée et la transmission du signal de sortie. Chacune des connexions est caractérisée par un poids synaptique, de façon à ce que le signal transmis par un neurone source soit multipliée par le poids associée à la connexion avant d'être reçu par le neurone destination. Les poids synaptiques peuvent être entiers ou réels, positifs ou négatifs selon que la synapse correspondante soit excitatrice ou inhibitrice respectivement.
- 2) L'additionneur qui réalise la somme des signaux d'entrée pondérés par les poids synaptiques [8].
- 3) La fonction d'activation qui est une fonction non linéaire de saturation servant à limiter l'amplitude du signal de sortie du neurone. Plusieurs types de fonctions d'activation peuvent être utilisés, les plus courantes et les plus citées dans la littérature sont énumérées dans le tableau (II.1) ci-dessous :

Nom de la fonction	Relation d'entrée/sortie	Îcône
Seuil	$a = 0$ si $n < 0$ $a = 1$ si $n \geq 0$	
Seuil symétrique	$a = -1$ si $n < 0$ $a = 1$ si $n \geq 0$	
Linéaire	$a = n$	
Linéaire saturée	$a = 0$ si $n < 0$ $a = n$ si $0 \leq n \leq 1$ $a = 1$ si $n > 1$	
Linéaire saturée symétrique	$a = -1$ si $n < -1$ $a = n$ si $-1 \leq n \leq 1$ $a = 1$ si $n > 1$	
Linéaire positive	$a = 0$ si $n < 0$ $a = n$ si $n \geq 0$	
Sigmoïde	$a = \frac{1}{1 + \exp^{-n}}$	
Tangente hyperbolique	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	
Compétitive	$a = 1$ si $n$ maximum $a = 0$ autrement	<b>C</b>

**Tableau II.1.** Types de fonctions d'activation

Les trois les plus utilisées dans le domaine de l'ingénierie sont les fonctions (a): "seuil" (b): "linéaire" et (c): "sigmoïde" comme représentées ci-dessous :



**Figure II.4.** Différents types de fonctions de transfert

La fonction seuil applique un seuil sur son entrée, plus précisément, une entrée négative ne passe pas le seuil, la fonction retourne la valeur 0 (faux), alors qu'une entrée positive ou nulle dépasse le seuil, et la fonction retourne 1 (vrai). Il est évident que ce genre de fonction permet de prendre des décisions binaires (cette fonction peut aussi être assimilée à la fonction de Heaviside) [9].

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

$$W \cdot \bar{p} = b \tag{II.1}$$

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

$$a = \frac{1}{1 + \exp(-n)} \tag{II.2}$$

Elle ressemble soit à la fonction seuil, soit à la fonction linéaire, selon que nous sommes loin ou près de  $b$  respectivement. La fonction seuil est très non linéaire car il y a une discontinuité lorsque  $W \cdot \bar{p} = b$ . De son côté, la fonction linéaire est tout à fait linéaire. Elle ne comporte aucun changement de pente. La sigmoïde est un compromis intéressant entre les deux précédentes. Notons finalement que la fonction tangente hyperbolique est une version symétrique de la sigmoïde [10].

## **II.6. Réseaux de neurones artificiels (ANN)**

Un réseau de neurones consiste en un ensemble de neurones reliés entre eux par des connexions pondérées. Il se caractérise principalement par le type des unités utilisées et par sa topologie. On distingue souvent deux types de neurones particuliers dans un réseau : les neurones d'entrée recevant les données du monde extérieur, et les neurones de sortie fournissant le résultat du traitement effectué. Les autres unités sont généralement qualifiées de cachées. Cette distinction n'est toutefois pas obligatoire et tous les neurones peuvent très bien communiquer dans les deux sens avec l'extérieur. Il est fréquent de différencier les réseaux suivant la présence ou non de cycles dans le graphe orienté des connexions entre les neurones [11]. On parle dans le cas positif de réseaux récurrents. Il est à noter que ces connexions cycliques, dont les valeurs dépendent des activations passées des unités du réseau, permettent de mieux traiter des problèmes comportant un aspect temporel. L'apprentissage est cependant généralement assez complexe dans ces réseaux, et leurs propriétés sont souvent moins bien connues que celles des réseaux non récurrents.

Une autre distinction importante est généralement faite entre codage local de l'information d'entrée et codage distribué. Dans les réseaux réalisant un codage local, chaque unité est spécialisée dans le traitement d'une petite partie de l'espace d'entrée, alors que dans les réseaux réalisant un codage distribué tout traitement fait intervenir l'ensemble des neurones. L'un des principaux attraits des réseaux de neurones artificiels (ANN) concerne les capacités d'apprentissage que possèdent certains modèles. On entend généralement par apprentissage la modification automatique des poids des connexions ou plus rarement du nombre et de l'organisation des neurones, afin d'adapter le traitement effectué par le réseau à une tâche particulière.

On distingue trois familles d'apprentissage en fonction de la nature des informations disponibles et du but recherché [12]:

- 1) L'apprentissage supervisé pour lequel il est nécessaire de disposer d'un ensemble de couples de données entrées du réseau ; sorties désirées correspondantes, appelées exemples ou patrons. La différence entre la sortie du réseau et la sortie désirée donne ainsi une mesure d'erreur quantitative sur le calcul effectué par le réseau, qui est utilisée pour réaliser l'adaptation.
- 2) L'apprentissage semi-supervisé ou apprentissage par renforcement pour lequel seule une mesure d'erreur qualitative (échec ou réussite) est disponible.

- 3) L'apprentissage non supervisé pour lequel il n'y a pas de réponse désirée. La tâche du réseau peut être par exemple dans ce cas de créer des regroupements de données selon des propriétés communes (catégorisation).

## **II.7. Architecture des réseaux de neurones**

Selon la topologie de connexion des neurones, on peut en classe en deux grandes catégories : Réseaux non bouclés (statique ou feed-forward) et réseaux bouclés (dynamique feed-back ou récurrent).

### **II.7.1. Les réseaux de neurones non bouclés (Statiques)**

Un réseau de neurones non bouclé réalise une ou plusieurs fonctions algébriques de ses entrées par composition des fonctions réalisées par chacun de ses neurones. Les connexions entre les neurones qui composent le réseau décrivent la topologie du modèle. Elle peut être quelconque, mais le plus souvent il est possible de distinguer une certaine régularité [13]. Ici la décharge du neurone  $i$  à un instant  $t$  peut s'écrire ainsi :

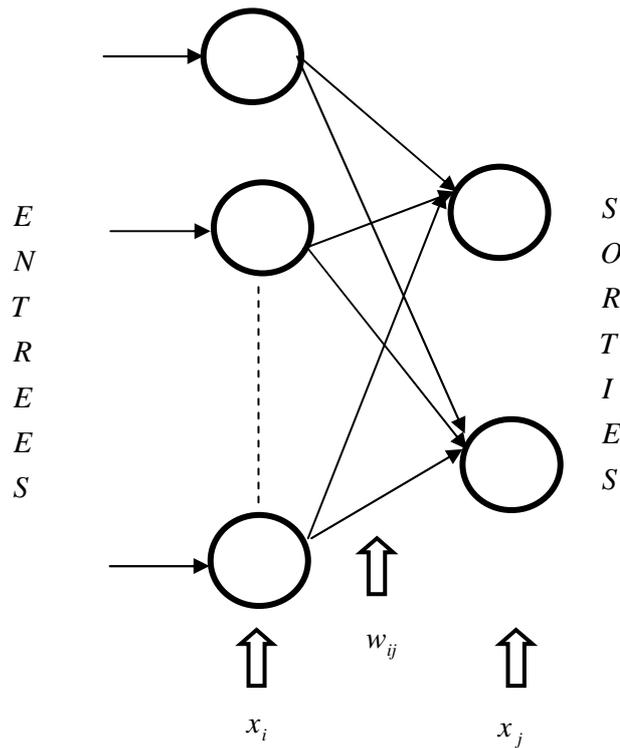
$$x_i = f(w_{ij}x_j) \tag{II.3}$$

avec

$f$ : Fonction d'activation

$w_{ij}$  : Poids de la connexion entre le neurone  $i$  et le neurone  $j$

$x_j$  : Activité du neurone  $j$



**Figure II.5.** Les réseaux feed-forward

Ce type de réseaux possède une couche d'entrée recevant les stimuli à traiter par l'intermédiaire des nœuds sources. Cette couche se projette en une couche de sortie composée de neurones (nœuds de calcul) transmettant les résultats du traitement au milieu extérieur.

La Figure (II.5) montre, par exemple, un réseau proactif monocouche à 3 nœuds d'entrée et 2 nœuds de sortie. La désignation monocouche est attribuée à la couche de sortie (nœuds de calcul). La couche d'entrée n'est pas comptée dans ce sens vu qu'il n'y a pas de calcul fait par les nœuds sources, ils servent uniquement à recevoir les signaux d'entrée et à les transmettre à la couche suivante. Un exemple classique de réseau monocouche est le perceptron qui est un réseau proactif monocouche à une seule sortie. Ce type de réseau ne peut réaliser que la discrimination de classes d'entrées linéairement séparables [14].

### II.7.2. Réseaux de neurones bouclés (Dynamiques)

C'est l'architecture la plus générale pour un réseau de neurone, dont le graphe des connexions est *cyclique*.

### II.7.3. Réseau à connexions récurrentes (Feed back)

Les connexions récurrentes ramènent l'information en arrière par rapport au sens de propagation défini dans un réseau multicouche. Ces connexions sont le plus souvent locales comme indiqués dans la Figure (II.6) [15].

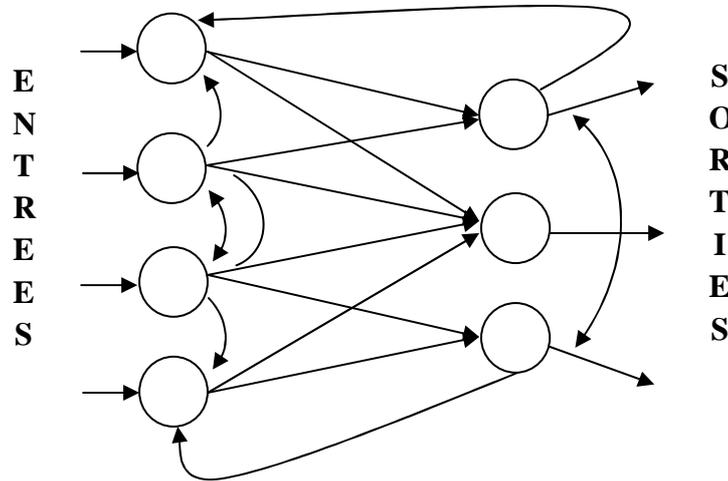
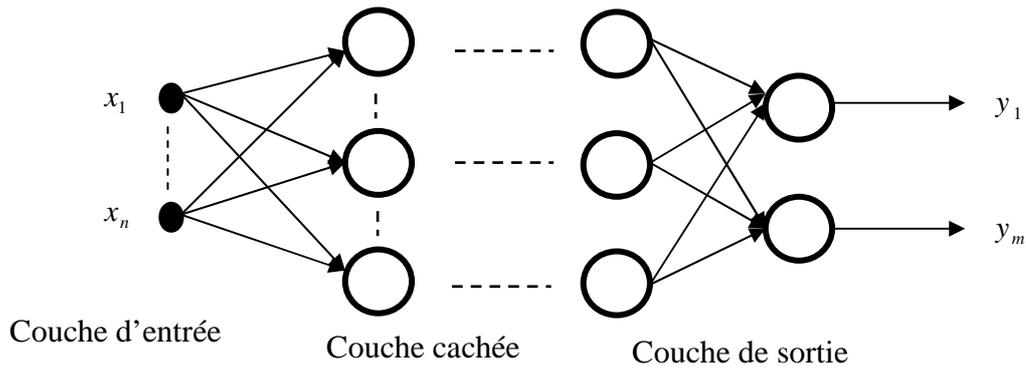


FIG II.6. Réseau a connexions récurrentes.

### II.8. Perception multicouche (MLP)

C'est le réseau de neurone statique le plus utilisé. Les neurones sont avancés par couche les neurones de la première couche reçoivent le vecteur d'entrée, il calcule leurs sortie qui sont transmises aux neurones de la seconde couche qui calculent eux même leur sortie et ainsi de suit de couche en couche jusqu'à celle de sortie. Chaque neurone dans la couche cachée est connecté à tout le neurone de la couche précédant et de la couche suivant, et il n'y a pas de connexion enté les cellules d'une même couche [16]. Dans cette architecture, comme montrée dans la Figure (II.7), les données sont traitées successivement par les couches cachées. Bien qu'une seule couche cachée suffise pour réaliser n'importe quelle fonction des entrées [17]-[18], le nombre optimal d'unités de la couche cachée reste inconnu. En plaçant ensuite bout à bout plusieurs couches et en connectant complètement les neurones de deux couches adjacentes.



**Figure II.7.** Structure du perceptron multicouche

Le MLP est très utilisé en identification. Avec une couche cachée, il constitue un approximateur universel. De récentes recherches montrent qu'il peut être entraîné de manière à approximer n'importe quelle fonction entrées-sorties sous réserve de mettre suffisamment de neurones dans la couche cachée et d'utiliser des sigmoïdes comme fonctions d'activation [0 où 1]. Cette architecture est particulièrement utilisée dans ce travail car elle possède des propriétés mathématiques intéressantes, qui seront présentées par la suite.

L'un des problèmes de l'utilisation des réseaux de neurones consiste dans le choix de sa topologie. Par exemple, il n'existe pas une règle générale qui donne le nombre de neurones à retenir pour la couche intermédiaire. Ce choix est spécifique à chaque application. Pour cela, un nombre aléatoire est toujours introduit au début. Ensuite, l'exécution consécutive de l'algorithme d'apprentissage et avec l'observation de l'erreur aide à sélectionner le nombre qui donne la précision souhaitée. Une fois que l'architecture est déterminée, on passe à l'étape de l'apprentissage. Au cours de cette phase est utilisé un algorithme pour assurer l'ajustement des poids synaptiques, afin de conférer au réseau le comportement entrée-sortie désiré. L'apprentissage des réseaux multicouches est assuré généralement par des algorithmes tels que (Rétro-propagation du gradient, Gauss Newton, Levenberg Marquardt,...) [19].

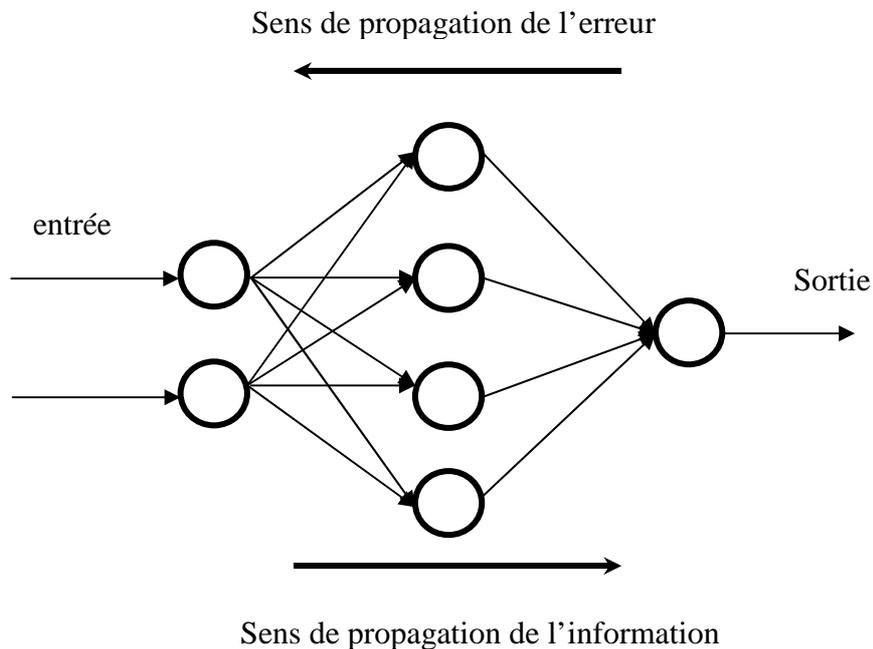
Nous présentons ici une des architectures de réseaux les plus utilisées. Elle correspond à une organisation des neurones en  $n$  couches successives ( $n \geq 3$ ). Les seules connexions présentées dans ce type de réseau relient chaque neurone avec l'ensemble de ceux de la couche suivante comme illustré dans la Figure (II.8), la propagation de l'information se déroule ainsi en sens unique depuis la couche d'entrée vers la couche de sortie [20].

La fonction d'activation utilisée pour les neurones peut être n'importe quelle fonction croissante et dérivable. On utilise souvent une fonction sigmoïde telle que :

$$g(x) = \frac{1}{1 + \exp(-x)} \quad (\text{II. 4})$$

Elle prend pour paramètre la somme pondérée des entrées du neurone

$$S_i = \sum_j W_{ij} a_j + b_i \quad (\text{II. 5})$$



**Figure. II.8.** Réseau multi-couches comportant 2 neurones d'entrée, 4 neurones cachés et un neurone de sortie.

où

$j$ : L'ensemble des neurones envoyant une connexion vers le neurone  $i$ .

$W_{ij}$ : Les poids de la connexion entre le neurone  $j$  et le neurone  $i$ .

$b_i$ : Un paramètre optionnel appelé biais.

## **II.9. Apprentissage des réseaux MLP**

### **II.9.1. Algorithme de rétro-propagation**

Nous présentons ici l'algorithme de retro-propagation du gradient qui est le plus connu pour réaliser l'adaptation des réseaux multi-couches. C'est à sa découverte que l'on doit le renouveau d'intérêt pour les ANN apparut au début des années 80. Il s'agit d'une méthode d'apprentissage supervisé, fondée sur la modification des poids du réseau dans le sens contraire à celui du gradient de l'erreur par rapport à ces poids. Nous allons présenter brièvement la méthode d'obtention de ce gradient, qui se base sur le calcul des dérivées partielles successives de fonctions compostées. La mesure de performance utilisée est l'erreur quadratique:

$$Q = \frac{1}{2} \sum_i (a_i - s_i)^2 \quad (\text{II. 6})$$

où  $i$  parcourt les indices des neurones de sortie, et  $a_i$  et  $s_i$  représentent respectivement l'activation mesurée et l'activation désirée pour ces neurones, Les poids du réseau sont modifiés [19] , en suivant la règle (II.7)

$$\Delta W_{ij} = -\eta \frac{\partial Q}{\partial W_{ij}} \quad (\text{II. 7})$$

où  $\eta$  est une constante positive appelée pas du gradient le choix de ce pas influe beaucoup sur la rapidité de convergence, un pas trop petit ralenti l'apprentissage, un pas trop important provoque un risque d'instabilité. Le calcul de la quantité  $\frac{\partial Q}{\partial W_{ij}}$  se fait en partant de la couche de sortie et en se déplaçant vers la couche d'entrée.

Cette propagation, suivant le sens inverse de celui de l'activation des neurones du réseau, justifie le nom de l'algorithme. Le calcul est décomposé de la manière suivante :

$$\frac{\partial Q}{\partial W_{ij}} = \frac{\partial Q}{\partial a_i} \frac{\partial a_i}{\partial \epsilon_i} \frac{\partial \epsilon_i}{\partial W_{ij}} \quad (\text{II. 8})$$

En posant  $\delta_i = \frac{\partial Q}{\partial a_i} \frac{\partial a_i}{\partial \epsilon_i}$  on obtient :

$$\frac{\partial Q}{\partial W_{ij}} = \delta_i \frac{\partial \epsilon_i}{\partial W_{ij}} \quad (\text{II. 9})$$

Et puisque  $\frac{\partial \epsilon_i}{\partial W_{ij}} = a_j$

$$\Delta W_{ij} = -\eta \delta_i a_j \quad (\text{II. 10})$$

La quantité  $\delta_i$  est appelée contribution à l'erreur du neurone  $i$ . Dans le cas où  $i$  est l'indice d'un neurone de sortie, on obtient :

$$\frac{\partial Q}{\partial a_i} = (a_i - s_i) \frac{\partial a_i}{\partial \epsilon_i} = g'(\epsilon_i) \quad (\text{II. 11})$$

Et donc :

$$\delta_i = g'(\epsilon_i)(a_i - s_i) \quad (\text{II. 12})$$

Dans le cas où  $i$  est l'indice d'un neurone caché on pose :

$$\frac{\partial Q}{\partial a_i} = \sum_k \frac{\partial Q}{\partial a_k} \frac{\partial a_k}{\partial a_i} \quad (\text{II. 13})$$

Où  $k$  parcourt les indices de tous les neurones vers lesquels le neurone  $i$  envoie une connexion .Le calcul nous donne :

$$\frac{\partial Q}{\partial a_k} \frac{\partial a_k}{\partial a_i} = \frac{\partial Q}{\partial a_k} \frac{\partial a_k}{\partial \epsilon_k} \frac{\partial \epsilon_k}{\partial a_i} = \delta_k \frac{\partial \epsilon_k}{\partial a_i} = \delta_k W_{ki} \quad (\text{II. 14})$$

Nous obtenons donc :

$$\frac{\partial Q}{\partial a_i} = \sum_k \delta_k W_{ki} \quad (\text{II. 15})$$

et

$$\delta_i = g'(\epsilon_i) \sum_k \delta_k W_{ki} \quad (\text{II. 16})$$

Cet algorithme, présente ici dans sa version la plus simple, possède de nombreuses variantes. Elles correspondent généralement à l'utilisation de valeurs variables pour la constante  $\eta$  [21], ou à l'utilisation de méthodes du deuxième ordre pour le calcul du gradient [22]. On utilise souvent une version légèrement différente de l'équation (II.7) pour calculer la quantité dont doivent être modifiés les poids :

$$\Delta W_{ij}(t) = -\eta \frac{\partial Q}{\partial W_{ij}} + \mu \Delta W_{ij}(t-1) \quad (\text{II. 17})$$

où  $\mu$  est une constante appelée le terme d'inertie (momentum), et  $t$  représente le temps. Cette version introduit un deuxième terme proportionnel à la dernière adaptation de  $W_{ij}$ .

Les modifications des poids peuvent intervenir après chaque présentation d'un patron, ou après la présentation de l'ensemble de la base d'exemples. L'apprentissage nécessite dans tous les cas un grand nombre de présentations de la totalité de ces exemples pour obtenir un résultat satisfaisant [12].

La phase d'apprentissage est souvent arrêtée lorsque l'erreur calculée sur l'ensemble de la base d'apprentissage est inférieure à un seuil déterminé par l'utilisateur. Il est possible d'arrêter l'apprentissage en fixant une limite au nombre d'itérations.

Cet algorithme souffre néanmoins de nombreux défauts, parmi lesquels :

- ✓ Temps de calcul excessif; apprentissage très long.
- ✓ Une grande sensibilité aux conditions initiales, c'est-à-dire à la manière dont sont initialisés les poids des connexions.
- ✓ De nombreux problèmes sont dus à la géométrie de la fonction d'erreur: minimums locaux. Ce problème est en partie résolu avec le gradient stochastique, mais il subsiste quand même.
- ✓ Le problème de dimensionnement du réseau. La rétro-propagation apprend une base d'apprentissage sur un réseau dont la structure est fixée a priori. La structure est définie par le nombre de couches cachées, le nombre de neurones par couches et la topologie des connexions. Un mauvais choix de structure peut dégrader considérablement les performances du réseau [2]. L'apprentissage des réseaux de neurones non bouclés se ramène donc au problème de la minimisation d'une fonction de coût, nous présentons ci-dessous la fonction de coût de Levenberg Marquardt.

### II.9.2. Algorithme de Levenberg-Marquardt

La méthode de Levenberg-Marquardt est un standard pour optimiser l'erreur quadratique due à ses propriétés de convergence rapide et de robustesse. Cet algorithme s'applique au cas particulier où  $E$  est une erreur quadratique moyenne [23]-[24]. On peut donc l'exprimer sous la forme:

$$E(W) = \langle (f(x, W) - y)^2 \rangle \quad (\text{II. 18})$$

où

$f$  : Une fonction de deux vecteurs  $x$  et  $W$ ,

$\langle \dots \rangle$  : La moyenne calculée sur un ensemble de couples  $(x, y)$ .

Dans la suite de cette partie toutes les dérivées sont en fonction du vecteur  $W$ . C'est en effet uniquement ce vecteur que l'on fait varier afin de trouver le minimum de  $E$ .

Comme pour la descente de gradient, on suppose, que l'on se trouve à une itération numéro  $i$ , et que l'on cherche à calculer un nouveau vecteur  $W_i$  en fonction de  $W_{i-1}$ , tel que  $E(W_i)$  se rapproche plus d'un minimum local de  $E$ . Pour cela on calcule une approximation quadratique  $\hat{E}$  de  $E$  à partir d'une approximation linéaire  $\hat{f}$  de  $f$  autour du point  $W_{i-1}$ .

En déterminant le point  $W$  auquel le gradient de  $\hat{E}$  s'annule, on obtient :

$$W_i = W_{i-1} - \left(\frac{1}{H}\right) d \quad (\text{II. 19})$$

avec:

$$d = \langle (f(x, W_{i-1}) - y) \nabla f(x, W_{i-1}) \rangle \quad (\text{II.20})$$

$$H = \langle (f(x, W_{i-1}) - y) \nabla f(x, W_{i-1})^T \rangle \quad (\text{II. 21})$$

La matrice  $H$  est une approximation du Hessian de  $E$  calculée à partir du gradient de  $f$  à condition que  $H$  soit inversible. L'équation précédente pourrait servir dans un algorithme d'optimisation, qui permet de calculer  $W_i$  à partir de  $W_{i-1}$  au cours de l'itération  $i$ . Mais ceci n'est efficace en pratique que si  $f$  est effectivement proche d'une droite autour du point  $W_{i-1}$ , dans le cas contraire cet algorithme donne de très mauvais résultats.

*Levenberg* utilise cette approche quadratique dans les zones où  $f$  est quasi-linéaire [24], et une descente de gradient dans les autres cas. Le pas d'une itération de cet algorithme est calculé de la manière suivante :

$$W_i = W_{i-1} - \left( \frac{1}{H + \lambda I} \right) d \quad (\text{II. 22})$$

Lorsque  $\lambda$  est faible, cette équation est équivalente à (II.19) et le nouveau vecteur de paramètres est déterminé avec l'approximation quadratique de  $E$ . Lorsque  $\lambda$  est grand, cette équation est équivalente à :

$$W_i = W_{i-1} - \frac{1}{\lambda} d \quad (\text{II. 23})$$

$$= W_{i-1} - \frac{1}{\lambda} \langle (f(x, W_{i-1}) - y) \nabla f(x, W_{i-1}) \rangle \quad (\text{II. 24})$$

$$= W_{i-1} - \frac{1}{2\lambda} \nabla E(x, W_{i-1}) \quad (\text{II. 25})$$

Ce qui convient bien à une descente de gradient. Pour des valeurs intermédiaires de  $\lambda$  l'algorithme est un mélange entre la descente de gradient et l'approche quadratique basée sur l'approximation linéaire de  $f$ . Ce coefficient  $\lambda$  est modifié à chaque itération, comme pour la descente de gradient adaptative. Si  $E(W_i)$  diminue au cours de l'itération, on diminue  $\lambda$ , et l'on se rapproche ainsi de la méthode quadratique. Au contraire si  $E(W_i)$  augmente, cela signifie que nous nous trouvons dans une région dans laquelle  $f$  n'est pas très linéaire, et donc on augmente  $\lambda$  afin de se rapprocher de la descente de gradient [22].

Cet algorithme a ensuite été amélioré par *Marquardt*, le pas de l'itération étant défini cette fois par:

$$W_i = W_{i-1} - \left( \frac{1}{H + \lambda \text{diag}(H)} \right) d \quad (\text{II. 26})$$

La matrice identité a été remplacée par la diagonale de  $H$ . Le but est ici de modifier le comportement de l'algorithme dans les cas où  $\lambda$  est grand, c'est à dire lorsque l'on est proche d'une descente du gradient. Avec cette modification l'on se déplace plus vite dans les

directions vers lesquelles le gradient est plus faible, afin d'éviter de passer de nombreuses itérations sur un plateau. Ceci est appelé l'algorithme de Levenberg –Marquardt.

Cette méthode a montré son efficacité surtout dans ce travail. Le réseau a convergé vers les valeurs désirées pour les paramètres quasi-statiques des lignes de transmission même parfois le nombre des entrées de ce réseau atteint jusqu'à 14 vecteurs pour la ligne de transmission multicouche elliptique MECPS par exemple.

### **II.10. Réseaux de neurones à fonctions de base radiales (RBF)**

Les réseaux de neurones à fonctions de base radiales sont des réseaux de type *feedforward* (à propagation avant) avec une seule couche cachée comme présentés dans la Figure (II.9). Ils sont proposés par J. Moody et C. Darken [25]. Ces réseaux capables de fournir une représentation locale de l'espace grâce à des fonctions de base dont l'influence est restreinte à une certaine zone de l'espace. Les paramètres de cette fonction de base sont donnés par un vecteur de référence (centre ou prototype)  $[u_j]_{j=1\dots n}$  et la dimension  $\sigma_j$  du champ d'influence. La réponse de la fonction de base dépend donc de la distance de l'entrée  $X$  au vecteur prototype  $u_j$  et de la taille du champ d'influence :

$$\phi_j = \phi(\|(X - u_j)\|, \sigma_j) \tag{II.27}$$

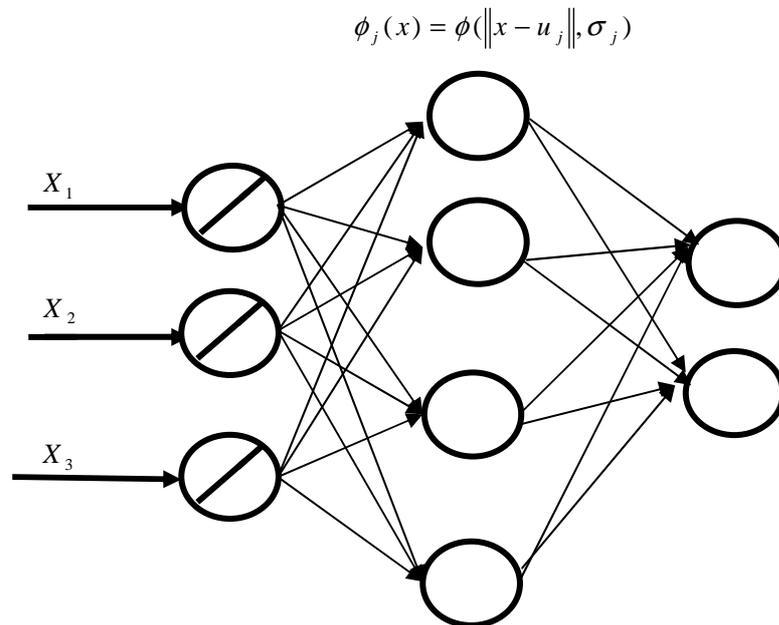
où les fonctions  $\Phi_j(.)$  sont généralement maximales lorsque  $X = \mu_j$  et tendent vers 0 quand  $\|(X - \mu_j) \rightarrow \infty\|$ .

La gaussienne est la fonction la plus employée. Elle s'exprime, sous la forme la plus générale, par :

$$\phi_j = \exp\left(-\frac{1}{2}(X - u_j)^t \sum_j^{-1} (X - u_j)\right) \tag{II.28}$$

où  $\sum_j$  désigne la matrice de variance-covariance associée à la cellule. Différents paramétrages de  $\sum_j$  sont possibles. Un choix courant reste cependant  $\sum_j = \sigma_j^2 I$  où l'on suppose que la décroissance de la gaussienne est la même pour toutes les directions de l'espace (gaussienne isotrope). Les courbes d'iso-activation des cellules cachées sont alors des hyper-sphères. Un nombre restreint de fonctions de base participent au calcul de la sortie pour

une entrée donnée. Les RBF peuvent être classés en deux catégories, en fonction du type de neurone de sortie : *normalisé* et *non-normalisé* [26]-[27]-[28].



**Figure II.9.** Réseau à fonctions de base radiales.

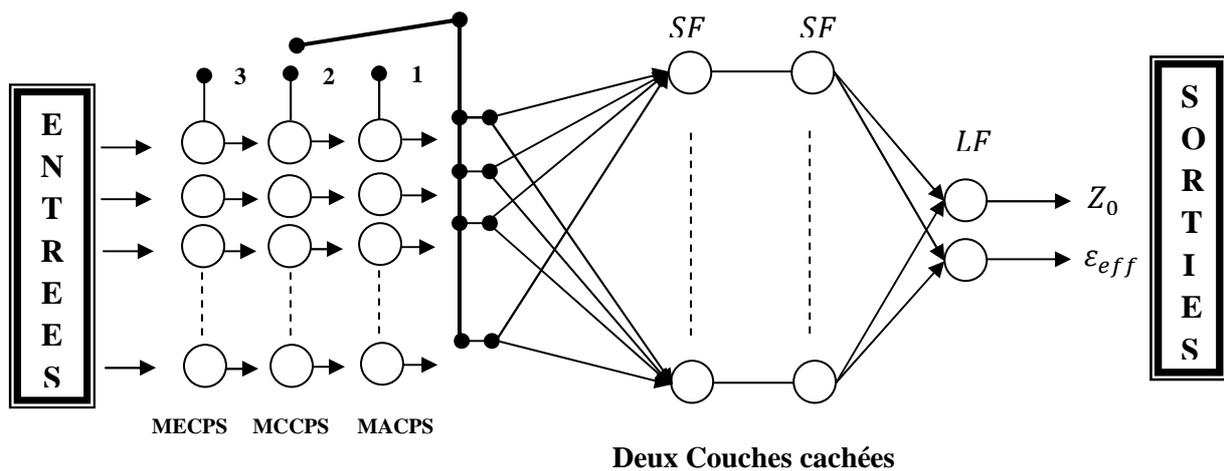
La construction d'un réseau RBF est rapide et facile, et c'est là le principal avantage de la technique [29]. Mais cet avantage se paye par des performances qui ne peuvent être aussi bonnes que celles de techniques plus sophistiquées (comme le Perceptron Multicouches).

En particulier, les réseaux RBF sont peu performants :

- ✓ Sur les données dans des espaces de grande dimension (beaucoup de variables d'entrée), cette faiblesse est propre à toutes les techniques locales surtout dans notre travail où le nombre des entrées atteint jusqu'à 14 vecteurs.
- ✓ Sur des données très bruitées. La reconstruction locale de la fonction empêche le réseau de "moyenner" le bruit sur tout l'espace (comparez avec la Régression Linéaire, dont l'objectif est justement de moyenner le bruit sur les données).

**II.11. Un réseau de neurone artificiel pour le calcul des paramètres quasi-statiques des lignes de transmission coplanaires (MACPS), (MCCPS) et (MECPS)**

Les réseaux de neurones peuvent fournir des solutions très intéressantes essentiellement pour les structures électromagnétiques. Un MLP à trois couches permet de calculer l'impédance caractéristique et la constante diélectrique effective des lignes de transmission MECPS, MCCPS et MACPS avec des résultats efficaces. Dans ce travail, l'algorithme standard de rétro propagation a été utilisé pour l'entraînement du MLP. La structure du réseau utilisée pour obtenir les paramètres quasi-statiques de trois lignes de transmission est illustrée dans la Figure (II.10). Les neurones, dans la couche d'entrée de chaque réseau dépendent de la base de données de l'entrée de chaque ligne de transmission et les fonctions de transfert des couches cachées utilisent la fonction sigmoïde (SF) par contre, la couche de sortie se base sur la fonction de transfert linéaire (LF).



**Figure II.10.** Modèle de réseau MLP pour calculer les paramètres quasi-statiques des lignes de transmission

L'identification de l'impédance caractéristique  $Z_0$  et la permittivité effective  $\epsilon_{eff}$  de MECPS, MCCPS et MACPS par la structure MLP de réseaux de neurones passe par les étapes suivantes:

- Création d'une base d'apprentissage obtenue par la technique CMT contient les entrées et les sorties souhaitées.
- L'initialisation aléatoire des poids et des biais sur les connexions de notre réseau neuronal.

- La modification des pondérations des poids par apprentissage pour diminuer l'erreur entre la sortie désirée et la sortie réelle.
- La normalisation appropriée, qui tient compte de l'amplitude des valeurs acceptées par le réseau.
- Le test de la validation par d'autres valeurs, qui ne sont pas utilisées dans la base d'apprentissage, pour assurer la performance du réseau.

