

TABLE DES MATIÈRES

RÉSUMÉ	iii
REMERCIEMENTS	iv
TABLE DES MATIÈRES	v
LISTE DES TABLEAUX	vii
LISTE DES FIGURES	viii
LISTE DES ACRONYMES	x
CHAPITRE I :INTRODUCTION	1
1.1 Objectifs	2
1.2 Méthodologie employée	3
1.3 Plan du mémoire	3
CHAPITRE II : Réseaux de neurones et application InfiniTEM	4
2.1 Réseaux de neurones artificiels	4
2.1.1 Introduction aux réseaux de neurones artificiels	4
2.1.2 Structure des réseaux de neurones artificiels	5
2.1.3 Architecture des réseaux de neurones	9
2.1.3.1 Les réseaux récurrents « FEED-BACK »	9
2.1.3.2 Réseaux propagation vers l'avant « FEED-FORWARD »	11
2.1.4 Apprentissage d'un réseau de neurone	13
2.1.5 L'algorithme d'apprentissage	15
2.2 Méthodes électromagnétiques (EM)	18
2.2.1 Introduction aux méthodes EM en géophysique	18
2.2.2 Théorie fondamentale de la méthode électromagnétique	19
2.2.3 Méthodes électromagnétiques fréquentielles (FDEM)	24
2.2.4 Méthodes électromagnétiques Temporelles (TDEM)	26
2.2.5 Configuration des systèmes électromagnétiques	29
CHAPITRE III : Modélisation InfiniTEM	32
3.1 Configuration InfiniTEM	32

3.2 Modélisation directe de la réponse InfiniTEM	34
3.2.1 Description du logiciel utilisé pour la modélisation	35
3.2.2 Signatures type des plaques minces générées par l’InfiniTEM	37
3.2.3 Étude du comportement du système InfiniTEM	48
3.2.3.1 Influence de la taille du conducteur à différents pendages	57
3.2.3.2 Influence de la conductance sur les conducteur à différents	58
Pendages	58
3.2.3.3 Influence de la position latérale à différents pendages	58
3.2.3.4 Influence de la taille de la boucle émettrice	59
3.2.4 Banque de données pour l’application des RNA	59
CHAPITRE IV : Application des RNA sur les données InfiniTEM	62
4.1 Processus du système RNA utilisé	62
4.1.1 Choix des paramètres d’entrée et de sortie	63
4.1.2 Choix des paramètres du modèle RNA	64
4.2 L’apprentissage du système de RNA utilisé	74
4.3 Résultats de prédiction	74
4.4 Discussion	77
CHAPITRE V: CONCLUSION ET RECOMMANDATION	79
BIBLIOGRAPHIE	81
ANNEXE I : Réponse InfiniTEM des conducteurs à différents pendages	88
ANNEXE II : Canaux d’échantillonnage pour l’InfiniTEM	95

LISTE DES TABLEAUX

LISTE DES FIGURES

Figure 3.16 : Influence de la conductance sur un conducteur vertical.....	49
Figure 3.17 : Influence de la position sur un conducteur vertical.....	50
Figure 3.18 : Influence de la taille sur un conducteur incliné.....	51
Figure 3.19 : Influence de la taille sur un conducteur incliné.....	51
Figure 3.20 : Influence de la position sur un conducteur incliné.....	52
Figure 3.21 : Influence de la taille sur un conducteur horizontal.....	53
Figure 3.22 : Influence de la conductance sur un conducteur horizontal.....	53
Figure 3.23 : Influence de la position sur un conducteur horizontal.....	54
Figure 3.24 : Influence de l'espacement entre les deux demi-boucles	55
Figure 3.25 : Influence de l'espacement entre les deux demi-boucles	56
Figure 3.26 : Influence de l'espacement entre les deux demi-boucles	57
Figure 4.1 : Schéma de la procédure d'apprentissage de notre RNA.....	63
Figure 4.2 : Processus du modèle RNA.....	64
Figure 4.3: Variation de l'erreur pour une couche cachée	67
Figure 4.4 : Variation de l'erreur pour 2 couches cachées.....	67
Figure 4.4 : Variation de l'erreur pour 3 couches cachées.....	68
Figure 4.6 : Variation de l'erreur pour 4 couches cachées.....	68
Figure 4.7: Variation RMS en fonction du nombre d'itérations pour une couche	70
Figure 4.8 : Variation RMS en fonction du nombre d'itérations pour 2 couches.....	71
Figure 4.9 : Variation RMS en fonction du nombre d'itérations pour 3 couches.....	72
Figure 4.10 : Variation RMS en fonction du nombre d'itérations pour 4 couches.....	73
Figure 4.11 : Erreur relative sur la prédiction de l'inclinaison	75
Figure 4.12 : Erreur relative sur la prédiction de la conductance	76
Figure 4.13 : Erreur relative sur la prédiction de la Profondeur	76

LISTE DES ACRONYMES

b	Vecteur d'induction magnétique en tesla (T)
d	Vecteur de déplacement diélectrique en coulomb par mètre carré (C/m^2)
e	Vecteur d'intensité du champ électrique en volt par mètre (V/m)
$e_s(t)$	Intensité du champ électrique en volt par mètre (V/m)
fem	Force électromotrice
$FDEM$	Électromagnétisme dans le domaine fréquentiel
h	Vecteur d'intensité du champ magnétique en ampère par mètre (A/m)
I_0	Courant initial émis au transmetteur
j	vecteur de densité de courant électrique en ampère par mètre carré (A/m^2)
k	Nombre d'onde
L	Inductance du conducteur.
M_{01}	Terme de couplage entre le transmetteur et le conducteur
M_{02}	Terme de couplage entre le transmetteur et le récepteur
M_{12}	Terme de couplage entre le conducteur et le récepteur
m	Vecteur de polarisation
PMC	Perceptron multicouches
O_p	Vecteur de sortie désiré
p	Vecteur de polarisation
RNA	Réseaux de neurones artificiels
RBF	Fonctions à base radial
SLP	Perceptron monocouches
$TDEM$	Électromagnétisme dans le domaine temporel
VMS	Sulfures massifs volcanogènes
$w_{j,k,i}$	Poids du neurone k de la couche j et le neurone i de la couche j .

x_p	Vecteur d'entrée du réseau
y_p	Vecteur de sortie du réseau
\hat{y}	Additivité électrique
\hat{z}	Impédance électrique
$\frac{\partial b_x}{\partial t}$	Dérivée de la composante horizontale du champ magnétique
$\frac{\partial b_y}{\partial t}$	Dérivée de la composante transversale du champ magnétique
$\frac{\partial b_z}{\partial t}$	Dérivée de la composante verticale du champ magnétique
$\theta_{j,k}$	Poids fictif du neurone k de la couche j
σ	Conductivité électrique du milieu
σ_a	Conductivité apparente du milieu
ϵ	Permittivité diélectrique du milieu
ϵ_0	Permittivité diélectrique du vide = 8.854×10^{-12} F/m
μ	Perméabilité magnétique
μ_0	Perméabilité magnétique du vide = $4 \pi \times 10^{-7}$ H/m
ρ	densité de charge électrique en coulomb par mètre cube (C/m^3)
δ	profondeur de peau « Skin depth »
τ	Constante de temps

CHAPITRE I

INTRODUCTION

Développées dans les années 60 pour l'exploration minière, les méthodes électromagnétiques en géophysiques constituent un outil robuste pour la détection des métaux de base sous forme massive. Les gisements de sulfure massive constituent une cible de choix pour les industries grâce à leur excellente conductivité, d'où l'intérêt et l'importance de la recherche et du développement des techniques d'acquisition électromagnétiques.

La configuration InfiniTEM est une technique d'acquisition électromagnétique qui opère dans le domaine de temps (TDEM), cette technique est développée conjointement par Abitibi Géophysique inc. et SOQUEM inc. La configuration InfiniTEM est bien adaptée pour les cibles profondes (supérieur à 400 mètres de profondeur) peu importe les conditions du terrain. Elle présente de précieux avantages comparant aux autres configurations traditionnelles grâce à l'intensité du champ primaire qui est presque doublée en profondeur et grâce aussi au couplage minime avec le mort terrain.

Afin de bien exploiter les techniques d'acquisition électromagnétique il faut avoir recours aux outils de traitement et d'interprétation qui permettent à l'opérateur d'extraire le plus efficacement possible toute les informations utiles. Parmi les outils mathématiques qui peuvent répondre à nos besoin on peut citer la méthode des réseaux de neurones artificiels (RNA) qui constitue un outil d'approximation de systèmes complexes qui sont difficiles à modéliser par les méthodes statistiques classiques.

Actuellement il y'a un intérêt grandissant pour l'utilisation d'algorithmes de réseaux de neurones dans des problèmes qui relèvent des sciences physiques et de l'ingénier (Haykin, 1999), (Mackay, 1992). L'intérêt porté à ces réseaux neuronaux réside dans leurs capacités de généralisation et de leur faisabilité d'implantation (Graf et al, 1988), (Mead, 1989), (Murray, 1989). A priori, ces algorithmes peuvent être appliqués aux problèmes de classification, de regroupement, de prévision, d'identification, d'optimisation combinatoire et de contrôle de procédés (Kohonen, 1988). Il existe plusieurs types de réseaux. À titre d'exemple, on trouve : les réseaux à une seule couche cachée (Sanger, 1989), les réseaux multicouches (Rumelhart et al, 1986) et les réseaux récurrents (Boné et al, 2005). Ces réseaux se distinguent les uns des autres par le nombre de couches et leurs structures.

À titre d'exemple, dans le cas d'identification du comportement des matériaux, soulignons les travaux d'Erchiqui et al (2004, 2011). À cet effet, une approche hybride qui utilise la modélisation numérique, l'expérimental et un algorithme des réseaux de neurones (de type rétro-propagation), est utilisée pour l'identification des paramètres mécanique des thermoplastiques.

1.1 Objectifs

Deux objectifs principaux feront l'objet du présent mémoire. Premièrement, il y à la partie de la modélisation directe et la mise en place d'une banque de données pour décrire le lien entre les caractéristiques de l'anomalie d'InfiniTEM et les conducteurs recherchés. Dans cette partie 854 modèles basés sur différentes valeurs de conductance, de pendage, et de profondeur de conducteurs sont générés.

Le deuxième objectif de cette étude est la prédiction des paramètres physiques et géométriques des conducteurs par l'utilisation de l'outil mathématique des réseaux de neurones artificiel (RNA) qui a été adapté à notre problématique.

Cette deuxième partie est basée sur les résultats et les simulations de la première partie

1.2 Méthodologie employée

La toute première étape de ce projet fut la modélisation des conducteurs géologiques de type plaque mince afin d'observer le comportement et la variation des anomalies enregistrées par le système d'InfiniTEM pour disposer à la fin d'une banque de données qui va servir comme base de données d'entrée pour les réseaux de neurones artificiels (RNA). La simulation de ces modèles est faite via un logiciel de modélisation électromagnétique *Maxwell* qui permet à la fois de définir d'une manière interactive notre système d'acquisition et de varier les paramètres physiques et géométriques du modèle géologique. Après avoir créé une base de données constituée de 854 modèles géologiques, on a utilisé une architecture de RNA appelée perceptron multicouche (PMC) et un algorithme de rétro-propagation pour l'entraînement du réseau. On fait entraîner notre système de réseaux de neurones par la variation des paramètres qui influencent significativement le résultat de prédiction tels que le nombre de couches cachées, nombre d'itérations et le nombre de neurones. Finalement nous avons analysé l'erreur relative de prédiction sur les paramètres des conducteurs.

1.3 Plan du mémoire

Le présent mémoire est divisé en six chapitres incluant l'introduction. Le chapitre deux présentent dans sa première partie les bases théoriques des méthodes de réseaux de neurones artificiels avec leurs différentes architectures, la deuxième partie de ce chapitre est réservée à la théorie de base des méthodes électromagnétiques en géophysique avec un accent marqué sur les méthodes électromagnétique qui opèrent dans le domaine du temps. Le troisième chapitre décrit la configuration d'InfiniTEM et traite la modélisation des conducteurs de type plaque mince. Le chapitre quatre décrit l'entraînement du réseau de neurones utilisé ainsi que le choix des paramètres qui peuvent nous aider dans la résolution de notre problématique. Le chapitre cinq présente des résultats et la discussion. La conclusion et la recommandation font l'objet du dernier chapitre.

CHAPITRE II

Réseaux de neurones et application InfiniTEM

2.1 Réseaux de neurones artificiels

2.1.1 Introduction aux réseaux de neurones artificiels

Depuis une vingtaine d'années, l'utilisation des réseaux de neurones artificiels (RNA) s'est étendue dans des domaines très divers de l'industrie et des services. En géophysique les RNA ont été utilisés pour plusieurs méthodes, par exemples pour détecter les premières arrivées d'ondes sismiques (Murat and Rudman, 1992; McCormack et al., 1993); classifier les différents signaux par l'inversion (Röth and Tarantola, 1994; Langer et al., 1996); transformer un problème de déconvolution sismique dans un réseau de Hopfield afin de réduire le temps de calcul (Wang and Mendal, 1992); pour caractériser la distribution de résistivité du sous-sol par l'inversion de données magnétotelluriques (Zhang and Paulson, 1997) et électromagnétiques (Poulton et al., 1992). Ils sont particulièrement utilisés pour résoudre des problèmes de classification, de prédiction, de reconnaissance des formes, de catégorisation, de mémoire associative et d'optimisation (Drew et Monson, 2000). Par l'entraînement d'un système non linéaire de multiples variables, les RNA peuvent prédire la variable indépendante (Huang et al., 1996). Par conséquent, les RNA constituent une technique d'approximation de systèmes complexes, qui sont difficiles à modéliser par les méthodes statistiques classiques. Puisqu'il existe un grand nombre de structures des réseaux de neurones artificiels, il est nécessaire de faire un résumé de leurs caractéristiques afin de choisir un réseau de neurone approprié au développement de ce mémoire.

2.1.2 Structure des réseaux de neurones artificiels

McCulloch et Pitts en 1943 ont implémenté un système de réseaux neuronaux artificiels, qui est analogue aux neurones biologiques fondée sur une structure complexe (tableau 1.1). Le système des RNA est considéré comme un arrangement d'éléments de structure identique appelés neurones interconnectées par analogie avec cellules du système nerveux humain. Il est composé également d'une succession de couches connectées de manière à ce que chaque neurone tienne son entrée de la sortie du neurone précédent. Chaque neurone dans ce cas fonctionne indépendamment par rapport aux autres afin que l'ensemble forme un système compact. L'information est emmagasinée de façon répartie dans le réseau sous forme de coefficients synaptiques. Le neurone formel calcule régulièrement un résultat qu'il transmet ensuite aux neurones suivant, chaque calcul est associé à un poids qui définit la force de la connexion (Hagan et al. 1996).

Tableau 2. 1 : Analogie entre le neurone biologique et le neurone formel

Neurone artificiel	Neurone biologique
Poids de connexion	Synapses
Signal de sortie	Axones
Signal d'entrée	Dendrite
Fonction d'activation	Soma

Mathématiquement, tel qu'illusté par la figure 2.1, chaque neurone reçoit des entrées sous forme vectorielle puis il calcule une somme pondérée de ses entrées pour que le résultat passe ensuite par la fonction d'activation afin de créer une sortie.

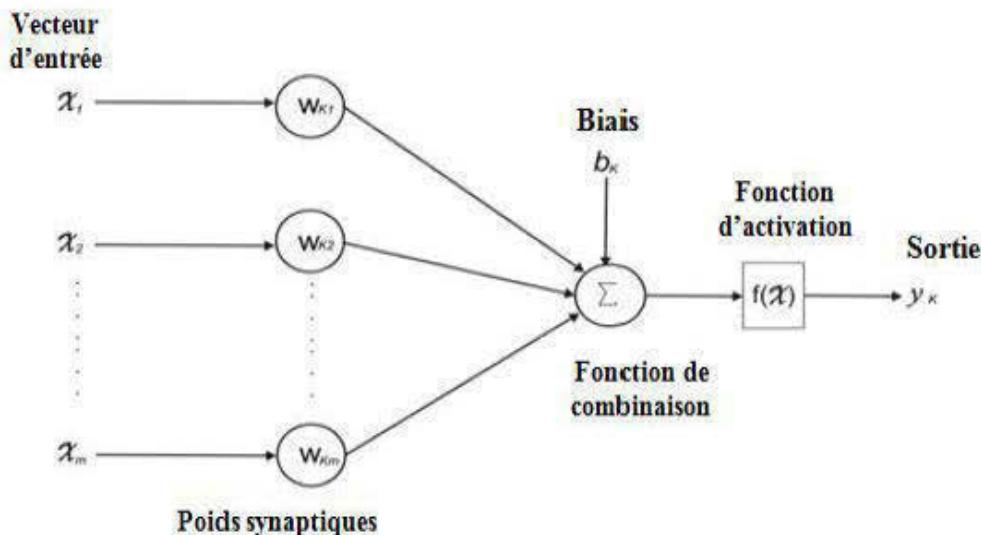


Figure 2.1 : Structure d'un neurone artificiel (Haykin, 1999)

Fonction d'activation

La fonction d'activation (ou fonction de transfert) sert à convertir le résultat de la somme pondérée des entrées d'un neurone en une valeur de sortie, cette conversion s'effectue par un calcul de l'état du neurone en introduisant une non-linéarité dans le fonctionnement du neurone (Cybenko 1989).

Le biais b joue un rôle de seuil, quand le résultat de la somme pondérée dépasse ce seuil, l'argument de la fonction de transfert devient positif ou nul; dans le cas contraire, il est considéré négatif. Finalement si le résultat de la somme pondérée est :

1. en dessous du seuil, le neurone est considéré comme non-actif.
2. aux alentours du seuil, le neurone est considéré en phase de transition.
3. au-dessus du seuil, le neurone est considéré comme actif.

Il y a plusieurs types de fonctions de transfert qui peuvent être utilisées dans les RNA, les fonctions d'activation souvent utilisées sont représentées ci-dessous :

a) La fonction non linéaire sigmoïde

La fonction non linéaire sigmoïde est fréquemment utilisée dans les RNA, particulièrement dans les réseaux utilisant l'algorithme de rétro-propagation (Van der Baan and Jutten, 2000) car contrairement à la fonction sigmoïde, les autres fonctions donnent seulement une sortie binaire ce qui rend plus difficile à estimer les poids optimaux.