II.12. Organigramme d'apprentissage d'ANN pour calculer les paramètres quasi-statistiques des lignes MECPS, MCCPS, et MACPS

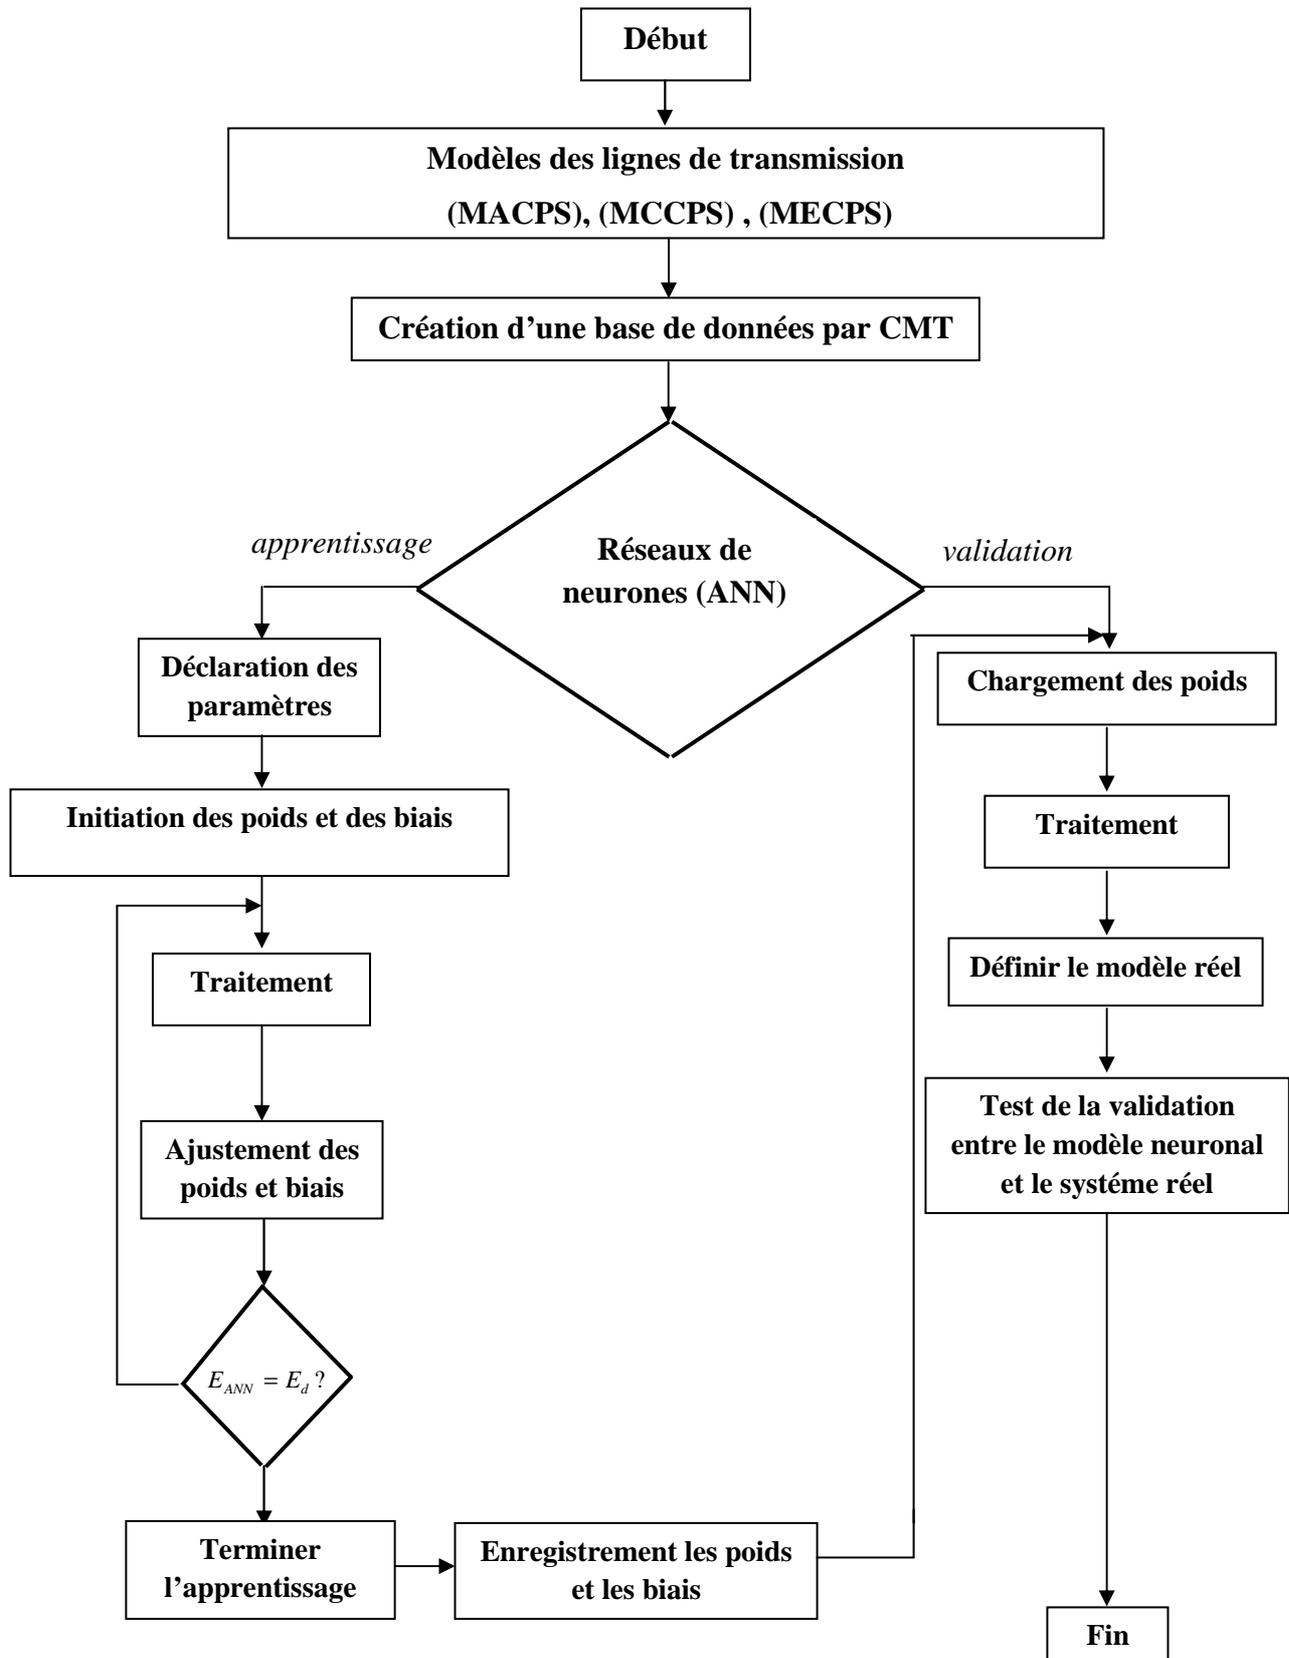


Figure II.11. Organigramme de réseau MLP pour calculer les paramètres quasi-statistiques des lignes de transmission

### **II.13. Conclusion**

Au cours de ce chapitre nous avons présenté une synthèse des quelques approches des réseaux de neurones artificiels. Le choix de l'une ou l'autre, leurs avantages et inconvénients ont été discuté. Nous avons particulièrement détaillé une seule architecture neuronale: Le MLP par laquelle nous avons réalisé ce travail. Si la littérature regorge d'exemples d'emploi des ANN sur des problèmes tests bien connus, les réalisations pratiques sont beaucoup plus rares. Une grande partie des travaux qui ont été évoqués dans ce travail surtout dans l'introduction générale se limitent en effet à l'étude de problèmes déjà résolus par des méthodes classiques, auxquels ils n'apportent qu'une contribution limitée [30].

Donc avant d'envisager l'utilisation d'ANN pour la résolution de problème d'identification des lignes de transmission, de nous poser la question de l'apport possible par rapport aux méthodes existantes.

Dans la suite de ce chapitre nous nous efforcerons de comparer les propriétés de cette approche neuronale avec celle d'autre méthode proposée dans la littérature , rapide , efficace précise appelée la méthode de la logique floue et en va consacrer notre étude sur l'approche de retro-propagation floue.

## Références bibliographiques

- [1] L. Melakhessou, «Contrôle et identification des systèmes non linéaires par les techniques neuronales », *Mémoire de magister* ,Université El-Hadj Lakhdar, Batna.
- [2] M.R. Zemouri, «Contribution à la surveillance des systèmes de production à l'aide des réseaux de neurones dynamiques : Application à la -maintenance », *Thèse de Doctorat*, Université Franche-compte, 2003.
- [3] E. Hervet , “Réseaux de neurones” *cours* , Université de Moncton Faculté des sciences, Département d’informatique Moncton, N.-B., CANADA E1A 3E9.
- [4] A. Aussem, «Théorie et Application des Réseaux de Neurones Récurents et Dynamiques à la Prédiction, à la Modélisation et au Contrôle Adaptatif des Processus Dynamiques », *Thèse de Doctorat*, Université René Descartes , Paris V, juin 1995.
- [5] C. Touzet, "Les réseaux de neurones artificiels, introduction au connexionnisme, cours, exercices et travaux pratiques", *préface de Jeanny Hérault*, EC2 éd. 150 pages, Paris, 1992.
- [6] F. Wang, V.K. Devabhaktuni, C. Xi, and Q. Zhang, “ Neural network structures and training algorithms for RF and microwave applications”, *Int. J. RF and Microwave Computer-Aided Eng*, Vol . 9, pp. 216–240, 1999.
- [7] W.S. McCulloch and W. Pitts, “A logical calculus of ideas immanent in nervous activity”, *Bull. Mathematical Bio-physics*, Vol. 5, 1943, pp. 115-133.
- [8] A. Assoum , «Etude de la tolérance aux aléas logiques des réseaux de neurones artificiels », *Thèse de Doctorat*, l'institut national polytechnique de Grenoble , laboratoire Logiciels Systèmes Réseaux, 4 Avril 1997.
- [9] J. Bernou “Robotique et vision artificielle ”, *cours*, Université du Québec en Outaouais Département d'informatique et d'ingénierie , Programme de Génie Informatique 7643.
- [10] B. Bouzy , “Réseaux de neurones” ,*cours* ,Université Paris Faculté des sciences , Département math et informatique, 18 octobre 2005.
- [11] B. Orsier , «Etude et application de systèmes hybrides neuro-symboliques ». *Thèse de Doctorat* , Université Joseph Fourier Grenoble, 1995.
- [12] E. Gauthier , «Utilisation des Réseaux de Neurones Artificiels pour la Commande d'un Véhicule Autonome », *Thèse de Doctorat*, l'institut national polytechnique de grenoble,

- Laboratoire LEIBNIZ en collaboration avec le projet SHARP de l'INRIA Rhone - Alpes, 25 Janvier 1999.
- [13] E. A. Arleo , «Les interactions cervelet – hippocampe dans la cognition spatiale : approche de modélisation neuromimétique », *Mémoire de Master* , Université Paris Descartes, Equipe NeuroComputation Adaptative Laboratoire de Neurobiologie des Processus Adaptatifs - Alpes, 25 Janvier 1999.
- [14] F. Rosenblatt, “The Perceptron : A Probabilistic Model for Information Storage and Organization in the Brain “, *Psychologica Revue*, n°65, 1958, pp. 386-408.
- [15] N. Hamdiken, “Analyse d’une antenne microbande circulaire par la méthode neurospectrale “ *Mémoire de Magister*, Université El-Hadj Lakhdar ,Batna - 12 sept. 2012.
- [16] M. Nouverssadat, « Etude performances des réseaux de neurone dynamique à représenter des systèmes réels, une approche dans l’espace d’état », *Mémoire de Magister*, Université Ferhat Abbas, Sétif , janvier,2009.
- [17] K. Hornik, M. Stinchcombe, and H. White. “Multilayer feedforward networks are universal approximators”, *Neural Networks*, 2:359\_366,1989.
- [18] G. Cybenko, “Approximation by superpositions of a sigmoidal function”, *Mathematics of Control, Signals, and Systems*, 2:303\_314, 1989.
- [19] L. Baghli, «Contribution à la commande de la machine asynchrone, utilisation de la logique floue, des réseaux de neurones et des algorithmes génétiques », *Thèse de Doctorat*, Université Henri Poincaré, Nancy-I, 14 janvier 1999
- [20] D. E. Rumelhart and J. L. McClelland, “ Parallel Distributed Processing: Explorations in the Microstructure of Cognition”, volume 1. *M.I.T. Press*, 1986.
- [21] M. Riedmiller and H. Braun, “A direct adaptive method for faster backpropagation learning the RPROP algorithm”, *In Proc. of the Int. Conf. on Neural Networks*, San Francisco (CA), 1993.
- [22] S. E. Fahlman, “An empirical study of learning speed in back-propagation networks”, *Technical Report CMU-CS-88-162*, CMU, 1988.
- [23] S. Saif Allah, "Identification des dispositifs hyper-fréquences par réseaux de Neurones" *Mémoire d'ingénieur*, Université Ferhat Abbas, Setif, 2006.

- [24] D. W. Marquardt. "An algorithm for least-squares estimation of nonlinear parameters", *Journal of the Society for Industrial and Applied Mathematics*, Vol: 11. N: 2, pp: 431-441, 1963.
- [25] J. Moody and C. Darken , "Fast learning in networks of locally-tuned processing units", *Neural Computation*, 1:281-294, 1989.
- [26] M.W. Mak, and S.Y Kung.,«Estimation of Elliptical Basis Function Parameters by the EM Algorithms with Application to Speaker Verification », *IEEE Trans. on Neural Networks*, vol. 11, n° 4, July 2000, p. 961-969.
- [27] J. Moody and J. Darken, «Fast Learning in networks of locally tuned processing units », *Neural Computation*, 1989, p. 281-194.
- [28] L. Xu, «RBF nets, mixture experts, and Bayesian Ying-Yang learning », *Neurocomputing*, 1998, p. 223-257.
- [29] A. Borgi, «Apprentissage supervise par génération de règles: le système SUCRAGE », *Thèse de Doctorat*, Université de Paris 6 ,1999.
- [30] J.M. Renders, "Algorithmes génétiques et réseaux de neurones ". Hermes, 1995.

---

## **CHAPITRE III**

### ***IDENTIFICATION DES PARAMETRES QUASI- STATIQUES DES LIGNES DE TRANSMISSION PAR LES SYSTEMES FLOUS (FSs)***

### **III.1. Introduction**

Une autre alternative pour l'identification et la modélisation des systèmes complexes est l'utilisation des concepts de la théorie des ensembles flous et des Systèmes Flous (FSs) [1]. Un modèle flou est une représentation des caractéristiques d'un système à l'aide de règles floues qui d'écrivent son comportement [2].

La logique floue introduite par Zadeh dans les années soixante constitue un outil très puissant pour la représentation des termes et des connaissances vagues [3]. Les métaheuristiques, comprenant notamment la méthode du recuit simulé, les algorithmes évolutionnaires, la méthode de recherche tabou, les algorithmes de colonies de fourmis... sont apparues à partir des années 80. Ce sont des algorithmes d'optimisation de type stochastiques et progressant vers un optimum par échantillonnage d'une fonction objective dont le but est la résolution de problèmes d'optimisation difficile. Cette dernière élargit la logique booléenne conventionnelle en utilisant le concept de "vérité partielle" pour les valeurs comprises entre "0" et "1", ce qui correspond respectivement à une logique de "complètement faux" et de "complètement vraie". La méthode de La logique Floue utilise des outils mathématiques pour modéliser un raisonnement approximatif lorsque la donnée est imprécise, incertaine, vague et incomplète.

Ce chapitre est consacré à la description des éléments de base de la théorie des systèmes flous FSs, nous traitons du problème d'identification des modèles flous à partir de données entrée-sortie. Nous introduisons d'abord la modélisation floue des systèmes, en nous focalisant particulièrement sur le modèle de type Takagi-Sugeno. En utilisant ce formalisme, nous représentons le comportement non linéaire d'un système par une composition des règles du type « *Si-Alors* » et de comprendre comment utiliser la logique floue pour l'apprentissage et l'identification de l'impédance caractéristique et la constante diélectrique effective des lignes de transmission MECPS, MCCPS, et MACPS.

### **III.2. Modélisation floue des systèmes**

Les modèles flous peuvent être considérés comme des modèles logiques qui utilisent des règles du type « *Si...Alors...* » pour établir des relations qualitatives entre les variables du modèle. Ils reposent sur une dualité linguistique/numérique dans laquelle les ensembles flous servent d'interfaces entre les variables qualitatives (linguistiques) impliquées dans les règles et les valeurs numériques présentes dans les données entrées/sorties du modèle. La nature des

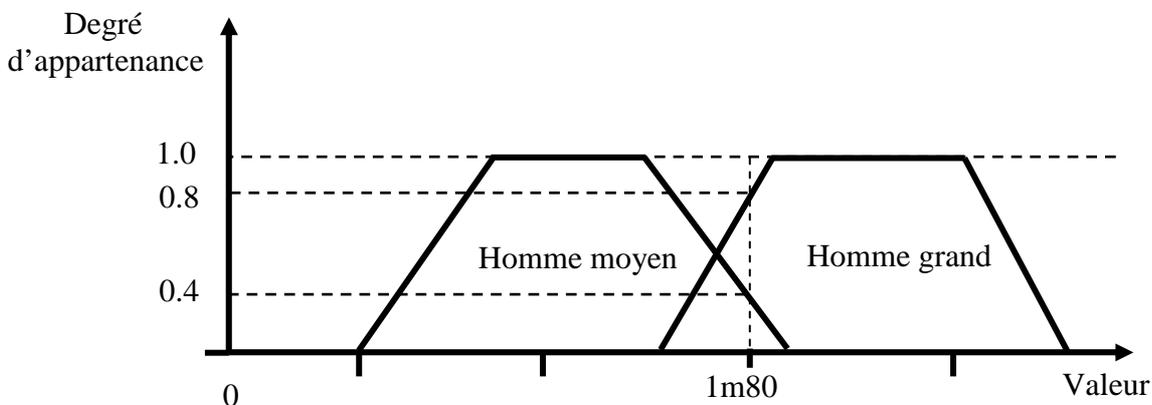
modèles flous, basée sur des règles, permet l'utilisation d'information sous la forme des expressions du langage naturel, ce qui facilite la formalisation de la connaissance des experts ainsi que la transparence et l'interopérabilité du modèle. De plus, les modèles flous ont une structure mathématique flexible capable d'approximer un grand nombre de systèmes non linéaires complexes avec une bonne précision [4]-[5]-[6]. Les algorithmes d'apprentissage sont aussi utilisés pour la modélisation floue, ils peuvent même être combinés avec des techniques conventionnelles de régression [7]-[8].

### III.3. Systèmes d'Inférence Floue

Les systèmes d'inférence floue (SIF) peuvent être considérés comme des systèmes logiques qui utilisent des règles linguistiques pour établir des relations entre leurs variables d'entrée et de sortie. Aujourd'hui, les applications des SIF sont très nombreuses outre le magnétisme, ils sont largement utilisés pour la modélisation, le diagnostic et la reconnaissance de formes [9]. Pour une meilleure compréhension, nous présentons quelques notions de base de ces systèmes ainsi que leurs types et leurs caractéristiques.

### III.4. Ensembles flous

Un ensemble flou est un ensemble de valeurs qui appartiennent à une certaine classe avec une certaine certitude. Par exemple un homme de 1m80 est grand avec une certitude de 80% et moyen avec une certitude de 40%. Ça veut dire qu'il appartient à la classe "hommes grands" avec une certitude de 0.80 et à la classe "hommes moyens" avec une certitude de 0.40. "Homme grand" et "homme moyen" comme présenté dans la Figure (III.1) sont des ensembles flous dont les limites dépendent par exemple de l'observateur et du pays concerné.



**Figure III.1.** Ensembles flous

Si l'homme pèse 95 kg il est aussi "homme lourd" avec une certitude de 0.9 et "homme moyennement lourd" avec une certitude de 0.15. Est-il alors un "homme fort", un "homme musclé" ou un "homme maigre"? Il est, par exemple, "homme fort" avec une certitude de 0.8, "homme musclé" avec une certitude de 0.5 et "homme maigre" avec une certitude de 0.001. Le calcul logique à effectuer est "homme grand" ET "homme lourd" => "homme fort", aussi bien que "homme moyen" ET "homme lourd" => "homme fort" ainsi que plusieurs autres déductions pour "homme musclé" par exemple.

La logique floue est une logique qui permet de propager les coefficients de certitude dans les opérations logiques, comme les opérations ET, OU et NON. Dans l'exemple ci-dessus il faut déjà utiliser les opérations ET et OU pour trouver la certitude que l'homme appartient au classe "homme fort". La façon de propager les facteurs est souvent d'utiliser le minimum pour l'opération ET et le maximum pour l'opération OU [10].

### III.4.1 Variable linguistique

La notion de variable linguistique permet de modéliser les connaissances imprécises ou vagues sur une variable dont la valeur précise est inconnue. Une variable linguistique, ou variable floue, est donc une variable dont les valeurs floues appartiennent à des ensembles flous pouvant représenter des mots du langage naturel. Ainsi une variable floue peut prendre simultanément plusieurs valeurs linguistiques [11]. Le domaine sur lequel ces termes et ces variables sont définies, constitue l'univers de discours. Le découpage de cet univers de discours par les termes flous est appelé une partition floue. Lorsque l'univers de discours est totalement recouvert par les termes flous, et que pour toutes valeurs, la somme des degrés d'appartenance est égale à 1, on parle alors de *partition floue forte*.

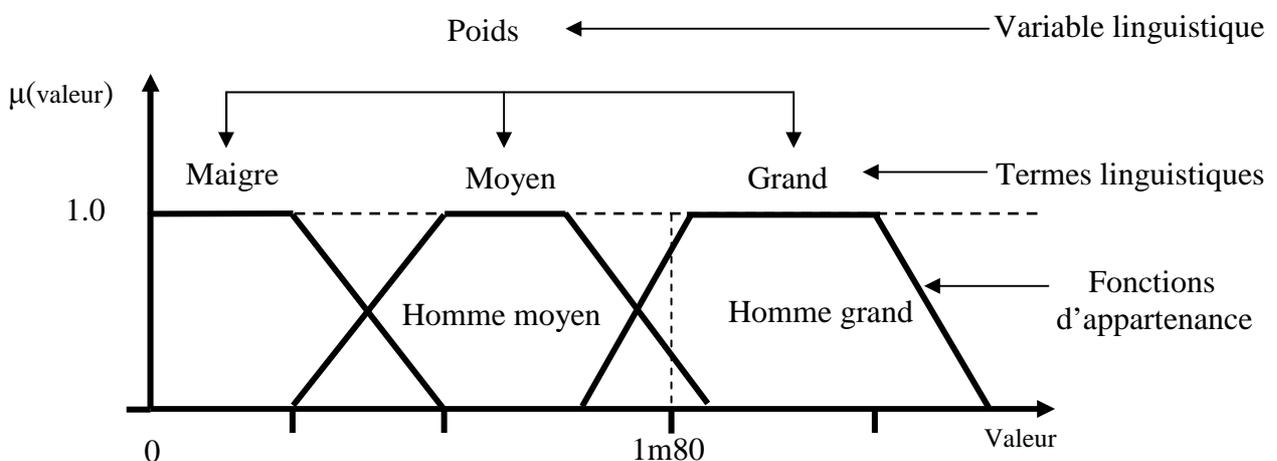


Figure. III.2. Variable linguistique

La variable linguistique peut être représentée par un triplet  $(x, T(x), U)$  dans lequel  $x$  est le nom de la variable linguistique,  $T(x)$  l'ensemble des valeurs linguistiques de  $x$  et  $U$  l'univers de discours. La Figure (III.2) illustre un exemple de variable linguistique 'poids' avec trois termes linguistiques: Maigre, Moyenne et Grande.

### III.4.2. Fonction d'appartenance

Un sous-ensemble flou  $A$  dans un univers du discours  $X$  est caractérisé par sa fonction d'appartenance  $\mu_A(x)$  qui associe à chaque élément  $x$  de  $X$  une valeur dans l'intervalle des nombres réels  $[0, 1]$ .

$$\mu_A: X \rightarrow [0,1] \quad (\text{III. 1})$$

Ainsi un sous-ensemble flou  $A$  dans  $X$  peut être représenté par un ensemble de couples ordonnés

$$A = \{(x, \mu_A(x)) | x \in X\} \quad (\text{III. 2})$$

Le sous-ensemble classique n'est en fait qu'un cas particulier de sous-ensemble flou dont la fonction d'appartenance ne prend que les valeurs 0 ou 1. Un sous-ensemble flou  $A$  de  $X$  est aussi souvent représenté par la notation suivante qui indique pour tout élément  $x$  de  $X$  son degré  $\mu_A(x)$  d'appartenance à  $A$  :

$$A = \int_X \frac{\mu_A(x)}{x} \quad \text{si } X \text{ est continu} \quad (\text{III. 3})$$

$$A = \sum_{x_i \in X} \frac{\mu_A(x_i)}{x_i} \quad \text{si } X \text{ est discret} \quad (\text{III. 4})$$

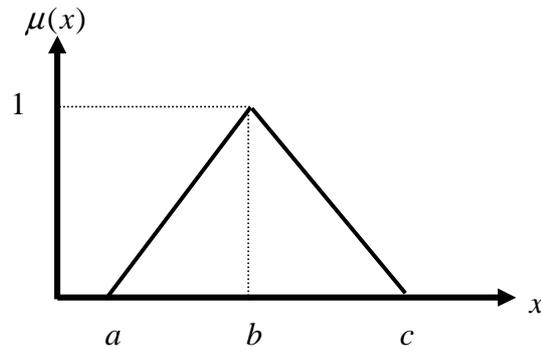
Comme les valeurs  $\mu_A(x_i)$  représentent les degrés d'appartenance avec lesquels les  $x_i$  appartiennent à  $A$ , si  $\mu_A(x_i)$  prend la valeur 1 pour tous les éléments de  $X$ , cela signifie que  $A$  est identique à  $X$ . Au contraire,  $A$  est vide si  $\mu_A(x_i)$  prend la valeur 0 sur tout  $X$  [9].

En apprentissage et identification floue, les fonctions d'appartenance utilisées peuvent théoriquement être quelconques. Pourtant on a choisi dans notre travail la fonction *Gaussienne* afin de simplifier les calculs et assurer la convergence.

Les gabarits de fonctions d'appartenance les plus utilisés sont représentés comme suit :

- **La fonction triangulaire** : Elle est caractérisée par trois paramètres (a, b, c); les sommets du triangle:

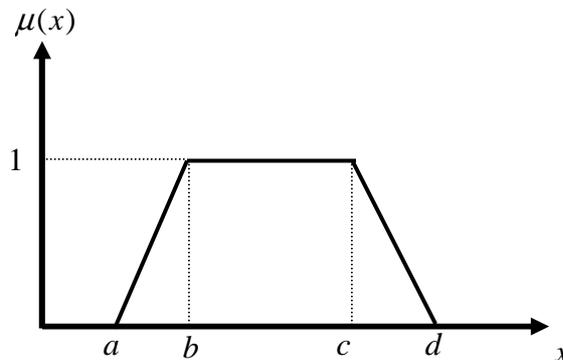
$$\mu(x) = \max\left(\min\left(\frac{x-a}{b-a}, \frac{c-x}{c-b}\right), 0\right) \quad (\text{III. 5})$$



**Figure III.3.** Fonction triangulaire

- **La fonction trapézoïdale**: Définie par quatre paramètres (a, b, c, d) :

$$\mu(x) = \max\left(\min\left(\frac{x-a}{b-a}, 1, \frac{d-x}{d-c}\right), 0\right) \quad (\text{III. 6})$$



**Figure III.4.** Fonction trapézoïdale

- **La fonction Gaussienne**: Définie par c et σ le centre , et l'épaisseur

$$\mu(x) = \exp\left(-\frac{(x-c)^2}{\sigma^2}\right) \quad (\text{III. 7})$$

où:

$\sigma$ : L'écart type.

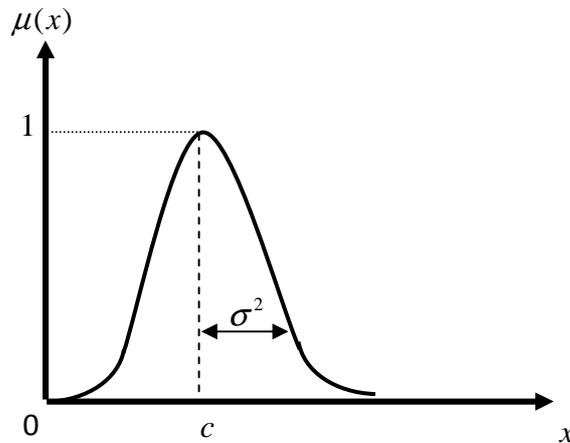


Figure III.5. Fonction Gaussienne

### III.4.3. Propositions floues

Une proposition floue générale est obtenue par la composition de propositions élémentaires «  $x$  est  $A$  », «  $y$  est  $B$  », ... pour des variables  $x, y$  ... supposées non indépendantes.

Habituellement les propositions floues générales sont classées en quatre types :

- La conjonction de propositions floues élémentaires [11] :

$$p: (X_1 \text{ est } A_1) \text{ et } \dots \text{ et } (X_n \text{ est } A_n)$$

Dans ce cas, la conjonction est associée au produit cartésien  $A_1 \times A_2 \dots A_n$  caractérisant la variable conjointe  $(X_1, \dots, X_n)$  sur les univers de discours  $X_1 \times X_2 \times \dots \times X_n$ . Sa valeur de vérité est alors définie par :

$$V(p): \min\{\mu_{A_1}(X_1), \dots, \mu_{A_n}(X_n)\} \tag{III. 8}$$

- La disjonction des propositions floues élémentaires :

$$p: (X_1 \text{ est } A_1) \text{ ou } \dots \text{ ou } (X_n \text{ est } A_n)$$

La valeur de vérité de la disjonction sur les univers du discours  $X_1 \times X_2 \times \dots \times X_n$  est définie par :

$$V(p): \max\{\mu_{A_1}(X_1), \dots, \mu_{A_n}(X_n)\} \tag{III. 9}$$

➤ Les implications entre propositions floues :

Règle 1 : Si ( $X$  est  $A_1$ ) ; alors ( $Y$  est  $B_1$ )

Règle 2 : Si ( $X$  est  $A_2$ ) ; alors ( $Y$  est  $B_2$ )

...

Règle n : Si ( $X$  est  $A_n$ ) ; alors ( $Y$  est  $B_n$ )

Les implications seront présentées plus en détail dans le paragraphe suivant.

➤ Les combinaisons de conjonction, disjonction et implication de propositions floues élémentaires [12]. Par exemple, «si ( $(X_1$  est  $A_{11})$  ) et ( $(X_2$  est  $A_{12})$  ) ; alors ( $Y$  est  $B_1$ )», etc ...

### III.4.4. Implications floues

Dans la proposition floue p: «Si ( $X$  est  $A$ ); alors ( $Y$  est  $B$ )», les propositions « $X$  est  $A$ » et « $Y$  est  $B$ » sont construites à partir des deux variables linguistiques ( $x, T(x), X, G, M$ ) et ( $y, T(y), Y, G, M$ ) qui sont a priori indépendantes. L'implication floue permet de définir une liaison entre la prémisse « $X$  est  $A$ » et la conclusion « $Y$  est  $B$ » de cette règle [12].

Les implications floues les plus souvent employées sont précisées dans le tableau (TAB.III.1)

Valeur de vérité	$I(\mu_A(x), \mu_B(x))$	Nom
$I_m$	$\min(\mu_A(x), \mu_B(x))$	Mamdani
$I_l$	$(\mu_A(x) \times \mu_B(x))$	Larsen
$I_r$	$1 - \mu_A(x) + \mu_A(x) \times \mu_B(x)$	Reichenbach
$I_w$	$\max(1 - \mu_A(x), \min(\mu_A(x), \mu_B(x)))$	Willmott
$I_{rg}$	$\begin{cases} 1 & \text{si } \mu_A(x) \leq \mu_B(x) \\ 0 & \text{sinon} \end{cases}$	Rescher-Gaines
$I_{kd}$	$\max(1 - \mu_A(x), \mu_B(x))$	Kleene-Dienes
$I_{bg}$	$\begin{cases} 1 & \text{si } \mu_A(x) \leq \mu_B(x) \\ \mu_B(x) & \text{sinon} \end{cases}$	Brouwer-Godel
$I_g$	$\begin{cases} \min\left(\frac{\mu_B(x)}{\mu_A(x)}, 1\right) & \text{si } \mu_A(x) \neq 0 \\ \mu_B(x) & \text{sinon} \end{cases}$	Goguen
$I_l$	$\min(1 - \mu_A(x) + \mu_B(x), 1)$	Lukasiewicz

TAB III.1. Implications floues les plus utilisées

### III.5. Structure interne d'un système d'inférence floue (SIF)

Comme le montre dans la Figure (III.6) le traitement réalisé par un SIF est constitué de trois étapes : la Fuzzification , l'Inférence et la Défuzzification.

- La Fuzzification transforme une valeur de l'entrée numérique  $x$  en une partie floue.
- L'Inférence produit l'image de la partie floue issue de la Fuzzification par une relation floue  $R$  généralement construite à partir de règles.
- La Défuzzification transforme la partie floue issue de l'inférence en une valeur numérique  $y$  de sortie.

Cette structure est utilisée dans tous les SIF quelle que soit l'application considérée (modélisation, approximation,...etc). L'étape de Défuzzification constituant alors une prise de décision. La mise en œuvre de ces trois étapes de traitement dépend de la nature des sous-ensembles flous véhiculés à l'intérieur du système.

En d'autres termes, les sous-ensembles flous  $E$  et  $F$  de la Figure (III.6) peuvent être des sous-ensembles flous numériques ou des sous-ensembles flous symboliques. De même la relation floue  $R$  peut être une relation floue numérique (liant entre eux des nombres), une relation floue symbolique (liant entre eux des symboles), ou une relation mixte (liant entre eux des nombres et des symboles) comme illustrée dans la Figure (III.6) [13].

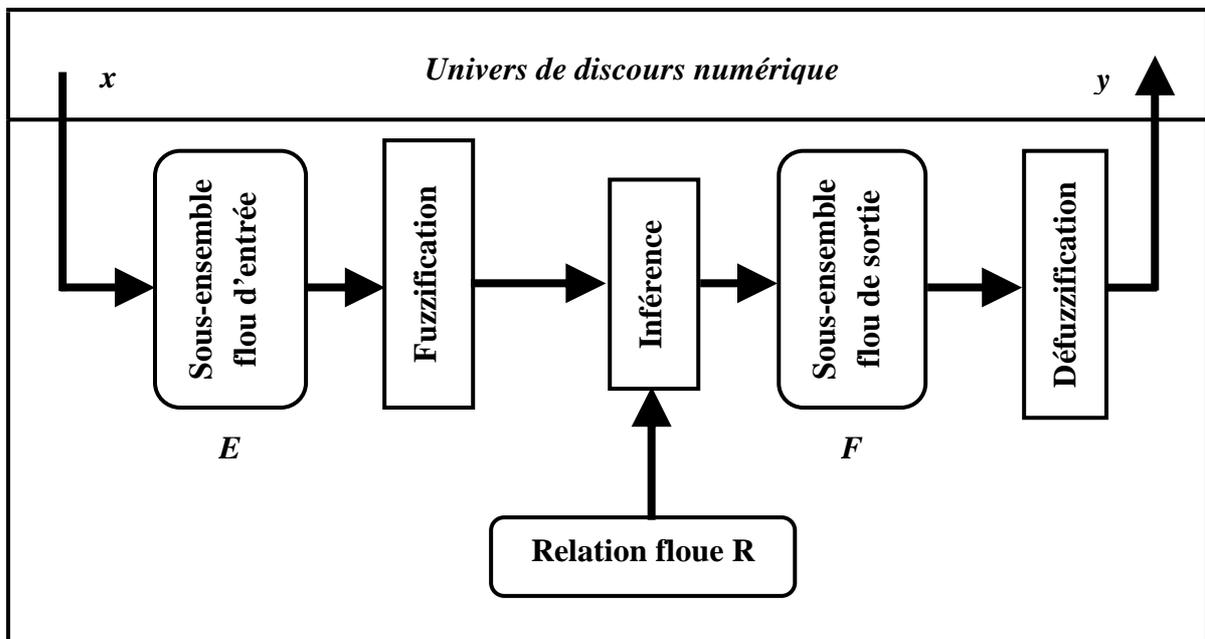


Figure III.6. Structure d'un SIF

### **III.5.1. Fuzzification**

La Fuzzification transforme une valeur numérique de l'entrée en une partie floue définie sur un espace de représentation lié à l'entrée. Du choix de cet espace de représentation (numérique ou linguistique) dépend de la nature de la partie floue  $E$  résultante de la Fuzzification. Cette dernière peut être un sous-ensemble flou numérique (élément de  $F(x)$ ) ou un sous-ensemble.

#### **III.5.1.1. Fuzzification numérique**

Une Fuzzification numérique transforme toute valeur numérique  $x$  de l'entrée en une partie floue numérique, c'est-à-dire un élément de  $F(x)$ . Cette partie floue caractérise l'imprécision qu'on peut avoir sur la mesure  $x$ . on distingue deux démarches possibles pour effectuer cette Fuzzification.

#### **III.5.1.2. Fuzzification singleton**

Cette démarche est utilisée lorsque la valeur fournie par le capteur est supposé précise. La Fuzzification singleton d'une valeur  $x = x_0$  est alors la partie floue numérique  $N(x_0)$  dont la fonction d'appartenance est définie par :

$$\mu_{N(x_0)}(x) = \begin{cases} 1 & \text{si } x = x_0 \\ 0 & \text{si } x \neq x_0 \end{cases} \quad (\text{III. 10})$$

En d'autres termes, l'entrée floue est un point singulier possédant une valeur d'appartenance unitaire [14]. Dans notre travail, seul ce type de Fuzzification a été utilisé.

#### **III.5.1.3. Fuzzification non-singleton**

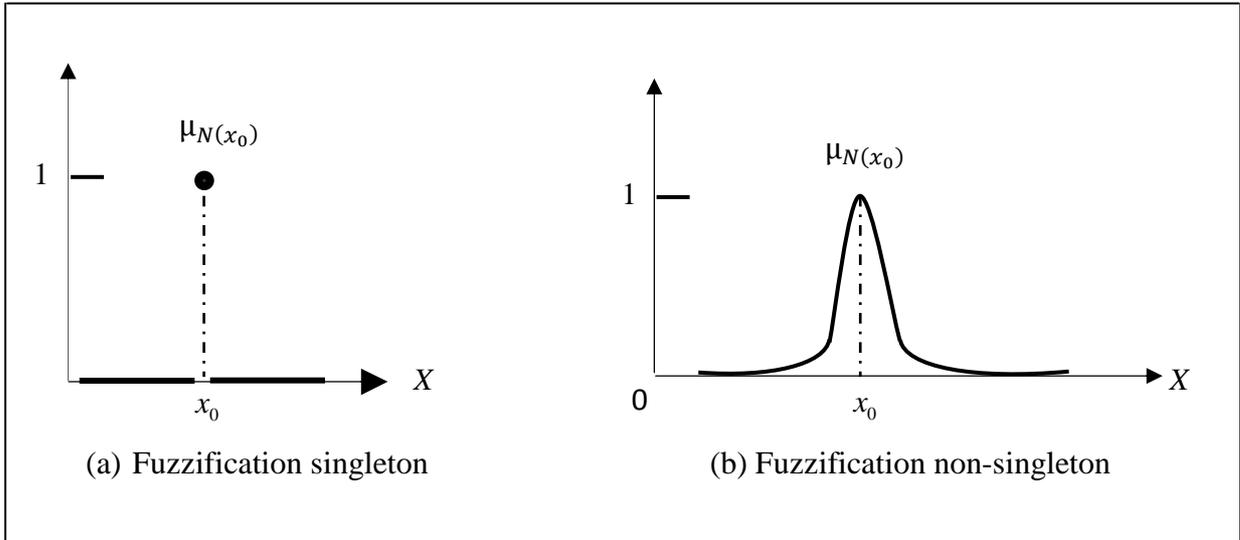
Dans cette démarche, on considère que le capteur peut effectuer une erreur de mesure ou être exposé à un bruit. La fonction d'appartenance de  $N(x_0)$  dépend dans ce cas de l'erreur ou du bruit, par exemple, elle peut être définie par une fonction gaussienne :

$$\mu_{N(x_0)}(x) = e^{-\frac{1}{2}\left(\frac{x-x_0}{B}\right)^2} \quad (\text{III. 11})$$

où

**B:** Un paramètre qui caractérise la largeur de la fonction d'appartenance.

Ces deux démarches sont illustrées dans la Figure (III.7) .Dans la littérature des SIF, la Fuzzification singleton est de loin la plus utilisée. Quelques rares cas illustrent cependant une Fuzzification non-singleton [15]-[16].



**Figure III.7.** La Fuzzification singleton et non-singleton.

#### III.5.1.4. Fuzzification symbolique

Elle transforme toute valeur numérique  $x$  en une partie floue linguistique, c'est-à-dire un élément de  $F(L(x))$ . Cette partie floue permet de caractériser à quel point la valeur numérique peut être décrite par les symboles de  $L(x)$ . Ainsi la Fuzzification symbolique de la valeur  $x = x_0$  est donnée par sa description floue  $D_{L(x)}(x_0)$  dont la fonction d'appartenance est directement déduite de la valeur d'erreur  $e = 0.3$  est donnée par le sous ensemble flou.

$$E = D_{L(x)}(0.3) = \frac{0}{N} + \frac{0.25}{Z} + \frac{0.75}{P} \tag{III. 12}$$

Dans le cas de données numériques floues, la Fuzzification symbolique peut être effectuée en utilisant la description supérieure ou inférieure de l'entrée floue [17]. Elle a été proposée par Willayes et Malvache [18] , puis utilisée par de nombreux auteurs (Wang et Langari [19], Xu et Lu [20]). La Figure (III.8) illustre et résume les deux choix possibles de Fuzzification . On peut noter que l'implantation d'une Fuzzification symbolique nécessite la connaissance de la signification des symboles permettant de décrire les nombres. Autrement dit, le partitionnement flou de l'univers de discours numérique  $X$  est un prérequis à la

Fuzzification symbolique des éléments de  $X$ . Par contre, une Fuzzification numérique peut être mise en œuvre sans aucune définition de symboles.