La fonction sigmoïde est définie par :

$$f(x) = \frac{1}{1 + e^{-x}}$$

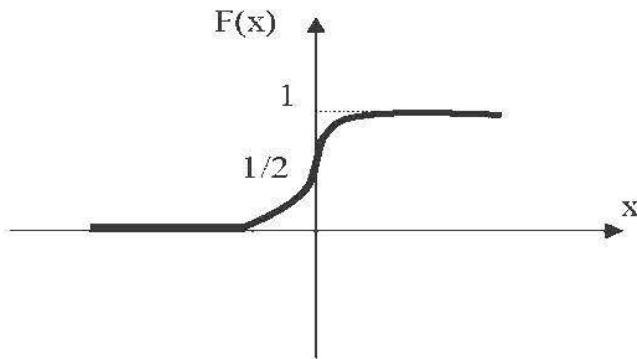


Figure 2.2 : Fonction Sigmoïde

b) La fonction à seuil

On peut citer comme exemple la fonction Heaviside et la fonction Signe qui sont définies respectivement comme suit :

Fonction Heaviside :

$$h(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{sinon} \end{cases}$$

Fonction Signe :

$$Sgn(x) = \begin{cases} +1 & \text{si } x \geq 0 \\ -1 & \text{sinon} \end{cases}$$

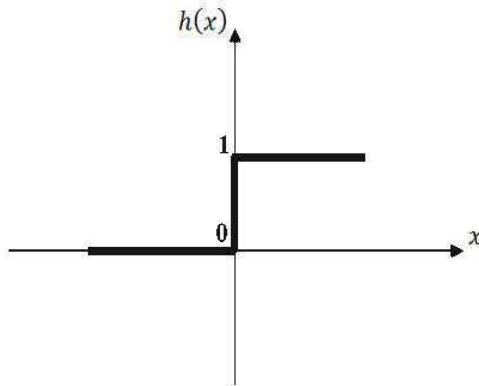


Figure 2.3 : Fonction Heaviside

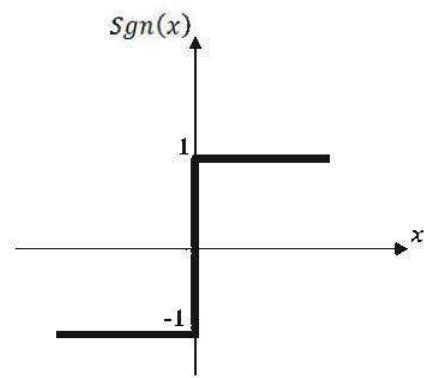


Figure 2.4 : Fonction Signe

La fonction linéaire à seuil

On peut la définir comme suit :

$$F(x) = \begin{cases} x & \in [u, v] \\ v & \text{si } x \geq v \\ u & \text{si } x \leq u \end{cases}$$

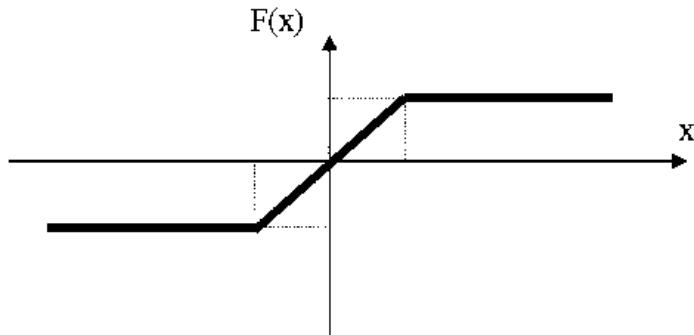


Figure 2.5 : Fonction linéaire à seuil

2.1.3 Architecture des réseaux de neurones

L'architecture est un concept très important qui joue un rôle déterminant dans la classification des RNA. Dans la littérature on utilise souvent le mot structure comme synonyme d'architecture (Maren et al. 1990; Hertz et al. 1991). Chaque architecture a sa propre organisation qui est adapté à des applications bien spécifiques (Sarle 1994; Haykin 1994).

2.1.3.1 Les réseaux récurrents « FEED-BACK »

Ce genre de réseaux est caractérisé par le pouvoir de laisser l'information circulé récursivement d'une manière partielle ou bien total (Kasabov 1996; Elman 1990). Les architectures les plus utilisées sont :

Les cartes auto-organisatrices de Kohonen

Ce type de réseaux utilise un apprentissage non-supervisé qui ajustent une carte discrète et ordonnée en fonction de patterns d'entrée. Ces réseaux sont dérivés des travaux de Fausett (1994) et Kohonen (1995) et sont généralement utilisés pour l'analyse de données grâce à leur pouvoir de distinguer les groupes dans un ensemble de données et de les cartographier en deux dimensions.

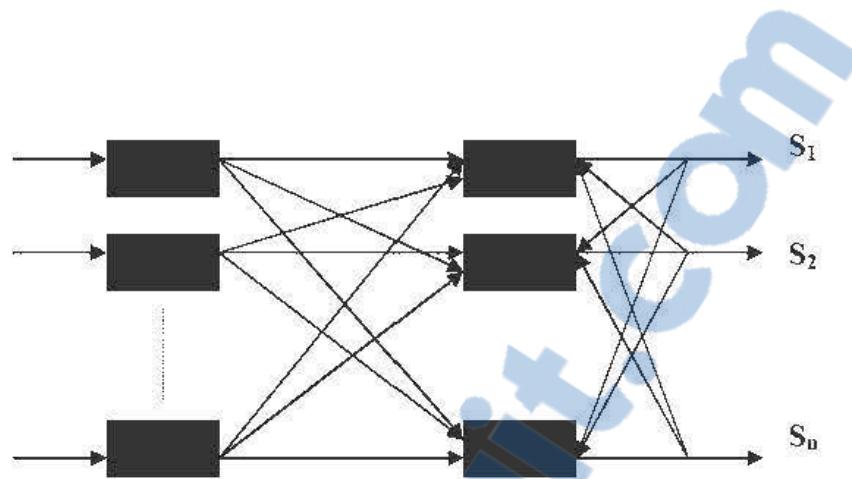


Figure 2.6 : Le modèle de Kohonen (Davallo et Naim)

Les réseaux de Hopfield

Ce type de réseaux utilise un apprentissage non-supervisé, il est particulièrement utilisé dans la résolution de problèmes d'optimisation.

Les réseaux de Hopfield sont considérés comme des réseaux totalement connectés et il n'y a aucune différenciation entre les neurones d'entrée et de sortie (Davallo et Naim 1989). Ce genre de réseaux opère comme une mémoire associative non-linéaire qui a la capacité de discerner un objet stocké dans un espace de données.

Les ART

Les réseaux ART sont utilisés comme détecteurs de caractéristiques afin d'ordonner des patterns dans un système donné sans autre information que leur description interne. Ils sont basés sur la théorie de la résonance adaptative (Adaptive Resonance Theory ou ART) (Grossberg 1976).

Ces réseaux peuvent acquérir de nouvelles connaissances sans perdre celles qui ont été accumulées antérieurement (Massey 2002). Ce dernier est intéressant pour des entraînements continus avec les ajouts de données.

2.1.3.2 Réseaux propagation vers l'avant « FEED-FORWARD »

La particularité de ce type de réseaux est que l'information se propage dans un sens unique, sans aucune rétroaction (des entrées vers les sorties). Ce genre de réseaux utilise un apprentissage supervisé, par correction des erreurs (Lippmann 1987) ou le signal d'erreur est rétro-propagé vers les entrées afin de mettre à jour les poids des neurones.

Le perceptron monocouche « SLP »

Avant de définir la structure collective d'un ensemble de neurones, il est important de définir le perceptron monocouche qui est un réseau très simple grâce à sa composition d'une couche d'entrée et d'une couche de sortie (figure 2.7) sans avoir de couche cachée, il obéit généralement un apprentissage supervisé selon la règle de correction de l'erreur ou selon la règle de Hebb.

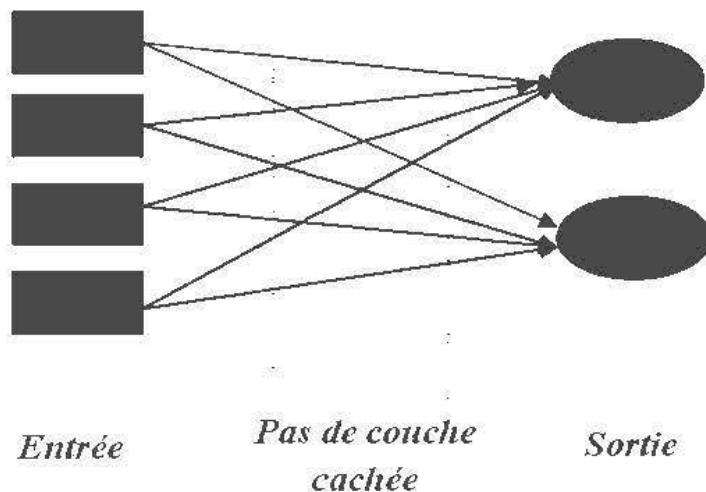


Figure 2.7 : Le réseau monocouche (Davalos et Naim)

Le perceptron multicouches «PMC»

Le PMC est une extension du perceptron monocouche qui dispose d'une ou de plusieurs couches cachées. Les neurones y sont rangés en couches successives : la première couche qui forme le vecteur des données d'entrée est appelée couche d'entrée tandis que la dernière couche qui produit les résultats est appelée couche de sortie. Toutes les autres couches qui se trouvent au milieu sont appelées couches cachées (Lippmann 1987; Hagan et al. 1996).