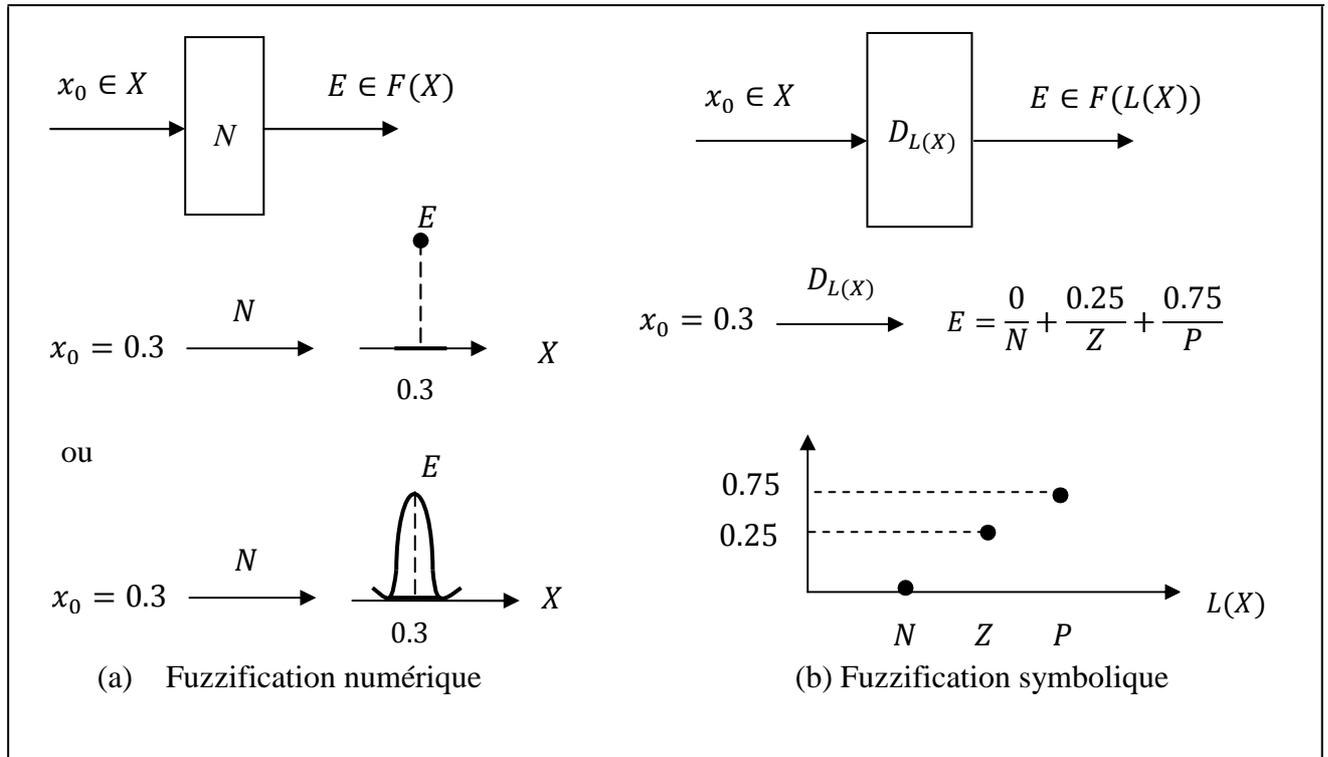


Figure III.8. La Fuzzification numérique et symbolique

### III.5.2. Différentes méthodes d'inférences floues

L'inférence floue est le processus d'élaboration des relations qui existent entre les variables d'entrées (exprimées comme variables linguistiques) et la variable de sortie (également exprimée comme variable linguistique). Ces relations fournissent ensuite *la base des règles* (BR) à partir de laquelle les décisions peuvent être prises. Le processus de l'inférence floue implique tous les éléments qui sont décrits dans les sections précédentes : les fonctions d'appartenance, les opérateurs à FS et les règles de type « Si...Alors ». Le module d'inférence est constitué de deux blocs, le moteur d'inférence et la *base des règles*.

La première étape consiste à créer des règles dont la syntaxe est très stricte bien que les termes utilisés paraissent naturels. La création de l'ensemble des règles de contrôle linguistique recourt le plus souvent aux connaissances d'experts ou d'opérateurs qualifiés travaillant sur le processus. Le réglage découle donc a priori des connaissances du fonctionnement du système. La représentation linguistique des règles est la suivante :

**Si** antécédent 1 **ET** antécédent 2 **ALORS** conséquence 1

où:

**Antécédent** : variable d'entrée

**Conséquence** : variable de sortie

ET : Opérateur de base (parfois pour certaines applications l'opérateur est OU)

**Exemple:**

**Si** température élevée **ET** sol sec **ALORS** durée d'arrosage longue **OU**

**Si** température normale **ET** sol humide **ALORS** durée d'arrosage courte

La quantité de règles dépend du nombre d'entrées et du nombre de zones de chacune d'elles. Si l'on considère  $n$  univers de discours  $U_i$  pour les entrées du système flou et que chaque univers  $U_i$  est partitionné en  $m_i$  fonctions d'appartenance floues, alors le nombre maximal de règles est donné par l'équation (III.13) [21]-[22].

$$r_{\max} = \prod_{i=1}^m w_i \tag{III. 13}$$

où:

$r_{\max}$ : Nombre maximal de règles

$w_i$ : Nombre de fonctions d'appartenance dans un univers du discours

À titre d'exemple, un système flou comportant 2 entrées segmentées chacune en 5 fonctions d'appartenance (ou ensembles flous) générera une base de 25 règles maximum. Du fait que plusieurs règles doivent être évaluées à chaque cycle de fonctionnement du système flou, le nombre d'entrées aura une incidence sur le nombre de calculs que devra effectuer le système à chaque cycle. De plus, l'élaboration des règles étant réalisée par des experts ou opérateurs qualifiés travaillant sur le processus et recourant le plus souvent à leurs connaissances, on comprendra que plus la dimension de la base de règles du système flou est grande, plus difficile sera l'élaboration des règles d'inférence et plus la cadence du fonctionnement du système flou diminuera [23]. Par conséquent, un système complexe qui aurait un nombre très élevé de règles entraînerait une limitation des performances du système flou. Lorsqu'on a établi la base de règles qui décrivent le fonctionnement, il faut choisir la méthode d'inférence floue, c'est-à-dire la méthode que le système doit employer pour calculer

la fonction de sortie à l'aide des relations qui existent entre les variables d'entrées et la variable de sortie utilisant la base des règles.

Dans la littérature, il existe plusieurs types de systèmes d'inférence floue qui peuvent être mis en œuvre dans les systèmes flous [24]. Par exemple, la méthode de *Mamdani* qui utilise les opérateurs *min* et *max* pour l'implication et l'agrégation, ou encore la méthode de Larsen qui utilise *un produit* et l'opérateur *max*, ou celle de *Sugeno* [25] qui utilise une fonction linéaire ou une constante pour les signaux de sortie [26]. Les deux méthodes qui sont les plus largement utilisées en pratique sont la *méthode de Mamdani* et la *méthode de Sugeno* [27]. Ces deux types de systèmes d'inférence varient quelque peu dans la façon dont les résultats sont déterminés.

### III.5.2.1. Inférence floue de type Mamdani

Une règle floue de type *Mamdani*, dont la conclusion est un ensemble flou s'écrit : *SI*  $x_1$  est  $A_1^i$  *ET* ... *ET*  $x_p$  est  $A_p^i$  *ALORS*  $y_1$  est  $C_1^i$  ... *ET*  $y_q$  est  $C_q^i$  où  $A_j^i$  et  $C_j^i$  sont des ensembles flous qui définissent le partitionnement des espaces d'entrée et de sortie, après l'inférence il faut passer par une étape de Défuzzification afin d'obtenir la valeur réelle de la commande à appliquer [28].

### III.5.2.2. Inférence floue de type Takagi-Sugeno-Kang (TSK)

Dans le modèle de Takagi-Sugeno la conclusion de la règle est nette [29]. Celle de la règle  $i$  pour la sortie  $j$  est calculée comme une fonction linéaire des entrées :

$$R_i: SI \ x_1 \text{ est } A_1^i \text{ ET } \dots \text{ ET } x_j \text{ est } A_j^i \text{ ALORS } y_j^i(k) = f_j^i(x(k)) \quad (\text{III. 14})$$

où  $i$ ,  $j$ , et  $k$  sont les indices de règles, les variables d'entrées, et le nombre d'échantillons par variable d'entrée, respectivement. Utilisant le modèle TSK, pour identifier les paramètres quasi-statiques des lignes de transmission étudiées dans notre travail qui sont calculés par:

$$y_j^i = f_j^i(x) = a_{j0}^i + a_{j1}^i x_1 + a_{j2}^i x_2 + \dots + a_{jn}^i x_n \quad (\text{III. 15})$$

Où  $n$  est l'ordre du système flou et  $a_{jp}^i$  sont les valeurs réelles des paramètres

La valeur numérique de la sortie de ce modèle est donnée par :

$$y = \frac{\sum_{l=1}^M \omega_l b_l}{\sum_{l=1}^M \omega_l} \quad (\text{III. 16})$$

où

$\omega_l$  : Le degré de vérité du Lème règle floue *SI – ALORS* qui peut être obtenu par :

$$w_i = \mu_{A_1^i}(x_1) \wedge \dots \wedge \mu_{A_p^i}(x_p) \quad (\text{III. 17})$$

$\mu_{A_j^i}(x_j)$  : Le degré d'appartenance de la valeur  $x_j$  à l'ensemble flou  $A_j^i$  [30].

**Remarque :** Pour une règle donnée  $i$ , son degré de vérité pour un exemple, également appelé poids, et noté  $w_i$ , résulte d'une opération de conjonction des éléments de la prémisse.

où:

$$\omega_l = \min\{\mu_{A_1}(x_1), \mu_{A_2}(x_2), \dots, \mu_{A_n}(x_n)\} \quad (\text{III. 18})$$

Pour un choix de fonction d'appartenance Gaussienne de la forme:

$$\mu_{A_i^l}(x_i) = \exp\left(-\left(\frac{(x_i - c_i^l)}{\sigma_i^l}\right)^2\right) \quad (\text{III. 19})$$

Et en utilisant l'équation (III.16), la sortie du système flou sera donnée par :

$$y = \hat{f}(\underline{x}) = \frac{\sum_{l=1}^M b_l \prod_{i=1}^n \exp\left(-\left(\frac{(x_i - c_i^l)}{\sigma_i^l}\right)^2\right)}{\sum_{l=1}^M \prod_{i=1}^n \exp\left(-\left(\frac{(x_i - c_i^l)}{\sigma_i^l}\right)^2\right)} \quad (\text{III. 20})$$

Pour toutes les étapes de simulation de ce travail le modèle flou de TSK d'ordre 0 ( $n = 0$ ) (modèle singleton) a été utilisé, dont la sortie est définie par l'équation (III.20) [31]. Pour l'identification des paramètres quasi-statiques des lignes de transmission MECPS, MCCPS, et MACPS.

### III.5.3. Défuzzification

Par cette étape se fait le retour aux grandeurs de sortie réelles. Il s'agit de calculer, à partir des degrés d'appartenance à tous les ensembles flous de la variable de sortie, l'abscisse qui correspond à la valeur de cette sortie [32].

### III.6. Construction des modèles TSK à partir des données

Dans le cadre de l'identification floue des paramètres quasi-statiques des lignes de transmission (MACPS), (MCCPS) et (MECPS), nous abordons une description d'une méthodologie générale pour la construction des modèles flous du type TSK, en mettant l'accent sur les besoins communs qui sont : la génération des fonctions d'appartenance et l'obtention des paramètres des conséquents [33].

Un système flou du type TSK à trois couches permet de calculer les paramètres des conséquents de trois lignes de transmission qui sont l'impédance caractéristique  $Z_0$  et la constante diélectrique effective  $\varepsilon_{eff}$  avec des résultats efficaces par l'algorithme de rétro propagation floue.

### III.7. Algorithme de rétro-propagation à l'identification floue

Soit un système de paire entrée-sortie, notre tâche est de déterminer un système flou  $f(\underline{x})$  de la forme de l'équation (III.20) et d'ajuster les paramètres de la fonction d'appartenance: le centre de partie prémisse ( $b^l$ ), le centre de partie conséquence ( $c_i^l$ ) et l'écart type ( $\sigma_i^l$ ), de telle sorte que le critère:

$$J = \frac{1}{2} \left( d - \hat{f}(\underline{x}) \right)^2 \quad (III.23)$$

Soit minimisé, afin de déterminer un système flou  $\hat{f}(x)$  sous la forme de l'équation (III.16) pour un couple d'entrée-sortie  $(x, d)$  donné [34].

Pour l'ajustement du paramètre  $b^l$  selon l'algorithme d'adaptation paramétrique:

$$b^l(k+1) = b^l(k) - \alpha \left. \frac{\partial J}{\partial b^l} \right|_k \quad (III.24)$$

où  $l = 1, 2, \dots, M$ ,  $k = 0, 1, 2, \dots$ , ( $\hat{f}(x)$  sera noté par  $\hat{f}$ ).

D'après la Figure (III.9) on déduit que  $\hat{f}$  (et par conséquent  $J$ ) dépend seulement de  $b^l$  à travers  $A$ , où :

$$\hat{f} = A/B, A = \sum_{l=1}^M b^l \omega_l, B = \sum_{l=1}^M \omega_l, \text{ tel que } \omega_l \text{ est donné par l'équation (III.17)}$$

alors, en dérivant  $J$  par rapport à  $b^l$  on aura :

$$\frac{\partial J}{\partial b^l} = -(d - \hat{f}) \frac{\partial \hat{f}}{\partial A} \frac{\partial A}{\partial b^l} = -(d - \hat{f}) \frac{1}{B} \omega_l \quad (\text{III. 25})$$

où :

$$\frac{\partial J}{\partial b^l} = - \frac{e}{B} \omega_l \quad (\text{III. 26})$$

Substituant (III.25) dans (III.24), on obtient l'algorithme d'ajustement du  $b^l$  comme :

$$b^l(k+1) = b^l(k) + \alpha \frac{e}{B} \omega_l \quad (\text{III. 27})$$

où  $l = 1, 2, \dots, M$ ,  $k = 0, 1, 2, \dots$

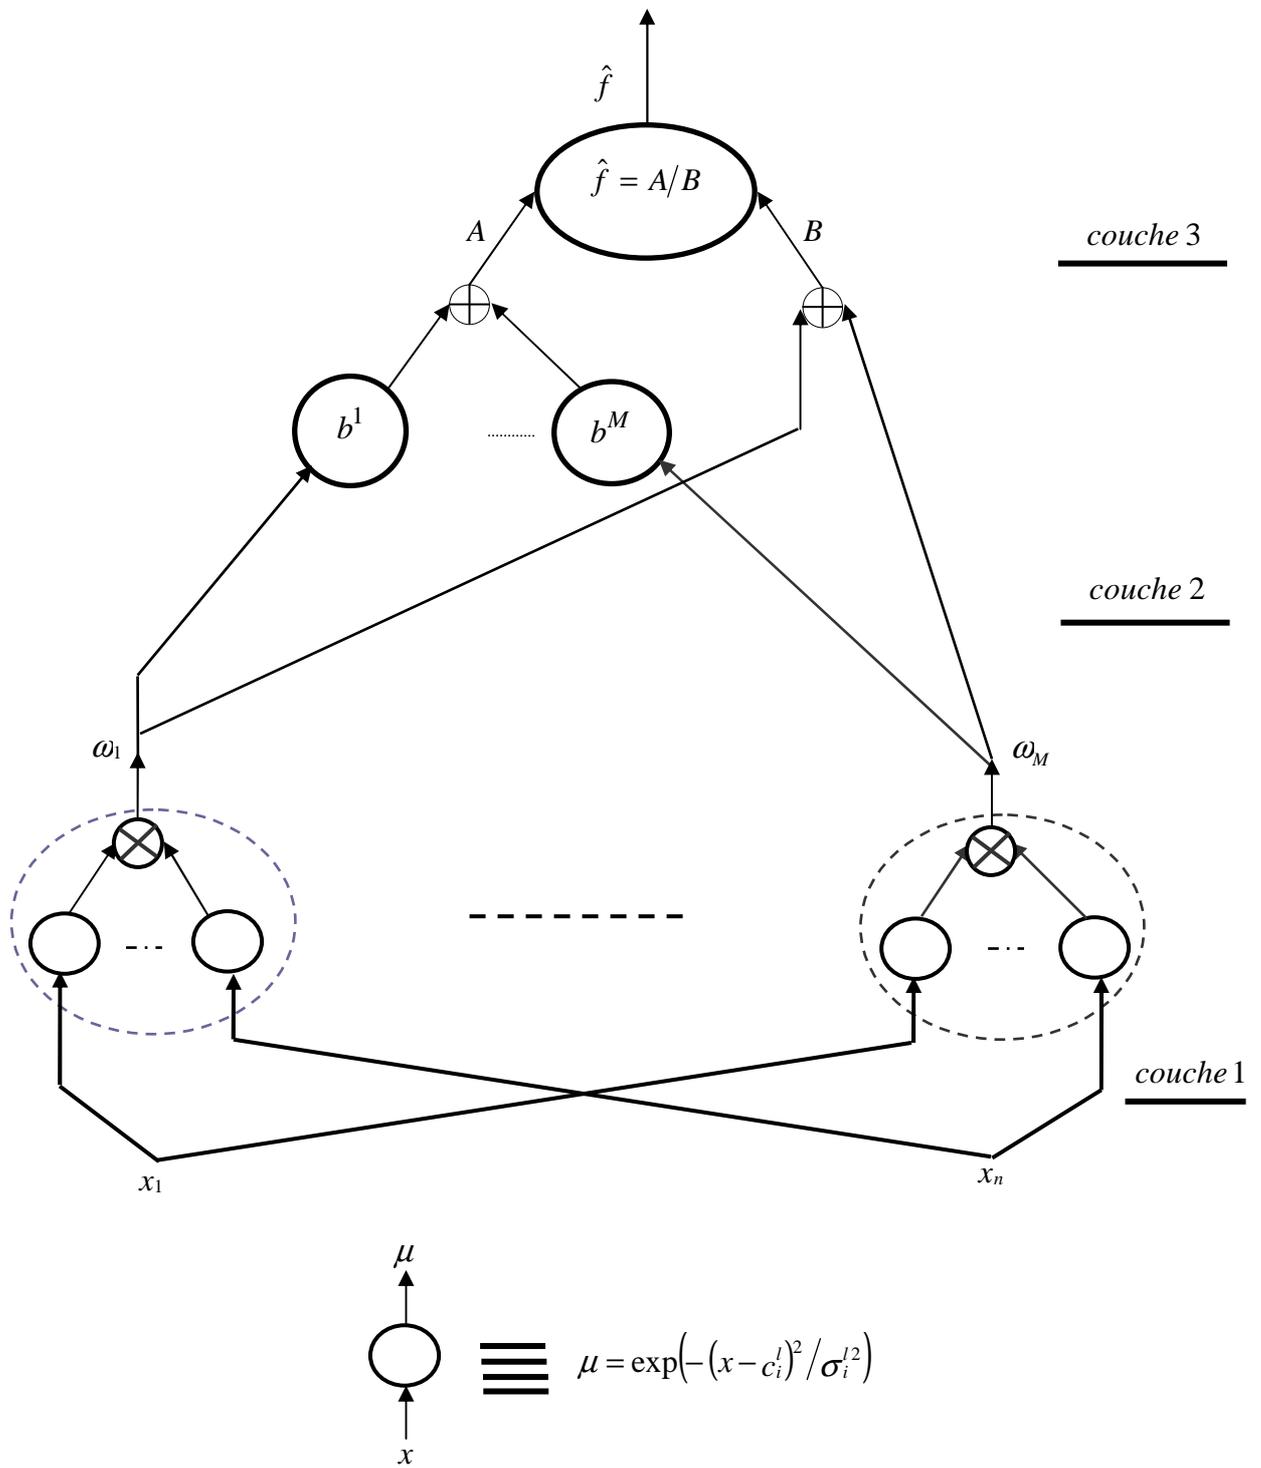


Figure III.9. Représentation en couches d'un système flou

Pour l'ajustement du paramètre  $c_i^l$  on a :

$$c_i^l(k+1) = c_i^l(k) - \alpha \left. \frac{\partial J}{\partial c_i^l} \right|_k \quad (\text{III. 28})$$

où  $l = 1, 2, \dots, M$ ,  $k = 0, 1, 2, \dots$ ,  $i = 1, 2, \dots, n$

D'après la Figure (III.9) on remarque que  $\hat{f}$  dépend seulement de  $c_i^l$  à travers  $\omega_l$ , donc:

$$\frac{\partial J}{\partial c_i^l} = -(d - \hat{f}) \frac{\partial \hat{f}}{\partial \omega_l} \frac{\partial \omega_l}{\partial c_i^l} \quad (\text{III. 29})$$

Nous avons:

$$\frac{\partial \hat{f}}{\partial \omega_l} = \frac{B(\partial A / \partial \omega_l) - A(\partial B / \partial \omega_l)}{B^2} = \frac{(\partial A / \partial \omega_l) - (A/B)(\partial B / \partial \omega_l)}{B}$$

$$\frac{\partial \hat{f}}{\partial \omega_l} = \frac{b^l - \hat{f}}{B} \quad (\text{III. 30})$$

Et nous avons encore :

$$\frac{\partial \omega_l}{\partial c_i^l} = \frac{2(x_i - c_i^l)}{\sigma_i^{l2}} \omega_l \quad (\text{III. 31})$$

Par substitution de (III.30) et (III.31) dans (III.29) on aura :

$$\frac{\partial J}{\partial c_i^l} = \frac{-(d - \hat{f})}{B} (b^l - \hat{f}) \frac{2(x_i - c_i^l)}{\sigma_i^{l2}} \omega_l \quad (\text{III. 32})$$

On obtient alors l'algorithme d'ajustement du paramètre  $c_i^l$  :

$$c_i^l(k+1) = c_i^l(k) + \alpha \frac{(d - \hat{f})}{B} (b^l - \hat{f}) \frac{2(x_i - c_i^l)}{\sigma_i^{l2}} \omega_l \quad (\text{III. 33})$$

En utilisant la même méthode pour l'écart type  $\sigma_i^l$  du gaussienne (largeur), on obtient l'algorithme d'ajustement suivant:

$$\sigma_i^l(k+1) = \sigma_i^l(k) + \alpha \frac{e}{B} (b^l - \hat{f}) \frac{2 (x_i - c_i^l)^2}{\sigma_i^{l3}} \omega_i \quad (\text{III. 34})$$

L'algorithme d'apprentissage (III.27), (III.33) et (III.34) exécute une procédure de rétro-propagation d'erreur [34].

Pour l'ajustement du paramètre  $b^l$ , l'erreur normalisée  $\frac{e}{B}$  est rétro propagée vers la couche  $b^l$  ensuite ce dernier est mis à jours en utilisant (III.27) où  $\omega_i$  est l'entrée de  $b^l$  (comme c'est montré dans la Figure (III. 13)).

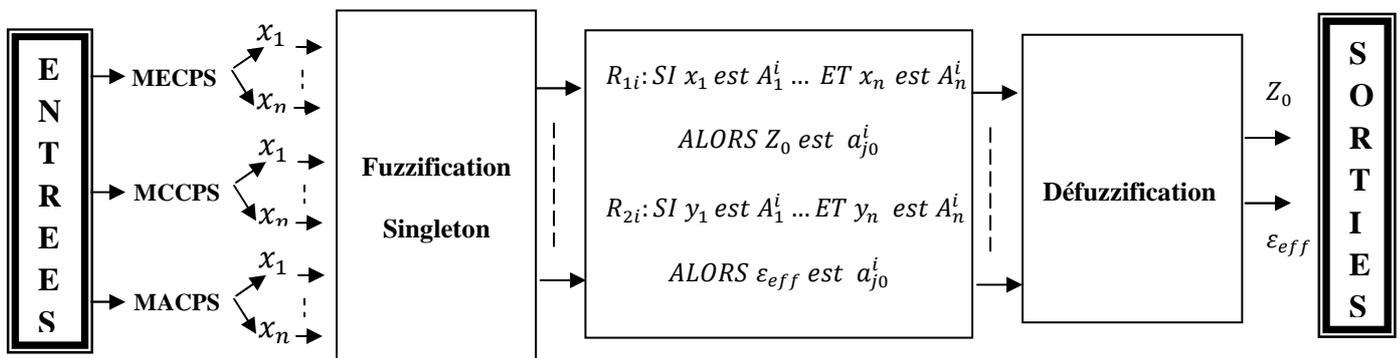
Pour l'ajustement des paramètres  $c_i^l$  et  $\sigma_i^l$ , l'erreur normalisée  $\frac{e}{B}$  ajuste  $b^l - \hat{f}$  ensuite  $\omega_i$  est rétro propagé vers l'unité de traitement de la couche  $l$  dont la sortie est  $\omega_i$  ; puis  $c_i^l$  et  $\sigma_i^l$  seront mis à jours par (III.33) et (III.34).

Pour l'identification de  $Z_0$  et  $\varepsilon_{eff}$  de MECPS, MCCPS et MACPS nous avons utilisé dans notre travail, le modèle flou décrit par (III.20) avec:

- ✓ La Fuzzification singleton.
- ✓ Nombre des règles floues sont 10 parfois 20, et pour chaque entrée on ajuste deux paramètres de fonctions d'appartenance d'entrée correspondante et de sortie (gaussienne, singleton respectivement) qui sont le centre de la partie prémisse et le centre de la partie conséquence.

**III.8. Structure de système d'inférence floue pour calculer les paramètres quasi-statiques des lignes de transmission coplanaires (MACPS), (MCCPS) et (MECPS)**

La structure du système utilisée pour obtenir les paramètres quasi-statiques des lignes de transmission est illustrée dans la Figure (III.10). Les règles, dans la première couche d'entrée de chaque réseau se déclarent à la base de données de l'entrées de chaque ligne de transmission et le nombre des fonctions d'appartenance de deuxième couche dépendent de données de l'entrées, qui utilisent la fonction Gaussienne, par contre la troisième couche de la sortie se base sur la fonction de transfert linéaire singleton.



**Figure III.10.** Schéma de principe de système d'inférence floue pour calculer les paramètres quasi-statiques des lignes de transmission

L'identification de l'impédance caractéristique et la permittivité effective de MECPS, MCCPS et MACPS par la méthode de TSK passe par les étapes suivantes:

- Création d'une base d'apprentissage obtenue par la technique CMT contient les entrées et les sorties souhaitées.
- Déclaration aléatoire de nombre des règles floues en générale ne dépassent pas 20.
- L'initialisation aléatoire des paramètres d'apprentissage  $b^l$ ,  $c_i^l$ , et  $\sigma_i^l$ .
- L'ajustement de  $b^l$ ,  $c_i^l$ , et  $\sigma_i^l$  par l'apprentissage pour diminuer l'erreur entre la sortie désirée et la sortie réelle.
- La normalisation appropriée, qui tienne compte de l'amplitude des valeurs acceptées par le modèle flou.
- Le test de la validation par d'autres valeurs, qui ne sont pas utilisées dans la base de l'apprentissage, pour assurer la performance de notre modèle flou.

III.9. Organigramme d'apprentissage de FS pour calculer les paramètres quasi-statistiques des lignes MECPS, MCCPS, et MACPS

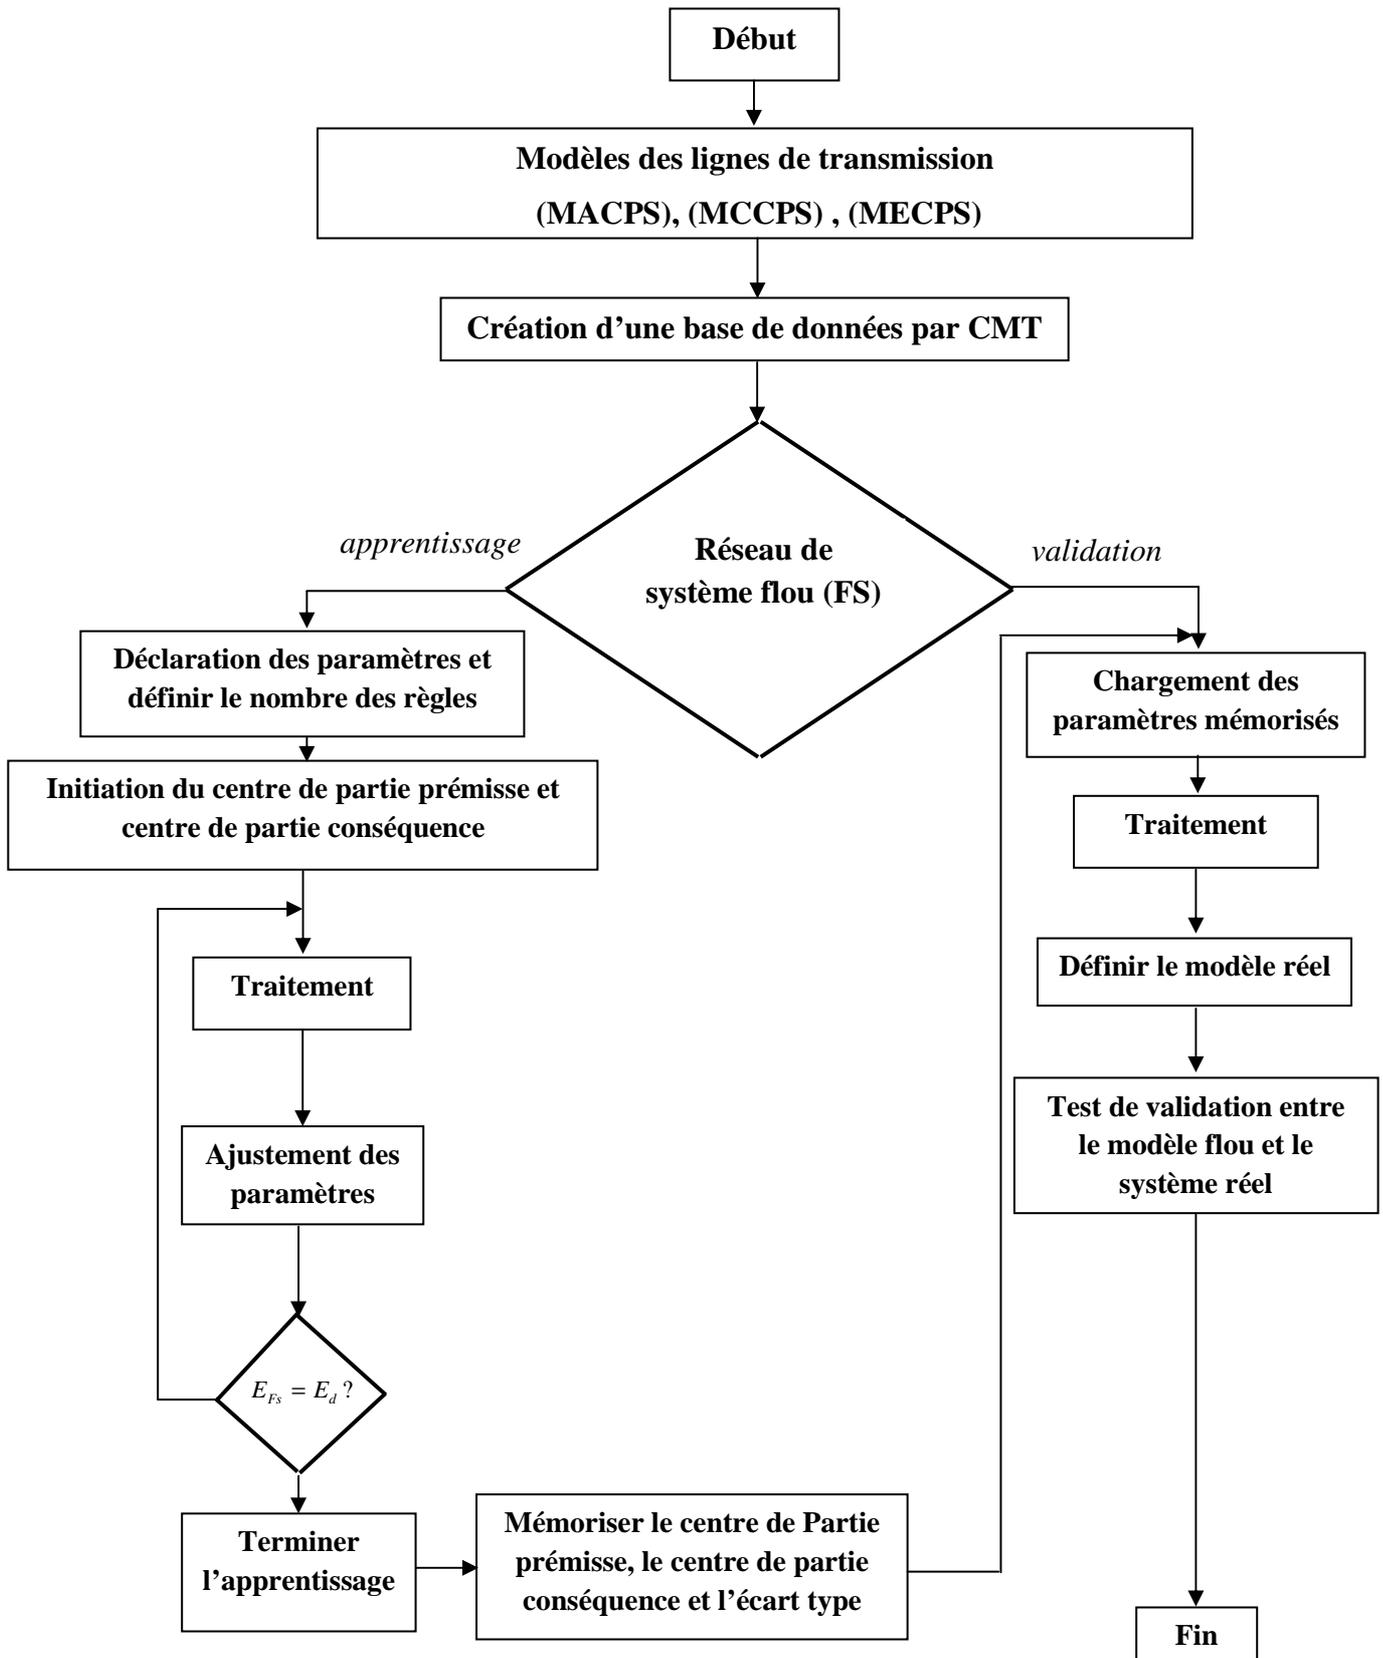


Figure III.11. Organigramme du système flou pour calculer les paramètres quasi-statistiques des lignes de transmissions

### **III.10. Conclusion**

Dans ce chapitre nous avons illustré des éléments de base de la théorie des systèmes flous FSs ainsi que la stratégie d'identification des données en se basant sur les modèles flous de TSK, moyennant un ensemble de règles *SI-ALORS*. Cette approche est destinée à modéliser les systèmes multi-variables et laisse ainsi prétendre une large application aux systèmes réels sans aucune hypothèse restrictive sur l'interaction entre les différentes boucles. Nous avons détaillé aussi l'algorithme de retro propagation flou par lequel nous avons réalisé ce travail. Cette méthode a été testée et simulée sur des lignes de transmission coplanaires multicouches asymétriques elliptiques, cylindriques comme nous allons voir dans le prochain chapitre. La logique floue a prouvé une grande efficacité de point de vue analyse et interprétation sans avoir recours au jugement d'un expert humain.

## Références bibliographiques

- [1] L.A. Zadeh., “*Information And Control*”, Fuzzy Sets vol.8, pp.338-353, 1965.
- [2] L.A. Zadeh, “Outline of a new approach to the analysis of complex systems and decision processes.” *IEEE Transactions on systems , man and cybernetics*, MC3, pp.24-44.
- [3] N. Talbi and K. Belarbi, “Fuzzy Takagi Sugeno System Optimization using Hybrid Particle Swarm Optimization and Tabu Search Learning Algorithm”, *International Journal of Tomography and Simulation, Ceser Publications*, vol.22, n°1, 2013, pp. 4-16.
- [4] B. Kosko. “Fuzzy systems as universal approximators. *IEEE transactions on computers*, pages 1329–1333, 1994.
- [5] L.X. Wang, “Adaptive fuzzy systems and control. In Analysis”. *Prentice Hall, New Jersey*, 1994. 108 .
- [6] X. Zeng and M. Singh, “Approximation theory of fuzzy systems – MIMO case”, *IEEE Trans. on Fuzzy Systems*, vol.3, n2, pp.219-235, 1995.
- [7] C. Lin, “Neural Fuzzy Control Systems with Structure and Parameter Learning”. *World Scientific*, Singapore, 1994.
- [8] R. Babuška ,“Fuzzy Modeling for Control”. *Kluwer Academic Publishers*, Mass., USA, 1998.
- [9] N. Talbi, «Conception des Systèmes d’Inférence Floue par des Approches Hybrides : Application pour la Commande et la Modélisation des Systèmes Non-linéaires », *Thèse de Doctorat*, Université de Constantine 1, 25 Février 2014.
- [10] J. Jlassi, «Amélioration de la performance par la Modélisation des flux logistiques des Patients dans un service d’urgence Hospitalier », *Thèse de Doctorat* , école doctorale cognition, langage, interaction Université de Paris 8,Vincennes-Saint-Denis.
- [11] C.C. Lee, “Fuzzy logic in control systems: fuzzy logic controller. Part1”, *IEEE Transactions on systems Man and Cybernetics*, Vol. 20, 1990, pp. 404-418.
- [12] W. Wei, «Synthèse d'un contrôleur flou par Algorithme Génétique Application au réglage dynamique des paramètres d'un système », *Thèse de Doctorat*, 'Université de lille 1 U.F.R , 18 Décembre 1998.

- [13] Y. Nakoula, «Apprentissage des modèles linguistiques flous par jeu de règles pondérées », *Thèse de Doctorat*, Université de Savoie, 30 mars 1992.
- [14] J.M. Mendel. “Fuzzy logic systems for engineering a tutorial”. *Proceedings of the IEEE*, 83(3) :345–377, 1995.
- [15] R. Palm, “Processing of signal distributions in control loops”, *Proc ,EUFIT’ 95*, sep 1994, Aachen, Germany , pp .310.-321.
- [16] S. Galichet , L. Foulloy , “State feedback fuzzy controllers“, Proc of the 5th Int. Conf. On information peocessing and Management and Uncertainty in knowledge Based Systems (IPMU’94), Paris France , July 94, pp.84-89.
- [17] L. Foulloy. S. Galichet , “Typology of fuzzy controllers“, *In Theoretical Aspects of fuzzy control* , pp.65-90, Publishers ,1995
- [18] D. Willaeyns and N. Malvache, “The use of fuzzy sets for the treatment of fuzzy information bu computer “, *Fuzzy Sets and Systems* , vol 5,pp.323-327,1981
- [19] L. Wang and R.Langari, “Building Sugeno –Type Models Using Fuzzy Discretization and Orthogonal Parameter Estimation Techniques”, *IEEE Trans. On Fuzzy systems* , vol 3, No. 4, November 1995, pp. 454-458
- [20] C.W. Xu , Y.Z. Lu, “Fuzzy Model Identification and Self-Learning for Dynamic Systems “, *IEEE Trans .on Systems, Man and cybernetics*, vol SMC 17, No 4, jully 87 . pp 683-689.
- [21] E. Elqaq and R. Priemer, “Fuzzy observer design using linear matrix inequalities for fuzzy closed-loop control systems”, *International Journal of General Systems*, vol.34, pp.507-522, 2005.
- [22] T. Tong et J. Raphaël.. “*La logique floue*” *Livre* , Editions ,Hermes, 160 p,1995.
- [23] K.M. Eksioglu, «Modélisation de la dépendance contextuelle des concepts flous :La structure SFC ». *Ph.D.*, Canada, Université de Sherbrooke (Canada), 99 p. 2000
- [24] J. Yen, R. Langari, L.A. Zadeh et IEEE Neural Networks Council. “*Industrial applications of fuzzy logic and intelligent Systems*”. New York , 1995
- [25] T. Takagi, T. Yamaguchi and M. Sugeno. «Conceptual fuzzy sets». In *Fuzzy Engineering Toward Human Friendly Systems, 13-15 Nov. 1991* (Yokohama, Japan). p. 261-72. IOS Press ,1992

- [26] P. Dadone, «Design optimization of fuzzy logic Systems ». *Ph.D.*, United States - Virginia, Virginia Polytechnic Institute and State University, 2001.
- [27] J. Lee, “On methods for improving performance of PI-type fuzzy logic controllers”, *Fuzzy Systems, IEEE Transactions on*, vol. 1, n° 4, p. 298-301, 1993
- [28] E.H. Mamdani and S. Assilian, “An experiment in linguistic synthesis with a fuzzy logic controller”, *International journal of Man-Machine Studies*, 7:1–13, 1975
- [29] I. Lagrat, H. Ouakka, and I. Boumhidi, “Fuzzy Clustering For Identification of Takagi-Sugeno Fuzzy Models of a Class of Nonlinear Multivariable Systems”, *Systems Electronique- Informatique & Traitement de l'Information Mohammédia*, pp: 210-215, 25 and 26 January 2007
- [30] T. Takagi and M. Sugeno, “Fuzzy identification of systems and its applications to modeling and control”. *IEEE Transactions on System Man and Cybernetics*, 15(1):116–132, 1985.
- [31] H.O. Wang, K. Tnaka, and M.F. Griffin, “An approach to fuzzy control of nonlinear systems”, *Stability and design issues, IEEE. Trans. Fuzzy Syst* ,. vol.4, 1996, pp.14-23.
- [32] L. Baghli, «Contribution à la commande de la machine asynchrone, utilisation de la logique floue, des réseaux de neurones et des algorithmes génétiques », *Thèse de Doctorat*, Université Henri Poincaré, Nancy-I, 14 janvier 1999.
- [33] V. Hugo, «Modélisation et commande floues de type Takagi-Sugeno appliquées a un bioprocédé de traitement des eaux usées» ,*Thèse de Doctorat*, Université de los Andes, Colombie, 22 février 2007
- [34] Li-Xin Wang and Jerry M. Mendel , “Back-propagation fuzzy system as nonlinear dynamic system identifiers ” *Signal and Image Processing Institute Department of Electrical Engineering-Systems University of Southern California Los Angeles, CA 90089-2564* ,(1992).



## **CHAPITRE IV**

### ***RÉSULTATS DE SIMULATION ET DISCUSSION***

## **IV.I. Introduction**

Après avoir présenter dans les chapitres précédents la théorie des lignes de transmission planaires, cylindriques et elliptiques ainsi que l'identification par les réseaux de neurones artificiels et la logique floue nous allons appliquer cette théorie sur cinq cas de structures de lignes de transmission. Pour fin de validation des modèles développés, nous commençons en premier lieu par la comparaison de nos résultats obtenus concernant les paramètres quasi statiques des trois types de lignes mentionnées avec ceux disponibles dans la littérature. Rappelons que le modèle utilisé pour ces paramètres est celui de la transformée conforme. En deuxième lieu, des résultats de la permittivité effective et de l'impédance caractéristique des lignes de transmission ont été générés et entraînés par les réseaux de neurones artificiels et la logique floue. Pour les réseaux de neurones, le MLP à trois couches dont une couche à l'entrée, une couche cachée et une couche à la sortie avec l'algorithme d'apprentissage de Levenberg-Marquardt est utilisé. Pour le système flou, il consiste également en trois couches ; la couche de Fuzzification, la couche des règles d'inférence et la couche de Défuzzification avec l'algorithme d'apprentissage de Takagi-Sugeno-Kang. Le modèle de référence utilisé pour les réseaux de neurones et la logique floue étant la transformée conforme dont le nombre de variables peut atteindre 14 échantillonnées à 10000 points. Les résultats obtenus sont commentés et discutés.

## **IV. 2. Résultats Numériques**

### **IV.2. 1. Comparaison des paramètres quasi-statiques des MECPS, MCCPS et MACPS avec la littérature**

Pour montrer que la méthode proposée est raisonnable, nous faisons une comparaison entre nos résultats utilisant la CMT et ceux de Akan [1]. Les dimensions diélectriques d'une ligne coplanaire monocouche ayant  $(\epsilon_{r1}, \epsilon_{r2}, \epsilon_{r3}) = (12.9, 1, 1)$  ont été augmentés. Les Figures [IV.1(a), IV.2(a)] représentent la constante diélectrique effective  $\epsilon_{eff}$  et l'impédance caractéristique  $Z_0$  de la ligne coplanaire monocouche avec  $w_1 = w_2$ ,  $s/(s + w_1) = 0.4$  et  $w/(s + w_1) = (3, 12)$ . La valeur absolue maximale du pourcentage d'erreur dans  $\epsilon_{eff}$  entre nos résultats et ceux de Akan est de 4%, comme illustrée dans la Figure (IV.1(b)), tandis que l'erreur dans  $Z_0$  est inférieure à 5%, comme montrée dans la Figure (IV.2(b)). Par conséquent, nous voyons très bon accord entre nos résultats calculés et ceux de Akan.

Pour la ligne planaire coplanaire monocouche/multicouche, l'augmentation de  $h_1/(s + w_1)$  résulte en une augmentation de la constante diélectrique effective jusqu'à  $(\epsilon_{r1} + 1)/2$  et une diminution de l'impédance caractéristique. Nous considérons également le cas d'une ligne planaire multicouche coplanaire avec  $(\epsilon_{r1}, \epsilon_{r2}, \epsilon_{r3}) = (12.9, 10, 10)$ ,  $h_1/(s + w_1) = 4$ ,  $h_3/(s + w_1) = 6.5$  et  $(h_2 - h_1)/(s + w_1)$  varie de 1 à 10. Les résultats simulés des paramètres quasi-statiques  $\epsilon_{eff}$  et  $Z_0$  en fonction de  $(h_2 - h_1)/(s + w_1)$  sont présentés dans les Figures [IV.3(a), IV.4(a)], respectivement.

Nous notons également que nos résultats sont en très bon accord avec ceux de Akan comme indiqué par les valeurs du pourcentage d'erreur données dans les Figures [IV.3(b), IV.4(b)], respectivement. A partir des Figures [IV.3(a), IV.4(a)], nous voyons que  $\epsilon_{eff}$  et  $Z_0$  sont presque constantes avec l'augmentation de  $h_2$ . Ceci peut s'expliquer par :

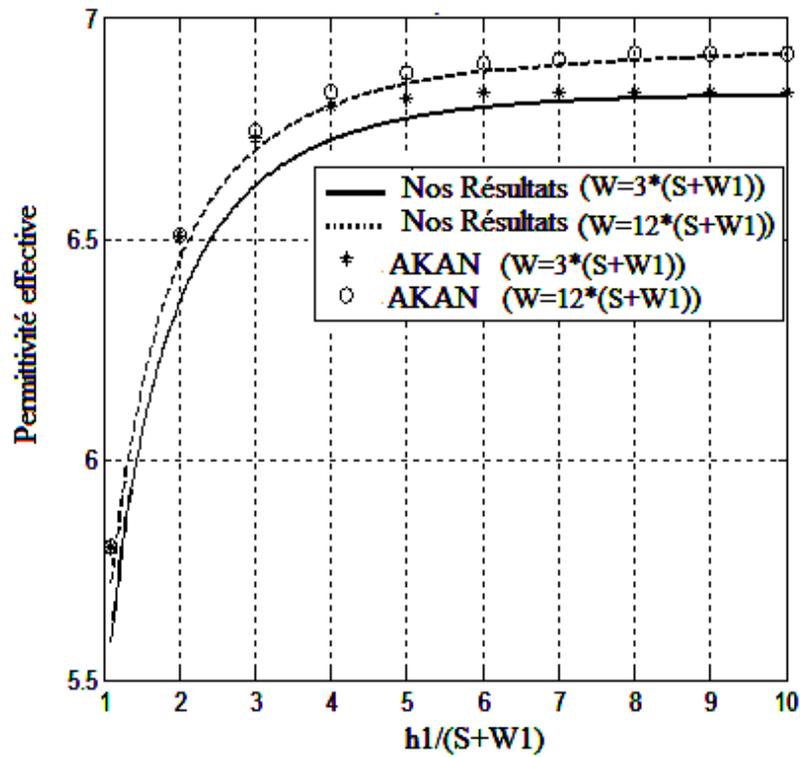
- ✓ Les épaisseurs  $h_1$  du substrat et  $h_3$  du superstrat sont pris très grands de telle sorte que ces deux couches sont considérées s'étendant à l'infini.
- ✓ L'espace est divisé en deux demi-espaces, la partie supérieure avec une permittivité  $\epsilon_{r3}$  et la partie inférieure avec une permittivité  $\epsilon_{r1}$ , donc la permittivité effective globale prend la valeur moyenne 11.45.

Maintenant, nous présentons les résultats de la structure cylindrique. Les Figures [IV.5(a), IV.6(a)] présentent  $\epsilon_{eff}$  et  $Z_0$  d'une MCCPS avec  $(\epsilon_{r1}, \epsilon_{r2}, \epsilon_{r3}) = (12.9, 1, 3.78)$ ,  $G = 2\phi + \theta_1 + \theta_2 = 40^\circ$  en fonction de  $2\phi/(2\phi + \theta_1 + \theta_2)$  qui varie de 0.1 à 0.9 pour différentes valeurs du rapport axial ( $AR = 0.1, 0.25, 0.5, 1$ ). Le maximum du pourcentage d'erreur dans  $\epsilon_{eff}$  entre nos résultats et ceux de Akan est de 2%, comme indiqué dans la Figure (IV.5(b)), tandis que l'erreur dans  $Z_0$  est inférieure à 11% comme représentée dans la Figure (IV.6(b)).

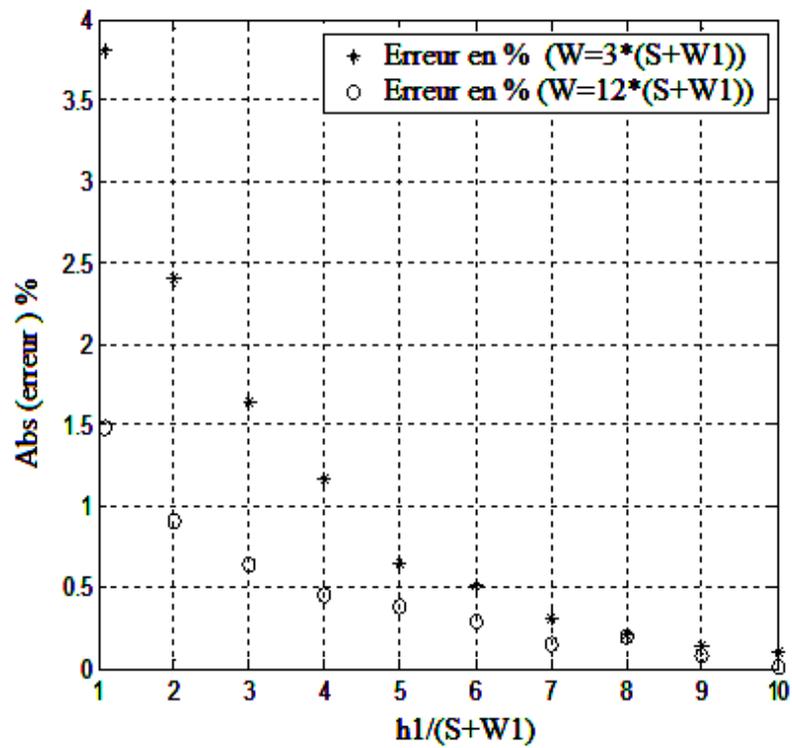
Les mêmes conclusions tiennent pour le cas de la structure elliptique représentée dans les Figures [IV.7(a), IV.8(a)]. Les paramètres de la MECPS sont:  $a_2 = 0.65$  mm,  $H_1 = 0.7a_2$ ,  $H_3 = 0.55a_2$ ,  $(\epsilon_{r1}, \epsilon_{r2}, \epsilon_{r3}) = (12.9, 1, 3.78)$ . Dans ce cas, le pourcentage maximal d'erreur dans  $\epsilon_{eff}$  et  $Z_0$  sont 1.8% et 8%, comme on le montre les Figures [IV.7(b), IV.8(b)], respectivement. Par conséquent, un bon accord entre nos résultats et ceux de Akan est obtenu.

Les conclusions suivantes sont applicables pour les deux structures elliptiques et cylindriques:

- Une diminution pour atteindre une valeur minimale de la constante diélectrique effective et une augmentation de l'impédance caractéristique avec l'augmentation de  $2\phi/(2\phi + \theta_1 + \theta_2)$ .
- La constante diélectrique effective et l'impédance caractéristique décroissent avec l'augmentation du rapport axial.

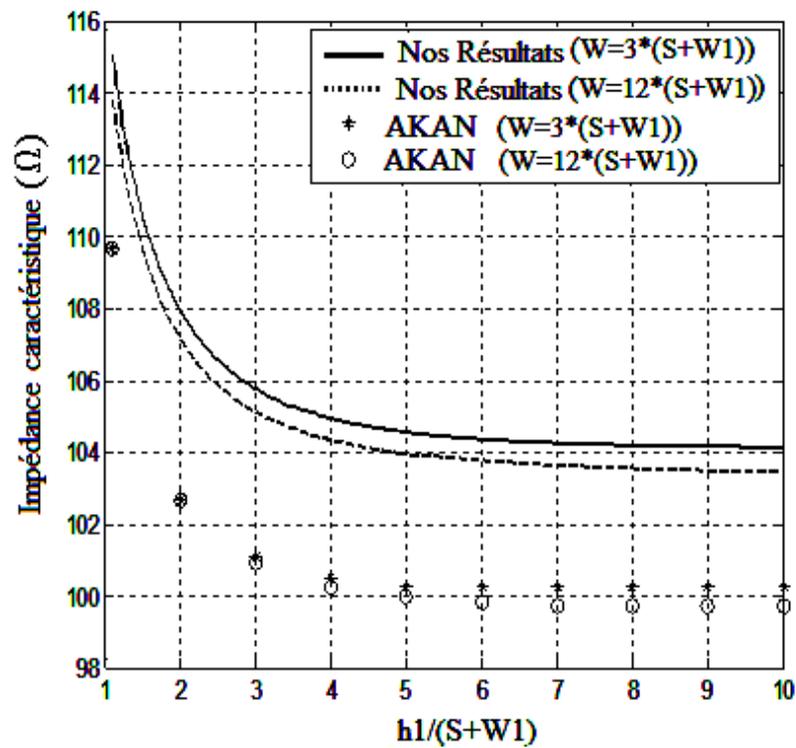


(a)

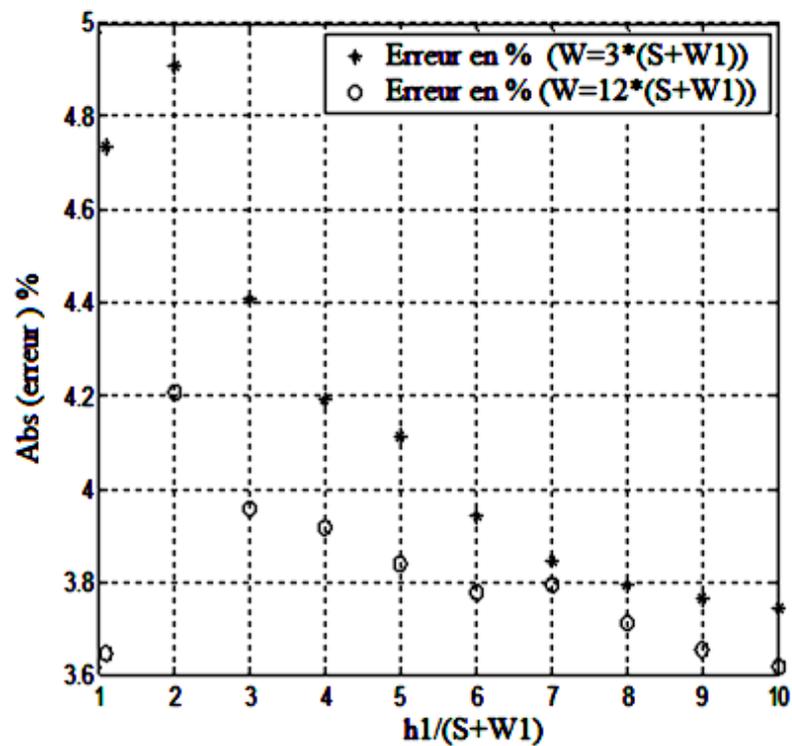


(b)

Figure IV.1. (a) Permittivité effective de la ligne coplanaire symétrique en terme de  $h_1/(s + w_1)$ , (b) Pourcentage d'erreur dans  $\epsilon_{eff}$

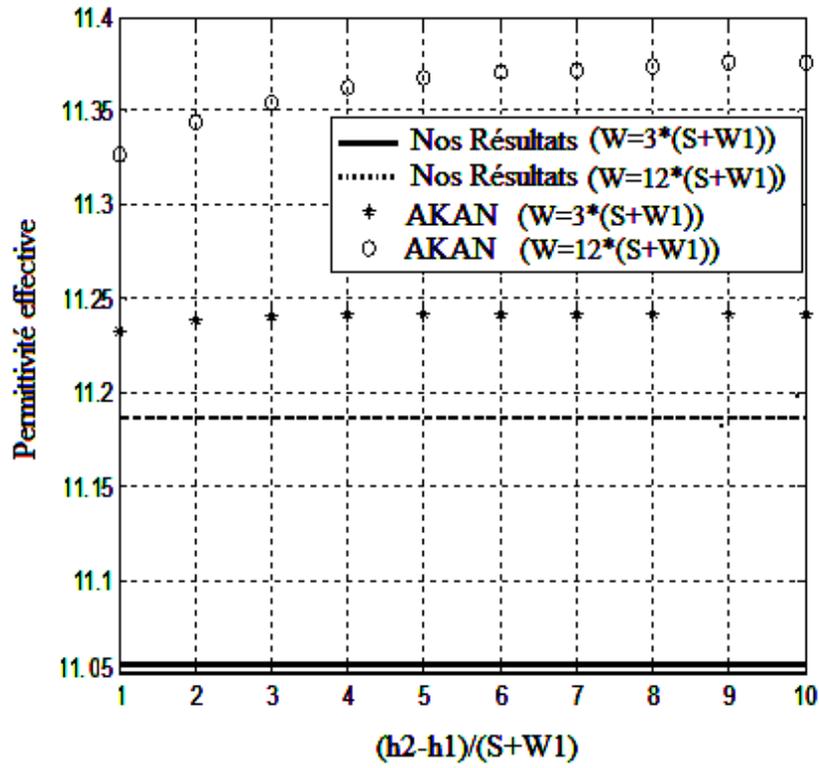


(a)

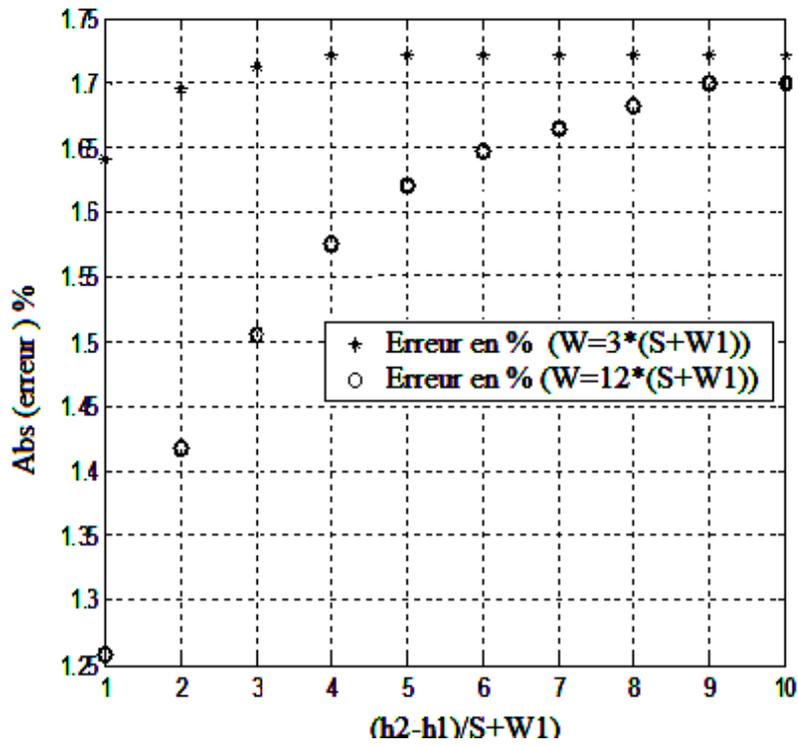


(b)

**Figure IV.2.** (a) Impédance caractéristique de la ligne coplanaire symétrique en terme de  $h_1/(s + w_1)$ , (b) Pourcentage d'erreur dans  $Z_0$

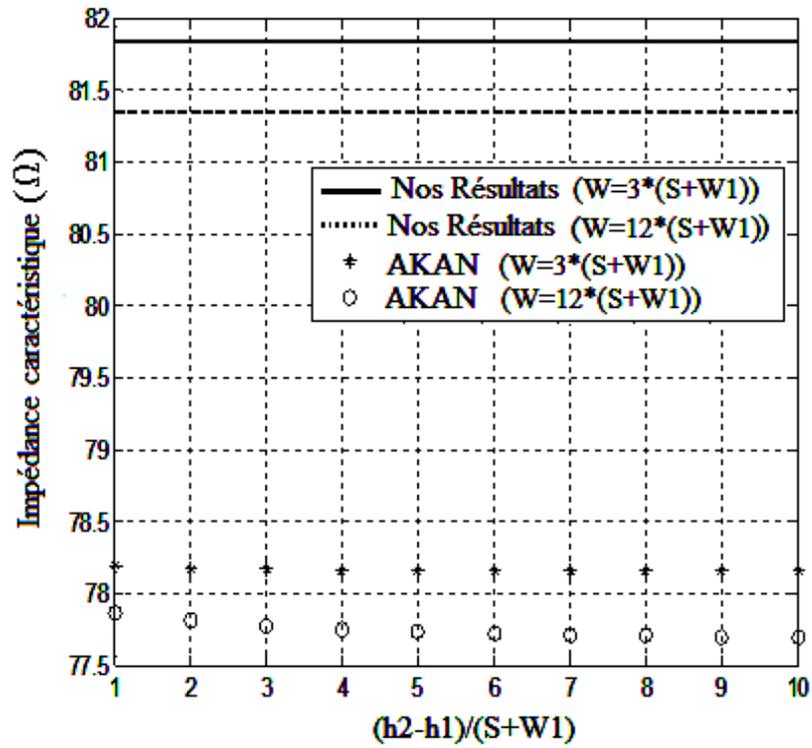


(a)

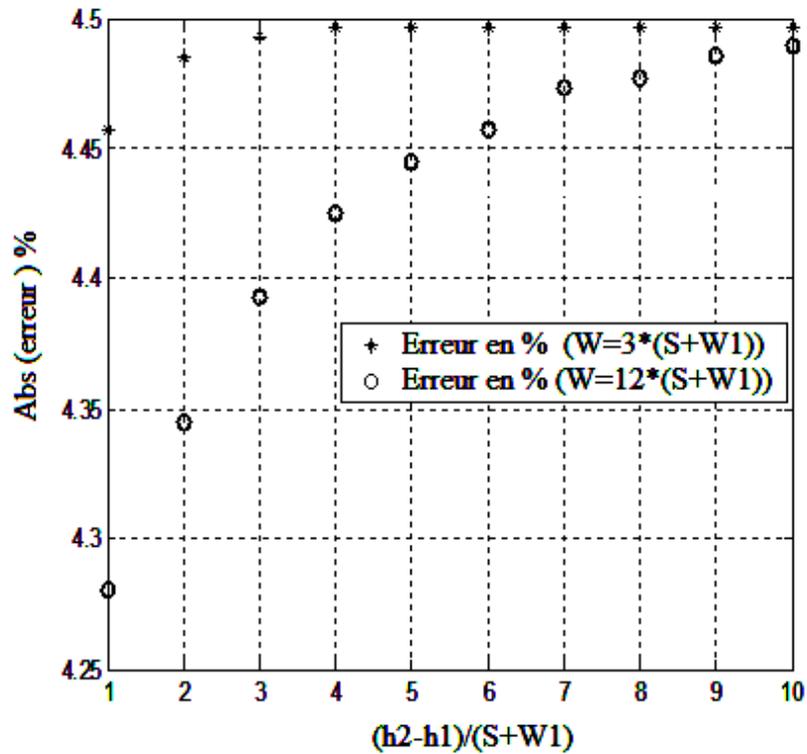


(b)

Figure IV.3.(a) Permittivité effective de la ligne asymétrique multicouche en terme de  $(h_2 - h_1)/(s + w_1)$ , (b) Pourcentage d'erreur dans  $\epsilon_{eff}$

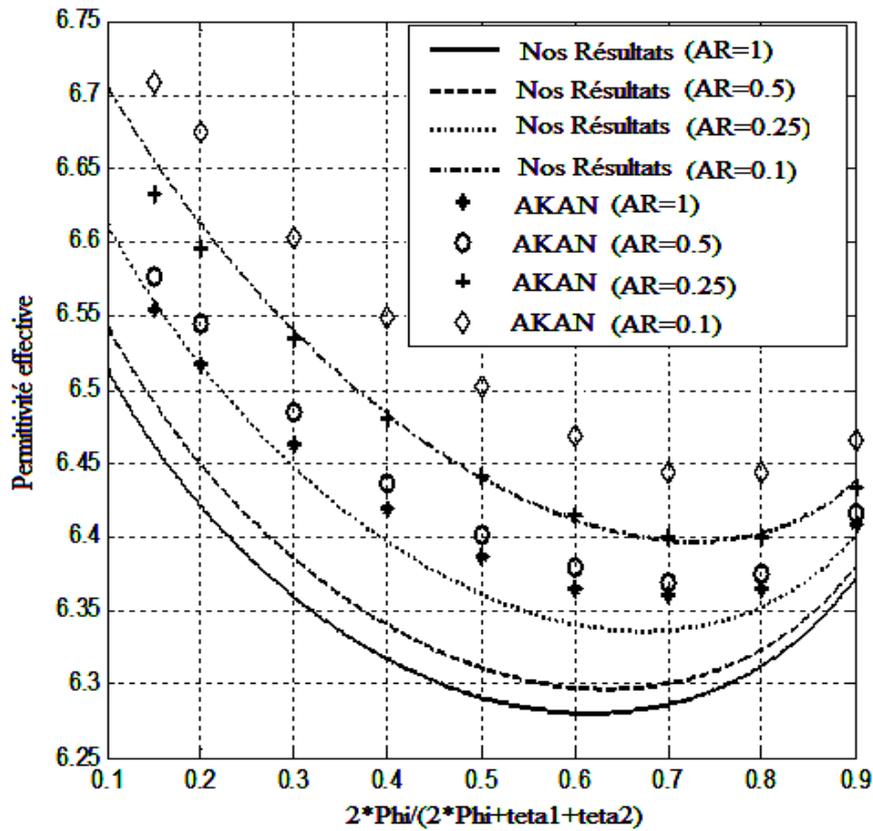


(a)

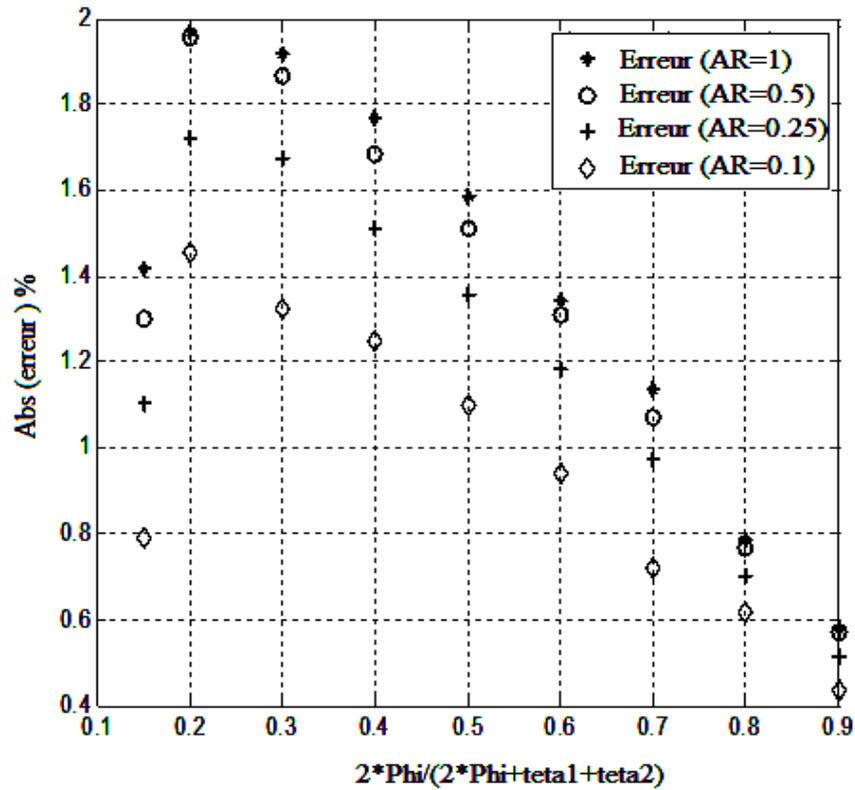


(b)

Figure IV.4.(a) Impédance caractéristique de la ligne asymétrique multicouche en terme de  $(h_2 - h_1)/(s + w_1)$ , (b) Pourcentage d'erreur dans  $Z_0$

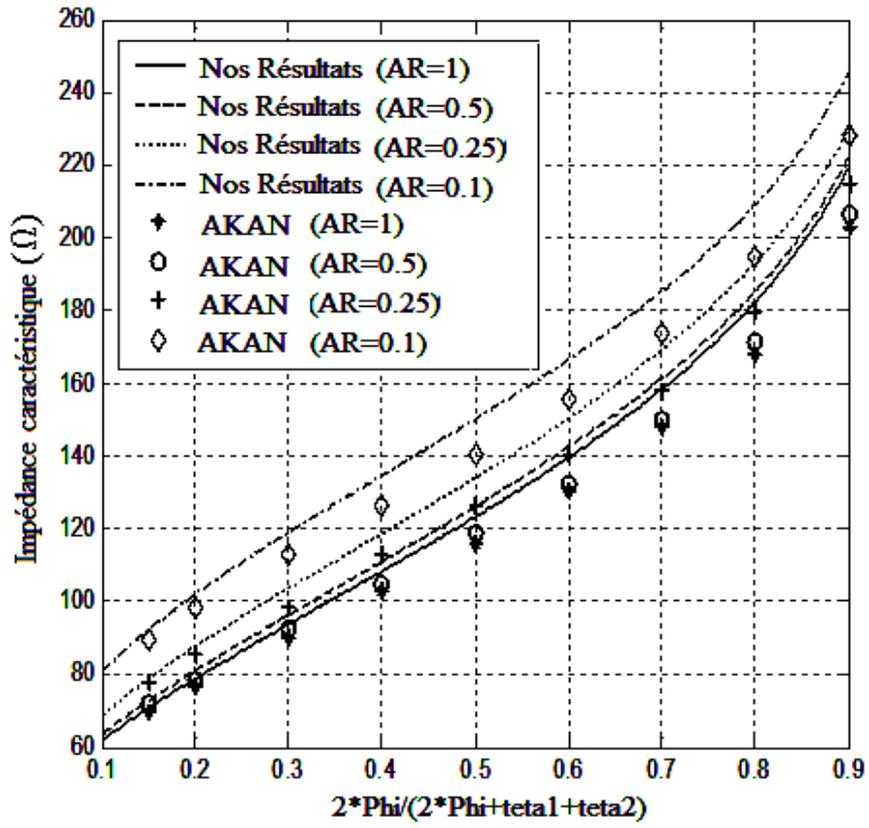


(a)

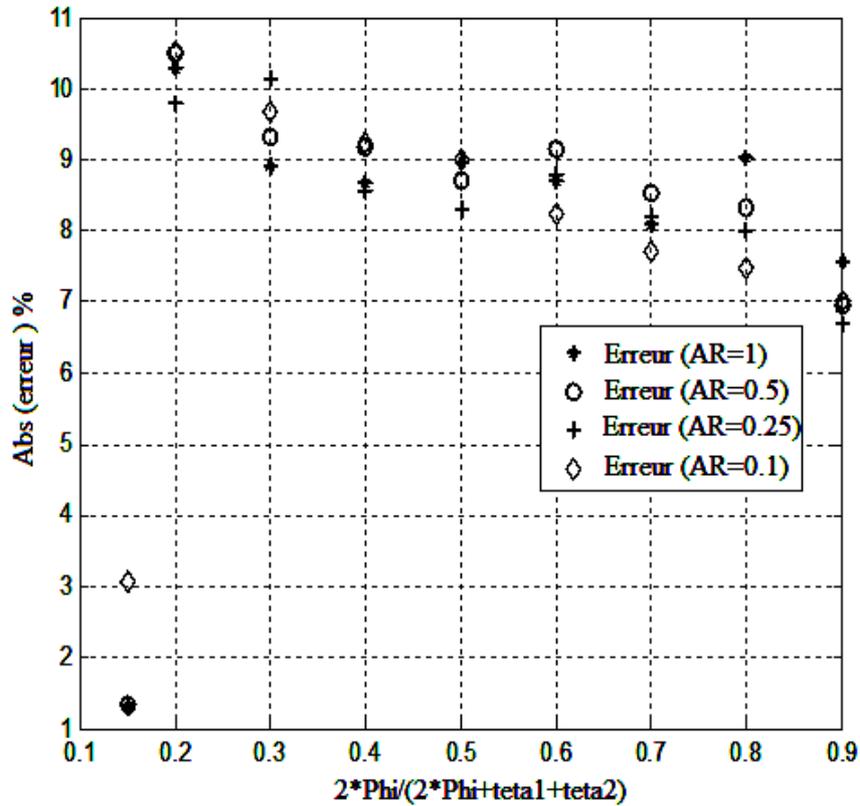


(b)

**Figure IV.5.** (a) Permittivité effective de la ligne coplanaire cylindrique multicouche en terme de  $(2\Phi/(2\Phi + \theta_1 + \theta_2))$ , (b) Pourcentage d'erreur dans  $\epsilon_{eff}$

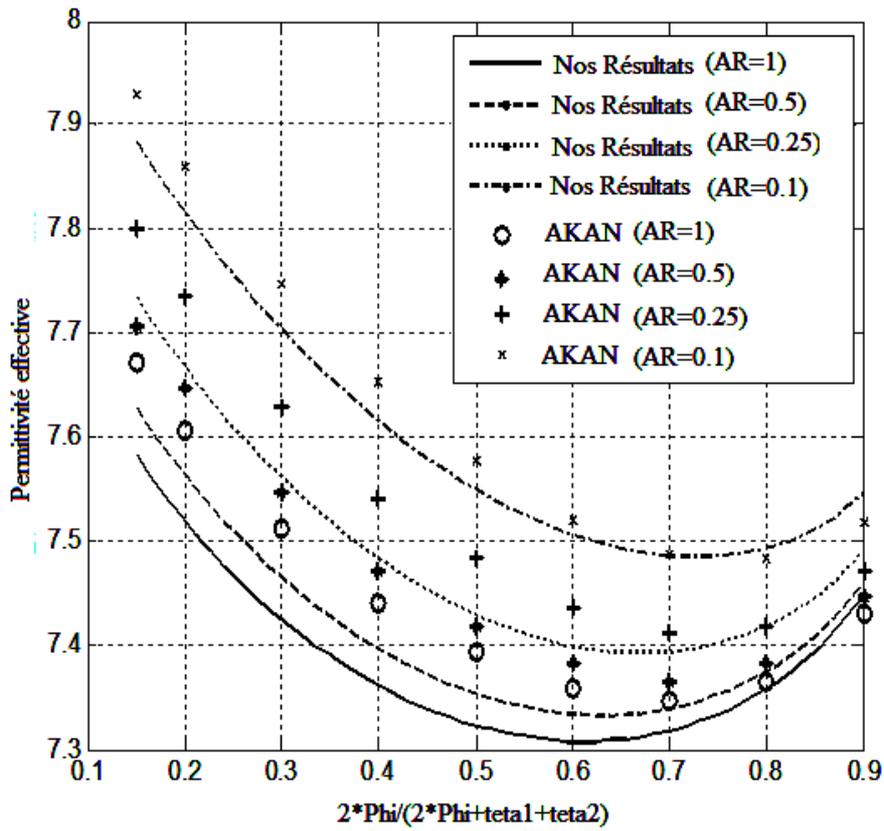


(a)

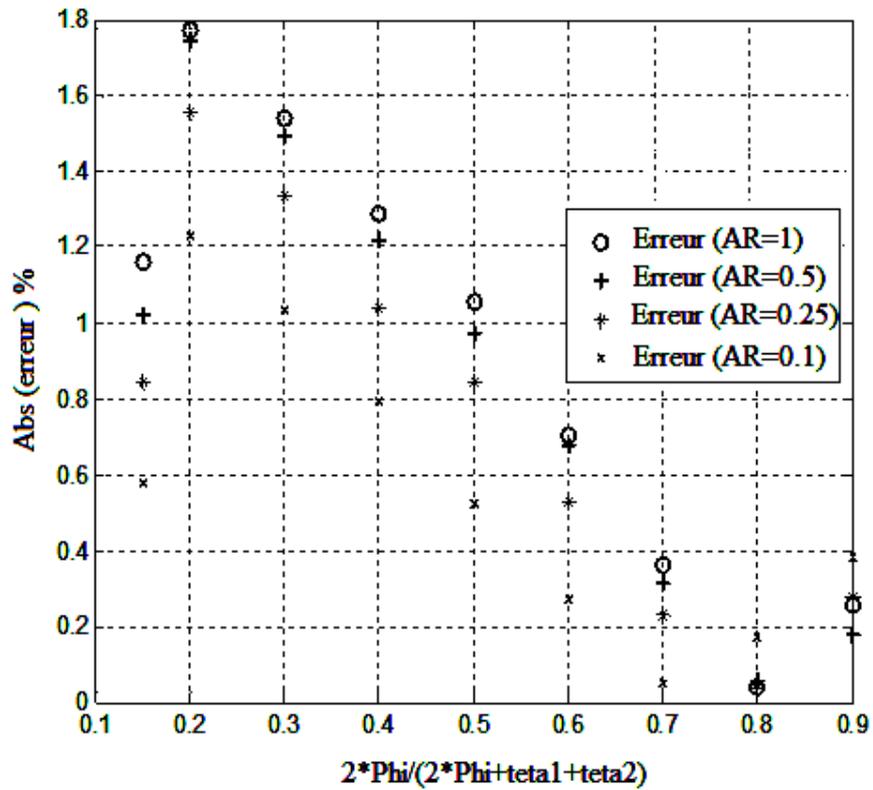


(b)

Figure IV.6.(a) Impédance caractéristique de la ligne coplanaire cylindrique multicouche en terme de  $(2\Phi / (2\Phi + \theta_1 + \theta_2))$ , (b) Pourcentage d'erreur dans  $Z_0$

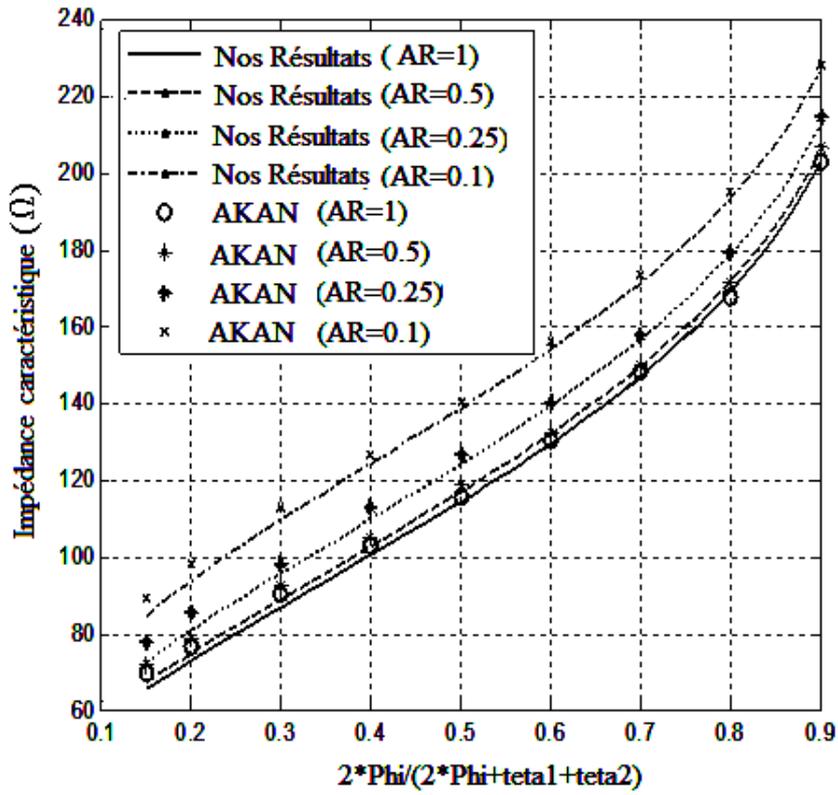


(a)

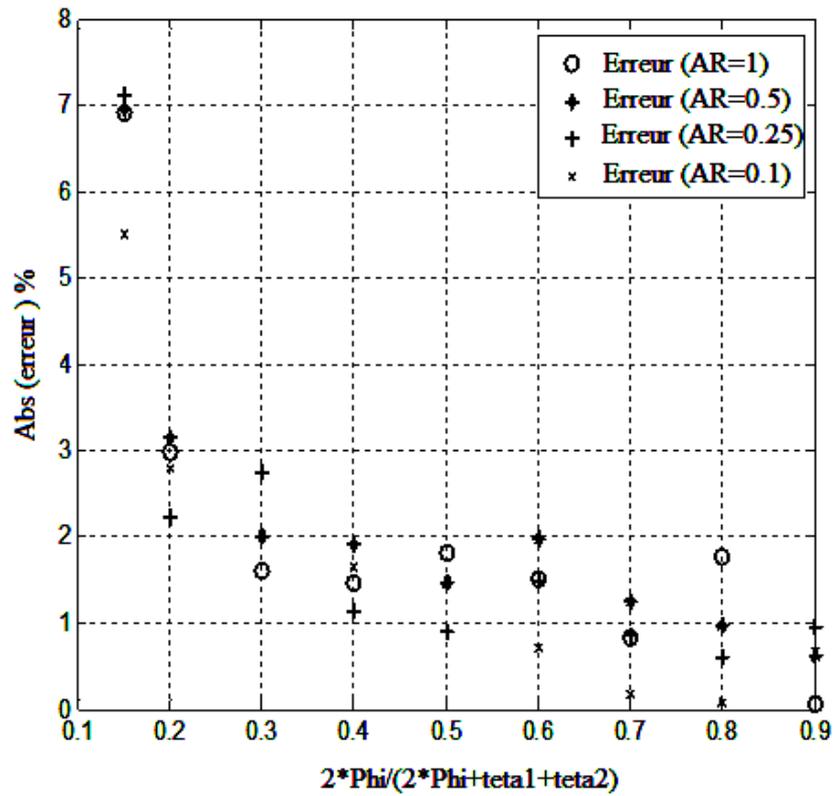


(b)

**Figure IV.7.**(a) Permittivité effective de la ligne coplanaire microruban elliptique multicouche en terme de  $(2\phi/(2\phi + \theta_1 + \theta_2))$ , (b) Pourcentage d'erreur dans  $\epsilon_{eff}$



(a)



(b)

Figure IV.8.(a) Impédance caractéristique de la ligne coplanaire microruban elliptique multicouche en terme de  $(2\Phi/(2\Phi + \theta_1 + \theta_2))$ , (b) Pourcentage d'erreur dans  $Z_0$

### **IV.3. Identification des paramètres quasi-statiques de MECPS, MCCPS et MACPS par les réseaux de neurones et la logique floue**

A présent, nous montrons que les réseaux de neurones et la logique floue sont effectivement capables de prédire les sorties désirées après l'entraînement, pour une base de données bien déterminées qui ne sont pas utilisées dans la phase d'apprentissage.