Les neurones de la couche d'entrée sont connectés uniquement à la couche suivante tandis que les neurones des couches cachées ont la particularité d'être connectés à tous les neurones de la couche précédente et de la couche suivante, par contre il n'y a pas de connexions entre les neurones elle-même dans n'importe quelle couche. Contrairement au SLP la présence d'une couche cachée dans le PMC facilite la modélisation des relations non linéaires entre les entrées et la sortie.

Le choix du nombre de couches cachées dépend généralement de la complexité du problème à résoudre, en théorie une seule couche cachée peut être suffisante pour résoudre un problème donné mais il se peut que le fait de disposer de plusieurs couches cachées permette de résoudre plus facilement un problème complexe.

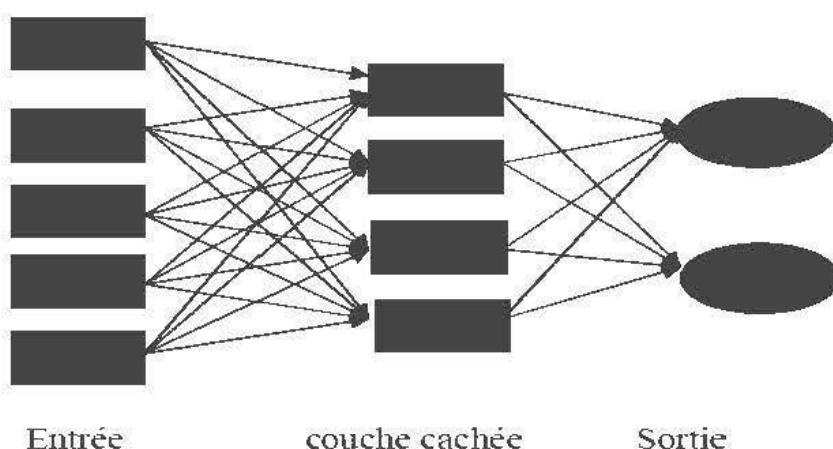


Figure 2.8 : Architecture d'un réseau multicouche

Réseaux à fonction radiale « RBF »

Les réseaux à fonction radiale RBF sont très semblables à celle des PMC mais leurs particularité est qu'ils sont caractérisés par l'utilisation des fonctions Gaussiennes comme fonctions de base. Les RBF sont donc utilisés dans les mêmes genres de problèmes que les PMC à savoir, en classification et en prédition. Parmi les types d'apprentissage utilisés pour les RBF on peut citer le mode hybride avec les règles de correction de l'erreur (Seshagiri et Khalil, 2000).

2.3.4 Apprentissage d'un réseau de neurone

L'apprentissage est une étape très importante du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié itérativement jusqu'à l'obtention du comportement désiré, et ce par l'ajustement des poids (connexion ou synapse) des neurones à une source d'information bien définie (Hebb 1949; Grossberg 1982; Rumelhart et al. 1986). L'apprentissage consiste également à extraire des conformités parmi les données utilisées pour l'entraînement du réseau mais l'objectif essentiel de l'apprentissage est la résolution du problème par la prévision, la classification...etc (Weiss et Kulikowski 1991).

Pour un RNA, l'apprentissage peut être regardé également comme étant le processus de la mise à jour des poids (connexion) au sein du réseau dans le but d'ajuster la réponse du réseau à l'expérience et aux exemples.

Il existe plusieurs types de règles d'apprentissage qui peuvent être rassemblées en deux catégories qui sont l'apprentissage supervisé et l'apprentissage non supervisé.

Apprentissage supervisé

Dans ce type d'apprentissage, on cherche à imposer au réseau un fonctionnement donné en forçant les sorties des réseaux à prendre des valeurs bien données (choisies par l'opérateur) et ce en modifiant les poids synaptiques.

Le réseau se comporte alors comme un filtre dont les paramètres de transfert sont ajustés à partir des couples entrée-sortie présentés (Hassoum 1995).

L'adaptation des paramètres du réseau s'effectue à partir d'un algorithme d'optimisation, l'initialisation des poids synaptiques étant le plus souvent aléatoire.

Des exemples d'utilisations de différentes règles d'apprentissage, architectures et algorithme qui sont relié à ce type supervisé sont illustrés dans le tableau 2.2

Apprentissage non supervisé

Contrairement à l'apprentissage supervisé, seules les valeurs d'entrée sont disponibles dans ce type d'apprentissage non supervisé qui est appelé aussi « apprentissage par compétition ». Dans ce cas, les exemples présentés à l'entrée provoquent une auto-adaptation du réseau afin d'engendrer des valeurs de sortie qui soient proches en réponse à des valeurs d'entrée similaires.

Des exemples d'utilisations de différentes règles d'apprentissage, architectures et algorithme qui sont relié à ce type supervisé sont illustrés dans le tableau 2.3.

Tableau 2.2 : Exemple de différents types d'apprentissages en mode supervisé

Paradigme	Architecture	Règle d'apprentissage	Algorithme	Taches
Supervisé	Perception Simple ou Multi-Couches	Correction d'erreur	Perceptron, Rétro- Propagation, Adaline, Madaline	Classification, Approximation de fonctions, Prédiction, Contrôle
	Récurrente	Bolzmann	Apprentissage de Boltzmann	Classification
	Multi-Couches non bouclés	Hebb	Analyse de discriminants linéaires	Analyse de données, Classification
	à compétition	Par compétition	LVQ	Catégorisation au sein d'une classe, Compression de données
	ART	ARTMap		Classification, Catégorisation au sein d'une classe

Tableau 2.3 : Exemple de différents types d'apprentissages en mode non supervisé

Paradigme	Architecture	Règle	Algorithmes	Taches
		d'apprentissage		
Non supervisé	Multi-couches non bouclé	Correction d'erreur	Projection de Sammon	Analyse de données
	Non bouclé ou à compétition	Hebb	Analyse en composantes	Analyse de données,
	à compétition	Par compétition	VQ	Catégorisation, Compression de données
	Carte de Kohonen		SOM	Catégorisation, Analyse de données
	ART		ART-1, ART-2	Catégorisation

2.1.5 L'algorithme d'apprentissage

Définir l'architecture d'un RNA pour un problème quelconque revient à faire un choix judicieux de la taille du réseau, du nombre total de couches et de neurones, distribution des données et des fonctions de transfert (Baum and Haussler 1989). Le choix de ces paramètres dépend de l'utilisateur. Il n'existe pas dans la littérature pour le moment des données suffisantes qui peuvent déterminer clairement les paramètres à adopter pour résoudre un problème donné (Coulibaly et al 1998). Les différentes techniques présentées par différents auteurs (Zurada 1992 ; Widrow et Lehr 1990; Murata et al. 1994; Jacobs et al. 1997; Rudolph 1997; Hecht-Nielsen 1987) sont destinées à résoudre des cas particuliers.

Afin de répondre à la problématique de ce mémoire, telle que la prédiction des paramètres géométriques des conducteurs géologiques recherchés (profondeur, pendage, conductance, longueur, largeurs d'un conducteur) nous avons choisi l'architecture de perceptrons multicouches PMC (Haykin 1994) en utilisant un algorithme de rétro-propagation avec fonction sigmoïde comme fonction de transfert.

Ce choix d'utiliser le PMC et l'algorithme rétro-propagation est dû principalement à la popularité de ces deux derniers dans la gestion des relations non linéaire entre les variables, ce qui est le cas pour notre étude du problème électromagnétique.

L'algorithme de rétro-propagation

L'algorithme d'apprentissage de rétro-propagation consiste dans un premier temps à circuler vers l'avant les données d'entrées jusqu'à l'obtention d'une entrée calculée par le réseau, puis la seconde étape est de comparer la sortie calculée à la sortie réelle connue (Rumelhart et al 1986). Les poids sont modifiés de telle sorte qu'à la prochaine itération, l'erreur commise entre la sortie calculée est minimisée, en prenant en considération la présence des couches cachées, l'erreur est rétro-propagé vers l'arrière jusqu'à la couche d'entrée tout en modifiant la pondération.

Le processus est répété sur tous les exemples jusqu'au temps où l'on obtienne une erreur de sortie considérée comme négligeable.

Mathématiquement on peut résumer l'algorithme de rétro-propagation comme suit :

on considère un ensemble d'apprentissage composé de K paire de vecteur

$$(x_1, o_1), (x_2, o_2), \dots, (x_k, o_k)$$

avec un vecteur d'entrée :

$$x_p = (x_{p,0,1}, x_{p,0,2}, \dots, x_{p,0,n})^t \in \mathbb{R}^n \quad (2.1)$$

et un vecteur de sortie désiré:

$$o_p = (o_{p,1}, o_{p,2}, \dots, o_{p,m})^t \in \mathbb{R}^m \quad (2.2)$$

et un vecteur de sortie réel du réseau :

$$y_p = (y_{p,1,1}, y_{p,1,2}, \dots, y_{p,l,m})^t \in \mathbb{R}^m \quad (2.3)$$

On définit l'entrée totale du K nœud pour la couche j par :

$$h_{p,j,k} = \sum_{i=0}^n w_{j,k,i} x_{p,j-1,i} \quad (2.4)$$

alors la sortie de ce nœud sera :

$$F(h_{p,j,k}) = \sum_{i=0}^n w_{j,k,i} x_{p,j-1,i} + \theta_{j,k} \quad (2.5)$$

Où

$w_{j,k,i}$: la connexion entre le neurone k de la couche j-1 et le neurone i de la couche j.