Deux types de réseaux neuronal et flou sont proposés pour le calcul des paramètres quasi-statiques de chaque structure de lignes de transmission multicouches; MACPS, MCCPS et MECPS. La Figure (IV.9) représente les modèles neuronaux et flous utilisés pour le calcul des paramètres quasi-statiques des trois lignes de transmission, avec les variables d'entrée et le bloc de l'algorithme de l'apprentissage.

Les entrées des réseaux sont définies comme suit :

- Les permittivités relatives des couches diélectriques ( $\epsilon_{r1}, \epsilon_{r2}, \epsilon_{r3}$ ).
- Les dimensions géométriques: ( $h_\tau, w_1, w_2, s$ ) pour la structure planaire, ( $r_i, \theta_1, \theta_2, \phi$ ) pour la structure cylindrique et ( $a_i, b_i, \theta_1, \theta_2, \phi$ ) pour le cas elliptique ou ( $i = 1, 2, 3, 4$ ) et ( $\tau = 1, 2, 3$ ).

Les sorties du modèle CMT de référence sont la permittivité effective et l'impédance caractéristique des lignes MACPS, MCCPS et MECPS. Nous devons toujours comparer les sorties des réseaux avec les données générées par le modèle de référence. Les ensembles des données d'apprentissage ont été obtenues à partir de la CMT avec 10000 valeurs qui ont été utilisées pour entraîner les réseaux neural et flou. L'ANN et le FS sont testés par d'autres ensembles de 50 données générées toujours par la CMT. Les intervalles des données d'apprentissage pour MACPS, MCCPS et MECPS sont:

**a) MACPS**

$$1 \leq \epsilon_{ri} \leq 50, \quad 0.25 \leq h_1 \leq 5.5, \quad 1.3 \leq h_2 \leq 5.75, \quad 0.5 \leq h_3 \leq 6, \quad 0.75 \leq w_1 \leq 8$$

$$0.9 \leq w_2 \leq 9, \quad 0.5 \leq s \leq 6 \quad \text{et} \quad 3 \leq w \leq 30 \text{ mm.}$$

**b) MCCPS**

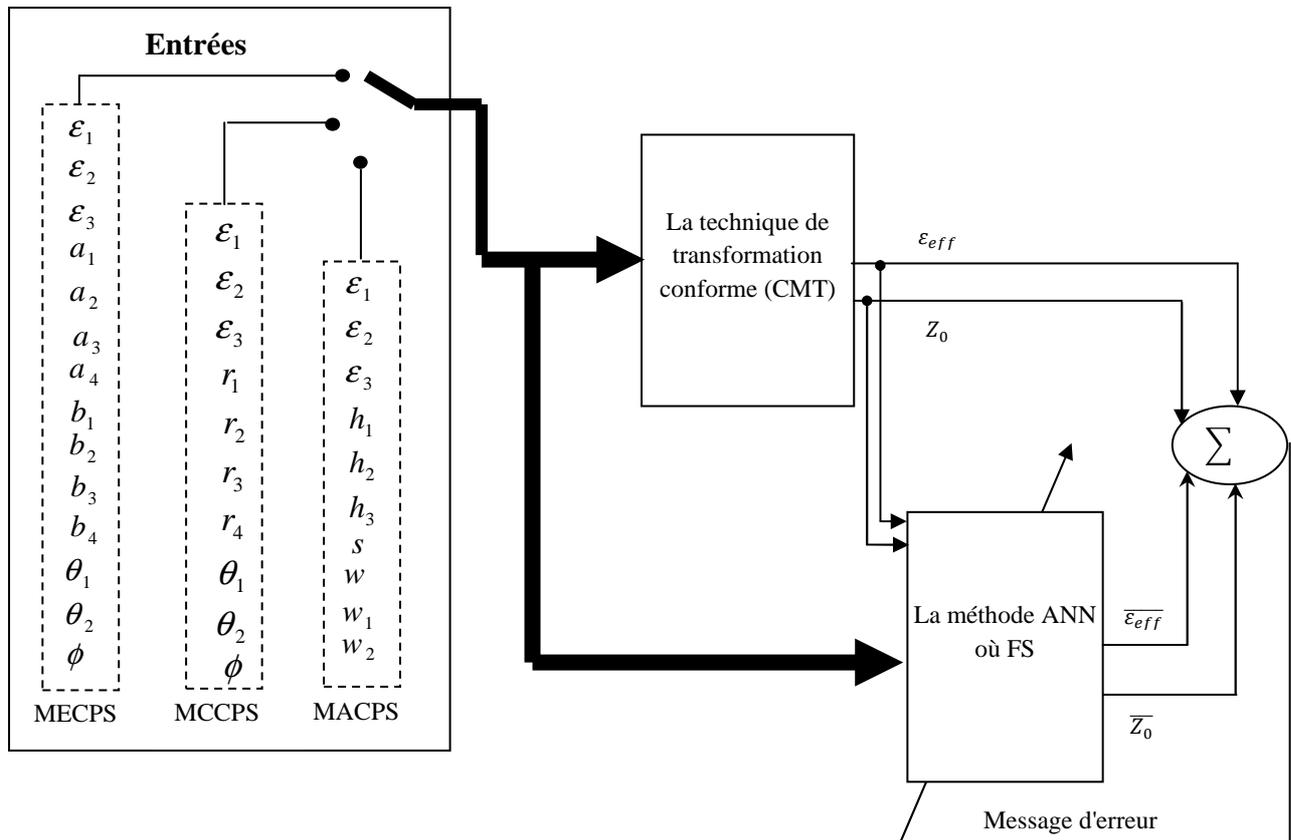
$$1 \leq \epsilon_{ri} \leq 50, \quad 0.1 \leq r_1 \leq 5, \quad 5 \leq r_2 \leq 10, \quad 10 \leq r_3 \leq 15, \quad 15 \leq r_4 \leq 20, \quad 0.2 \leq \theta_1 \leq 1.8$$

$$0.2 \leq \theta_2 \leq 1.8, \quad 0.2 \leq \phi \leq 1.8.$$

**c) MECPS**

$$1 \leq \epsilon_{ri} \leq 50, \quad 0.1 \leq a_1 \leq 5, \quad b_1 = 0.45 a_1, \quad 5 \leq a_2 \leq 10, \quad b_2 = 0.65 a_2, \quad a_3 = 1.7 a_2$$

$$b_3 = 1.35 a_2, \quad a_4 = 2.25 a_2, \quad b_4 = 1.9 a_2, \quad 0.2 \leq \theta_1 \leq 1.8, \quad 0.2 \leq \theta_2 \leq 1.8, \quad 0.2 \leq \phi \leq 1.8$$



**Figure IV.9.** Modèles ANN et FS utilisés pour le calcul des paramètres quasi-statiques  $\varepsilon_{eff}$  et  $Z_0$  des lignes de transmission.

### IV.3.1. Détermination de l'architecture convenable du modèle neuronal et flou

Autour de différentes expériences combinatoires qui ont été réalisées afin de déterminer la meilleure architecture de notre réseau de neurones et modèle flou, les meilleures architectures ont été sélectionnées, sur la base de la précision des résultats prédits sont présentés dans le tableau (IV.1). En particulier, les coefficients  $\alpha_b$ ,  $\alpha_c$ , et  $\alpha_\sigma$  sont déterminés suivant les essais et la procédure d'erreur qui sont illustrés dans le même tableau pour faciliter la convergence de notre algorithme d'apprentissage du FS.

La mise en œuvre des réseaux de neurones et la logique floue comporte à la fois une partie conception dont l'objectif est de choisir la meilleure architecture possible, et une partie de calcul numérique, pour réaliser l'apprentissage des deux modèles.

Modèles		Lignes de transmission		MACPS		MCCPS		MECPS	
		Sortie		$\epsilon_{eff}$	$Z_0$	$\epsilon_{eff}$	$Z_0$	$\epsilon_{eff}$	$Z_0$
Réseaux de neurones (ANN)	Structure								
	Algorithme d'apprentissage	Rétro propagation d'erreur							
	Nombre des couches cachées	2							
	Variables d'entrées	10	10	10	10	14	14		
	Neurones cachés	30	25	30	35	30	35		
	La fonction d'activation de chaque couche	Sigmoïde							
	La fonction de transfert de couche de sortie	Linéaire							
	La base de données	10000 pour l'apprentissage et 50 pour la validation							
	Temps du calcul (heure)	8.4521	3.2341	0.47	0.22	7.5789	15.3237		
	Nombre d'itérations	100000	100000	10000	10000	100000	100000		
	Logique floue (FS)	Algorithme d'apprentissage	Rétro propagation d'erreur						
La fonction d'appartenance		Gaussienne							
Nombre des règles		15	15	10	20	10	15		
Variables d'entrées		10	10	10	10	14	14		
Partie conséquence $\alpha_b$		0.5	1	0.1	0.01	0.5	1		
Partie prémisse $\alpha_c$		0.1	0.1	0.09	0.1	0.1	0.1		
Ecart type $\delta$		1	1	1	0.7	1	1		
La base de données		10000 pour l'apprentissage et 50 pour la validation							
Temps du calcul (heure)		20.3883	12.6061	5.1536	2.5411	12.9261	28.9633		
Nombre d'itérations		38613	20221	12066	3047	22205	34342		

**Tableau IV.1.** Architectures des réseaux neuronaux et systèmes flous utilisées pour prédire les paramètres quasi-statiques des lignes de transmission

### IV.3.2. Différents cas de validation des modèles suggérés

L'ANN et FS ont été entraînés pour obtenir des meilleures performances et une convergence plus rapide avec une structure simple. Afin de montrer la validation de nos modèles, cinq comparaisons entre la CMT, ANN, et FS ont été réalisées et des résultats obtenus sont discutés comme suivant:

➤ **Cas 1: Les permittivités  $(\epsilon_{r1}, \epsilon_{r2}, \epsilon_{r3})$  sont constantes, et  $(w_1, w_2, s, w, h_i)$  pour la structure planaire,  $(\theta_1, \theta_2, \phi, r_p)$  pour la géométrie cylindrique, et  $(\theta_1, \theta_2, \phi, a_p, b_p)$  pour le cas elliptique variant ( $p = 1,2,3,4$ ), ( $i = 1,2,3$ ).**

- 1) La ligne coplanaire multicouche asymétrique MACPS consiste en trois couches diélectriques de permittivités  $(\epsilon_{r1}, \epsilon_{r2}, \epsilon_{r3}) = (49.34, 9, 25.6)$  et  $(s, w_1, w_2, w, h_i)$  varient. La permittivité effective  $\epsilon_{eff}$  et l'impédance caractéristique  $Z_0$  sont présentées dans les Figures [IV.10(a), IV.11(a)], respectivement. Le pourcentage d'erreur entre les sorties calculées par CMT et les sorties des réseaux de neurones ANN et la logique floue FS est présenté dans les Figures [IV.10(b), IV.11(b)]. Les valeurs du pourcentage d'erreur dans  $\epsilon_{eff}$  est inférieur à 1.2% pour ANN et inférieur à 1.6% pour le FS. Tandis que le pourcentage maximal d'erreur dans  $Z_0$  est inférieur à 1.2% pour ANN et inférieur à 0.8% pour FS.
  
- 2) La ligne coplanaire cylindrique multicouche asymétrique MCCPS consiste en trois couches diélectriques de permittivités  $(\epsilon_{r1}, \epsilon_{r3}) = (12.9, 3.78)$  et  $\epsilon_{r2} = 1$ . Les caractéristiques dimensionnelles  $(\theta_1, \theta_2, \phi, r_p)$  varient. La permittivité effective et l'impédance caractéristique sont présentées dans les Figures [IV.12(a), IV.13(a)] respectivement. Le pourcentage d'erreur entre les sorties calculées par CMT et les sorties des réseaux de neurones et la logique floue est présenté dans les Figures [IV.12(b), IV.13(b)]. Les valeurs du pourcentage d'erreur dans  $\epsilon_{eff}$  est inférieur à 0.05% pour ANN et inférieur à 0.3% pour FS, cependant les valeurs du pourcentage d'erreur dans  $Z_0$  est inférieur à 0.16% pour ANN et inférieur à 1.2% pour le model FS .
  
- 3) Les Figures [IV.14(a) , IV.15(a)] présentent les  $\epsilon_{eff}$  et  $Z_0$  de la ligne coplanaire elliptique multicouche MECPS qui a les mêmes caractéristiques diélectriques du cas cylindrique , avec  $(\theta_1, \theta_2, \phi, a_p, b_p)$  varient . Les valeurs du pourcentage d'erreur dans  $\epsilon_{eff}$  est inférieur à 0.05% pour ANN et inférieur à 0.4% pour FS, les valeurs du pourcentage d'erreur dans  $Z_0$  est inférieur à 0.16% pour ANN et 1.8% pour FS.

- **Cas 2: Les permittivités  $(\epsilon_{r2}, \epsilon_{r3})$  et  $(w_1, w_2, s, w, h_i)$  pour la structure planaire,  $(\theta_1, \theta_2, \phi, r_p)$  pour la géométrie cylindrique, et  $(\theta_1, \theta_2, \phi, a_p, b_p)$  pour la géométrie elliptique constantes, et  $\epsilon_{r1}$  varie.**

Dans ce cas nous comparons, nos résultats obtenus par ANN et FS pour les lignes de transmission avec les résultats générés par CMT, présentés dans le tableau (IV.2).

Paramètres Lignes de transmission	$\epsilon_{r1}$	$\epsilon_{r2}$	$\epsilon_{r3}$	Pourcentage d'erreur dans $\epsilon_{eff}$ entre CMT et ANN et FS		Pourcentage d'erreur dans $Z_0$ entre CMT et ANN et FS	
				ANN	FS	ANN	FS
<b>MACPS</b>	1 à 50	28.45	43.78	<0.22%	<0.7%	<0.12%	<0.35%
<b>MCCPS</b>	1 à 50	50	10.55	<0.04%	<0.12%	<0.053%	<0,8%
<b>MECPS</b>	1 à 50	50	10.55	<0.1%	<0.3%	<0.16%	<1.5%

**Tableau IV.2.** Pourcentage d'erreur dans  $\epsilon_{eff}$  et  $Z_0$  entre CMT, ANN et FS pour les lignes de transmission

- 1) La permittivité effective  $\epsilon_{eff}$  et l'impédance caractéristique  $Z_0$  de la ligne MACPS sont présentées dans les Figures [IV.16(a) , IV.17(a)] respectivement. Le pourcentage d'erreur entre les sorties calculées par CMT et les sorties des réseaux de neurones et la logique floue est présenté dans les Figures [IV.16(b), IV.17(b)].
- 2) La permittivité effective  $\epsilon_{eff}$  et l'impédance caractéristique  $Z_0$  pour la ligne coplanaire asymétrique cylindrique MCCPS sont présentées dans les Figures [IV.18(a) , IV.19 (a)] respectivement. Le pourcentage d'erreur entre les sorties calculées par CMT et les sorties des réseaux de neurones et la logique floue est présenté dans les Figures [IV.18(b), IV.19(b)].
- 3) Les Figures [IV.20(a) , IV.21(a)] présentent les  $\epsilon_{eff}$  et  $Z_0$  de la ligne coplanaire elliptique multicouche MECPS qui a les mêmes caractéristiques diélectriques du cas cylindrique et le pourcentage d'erreur entre les sorties calculées par CMT et les sorties de ANN et FS sont présentés dans les Figures [IV.20(b), IV.21(b)].

➤ **Cas 3: Les permittivités  $(\epsilon_{r1}, \epsilon_{r3})$  et  $(w_1, w_2, s, w, h_i)$  pour la structure planaire,  $(\theta_1, \theta_2, \phi, r_p)$  pour la géométrie cylindrique, et  $(\theta_1, \theta_2, \phi, a_p, b_p)$  pour la géométrie elliptique constantes, et  $\epsilon_{r2}$  varie.**

Le tableau (IV.3) présente les résultats numériques de ce cas

Paramètres Lignes de transmission	$\epsilon_{r1}$	$\epsilon_{r2}$	$\epsilon_{r3}$	Pourcentage d'erreur dans $\epsilon_{eff}$ entre CMT et ANN et FS		Pourcentage d'erreur dans $Z_0$ entre CMT et ANN et FS	
				ANN	FS	ANN	FS
<b>MACPS</b>	50	1 à 50	10.55	<0.1%	<0.25%	<0.04%	<0.12%
<b>MCCPS</b>	20.94	1 à 50	10.55	<4.5×10 <sup>-3</sup> %	<0.45%	<0.053%	<0,8%
<b>MECPS</b>	20.94	1 à 50	10.55	<0.02%	<0.14%	<0.06%	<1%

**Tableau IV.3.** Pourcentage d'erreur de  $\epsilon_{eff}$  et  $Z_0$  entre CMT, ANN et FS pour les lignes de transmission

- 1) Les paramètres quasi-statiques  $\epsilon_{eff}$  et  $Z_0$  de la ligne MACPS sont présentés dans les Figures [IV.22(a) , IV.23(a)] respectivement. Le pourcentage d'erreur est présenté dans les Figures [IV.22(b) , IV.23(b)].
  - 2) Les résultats numériques de  $Z_0$  et  $\epsilon_{eff}$  par CMT , ANN et FS de la ligne MCCPS sont présentés dans les Figures [IV.24(a) , IV.25(a)] respectivement. Le pourcentage d'erreur est présenté dans les Figures [IV.24(b) , IV.25(b)].
  - 3) Les Figures [IV.26(a), IV.27(a)] présentent la permittivité effective et l'impédance caractéristique de la ligne MECPS qui a les mêmes caractéristiques diélectriques du cas cylindrique et les pourcentages d'erreur sont présentés dans les Figures [IV.26(b) , IV.27(b)].
- **Cas 4: Les permittivités  $(\epsilon_{r1}, \epsilon_{r2})$  et  $(w_1, w_2, s, w, h_i)$  pour la structure planaire,  $(\theta_1, \theta_2, \phi, r_p)$  pour la géométrie cylindrique, et  $(\theta_1, \theta_2, \phi, a_p, b_p)$  pour la géométrie elliptique constantes, et  $\epsilon_{r3}$  varie .**

Nous illustrons dans le tableau (IV.4) les résultats de la simulation du cas n °4 qui permet de valider nos résultats.

Paramètres Lignes de transmission	$\epsilon_{r1}$	$\epsilon_{r2}$	$\epsilon_{r3}$	Pourcentage d'erreur dans $\epsilon_{eff}$ entre CMT et ANN et FS		Pourcentage d'erreur dans $Z_0$ entre CMT et ANN et FS	
				ANN	FS	ANN	FS
<b>MACPS</b>	20.49	39.85	1 à 50	<0.5%	< 1%	<0.3%	<0. 5%
<b>MCCPS</b>	20.49	39.85	1 à 50	<0.01%	<0.35%	<1.8×10 <sup>-3</sup> %	<0.35%
<b>MECPS</b>	20.49	39.85	1 à 50	<0.02%	<0.18%	<0.06%	<1.2%

**Tableau IV.4.** Pourcentage d'erreur de  $\epsilon_{eff}$  et  $Z_0$  entre CMT, ANN et FS pour lignes de transmission

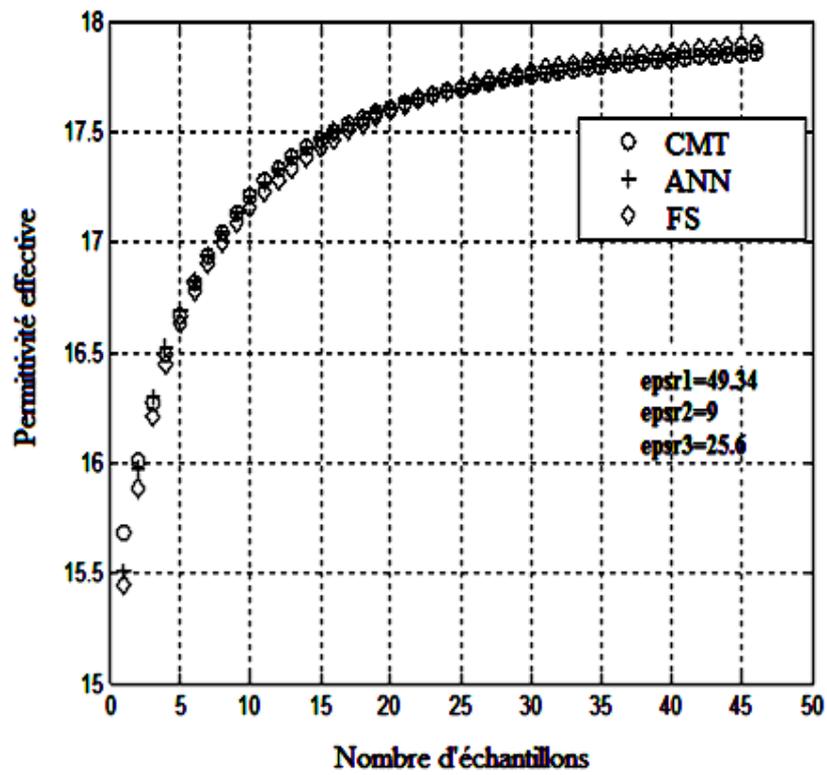
- 1) La permittivité effective et l'impédance caractéristique de la ligne MACPS .sont présentées dans les Figures [IV.28(a), IV.29(a)] respectivement et le pourcentage d'erreur entre les sorties calculées par CMT et les sorties de ANN et FS sont présentés dans les Figures [IV.28(b), IV.29(b)].
  - 2) La ligne MCCPS consiste en trois couches diélectriques de permittivité effective et d'impédance caractéristique présentées dans les Figures [IV.30(a), IV.31(a)] respectivement et le pourcentage d'erreur présenté dans les Figures [IV.30(b) , IV.31(b)].
  - 3) Les Figures [IV.32(a) , IV.33(a)] présentent les  $\epsilon_{eff}$  et  $Z_0$  de la ligne MECPS , ainsi le pourcentage d'erreur entre les sorties calculées par CMT et les sorties de ANN et FS sont présentés dans les Figures [IV.32(b), IV.33(b)].
- **Cas 5: Tous les paramètres de la ligne varient ;** Dans ce cas, tous les paramètres de la ligne sont supposés variés ensemble. Nous avons pris 6 ensembles de points définis comme:  $(w_1, w_2, s, w, h_i)$  pour la structure planaire,  $(\theta_1, \theta_2, \phi, r_p)$  pour la géométrie cylindrique, et  $(\theta_1, \theta_2, \phi, a_p, b_p)$  pour le cas elliptique varient.

Les permittivités diélectriques varient comme suit:

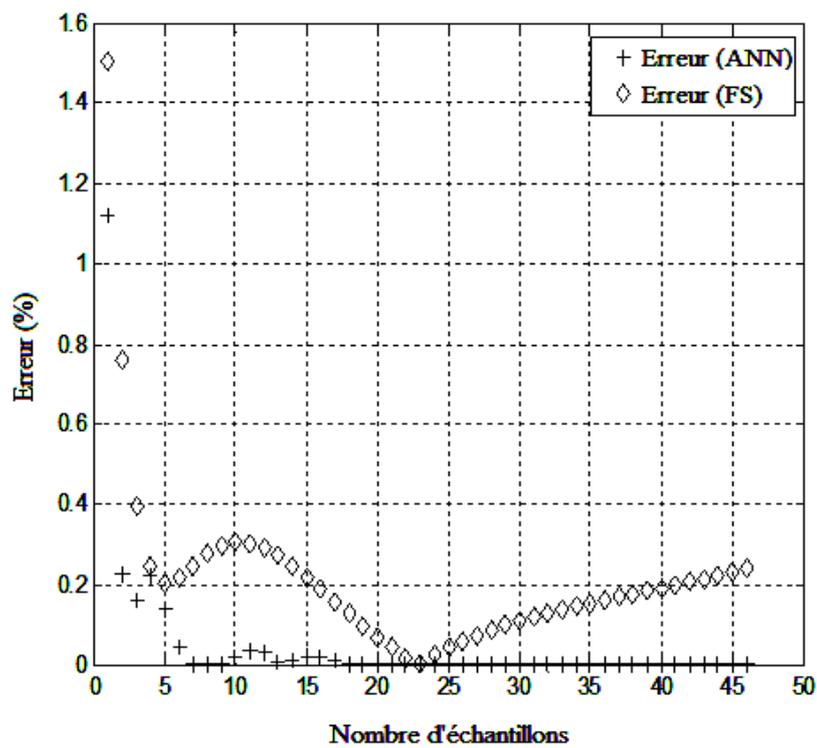
- ✓ Ensemble #1:  $\epsilon_{r1} = 25, \epsilon_{r2} = 5, \epsilon_{r3} = 20.$
- ✓ Ensemble #2:  $\epsilon_{r1} = 5, \epsilon_{r2} = 50: -1: 46, \epsilon_{r3} = 5.$
- ✓ Ensemble #3:  $\epsilon_{r1} = 20: -1: 15, \epsilon_{r2} = 20, \epsilon_{r3} = 50.$
- ✓ Ensemble #4:  $\epsilon_{r1} = 34: 1: 48, \epsilon_{r2} = 3: 1: 49, \epsilon_{r3} = 34.$
- ✓ Ensemble #5:  $\epsilon_{r1} = 1: 0.5: 4.5, \epsilon_{r2} = 34: 1: 41, \epsilon_{r3} = 35: 1: 42.$
- ✓ Ensemble #6:  $\epsilon_{r1} = 24: 1: 29, \epsilon_{r2} = 35, \epsilon_{r3} = 15$

- 1) La permittivité effective et l'impédance caractéristique de la ligne MACPS sont présentées dans les Figures [IV.34(a), IV.35(a)] respectivement. Le pourcentage d'erreur entre les sorties calculées par CMT et les sorties de ANN et FS sont présentées dans les Figures [IV.34(b), IV.35(b)]. Les valeurs du pourcentage d'erreur dans  $\varepsilon_{eff}$  est inférieur à 1 % pour ANN et inférieur à 1.6% pour FS. Cependant que les valeurs du pourcentage d'erreur dans  $Z_0$  est inférieur à 0.5% pour ANN et inférieur à 0.8% pour FS.
- 2) La permittivité effective et l'impédance caractéristique de la ligne MCCPS sont présentées dans les Figures [IV.36(a) , IV.37(a)] respectivement. Le pourcentage d'erreur entre les sorties calculées par CMT et les sorties de ANN et FS sont présentées dans les Figures [IV.36(b) , IV.37(b)]. Les valeurs du pourcentage d'erreur dans  $\varepsilon_{eff}$  est inférieur à 0.05% pour ANN et inférieur à 0.25% pour FS. Ainsi que les valeurs du pourcentage d'erreur dans  $Z_0$  est inférieur à 0.2% pour ANN et inférieur à 1.5% pour le système flou.
- 3) Les Figures [IV.38(a) , IV.39(a)] présentent le  $\varepsilon_{eff}$  et  $Z_0$  du MECPS. Les valeurs du pourcentage d'erreur dans  $\varepsilon_{eff}$  est inférieur à 0.05% pour ANN et inférieur à 0.6% pour le model FS, tandis que les valeurs du pourcentage d'erreur dans  $Z_0$  est inférieur à 0.1% pour ANN et inférieur à 1.4% pour FS comme indiqué dans les Figures [IV.38(b) , IV.39(b)].

IV.3.3. Les courbes de comparaison entre ANN , FS et CMT

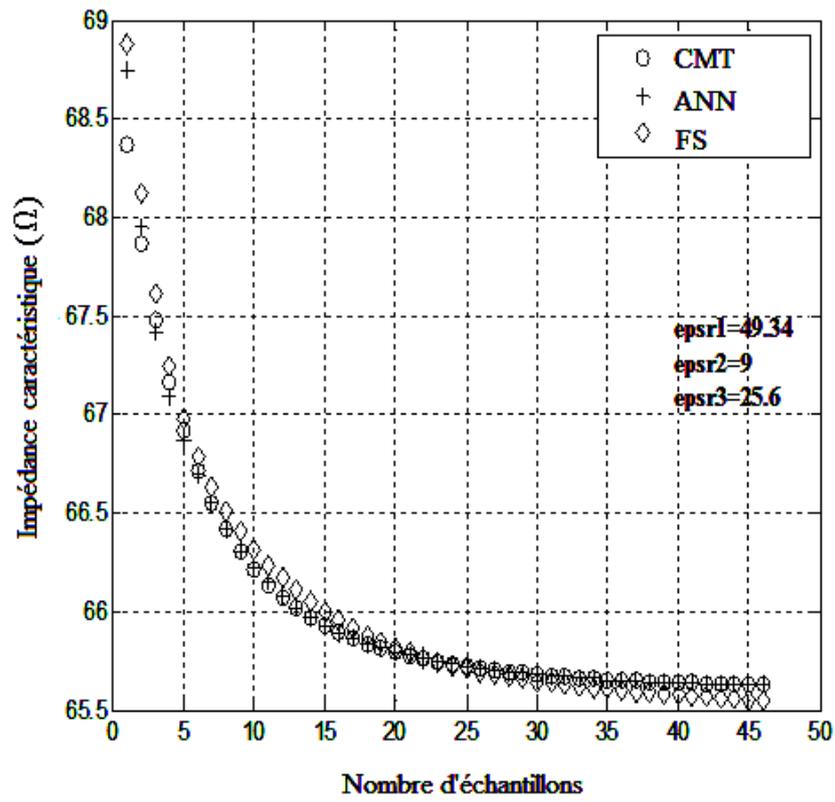


(a)

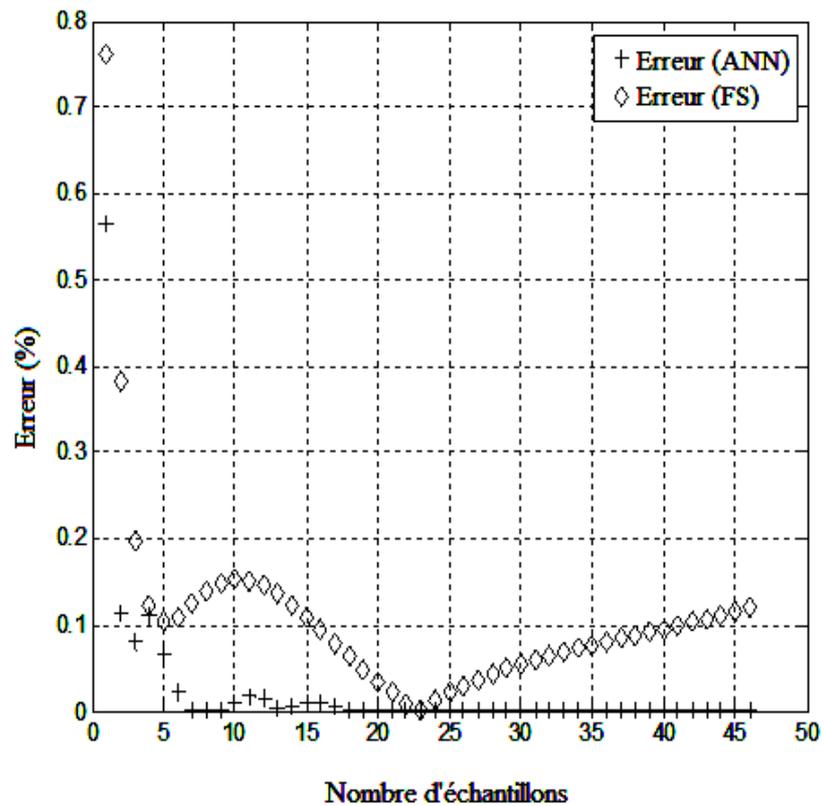


(b)

Figure IV.10.(a) Permittivité effective de la ligne coplanaire multicouche ACPS  
 (b) Pourcentage d'erreur dans  $\epsilon_{eff}$

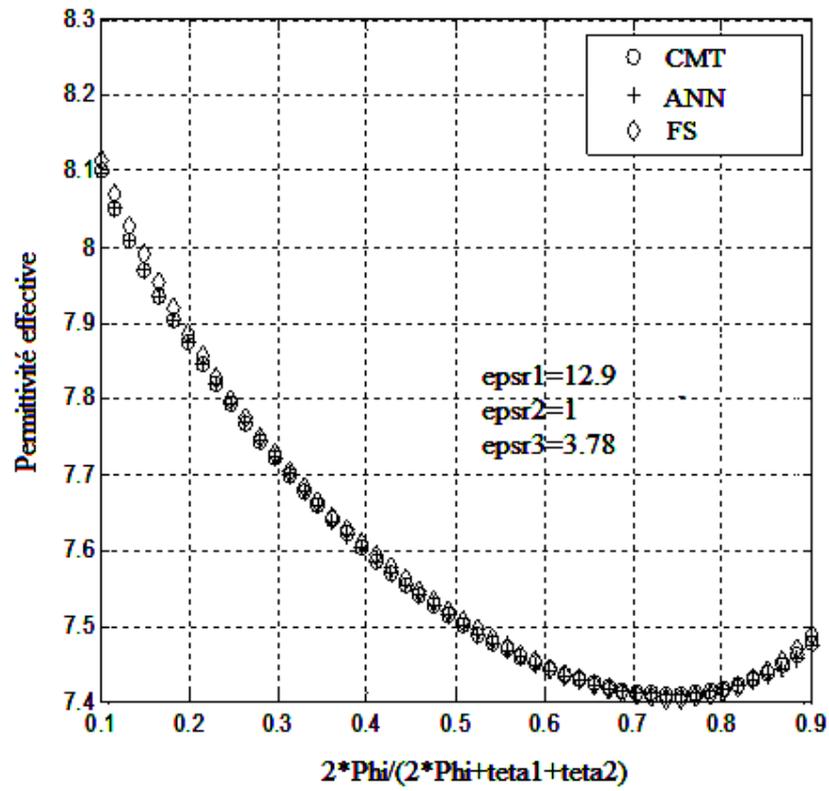


(a)

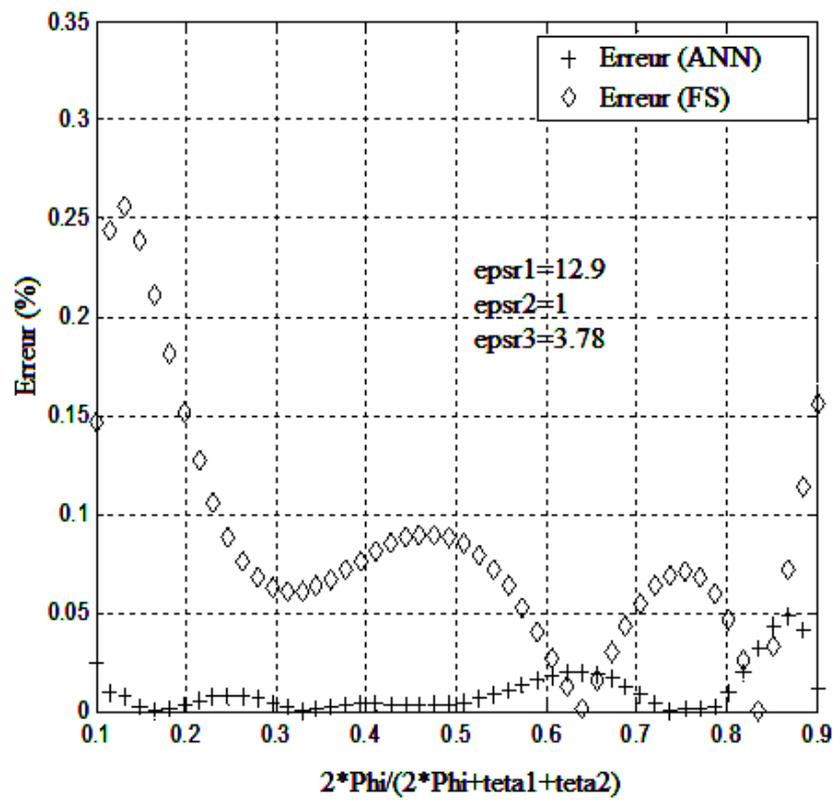


(b)

**Figure IV.11.**(a) Impédance caractéristique de la ligne coplanaire multicouche cylindrique ,  
(b) Pourcentage d'erreur dans  $Z_0$ .

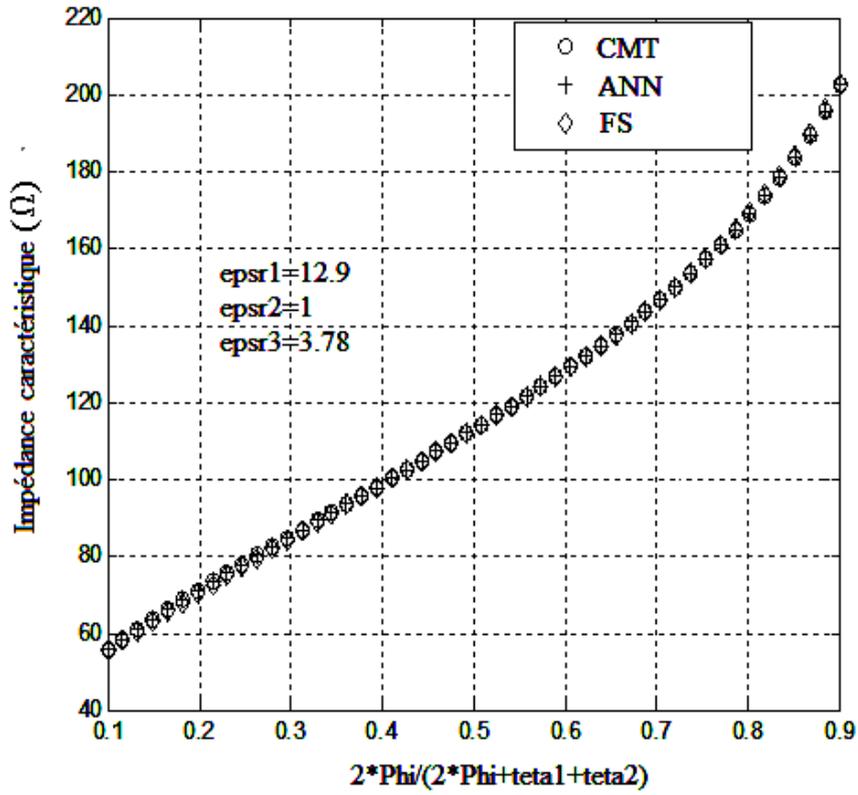


(a)

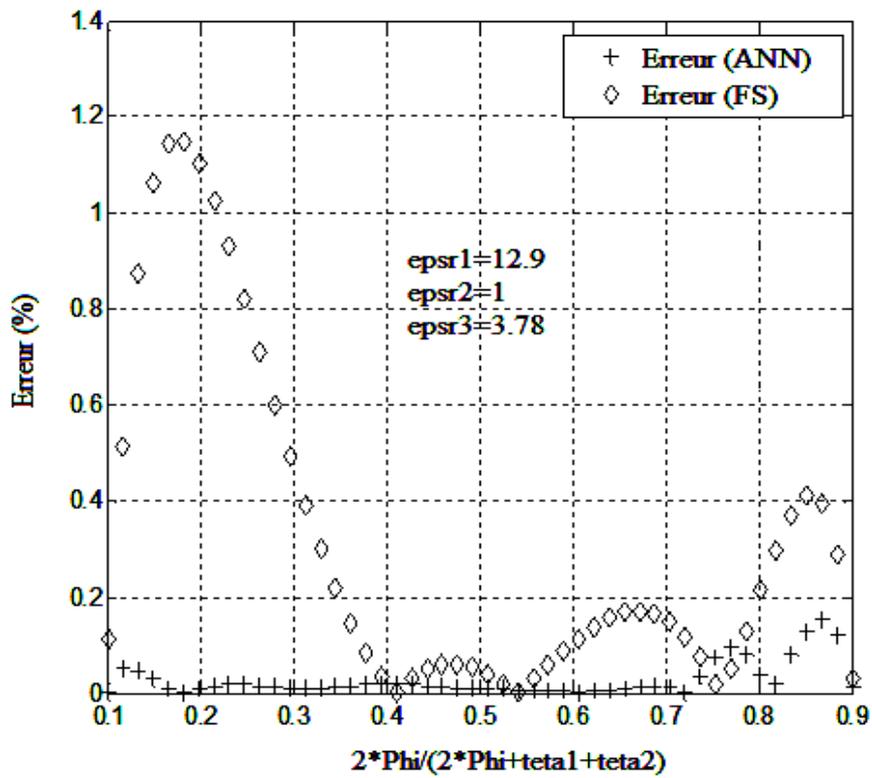


(b)

**Figure IV.12.**(a) Permittivité effective de la ligne coplanaire multicouche cylindrique en terme de  $(2\Phi/(2\Phi + \theta_1 + \theta_2))$ , (b) Pourcentage d'erreur dans  $\epsilon_{eff}$

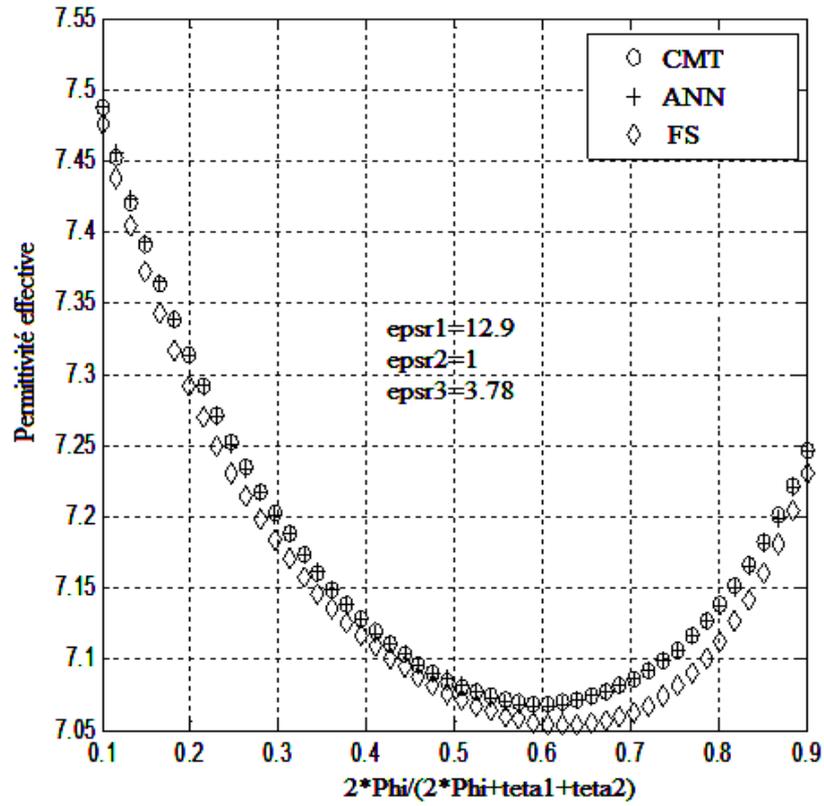


(a)

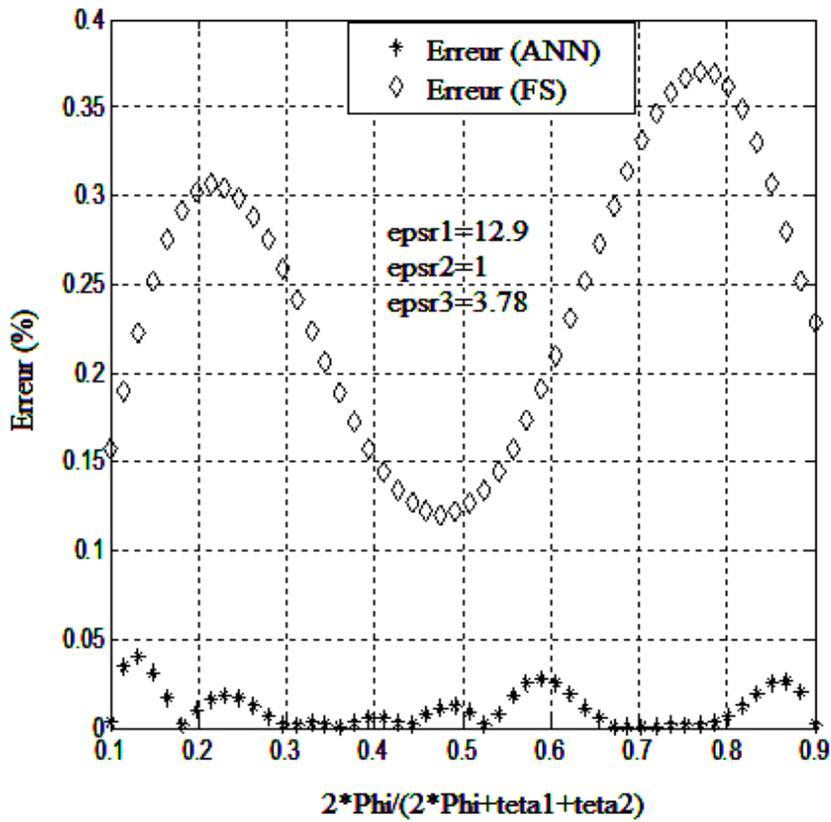


(b)

Figure IV.13.(a) Impédance caractéristique de la ligne coplanaire multicouche cylindrique en terme de  $(2\Phi / (2\Phi + \theta_1 + \theta_2))$ , (b) Pourcentage d'erreur dans  $Z_0$

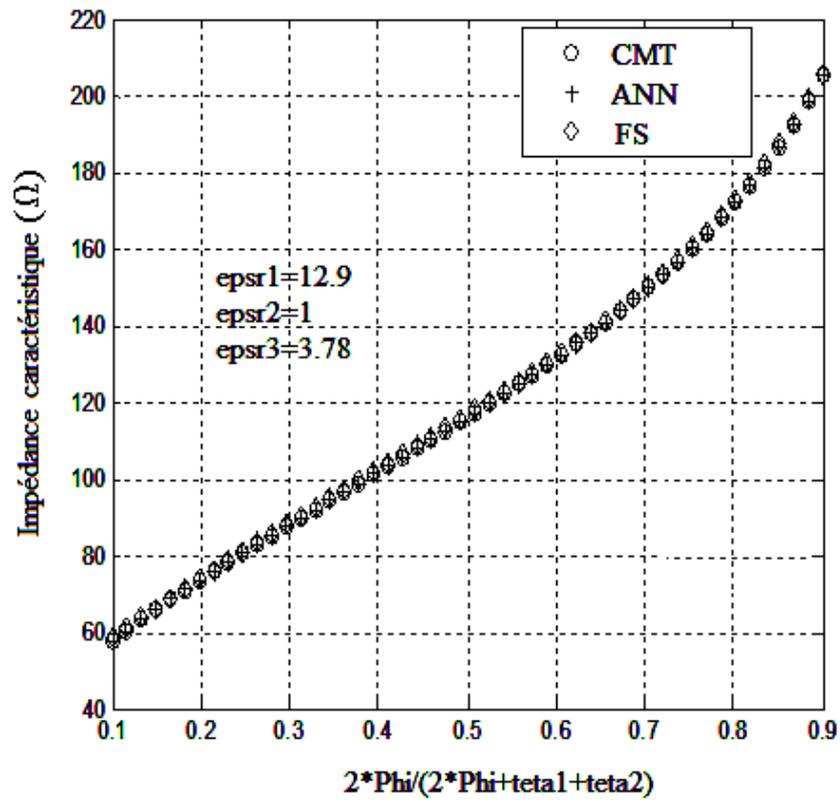


(a)

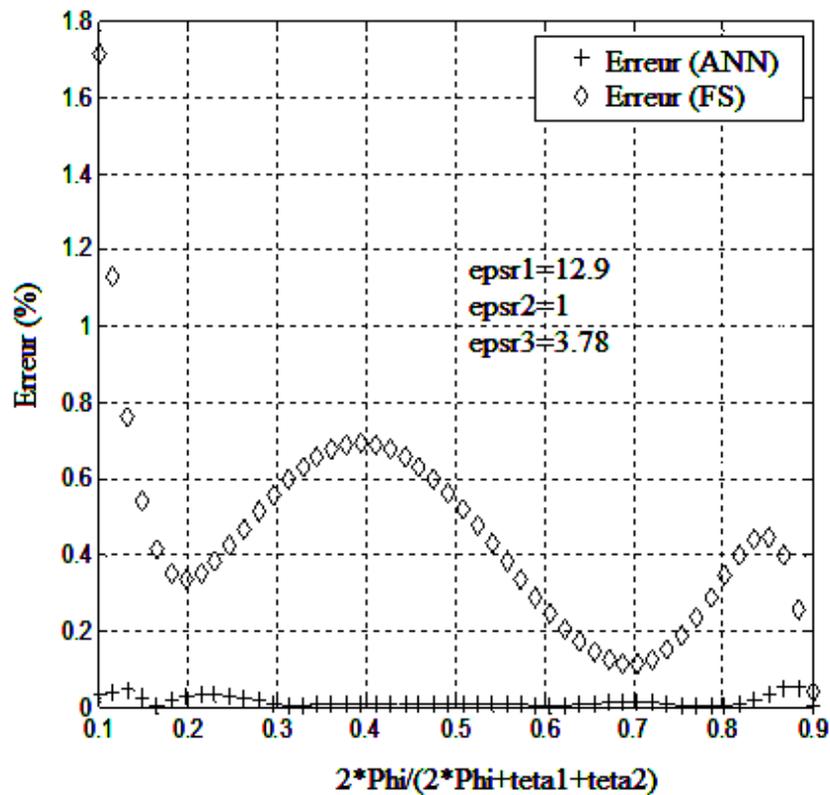


(b)

Figure IV.14.(a) Permittivité effective de la ligne coplanaire multicouche elliptique en terme de  $(2\Phi/(2\Phi + \theta_1 + \theta_2))$ , (b) Pourcentage d'erreur dans  $\epsilon_{eff}$

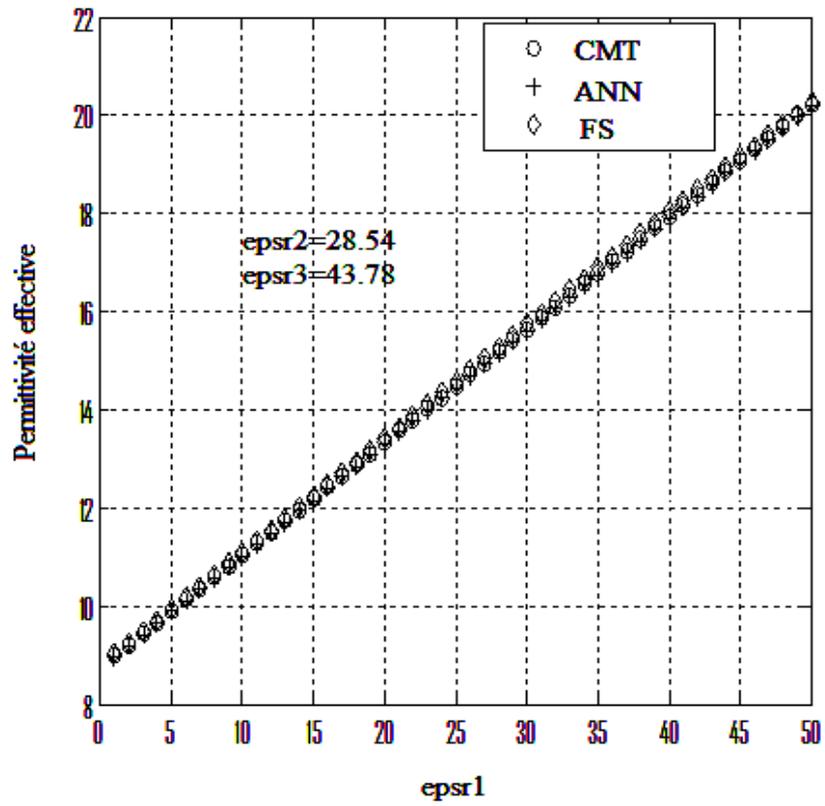


(a)

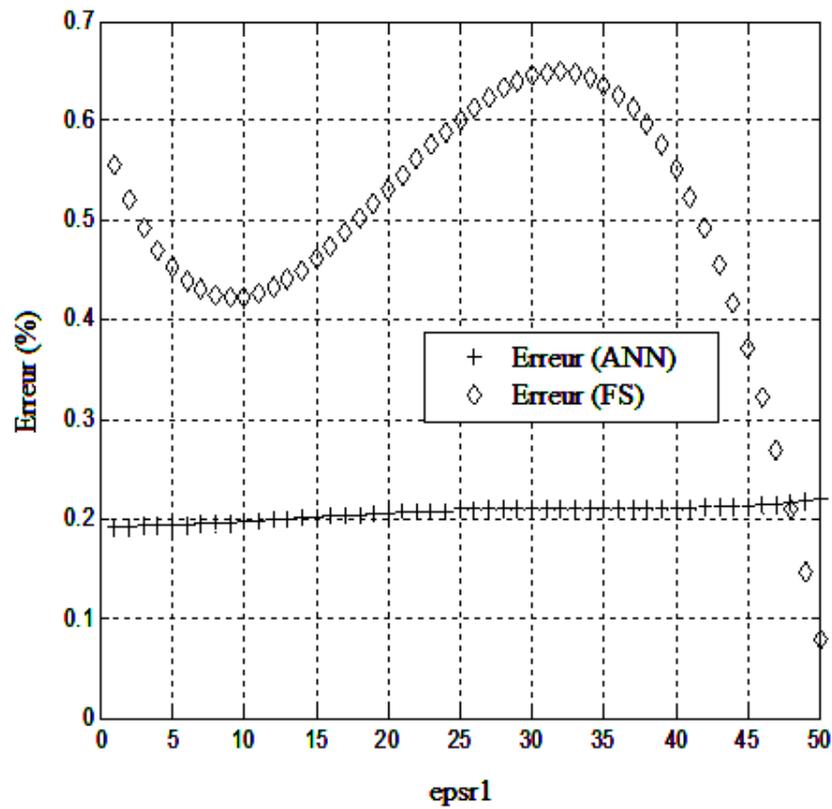


(b)

**Figure IV.15.**(a) Impédance caractéristique de la ligne coplanaire multicouche elliptique en terme de  $(2\Phi/2\Phi + \theta_1 + \theta_2)$ , (b) Pourcentage d'erreur dans  $Z_0$ .

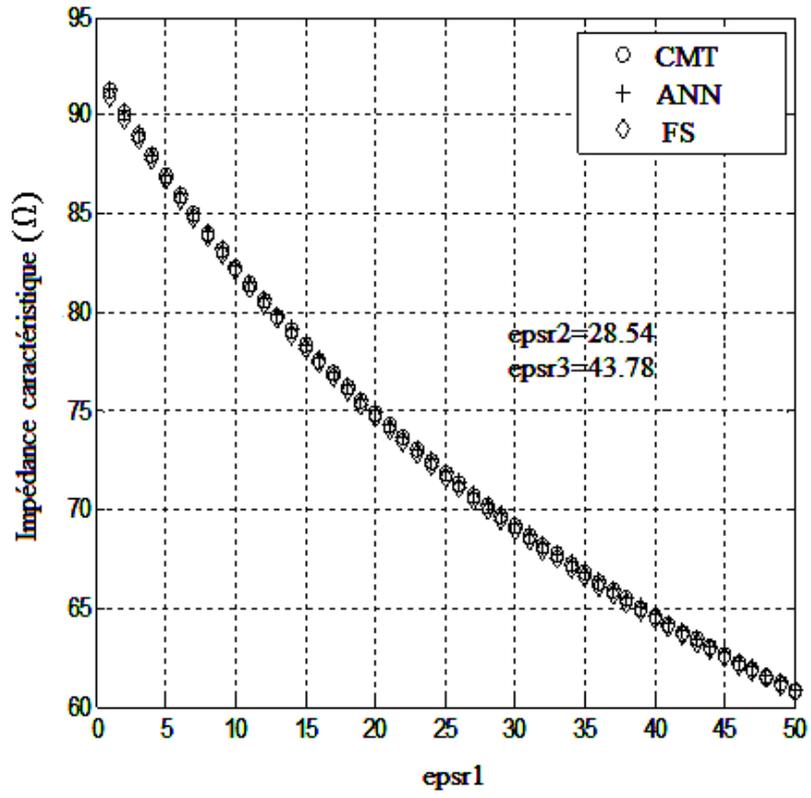


(a)

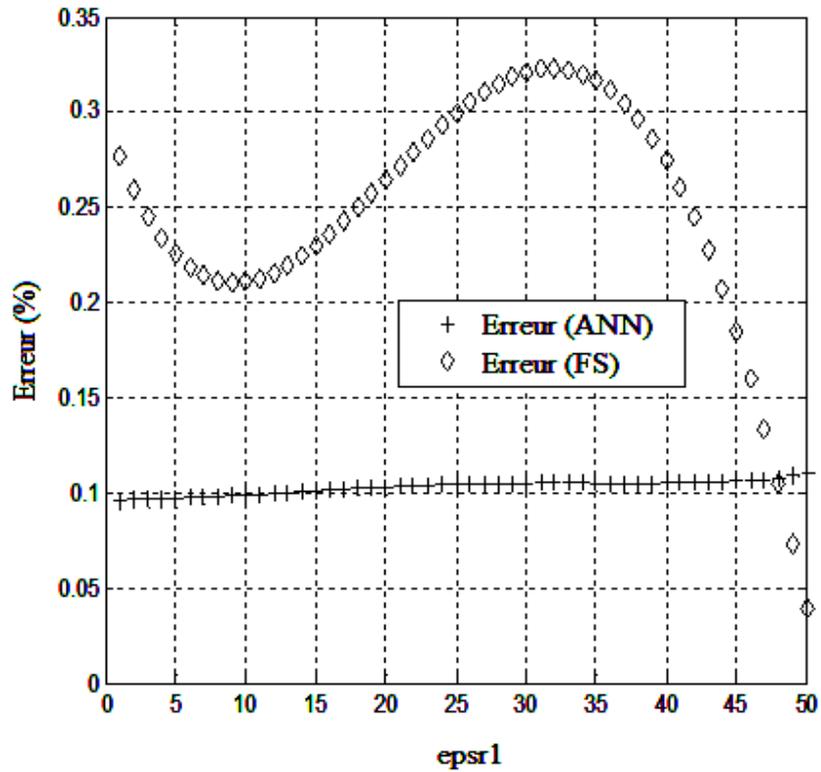


(b)

**Figure IV.16.**(a) Permittivité effective du MACPS en terme de  $\epsilon_{r1}$ , (b) Pourcentage d'erreur dans  $\epsilon_{eff}$

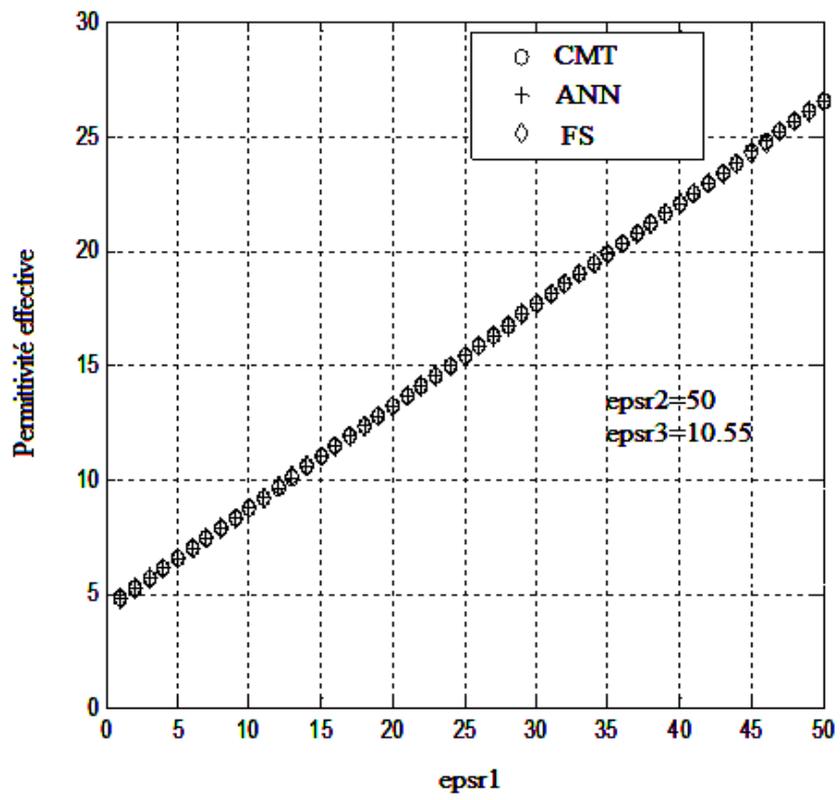


(a)

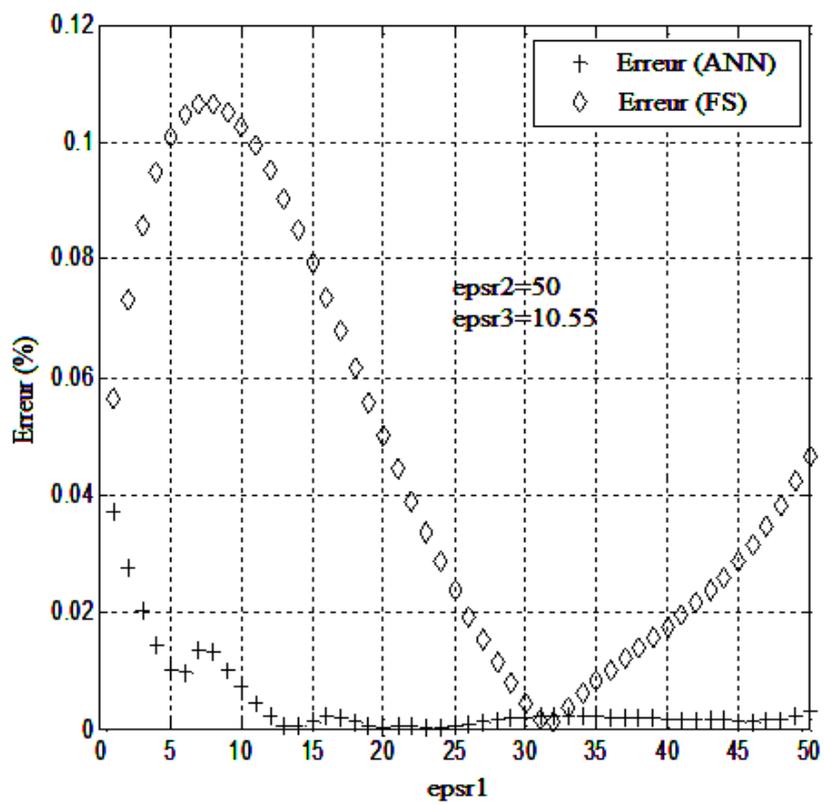


(b)

Figure IV.17.(a) Impédance caractéristique du MACPS en terme de  $\epsilon_{r1}$ , (b) Pourcentage d'erreur dans  $Z_0$

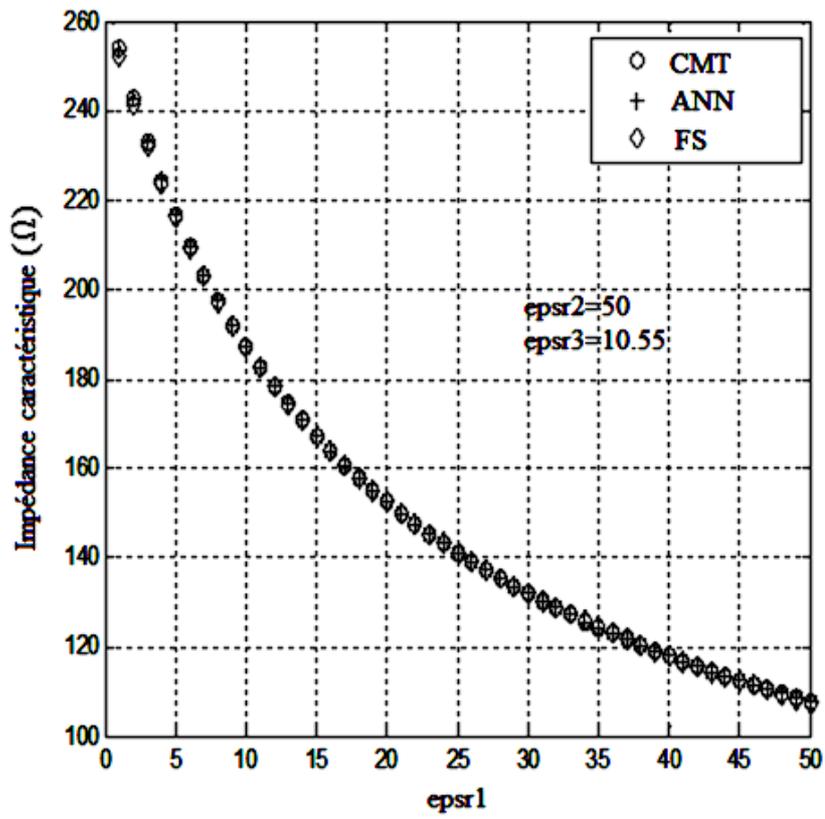


(a)

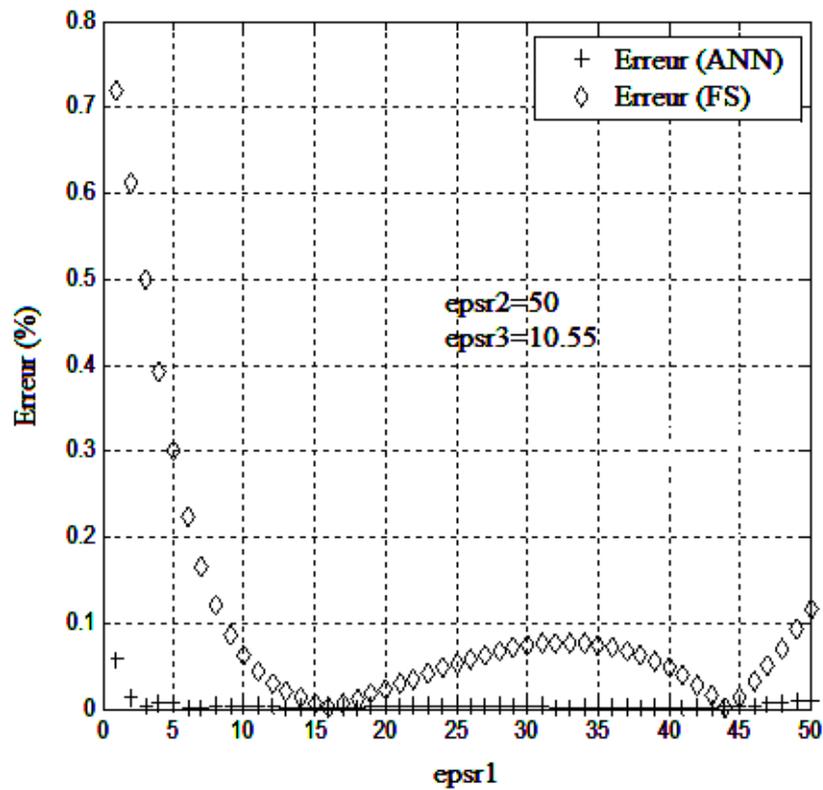


(b)

**Figure IV.18.**(a) Permittivité effective du MCCPS en terme de  $\epsilon_{r1}$ , (b) Pourcentage d'erreur dans  $\epsilon_{eff}$

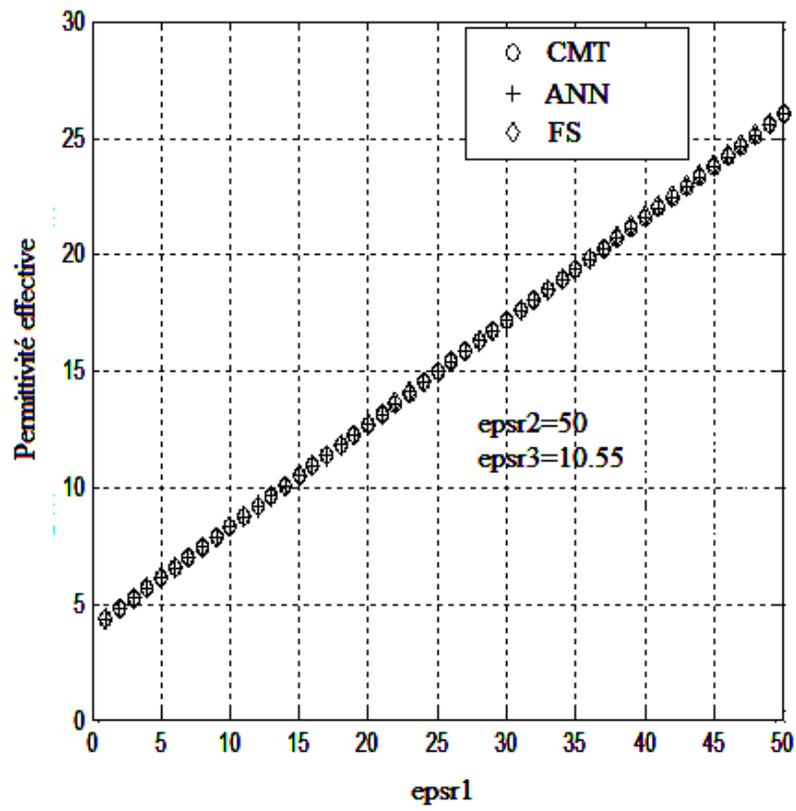


(a)

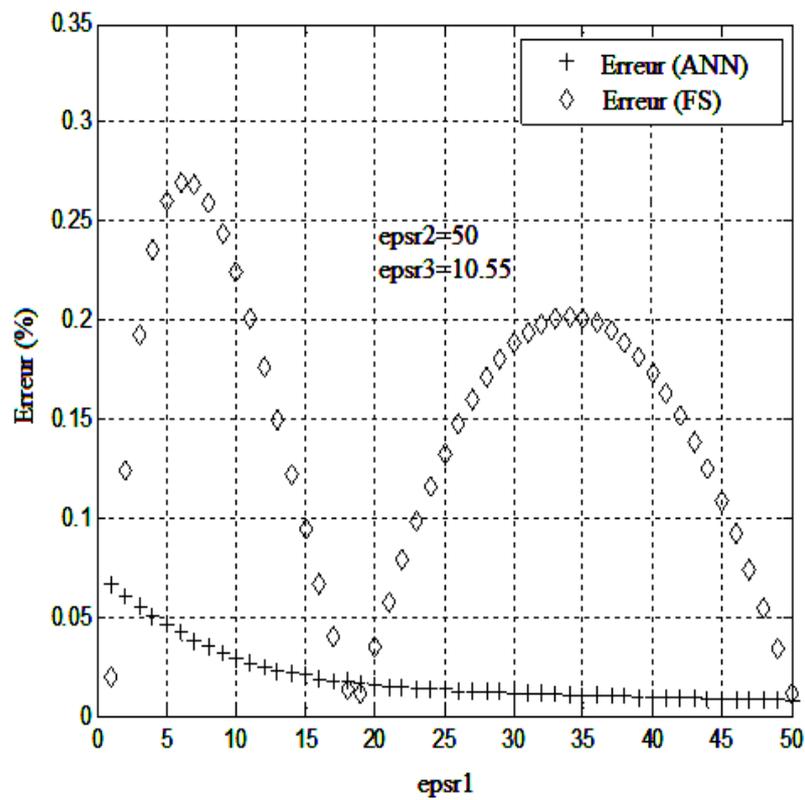


(b)

Figure IV.19.(a) Impédance caractéristique du MCCPS en terme de  $\epsilon_{r1}$ , (b) Pourcentage d'erreur dans  $Z_0$ .