$h_{p,j,k}$: l'entrée totale du neurone k pour l'échantillon p de la couche j.

$\theta_{j,k} = w_{p,j,0}$: le poids fictif du neurone k de la couche j

On pourra alors définir le terme d'erreur total commit sur tout les nœuds de sortie par :

$$E_p = \frac{1}{2} \sum_{i=0}^m \delta_{p,k}^2 = \frac{1}{2} \sum_{i=0}^m (O_{p,k} - x_{p,l,k})^2 \quad (2.6)$$

Où $\delta_{p,k} = (O_{p,k} - x_{p,l,k})$ est l'erreur commise sur le K^{ème} nœud de sortie.

Afin de minimiser l'erreur E_p , le gradient est calculé par rapport à chaque poids w , puis à leurs tour les poids sont modifiés dans le sens inverse du gradient.

La mise à jour des poids de la couche de sortie est décrite par les équations suivantes :

$$\nabla E_p = \frac{\partial E_p}{\partial w_{l,k,j}} = -(O_{p,k} - x_{p,l,k}) \frac{\partial [f(y_{p,l,k})]}{\partial w_{l,k,j}} \quad (2.7)$$

$$\nabla E_p = -(O_{p,k} - x_{p,l,k}) \frac{\partial f(y_{p,l,k}) \partial (y_{p,l,k})}{\partial w_{l,k,j} \partial (y_{p,l,k})} \quad (2.8)$$

$$\begin{cases} \frac{\partial y_{p,l,k}}{\partial w_{l,k,j}} = \frac{\partial}{\partial w_{l,k,j}} \sum_{j=0}^m (w_{l,k,j} - x_{l,k,j}) = x_{p,l-1,j} \\ \frac{\partial f(y_{p,l,k})}{\partial y_{l,k,j}} = f'(y_{p,l,k}) \end{cases} \quad (2.9)$$

$$\nabla E_p = \frac{\partial E_p}{\partial w_{l,k,j}} = -(O_{p,k} - x_{p,l,k}) f'(y_{p,l,k}) x_{p,l-1,k,j} \quad (2.10)$$

$$\nabla E_p = \delta_{p,k} x_{p,l,k} (1 - x_{p,l,k}) x_{p,l-1,j} \quad (2.11)$$

Ainsi la mise à jour des poids peut être décrite comme par les équations suivantes :

$$w_{l,k,j}(t+1) = w_{l,k,j}(t) + \Delta_p w_{l,k,j}(t) \quad (2.12)$$

$$\Delta_p w_{l,k,j}(t) = \lambda (O_{p,k} - x_{p,l,k}) f'(y_{p,l,k}) x_{p,l-1,j} \quad (2.13)$$

Où λ est le pas $0 < \lambda < 1$

2.2 Méthodes électromagnétiques (EM)

2.2.1 Introduction aux méthodes EM en géophysique

Développées dès les années 60 pour l'exploration minière, les méthodes électromagnétiques en géophysique permettent de mesurer la résistivité du sous-sol jusqu'à certaines profondeurs afin de déduire la géologie correspondante.

Les méthodes électromagnétiques (EM) en géophysique sont utilisées particulièrement pour la recherche des conducteurs dans un sous-sol terrestre en utilisant un champ électromagnétique primaire provenant de différentes sources artificielles ou naturelles. Lorsqu'un corps géologique conducteur est présent dans le sous-sol, un champ électromagnétique secondaire est induit et peut être détecté et mesuré par les appareils appropriés. Dans la prospection EM on s'intéresse par

exemple aux gisements de sulfures massifs volcanogènes qui sont considérés comme de bons conducteurs et des cibles très importantes pour l'exploration minière (Cooper et Swift 1994).

Les méthodes EM peuvent être également utilisées pour la protection de l'environnement tel que la cartographie des eaux souterraines polluées ou contaminées ainsi que les intrusions saline en hydrogéologie (Hautot et al. 2002 ; Mitsuhashi et al 2006 ; Johnson et al 2010), la détection des permafrosts (Harada et al 2000; Hauck et al 2001 ; Pettersson et al 2003) et la détection des objets non explosés UXO (Billings et al 2010).

2.2.2 Théorie fondamentale de la méthode électromagnétique

Le fondement théorique des méthodes électromagnétiques repose sur l'induction électromagnétique régit par les équations de Maxwell. Cette théorie est basée sur trois processus physiques (Spies et Frischknecht 1991):

- 1- la génération d'un champ électromagnétique primaire.
- 2- la naissance de courants induits (courant de Foucault) dans tous les conducteurs sur lesquels agit ce champ primaire.
- 3- la détection de ces conducteurs géologiques via la mesure des champs électromagnétiques secondaires générés par les courants de Foucault.

Équations de Maxwell

Les équations de Maxwell sont des équations différentielles qui décrivent la propagation et l'atténuation des ondes électromagnétiques en reliant les composantes du champ magnétique et du champ électrique (Ward et Hohmann 1988). Ces équations s'expriment sous la forme :

$$\nabla \times E = - \frac{\partial B}{\partial t} \quad (2.14)$$

$$\nabla \times H = \frac{\partial D}{\partial t} + j \quad (2.15)$$

$$\nabla \cdot B = 0 \quad (2.16)$$

$$\nabla \cdot D = \rho \quad (2.17)$$

avec :

E : vecteur d'intensité du champ électrique en volt par mètre (V/m),

H : vecteur d'intensité du champ magnétique en ampère par mètre (A/m),

B : vecteur d'induction magnétique en tesla (T),

J : vecteur de densité de courant électrique en ampère par mètre carré (A/m^2),

D : vecteur de déplacement diélectrique en coulomb par mètre carré (C/m^2),

ρ : densité de charge électrique en coulomb par mètre cube (C/m^3).

L'équation (2.14) décrit la loi de faraday selon laquelle un champ électrique peut être généré par un champ magnétique variable dans le temps.

L'équation (2.15) stipule qu'un champ magnétique peut être créé par un flux de courant ainsi que par un champ électrique qui varie dans le temps.

L'équation (2.16) montre que le champ magnétique n'est pas unipolaire mais dipolaire tandis que l'équation (2.17) met en évidence la présence de la charge dans un champ électrique.

Pour étudier le comportement électromagnétique de la terre il faut avoir un lien intrinsèque entre le champ électromagnétique induit ou naturel et les roches du sous-sol. Si on considère que le milieu est homogène et isotrope, la loi d'Ohm décrit que la densité du courant électrique est proportionnelle à l'intensité du champ électrique qui lie à la conductivité du milieu (σ) :

$$J = \sigma E \quad (2.18)$$

Où σ : la conductivité électrique du milieu.

La densité du flux électrique est aussi proportionnelle à l'intensité du champ électrique liée par la permittivité diélectrique du milieu (ϵ) :

$$D = \epsilon E \quad (2.19)$$

Où ϵ : la permittivité diélectrique du milieu ; ϵ_0 : celle du vide = 8.854×10^{-12} F/m.

Par l'analogie, l'induction magnétique est proportionnelle à l'intensité du champ magnétique :

$$B = \mu H \quad (2.20)$$

Où μ : la perméabilité magnétique du milieu; μ_0 : celle du vide = $4 \pi \times 10^{-7}$ H/m.

Ces équations permettent de tenir compte de l'influence de la variation du champ électromagnétique sur la géologie du sous-sol qui est caractérisée par les trois paramètres physiques (μ , σ et ϵ)

Les équations (2.14), (2.15), (2.16), (2.17) dans le cas homogène et isotrope peuvent donc être réécrites en termes de propriétés physiques :

$$\nabla \times E = -\mu \frac{\partial H}{\partial t} \quad (2.21)$$

$$\nabla \times H = \sigma E + \epsilon \frac{\partial E}{\partial t} \quad (2.22)$$

$$\nabla \cdot (\mu H) = 0 \quad (2.23)$$

$$\nabla \cdot (\epsilon E) = \rho \quad (2.24)$$

Ces équations nous permettent d'interpréter les variations du champ électromagnétique en termes de structure géologique ou de composition des roches dans le sous-sol.

Profondeur de peau «Skin depth»

Dans un milieu homogène où $\nabla \cdot E = 0$ et $\nabla \cdot H = 0$ nous avons alors :

$$\nabla^2 E - \mu\epsilon \frac{\partial^2 E}{\partial t^2} - \mu\sigma \frac{\partial E}{\partial t} = 0 \quad (2.25)$$

$$\nabla^2 H - \mu\epsilon \frac{\partial^2 H}{\partial t^2} - \mu\sigma \frac{\partial H}{\partial t} = 0 \quad (2.26)$$

En appliquant les transformées de Fourier aux équations (2.25), (2.26) on obtient les équations suivantes dans le domaine fréquentiel :

$$\nabla^2 E + k^2 E = 0 \quad (2.27)$$

$$\nabla^2 H + k^2 H = 0 \quad (2.28)$$

Où $k = (-i\omega\sigma\mu)^{1/2}$ est le nombre d'onde.

La solution aux équations (2.27), (2.28) peut s'exprimer sous la forme :

$$E = e_0^+ e^{-i\alpha z} e^{-\beta z} e^{-i\omega t} \quad (2.29)$$

$$H = h_0^+ e^{-i\alpha z} e^{-\beta z} e^{-i\omega t} \quad (2.30)$$

Où

$$\alpha = \beta = \left(\frac{\omega\mu\sigma}{2}\right)^{1/2}$$

En analysant les équations (2.29) et (2.30) on remarque que le champ électromagnétique varie en fonction de la profondeur et du temps.