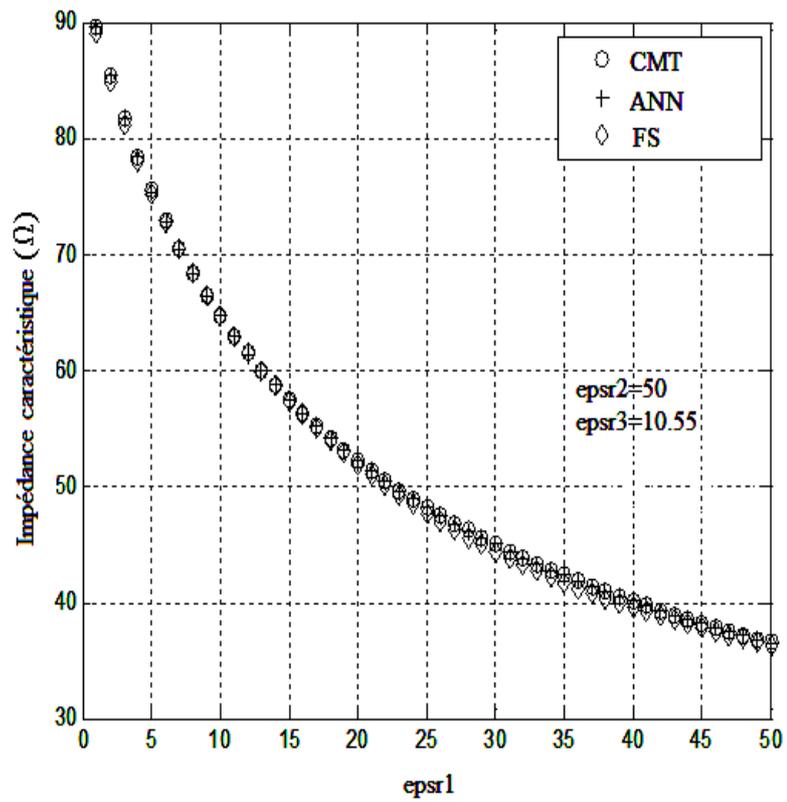


(a)

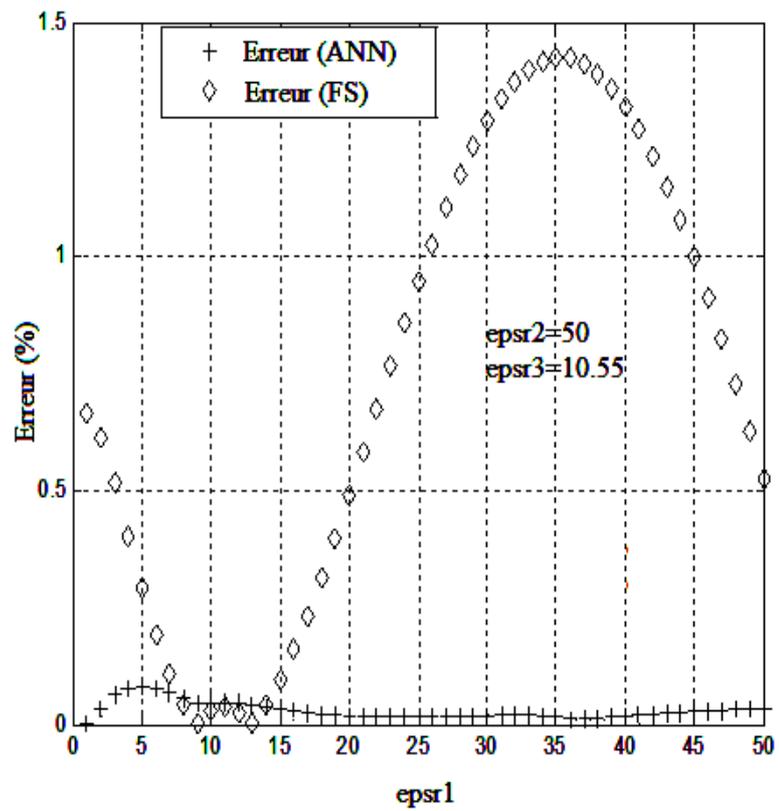


(b)

**Figure IV.20.**(a) Permittivité effective du MECPS en terme de  $\epsilon_{r1}$ , (b) Pourcentage d'erreur dans  $\epsilon_{eff}$

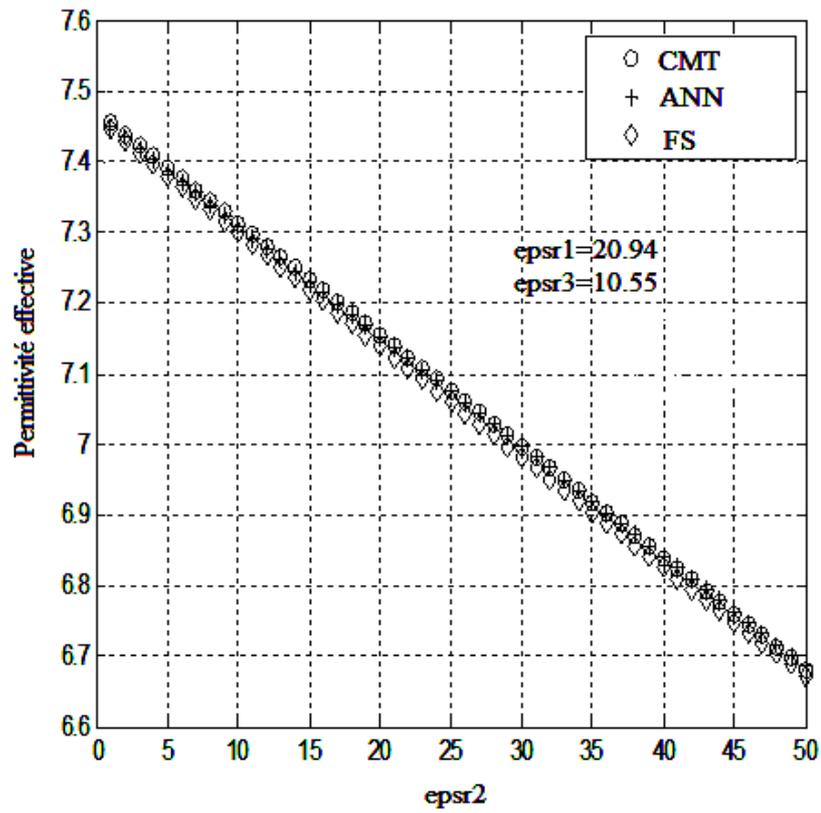


(a)

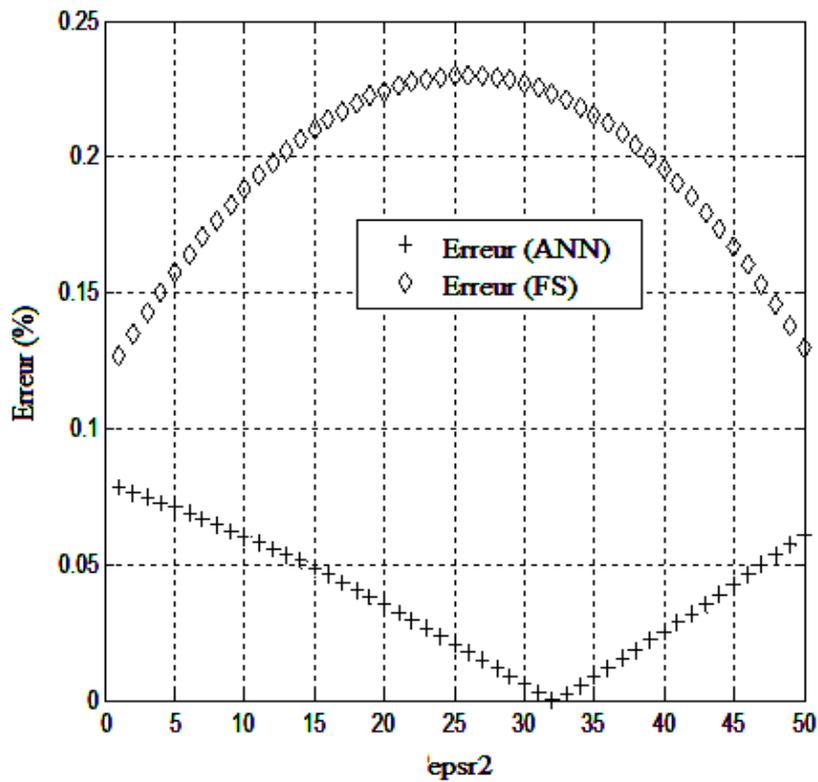


(b)

Figure IV.21.(a) Impédance caractéristique du MECPS en terme de  $\epsilon_{r1}$ , (b) Pourcentage d'erreur dans  $Z_0$

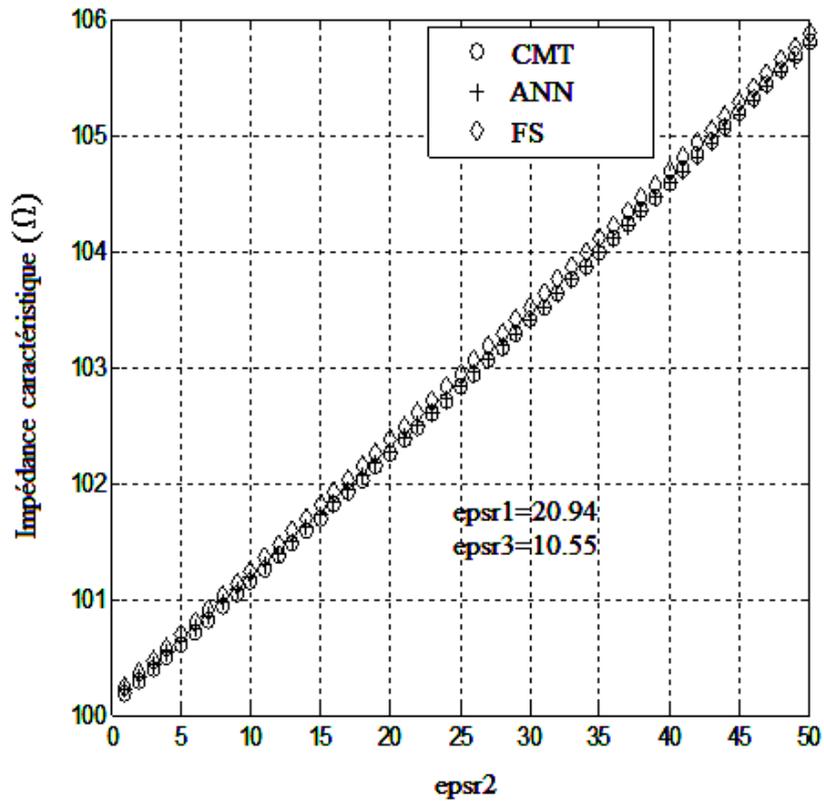


(a)

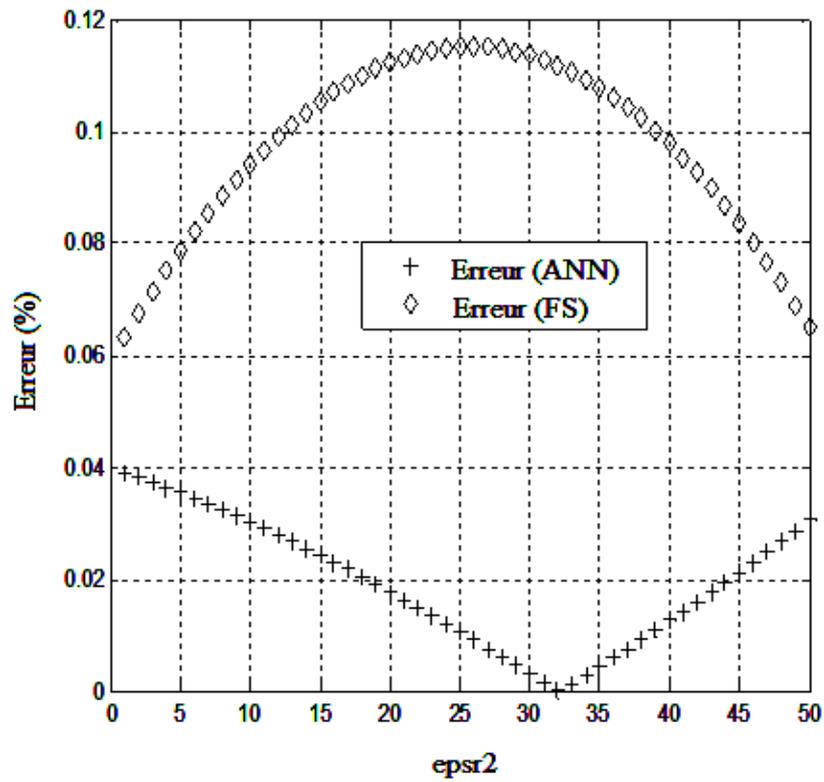


(b)

Figure IV.22. (a) Permittivité effective du MACPS en terme de  $\epsilon_{r2}$ , (b) Pourcentage d'erreur dans  $\epsilon_{eff}$

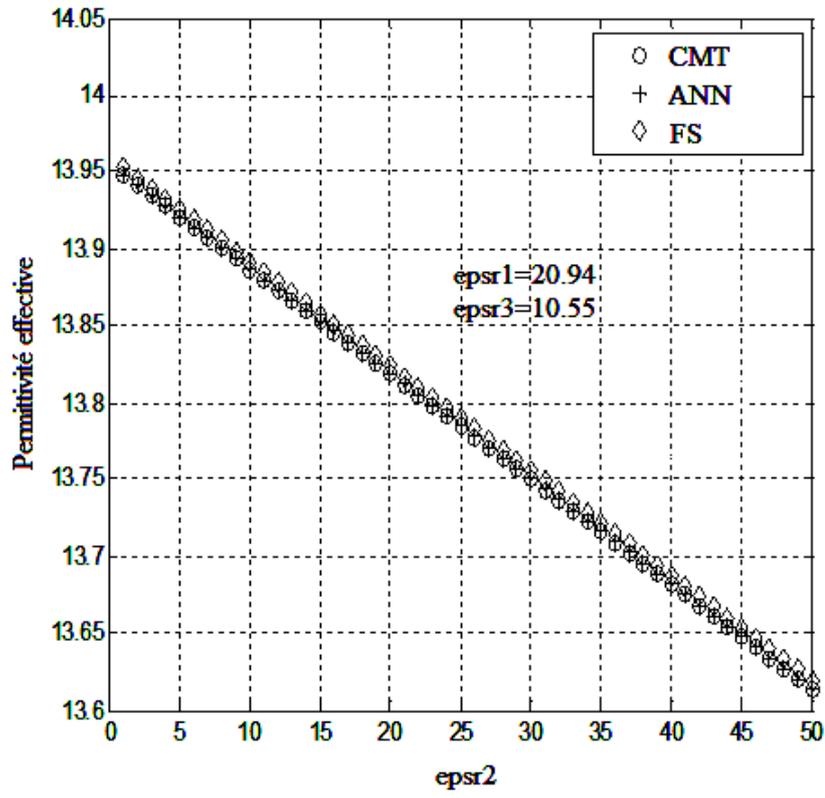


(a)

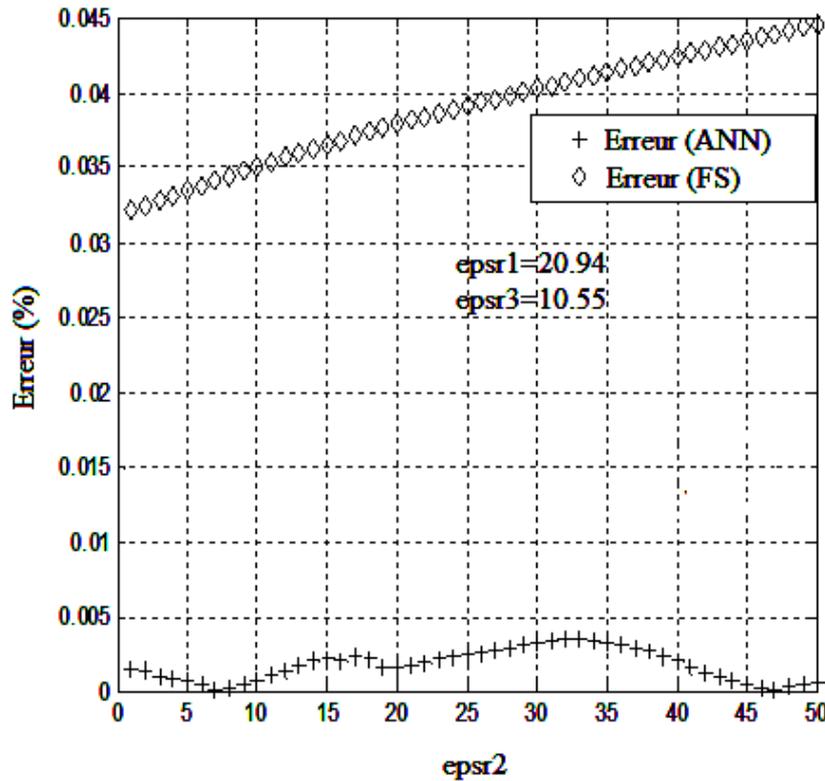


(b)

Figure IV.23.(a) Impédance caractéristique du MACPS en terme de  $\epsilon_{r2}$ , (b) Pourcentage d'erreur dans  $Z_0$



(a)



(b)

**Figure IV.24.** (a) Permittivité effective du MCCPS en terme de  $\epsilon_{r2}$ , (b) Pourcentage de l'erreur dans  $\epsilon_{eff}$

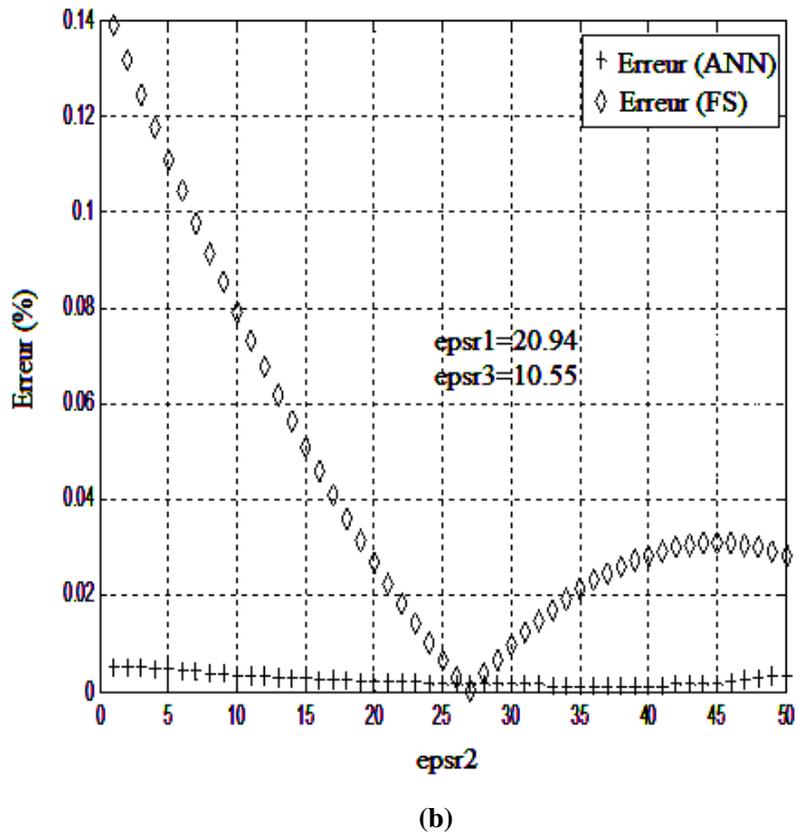
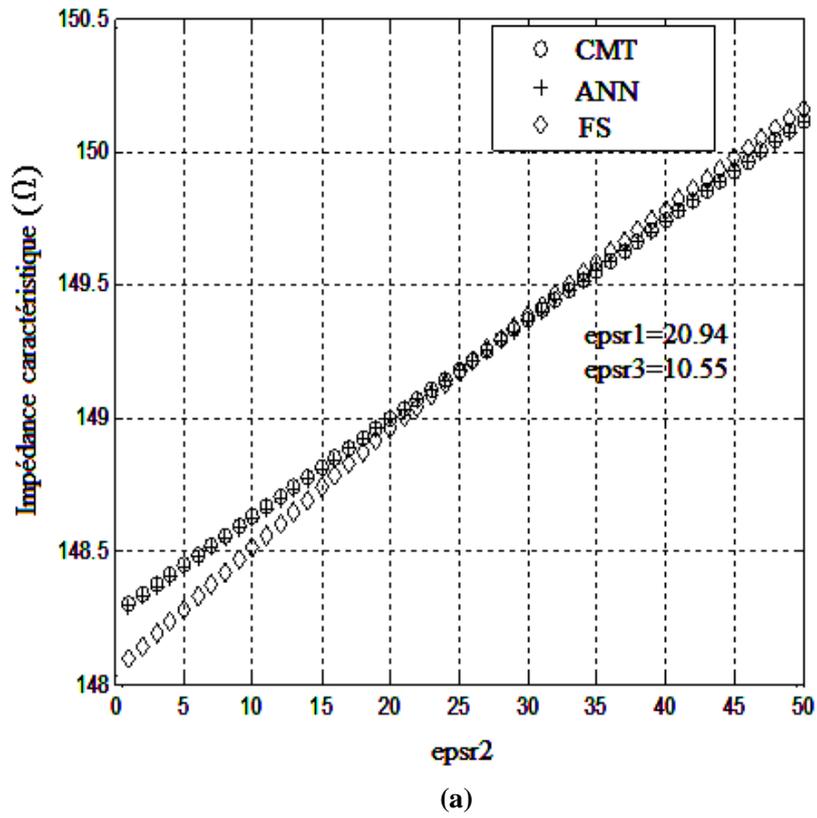
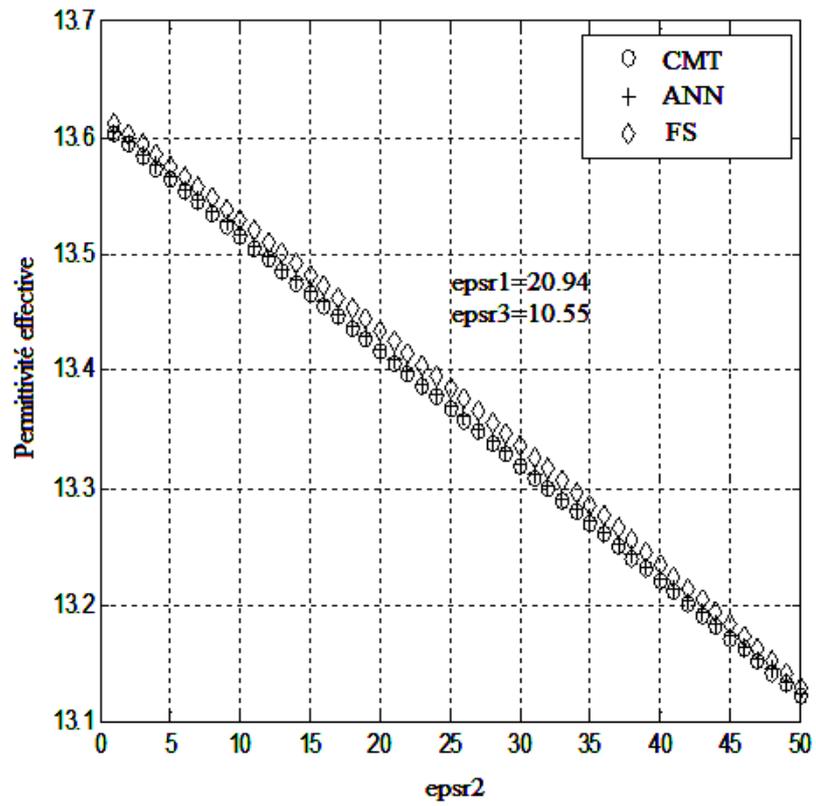
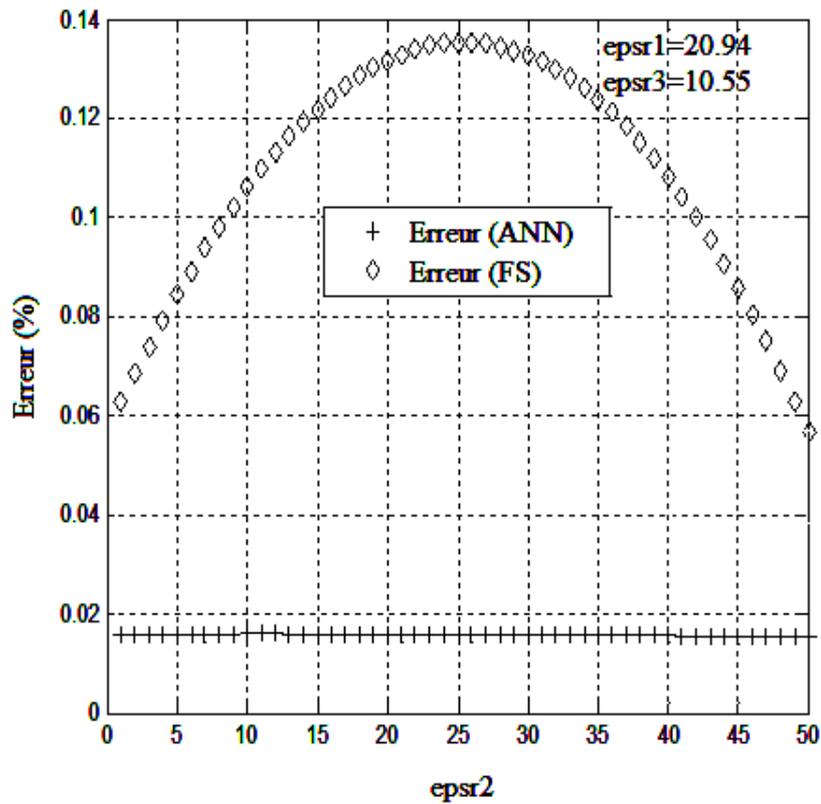


Figure IV.25.(a) Impédance caractéristique du MCCPS en terme de  $\epsilon_{r,2}$ , (b) Pourcentage d'erreur dans  $Z_0$

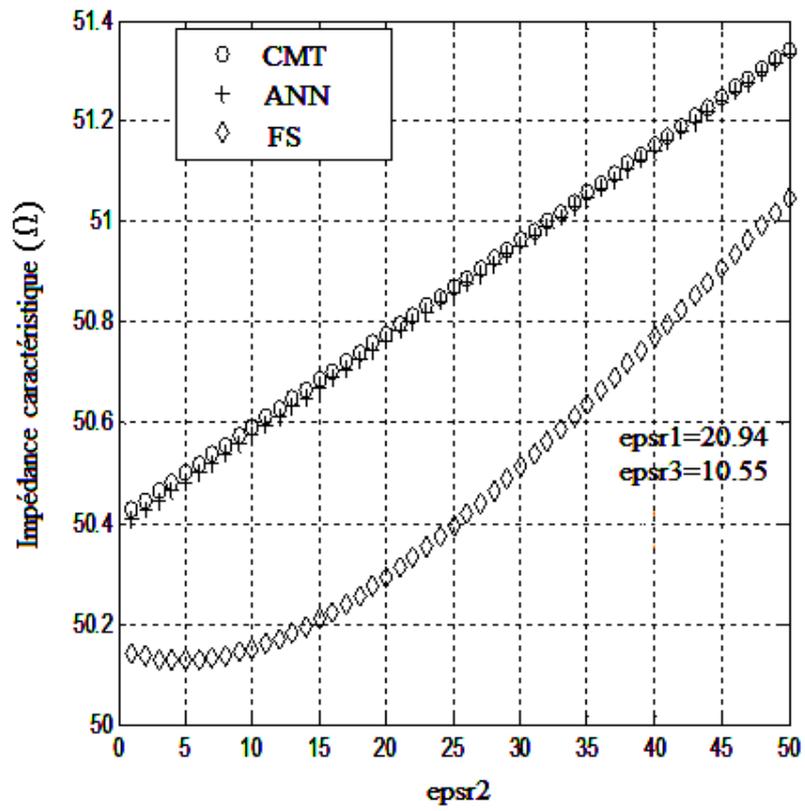


(a)

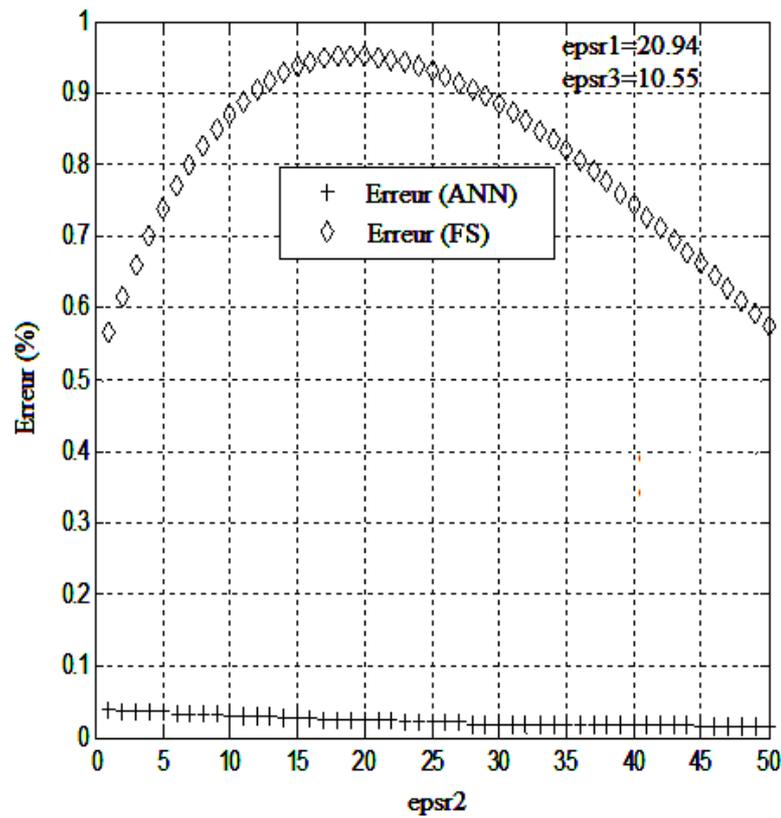


(b)

Figure IV.26.(a) Permittivité effective du MECPS en terme de  $\epsilon_{r2}$ , (b) Pourcentage d'erreur dans  $\epsilon_{eff}$

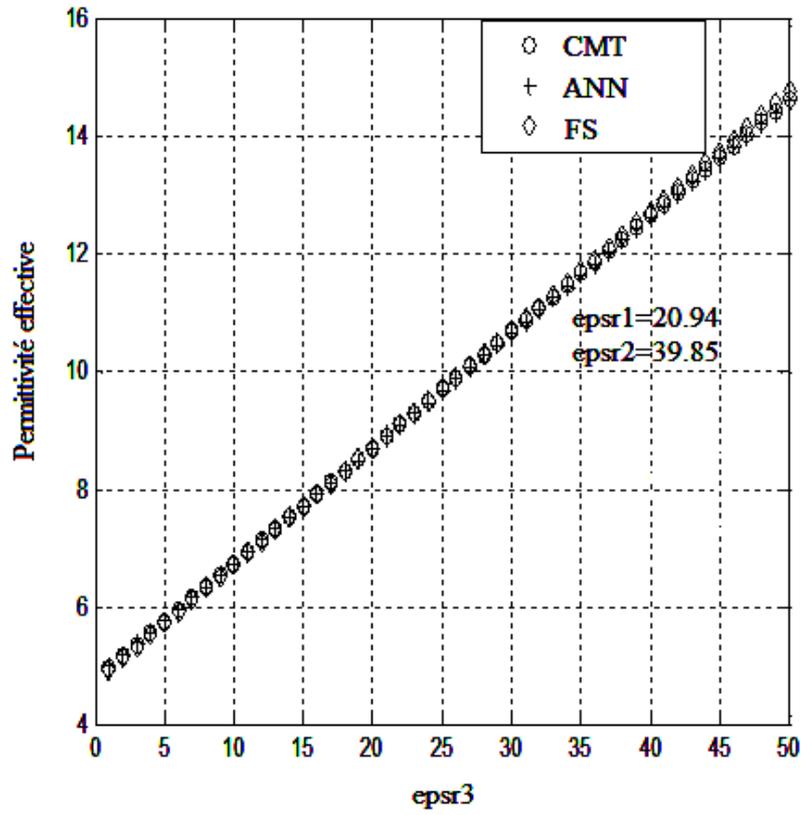


(a)

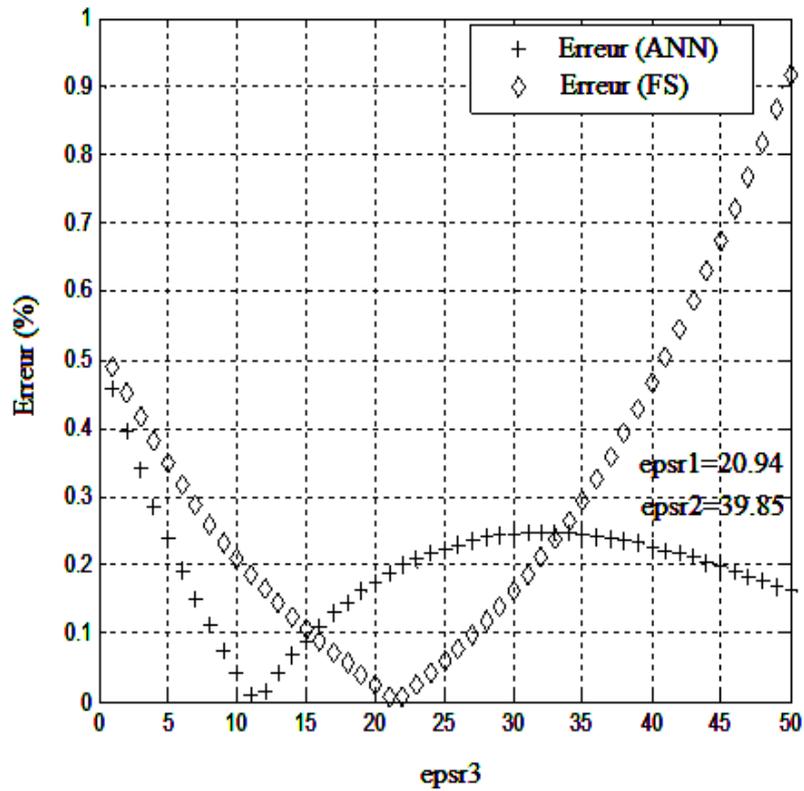


(b)

Figure IV.27. (a) Impédance caractéristique du MECPS en terme de  $\epsilon_{r2}$ , (b) Pourcentage d'erreur dans  $Z_0$



(a)



(b)

Figure IV.28.(a) Permittivité effective du MACPS en terme de  $\epsilon_{r3}$ , (b) Pourcentage d'erreur dans  $\epsilon_{eff}$

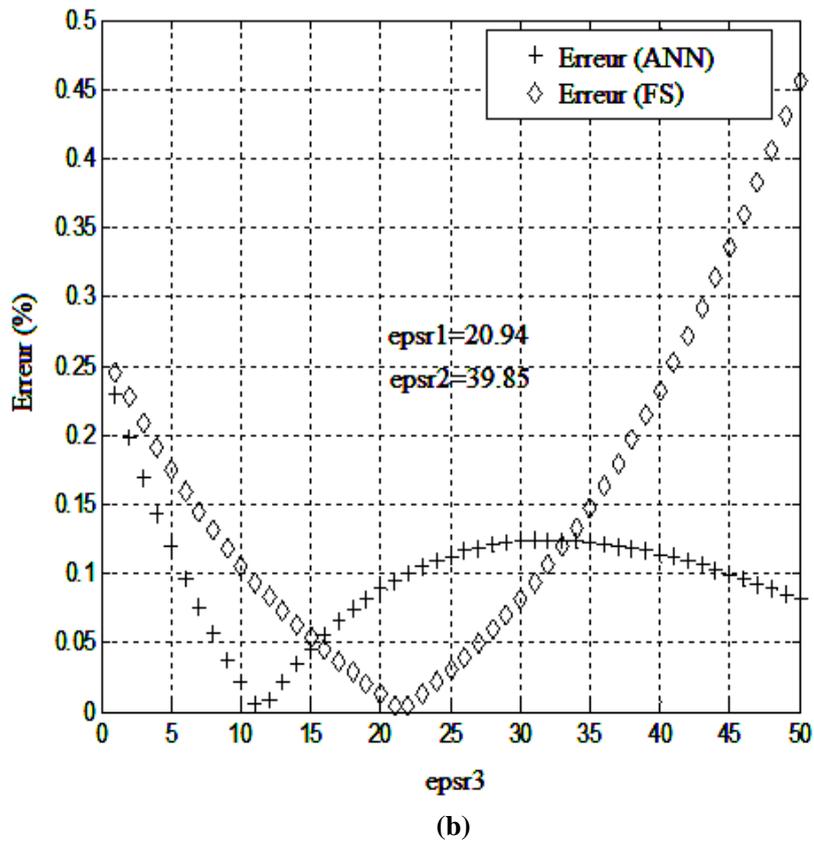
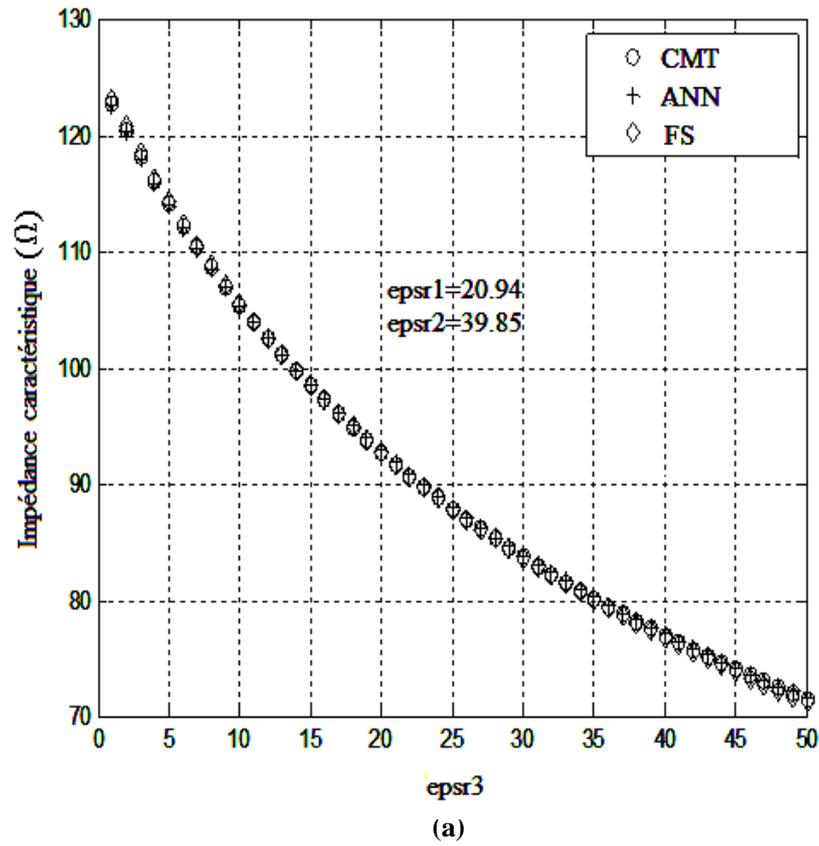
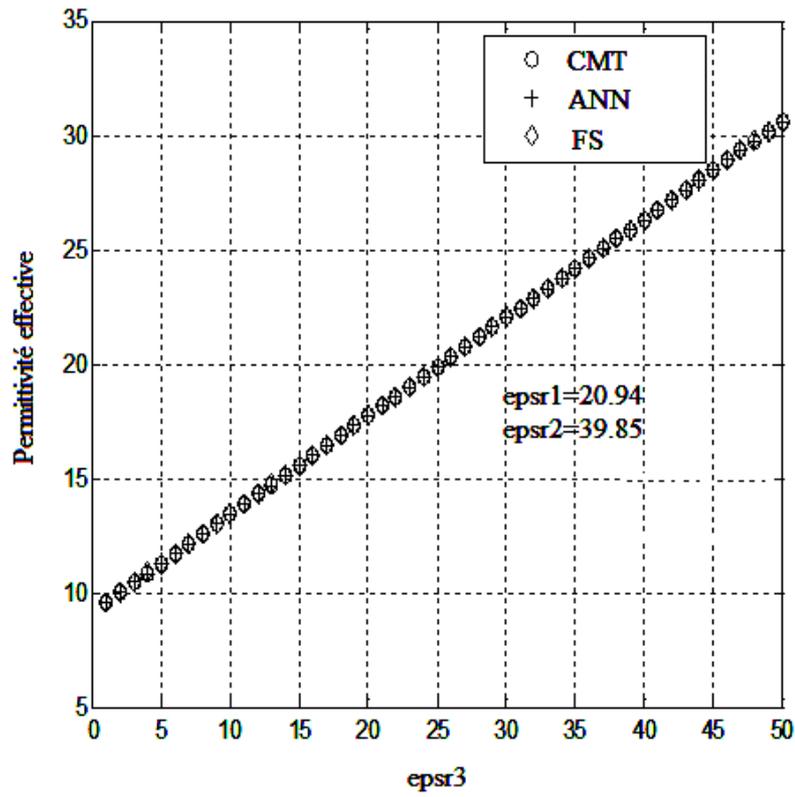
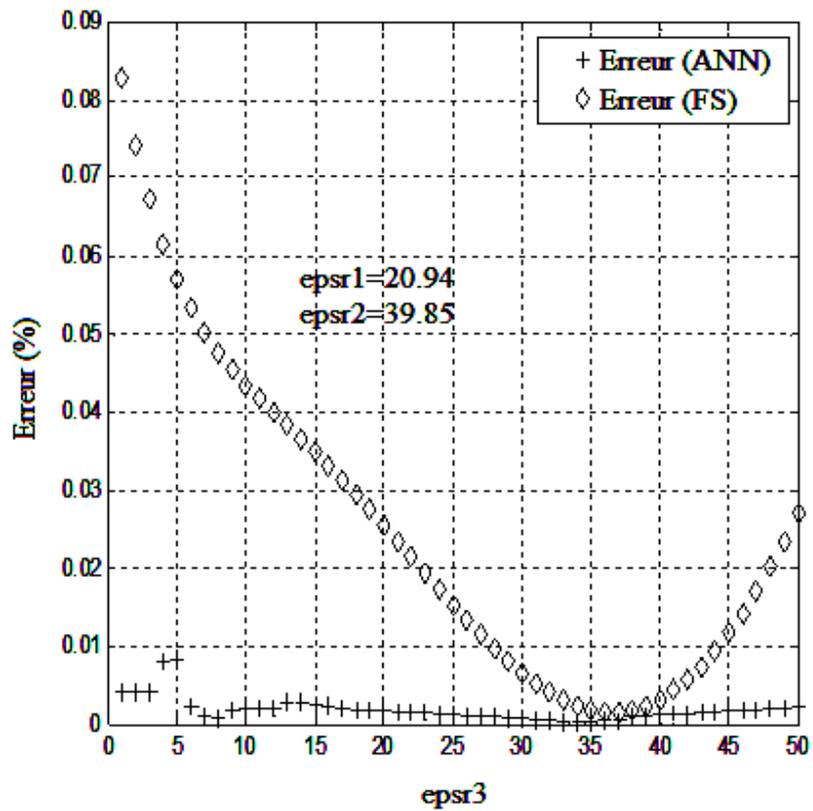


Figure IV.29.(a) Impédance caractéristique du MACPS en terme de  $\epsilon_{r3}$ , (b) Pourcentage d'erreur dans  $Z_0$

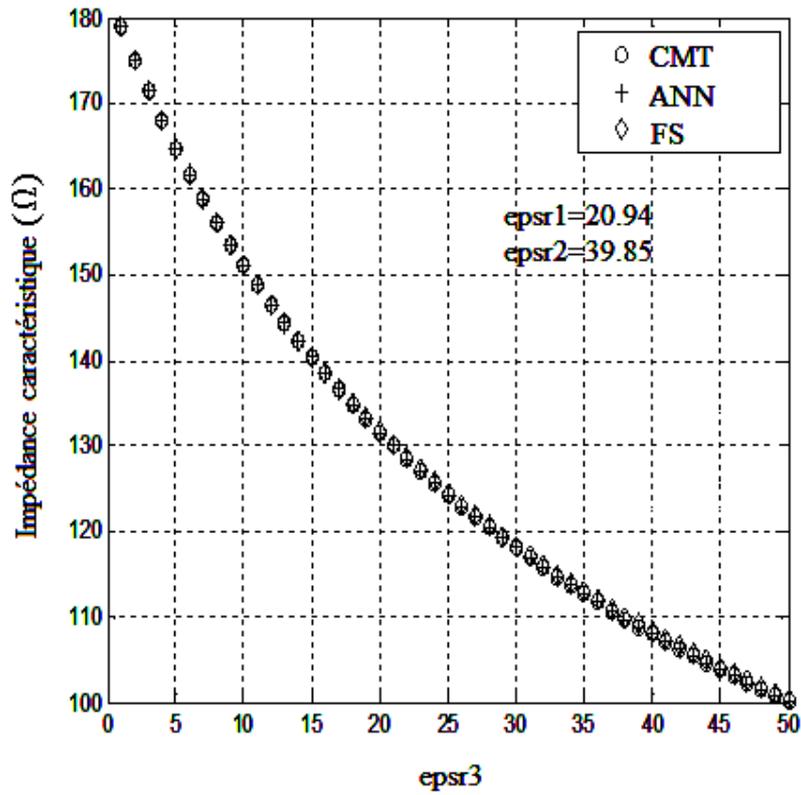


(a)