Comme β est un nombre réel, $e^{-\beta z}$ devient très petit quand z augmente, alors ça représente l'atténuation et l'onde électromagnétique qui diminue de $1/e$ en

profondeur (Ward et Hohmann 1988). Cette profondeur à laquelle l'amplitude du signal diminue de $1/e$ est appelée la profondeur de peau ou bien « Skin depth » et elle est définie par :

$$\delta = \left(\frac{2}{\omega \mu \sigma_2} \right)^{1/2} = 503 \left(\frac{1}{f \sigma} \right)^{1/2} \quad (2.31)$$

Comme le montre l'équation (2.31) la profondeur de pénétration dépend de la conductivité du sous-sol et de la fréquence utilisée. En pratique pour que l'anomalie d'un corps enfoui soit détectable, la profondeur de ce corps doit être inférieure à $\delta/5$ (Reynolds 1997).

Polarisation et magnétisation

Les résultats acquis jusqu'au présent sont valables seulement pour les milieux homogènes qui ne tiennent pas compte des sources de courant. Afin de compléter l'analyse des régions contenant des sources électromagnétiques nous allons introduire la notion des vecteurs de polarisation et de potentiel (Ward et Hohmann 1988) qui sont définis comme suit:

$$p \equiv D - \epsilon_0 E \quad (2.32)$$

$$m \equiv \frac{1}{\mu_0} B - H \quad (2.33)$$

Les vecteur de polarisation p et m sont composé d'une partie source représenté par le terme S et d'une partie induite représenté par le terme du champ induit I donné par :

$$p \equiv p^I + p^S \quad (2.34)$$

$$p \equiv p^I + p^S \quad (2.35)$$

En tenant compte des équations des vecteurs de polarisation les équations de maxwell (2.14), (2.15) peuvent être réécrites de la façon suivante :

$$\nabla \times E + -\mu \frac{\partial H}{\partial t} + -\mu_0 \frac{\partial m^s}{\partial t} = 0 \quad (2.36)$$

$$\nabla \times h - \varepsilon \frac{\partial E}{\partial t} - \frac{\partial p^s}{\partial t} = J_e \quad (2.37)$$

Afin d'obtenir les équations de maxwell dans un milieu non homogène on introduit les termes de source électrique et source magnétique dans le domaine fréquentiel qui sont donné par :

$$J_e^s = i\omega P^s \quad \text{et} \quad J_m^s = i\mu_0 \omega M^s$$

On peut alors définir les deux premières équations de Maxwell dans un milieu non-homogène :

$$\nabla \times E + \hat{z}H = -J_m^s \quad (2.38)$$

$$\nabla \times H + \hat{y}E = -J_e^s \quad (2.39)$$

où $\hat{z} = i\mu\omega$ est l'impédance électrique et $\hat{y} = \sigma + i\epsilon\omega$ est l'additivité électrique

2.2.3 Méthodes électromagnétiques fréquentielles (FDEM)

La méthode de prospection électromagnétique fréquentielle est basée sur trois processus physiques distincts. L'émission d'un champ électromagnétique primaire qui varie avec le temps avec une fréquence constante donne naissance à des courants appelés courants induit (courants de Foucault) dans tous les conducteurs au voisinage

de l'émetteur sur lesquels agit ce champ primaire. Le conducteur à son tour émet un champ secondaire à la même fréquence que le champ primaire mais avec un déphasage (Hannrson et West 1984). L'amplitude de ce déphasage entre le champ primaire et le champ secondaire permet de définir la conductivité apparente des milieux où les ondes électromagnétiques se propagent. La figure 2.9 illustre l'interaction entre le champ primaire et le champ secondaire électromagnétique.

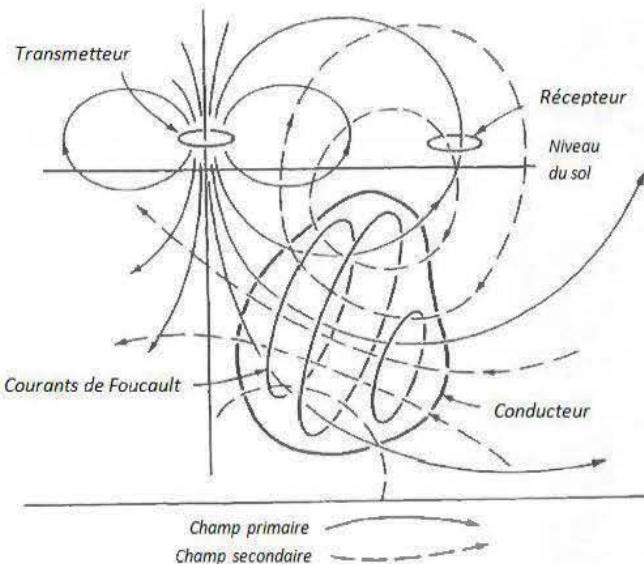


Figure 2.9 : Schéma illustrant les champs impliqués dans le processus de mesure EM (Reynolds, 1997)

Habituellement on peut distinguer différentes techniques selon la configuration du système de mesure et les fréquences utilisées. Par exemple la méthode à basse fréquence qui est également appelée Slingram qui utilise un émetteur et récepteur sous la forme d'une horizontale. Le champ secondaire H_s mesuré dans ce cas est considéré comme une fonction qui dépend des paramètres de l'espacement entre l'émetteur et le récepteur S , la fréquence du champ primaire H_p et la conductivité du

sous-sol σ_a (McNeill, 1980b). Sous la condition de faibles longueurs d'ondes le rapport des champs $\frac{H_p}{H_s}$ est donné par la formule (McNeill 1980a) :

$$\frac{H_s}{H_p} = \frac{i\omega\mu_0 s^2}{4} \quad (2.40)$$

Le rapport entre le champ primaire et le champ secondaire varie linéairement avec la conductivité du terrain. La conductivité apparente est donnée par l'équation suivante :

$$\sigma_a = \frac{4}{\omega\mu_0 s^2} \left(\frac{H_s}{H_p} \right)_{\text{composante en quadrature}} \quad (2.41)$$

Parmi un grand nombre de techniques basé sur le principe électromagnétique qui opèrent dans le domaine des fréquences on trouve les systèmes suivants qui sont couramment utilisés pour les levés géophysiques: Maxmin multi fréquences, PROMIS, Magnétotellurique (MT), Audio-magnétotellurique (AMT), Radio-magnétotellurique (RMT), VLF (Very Low Frequency) (Cagnard 1953; Ficher et al. 1983; Ficher et al. 1981; Strangway et al 1973).

2.2.4 Méthodes électromagnétiques Temporelles (TDEM)

Contrairement aux méthodes fréquentielles qui considèrent la réponse mesurée au récepteur comme une combinaison entre le champ primaire et le champ secondaire, les méthodes temporelles (transitoires) opérant dans le domaine du temps et enregistrent la réponse du sous-sol en l'absence du champ primaire. La procédure de mesure de ces méthodes consiste à créer un champ électromagnétique dans le sous-sol via une boucle d'émission parcourue par un courant qui est coupé brusquement au temps fixe et ensuite mesurer la réponse du sous-sol en temps mort. On définit le temps d'émission du courant comme « en temps » ou *time-on* et le temps de coupure du courant comme « en temps mort » ou *time-off* (Figure 2.10).

Suivant les lois de Maxwell, la coupure du courant injecté crée une variation dans le champ magnétique primaire, qui engendre des courants de Foucault dans un corps conducteur et fait circuler les courants dans les formations géologiques. Avec la variation dans le temps du champ électromagnétique primaire, l'intensité de ces courants secondaires varie dans le temps ce qui donne naissance à un champ magnétique secondaire. La variation dans le temps de ce dernier est finalement enregistré par le récepteur du système TDEM.

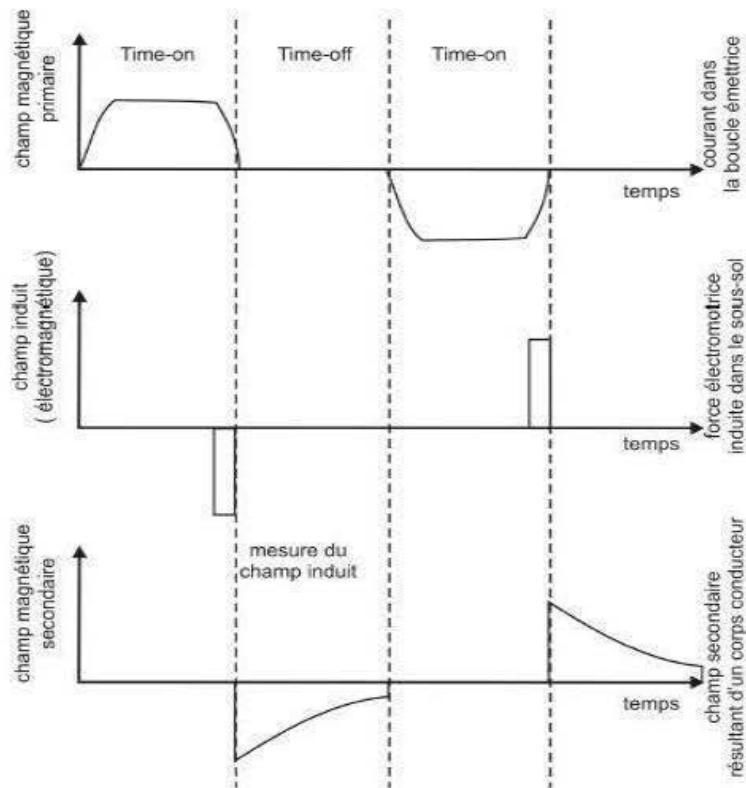


Figure 2.10 : Principe général de la TDEM : courant injecté en haut ; force électromotrice induite au milieu ; variation du champ magnétique mesuré au récepteur en bas (Reynolds 1997).

Le potentiel au récepteur est proportionnel au taux de variation du champ magnétique secondaire en fonction du temps. Le couplage électromagnétique entre l'émetteur,

récepteur et le corps conducteur est défini par la relation suivante (Nabighian et Macnae 1991) :

$$e_s(t) = M_{02} \frac{\partial I}{\partial t} = I_0 \frac{M_{01} M_{12}}{L} \left[\delta(t) - \frac{e^{-t/\tau}}{\tau} \right] \quad t \geq 0 \quad (2.42)$$

Avec :

$e_s(t)$: Intensité du champ électrique en volt par mètre (V/m).

M_{02} : le terme de couplage entre le transmetteur et le récepteur.

M_{01} : le terme de couplage entre le transmetteur et le conducteur.

M_{12} : le terme de couplage entre le conducteur et le récepteur.

I_0 : le courant initial émis au transmetteur.

L : l'inductance du conducteur.

τ : Constante de temps.

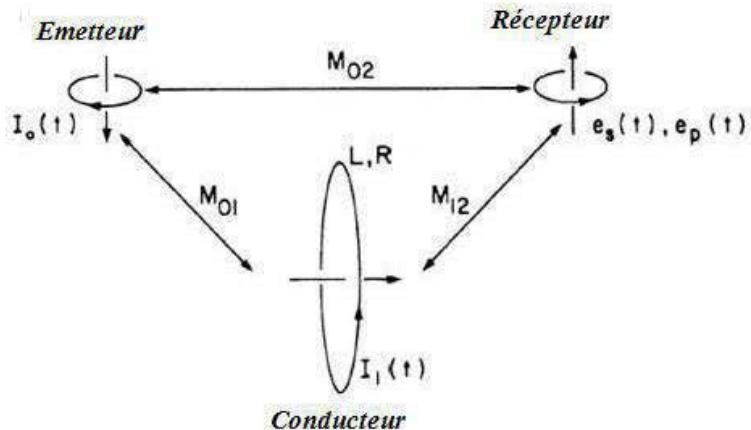


Figure 2.11: Représentation d'un système électromagnétique transitoire (Nabighian et Macnae 1991)

2.2.5 Configuration des systèmes électromagnétiques

La configuration d'un système électromagnétique est caractérisée par la disposition de l'émetteur et du récepteur sur le terrain. Selon la technique d'acquisition utilisée (avion, au sol, ou dans le trou de forage), il existe une grande variété de configurations. Dans notre étude on s'intéresse uniquement aux techniques d'acquisitions au sol et les systèmes temporels. La figure 2.12 décrit les types de configurations les plus utilisées.

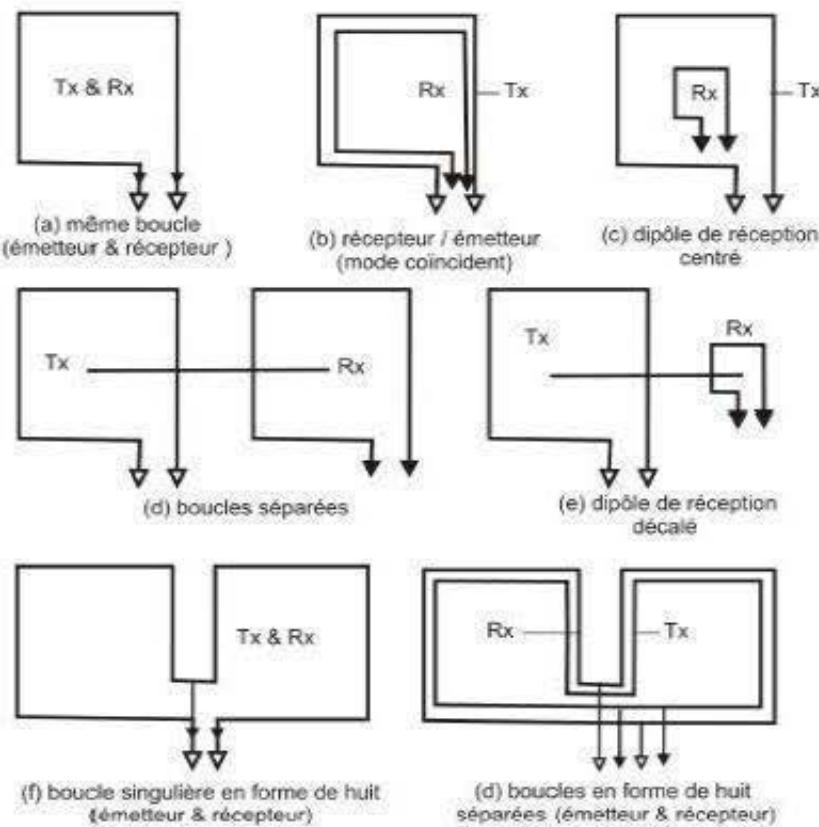


Figure 2.12: Différents types de configurations pour les levés TDEM
(Reynolds 1997)

Fondamentalement les configurations TDEM utilisées en industrie peuvent être divisées en deux catégories qui sont respectivement les configurations à boucles fixes et les configurations à boucles mobiles (figure 2.13).

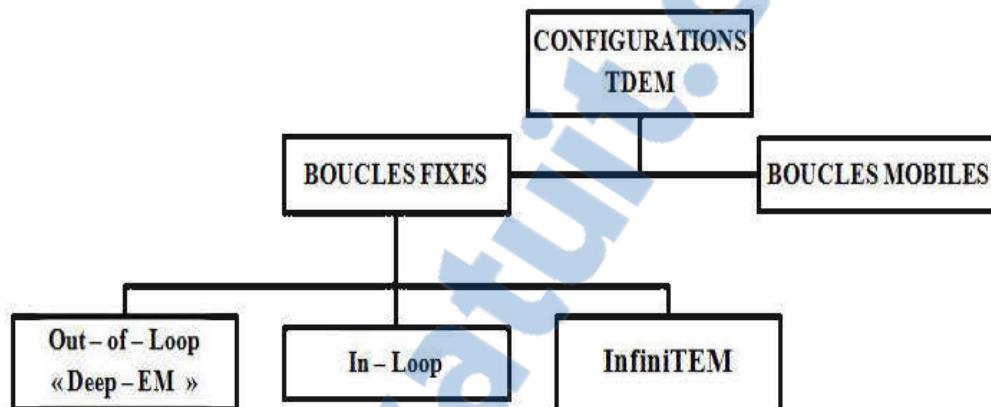


Figure 2.13: Configurations utilisées en industrie

Configuration In-Loop

Ce type de configuration est caractérisé par une boucle d'émission fixe et un récepteur mobile, tandis que les mesures sont prises à l'intérieur de la boucle (figure 2.14). Le moment magnétique pour cette configuration est important mais par contre le couplage avec un corps vertical centré au milieu de la boucle est considéré faible.

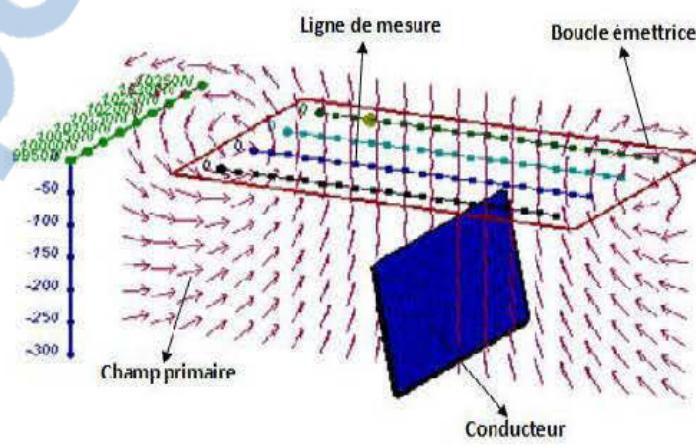


Figure 2.14: Configuration In-Loop

Configuration Out-of-Loop

Ce type de configuration est caractérisé par une boucle d'émission fixe et un récepteur mobile. Les mesures sont prises à l'extérieur de la boucle (Figure 2.15).

Puisque le moment magnétique est important seulement près de la boucle, le couplage entre le champ électromagnétique émis et une cible recherchée est considéré de plus en plus faible lorsque le conducteur s'éloigne de l'émetteur.