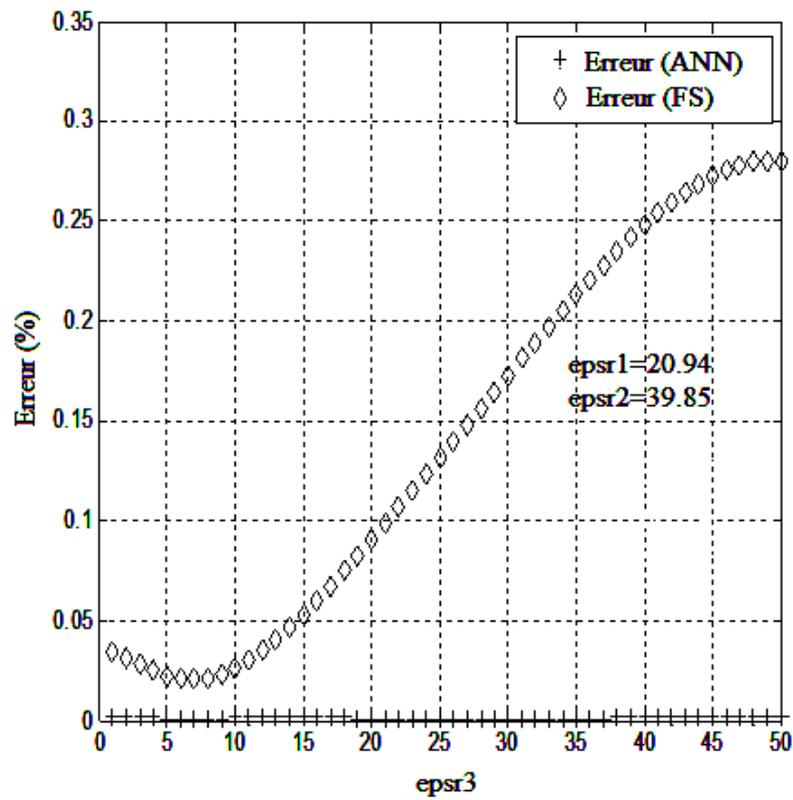


(b)

Figure IV.30.(a) Permittivité effective du MCCPS en terme de  $\epsilon_{r3}$ , (b) Pourcentage d'erreur dans  $\epsilon_{eff}$

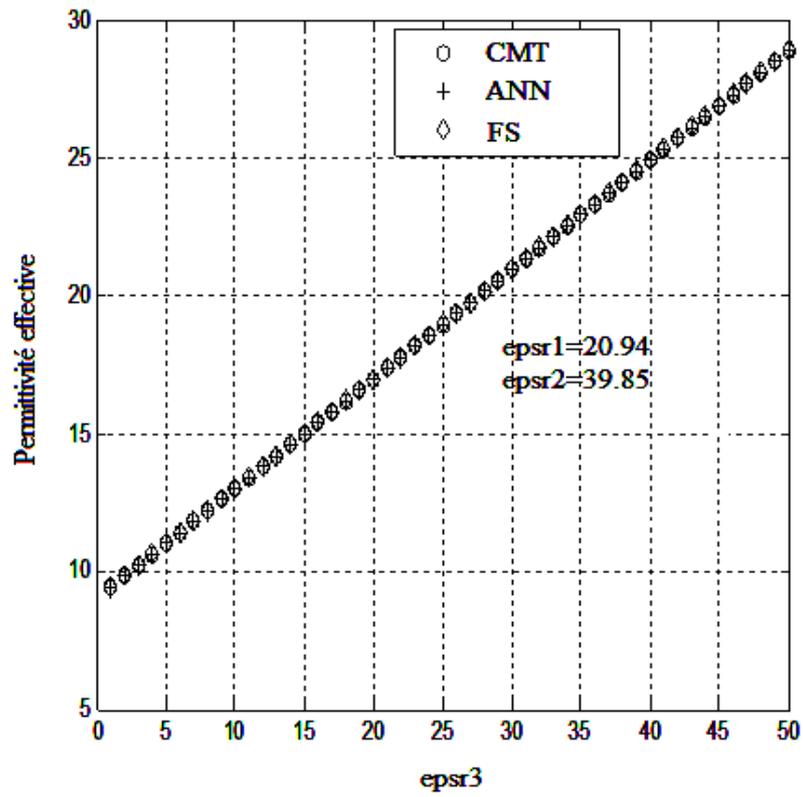


(a)

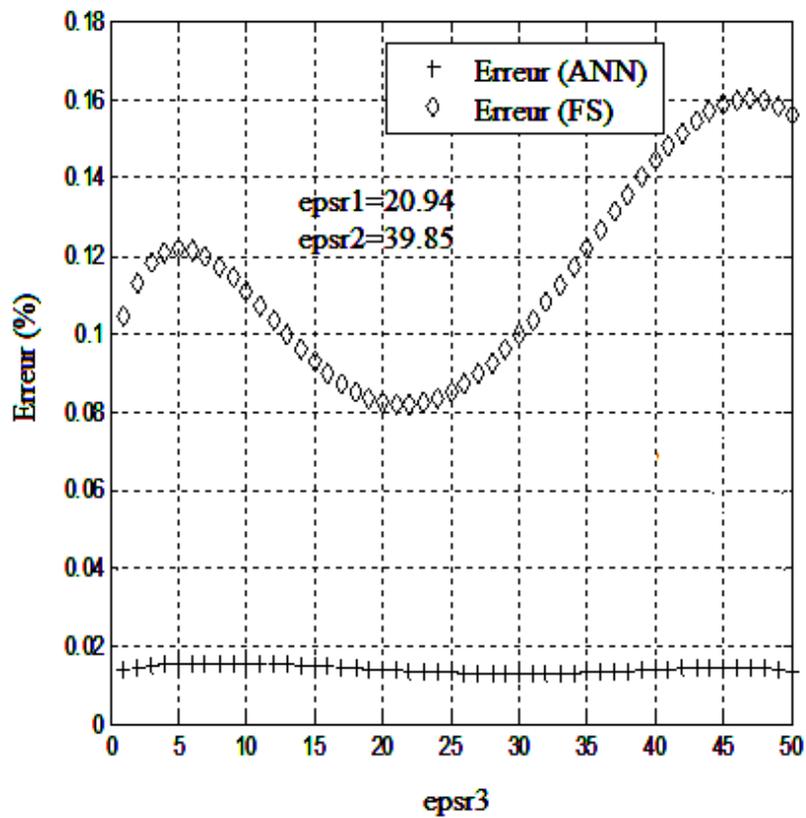


(b)

Figure IV.31.(a) Impédance caractéristique du MCCPS en terme de  $\epsilon_{r3}$ , (b) Pourcentage d'erreur dans  $Z_0$

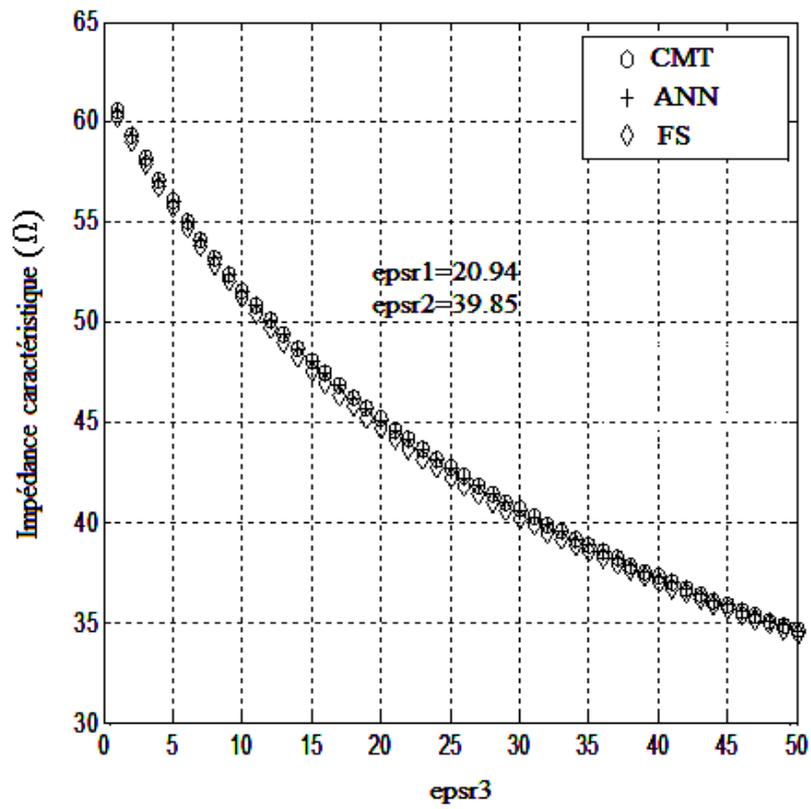


(a)

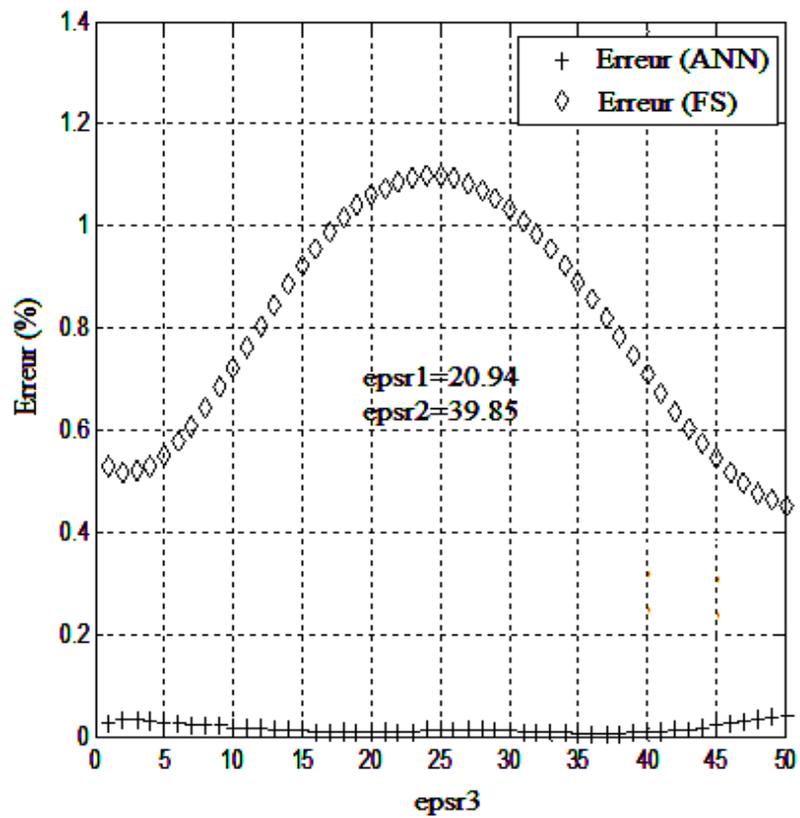


(b)

Figure IV.32. (a) Permittivité effective du MECPS en terme de  $\epsilon_{r3}$ , (b) Pourcentage d'erreur dans  $\epsilon_{eff}$

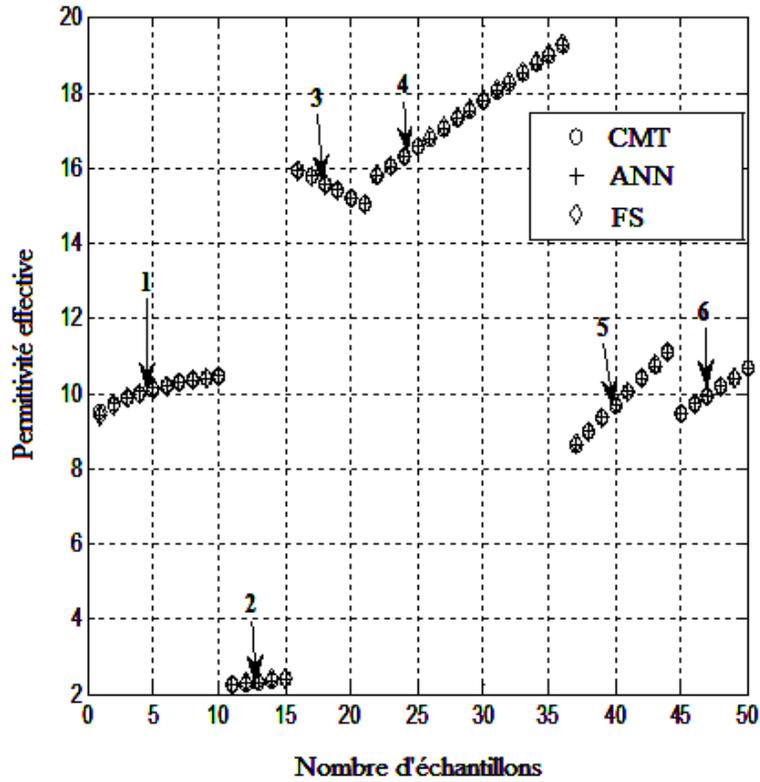


(a)

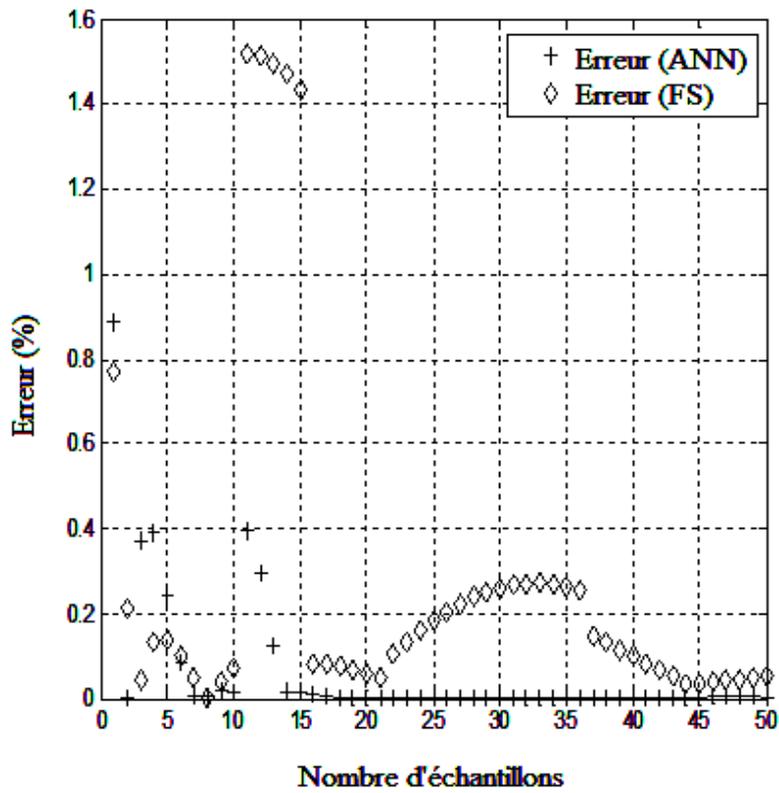


(b)

Figure IV.33.(a) Impédance caractéristique du MECPS en terme de  $\epsilon_{r3}$  , (b) Pourcentage d'erreur dans  $Z_0$

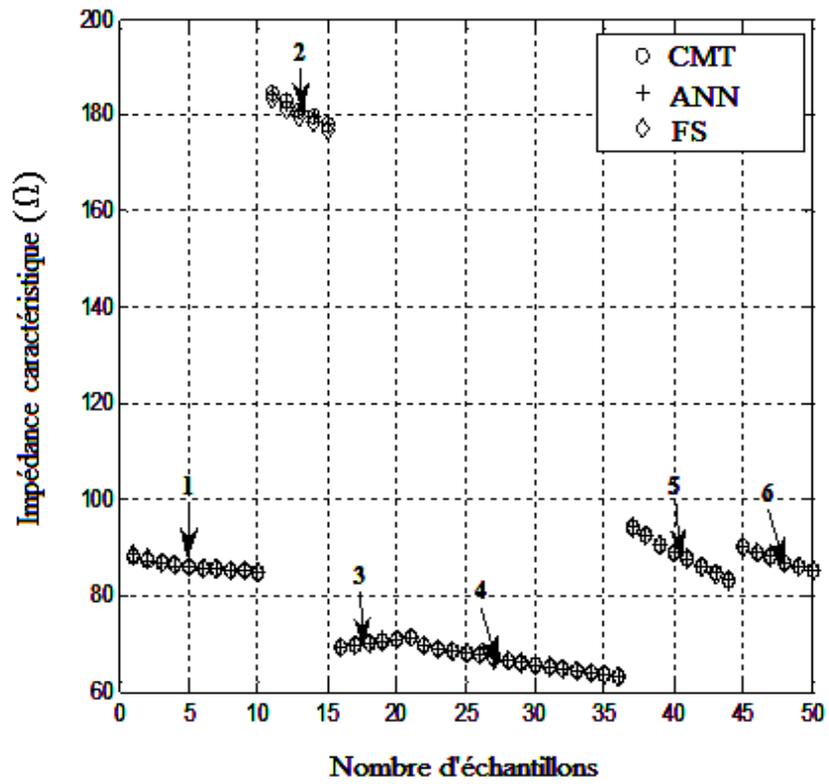


(a)

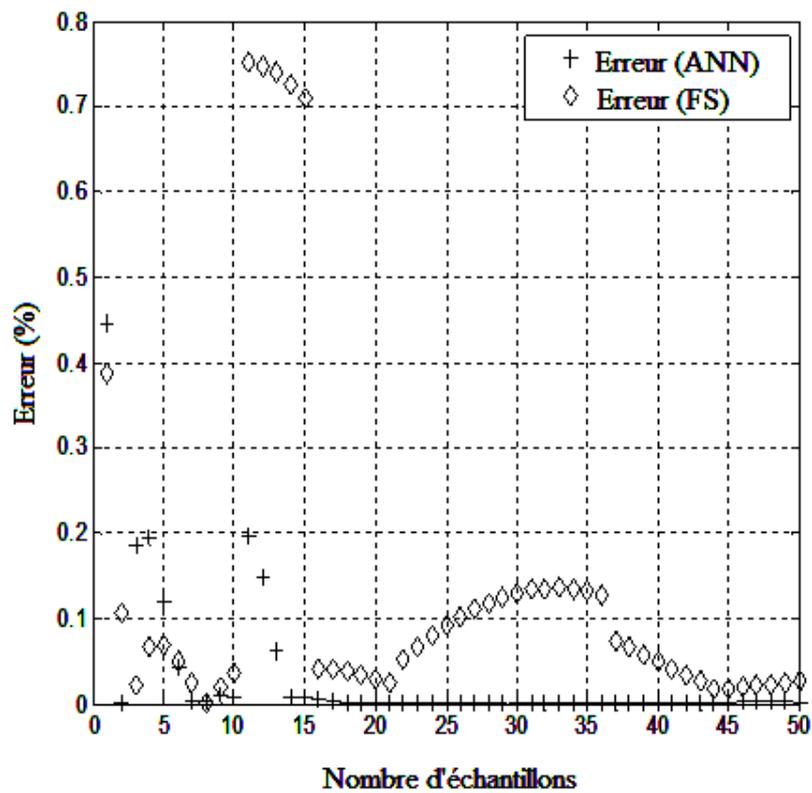


(b)

Figure IV.34. (a) Permittivité effective du MACPS où tous les paramètres varient, (b) Pourcentage d'erreur dans  $\epsilon_{eff}$

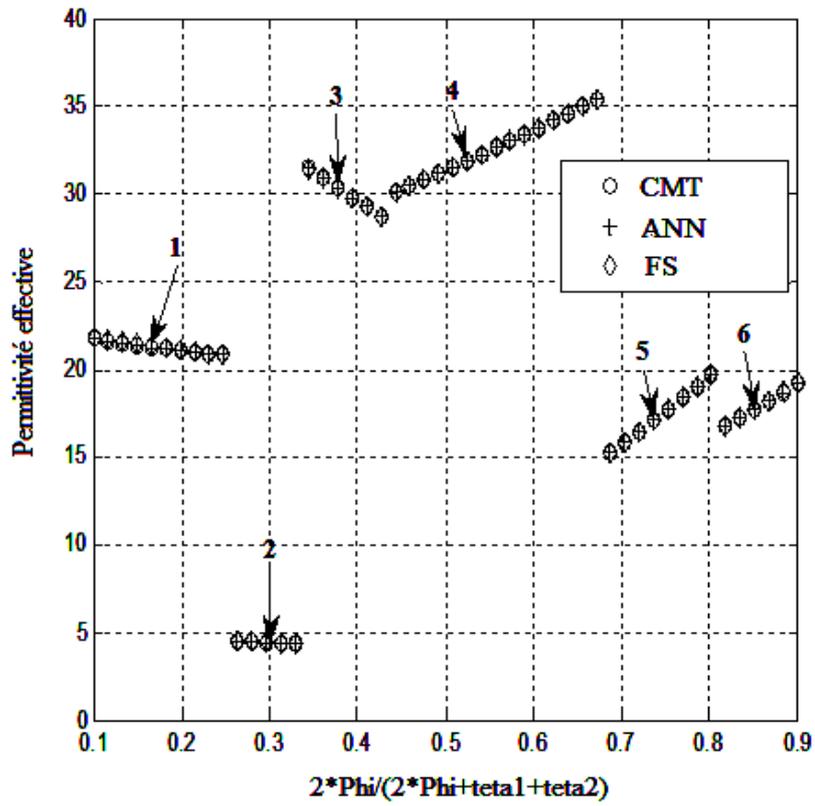


(a)

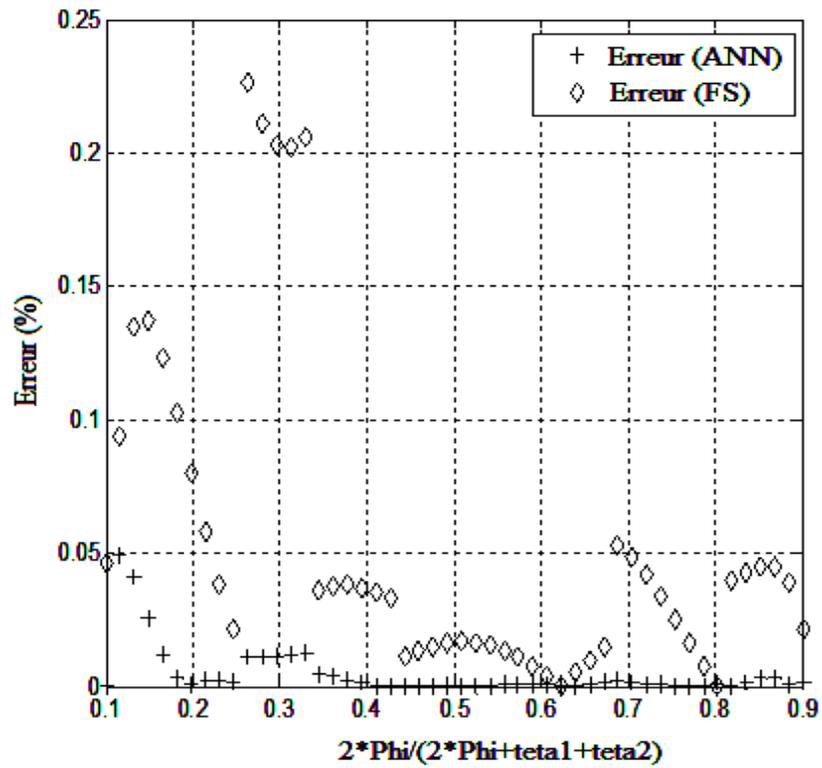


(b)

Figure IV.35. (a) Impédance caractéristique du MACPS où tous les paramètres varient, (b) Pourcentage d'erreur dans  $Z_0$

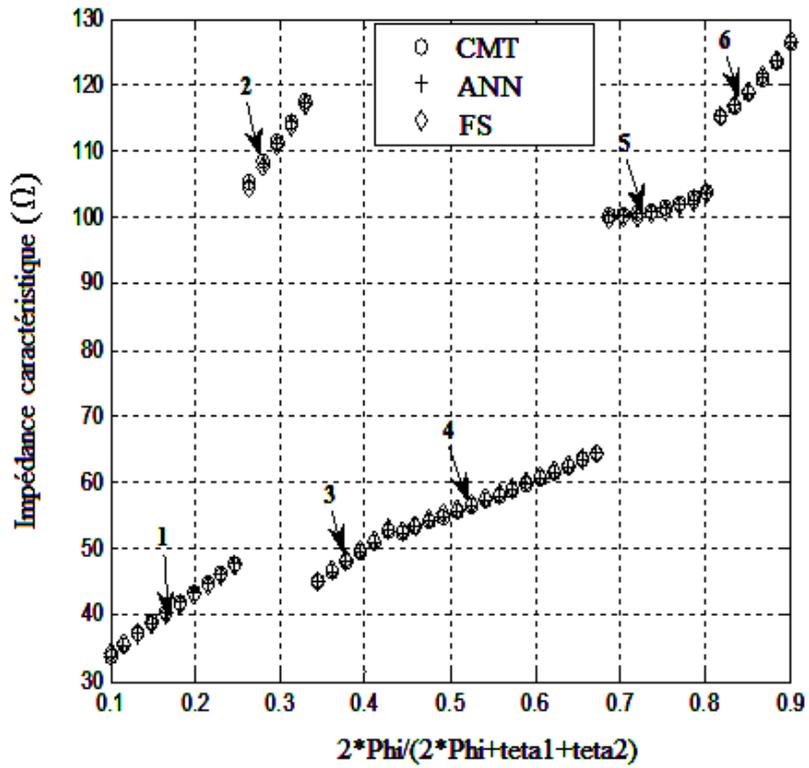


(a)

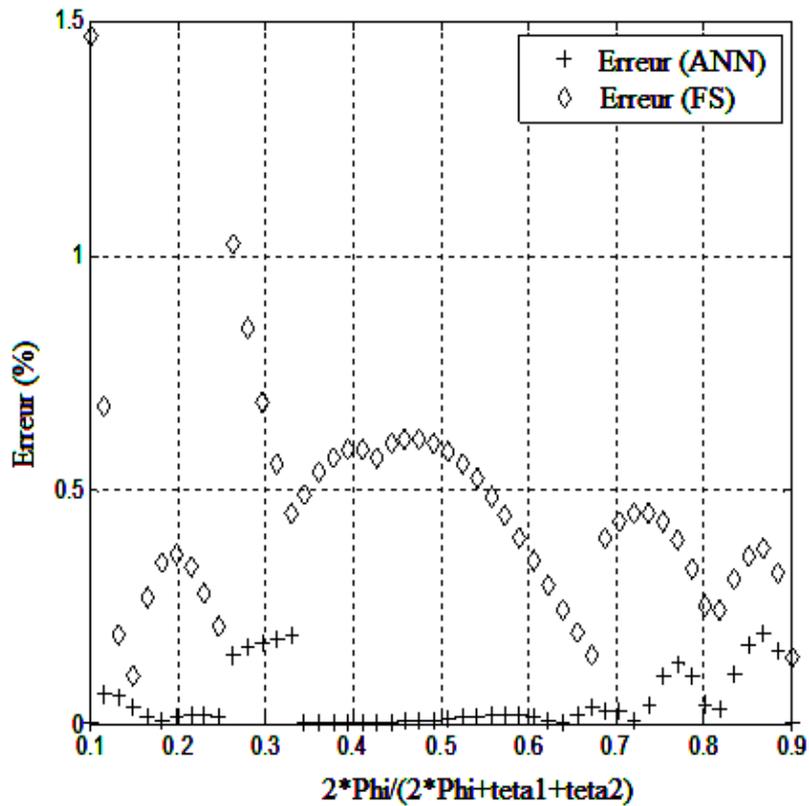


(b)

Figure IV.36.(a) Permittivité effective du MCCPS où tous les paramètres varient  
 (b) Pourcentage d'erreur dans  $\epsilon_{eff}$

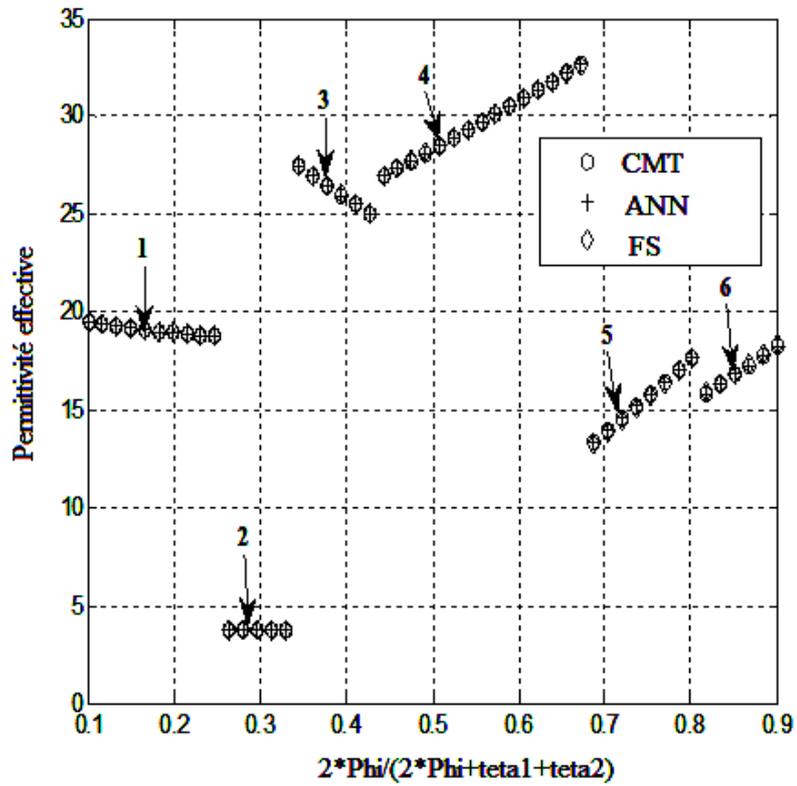


(a)

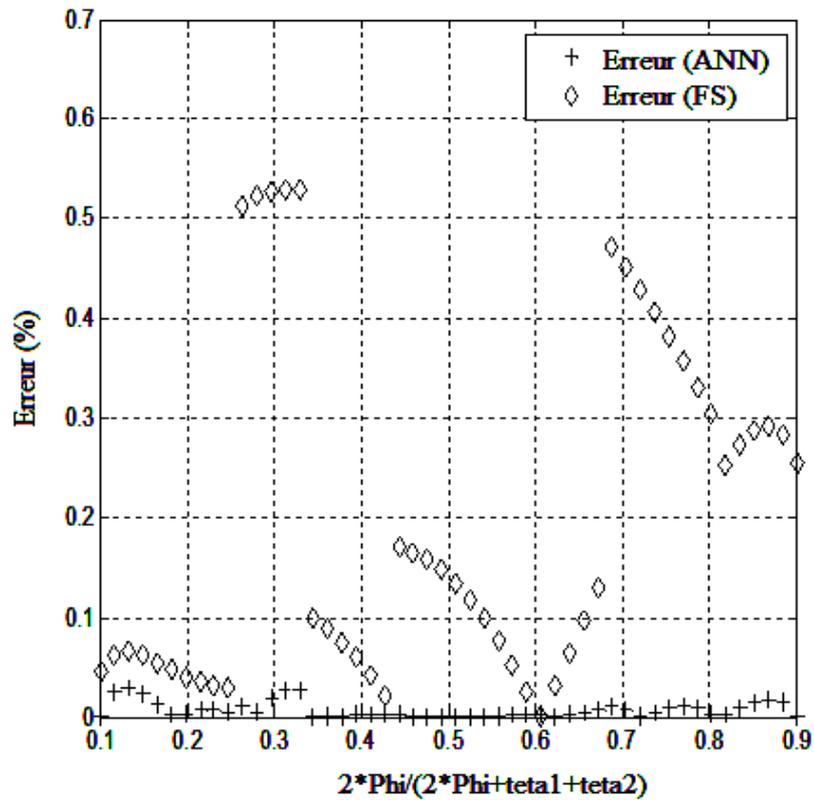


(b)

Figure IV.37. (a) Impédance caractéristique du MCCPS où tous les paramètres varient  
(b) Pourcentage d'erreur dans  $Z_0$

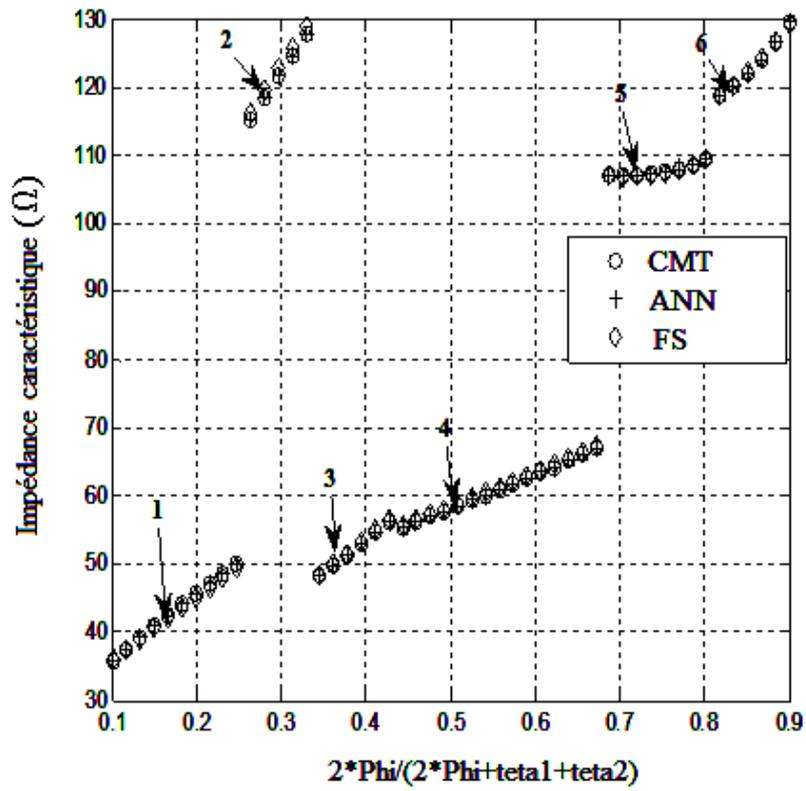


(a)

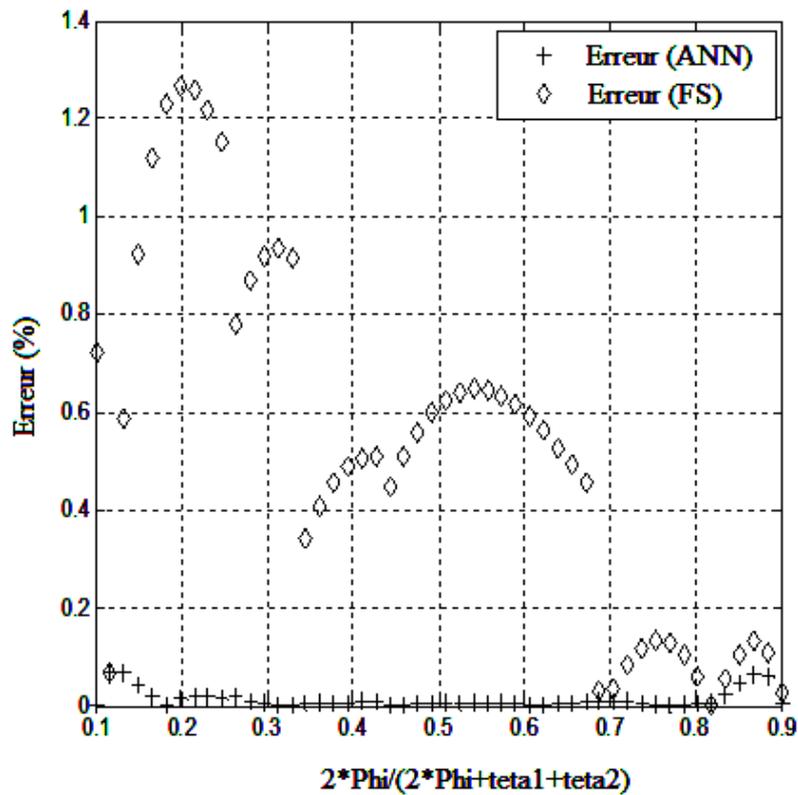


(b)

Figure IV.38.(a) Permittivité effective du MECPS où tous les paramètres varient, (b) Pourcentage d'erreur dans  $\epsilon_{eff}$



(a)



(b)

**Figure IV.39.**(a) Impédance caractéristique du MECPS où tous les paramètres varient, (b) pourcentage d'erreur dans  $Z_0$

En examinant les pourcentages d'erreur de tous les cas des lignes de transmission considérées dans ce travail, on peut voir que la CMT est très efficace puisqu'elle se compare très bien avec les résultats disponibles dans la littérature. Aussi, l'ANN et FS implémentés sont capables de prédire les paramètres quasi-statiques des lignes de transmission pour tout ensemble de valeurs des entrées appartenant à leurs domaines de variations prescrits.

#### **IV.4. Conclusion**

Nous avons présenté cinq cas de structures de lignes de transmission. Une comparaison de nos résultats obtenus concernant les paramètres quasi statiques des trois types de lignes mentionnées avec ceux disponibles dans la littérature. Ensuite, des résultats de la permittivité effective et de l'impédance caractéristique des lignes de transmission ont été générés et entraînés par les réseaux de neurones artificiels et la logique floue. Le modèle de référence utilisé pour les réseaux de neurones et la logique floue étant la transformée conforme dont le nombre de variables peut atteindre 14 échantillonnées à 10000 points. Les résultats obtenus sont commentés et discutés. Tous les résultats obtenus dans ce chapitre sont présentés par la simulation utilisant le logiciel Matlab®R13 . Finalement une interprétation, une discussion de ces résultats ont été présentée.

***Références bibliographiques***

- [1] V. Akan and E. Yazgan, "Quasi-Static Solutions of Multilayer Elliptical, Cylindrical Coplanar Striplines and Multilayer Coplanar Striplines with Finite Dielectric Dimensions - Asymmetrical Case," *IEEE Transactions on Microwave Theory and Techniques*, vol. 53, n° 12, pp. 3681–3686, December 2005.

---

## ***CONCLUSION GÉNÉRALE***

## ***CONCLUSION GÉNÉRALE***

Dans ce travail, nous avons étudié l'identification des paramètres quasi-statiques des lignes de transmission multicouches symétriques/asymétriques (MACPS), (MCCPS) et (MECPS). Les expressions mathématiques du modèle de la transformée conforme ont été développées pour ces lignes de transmission. La formulation est généralisée prenant en compte un nombre arbitraire de couches diélectriques ci-dessus et / ou en dessous de l'interface des rubans est présentée sous forme compactée.

- Premièrement, nous avons développé les modèles théoriques expérimentaux basés sur la transformée conforme pour la caractérisation des lignes de transmission multicouches symétriques / asymétriques (MACPS), (MCCPS) et (MECPS).
- Deuxièmement, l'architecture du ANN et FS ont été mise en œuvre et formées pour modéliser les paramètres quasi-statiques des lignes de transmission, en utilisant la méthode de rétro-propagation en conjonction avec des algorithmes de LM et le modèle TSK respectivement, tel que la technique CMT étant le modèle de référence. A l'aide de codes développés sous le logiciel Matlab, le nombre total d'entrées du ANN et FS peut être augmenté à quatorze, et alors les structures obtenues peuvent être examinées facilement en utilisant la méthode proposée.
- Troisièmement, certaines lignes de transmission ont été étudiées et des résultats obtenus en utilisant CMT, ANN, et FS ont été comparés. Dans tous les cas, un très bon accord entre les trois méthodes mentionnées ci-dessus est obtenu.

Enfin, on peut souligner que les méthodes présentées peuvent être facilement appliquées à d'autres problèmes de micro-onde. Précises, rapides et fiables l'ANN et le FS peuvent être développées à partir des données mesurées/ simulées de micro-onde. Une fois l'apprentissage est accompli, la mise au point de ces méthodes pourrait être utilisés à la place des modèles numériques de calcul intensif pour accélérer l'analyse et le design de l'appareil micro-onde.

Il est nécessaire comme perspective de:

- Considérer d'autre méthode intelligente comme la logique floue type 2 , qui est utilisée en vue de concevoir une structure robuste dans le cas de présence des incertitudes de modélisation ou linguistiques entravant l'obtention des fonctions d'appartenance précises.
- Remplacer le modèle quasi-statique basé sur la CMT par une méthode full-wave telle que les éléments finis ou les différences finies. On peut alors explorer d'autres formes de lignes de transmission.