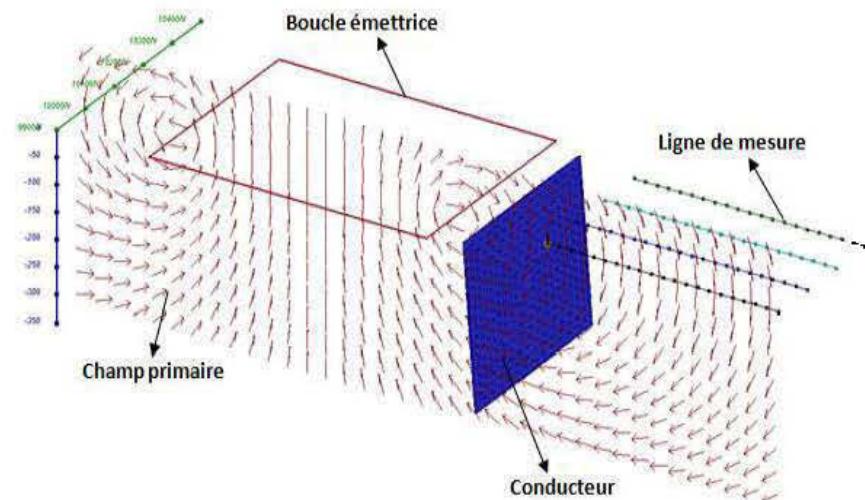


Figure 2.15: Configuration Out-of-Loop

En se basant sur la distribution du champ électromagnétique (figures 2.14 et 2.15), nous pouvons conclure que le couplage entre un conducteur horizontal (e.g. le mort terrain) situé au centre de boucle émettrice est fort, par contre pour détecter les conducteurs inclinés ou sub-verticaux il faut qu'ils soient positionnés à un endroit favorable. Vu l'importance de la configuration d'un système de mesure sur la détection des conducteurs à différentes positions, nous allons présenter dans le prochain chapitre la configuration InfiniTEM.

CHAPITRE III

Modélisation InfiniTEM

3.1 Configuration InfiniTEM

Inspiré de la boucle en forme de huit (Spies 1975 ; Macnae 1978), le système d’InfiniTEM a été développé conjointement par Abitibi Géophysique inc. et SOQUEM inc. Ce système utilise une boucle d’émission fixe et un récepteur mobile tandis que les mesures sont prises à l’intérieur aussi bien qu’à l’extérieur de la boucle (Figure 3.1).

Cette configuration est caractérisée par la forme de sa boucle émettrice sous forme du chiffre huit composée de deux demi-boucles connectées en série.

Contrairement aux configurations traditionnelles, la configuration InfiniTEM présente de précieux avantages grâce à l’intensité du champ primaire qui est presque doublée en profondeur ainsi que le couplage minime avec le mort terrain qui influence négativement les mesures électromagnétiques. Cette configuration est également très avantageuse pour la détection des cibles sub-verticales grâce au champ horizontal généré qui est optimal pour ce genre de cibles et qui est issue de la circulation du courant dans les deux demi-boucles dans un sens opposé.

Par conséquent, cette configuration est bien adaptée pour la détection des cibles sub-verticales profondes (supérieur à 400 mètres de profondeur) peu importe les conditions du mort terrain.

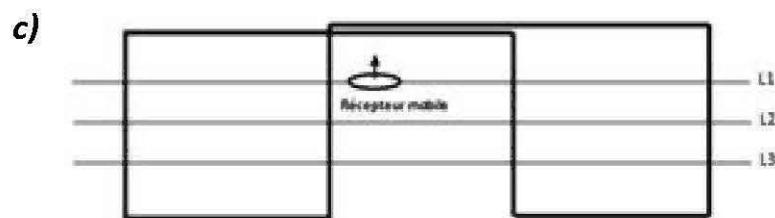
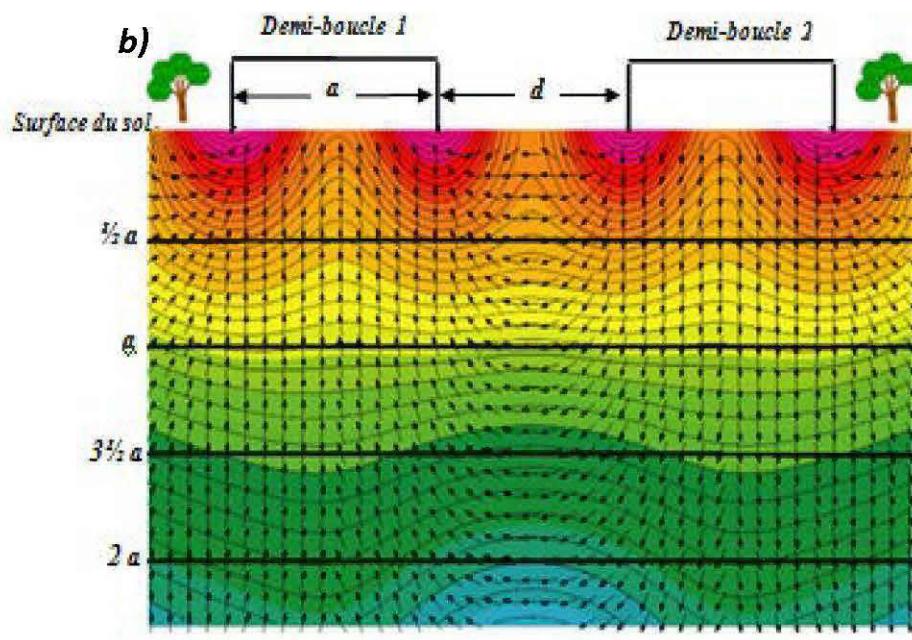
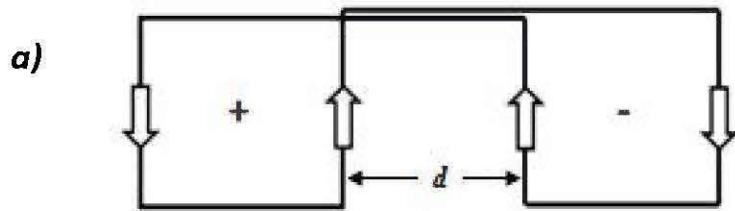


Figure 3.1 : Configuration InfiniTEM a) vue plan b) Coupe transversale et c)
design d'un levé InfiniTEM

3.2 Modélisation directe de la réponse InfiniTEM

La modélisation directe en électromagnétisme consiste à calculer la réponse électromagnétique (variation du champ EM) à partir des modèles de terrain (figure 3.2). Cette réponse du modèle ou variation du champ EM dépend directement des paramètres géométriques et propriétés physiques des conducteurs enfouis dans le sous-sol (conductivité, épaisseur, longueur, profondeur, inclinaison...etc).

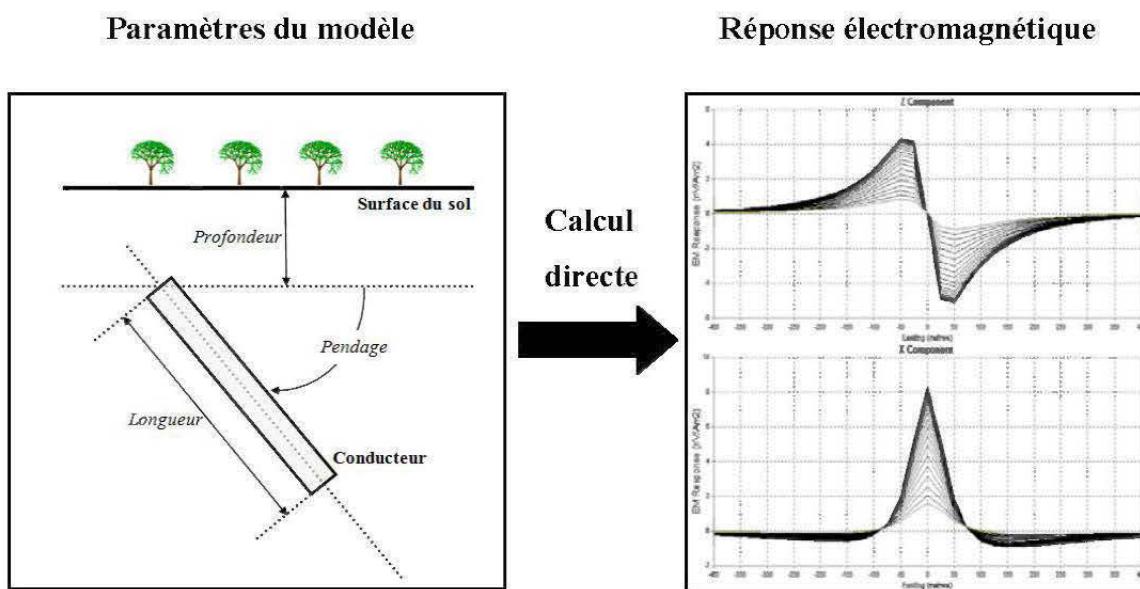


Figure 3.2: Problème directe en électromagnétisme

L'utilité de la modélisation directe peut être résumée comme suit :

- Une interprétation rapide des anomalies observées sur le terrain
- Caractériser la réponse de différentes sources.
- Aider à développer des outils d'interprétation automatique de données ou à perfectionner le système de mesure.

Dans le cadre d'étude de ce mémoire, une série de modélisations tridimensionnelles a été réalisée dans le but de construire une banque de modèles-réponses appropriés au système d'InfiniTEM. Le nombre de modèles-réponses que nous allons avoir va servir en premier lieu à décrire le comportement du système d'InfiniTEM et ensuite il

va servir à entraîner un système de réseau neurone intelligent pour estimer les paramètres de conducteur enfoui dans le sous-sol à partir des données mesurées.

3.2.1 Description du logiciel utilisé pour la modélisation

Le logiciel de modélisation tridimensionnelle utilisé dans cette étude est le «**Maxwell**» qui est développé par EMIT (Electromagnetic Imaging Technology).

Nous avons choisi le Maxwell parmi plusieurs logiciels car il dispose d'une plateforme de travail très complète pour concevoir des modèles géologiques et en même temps de visualiser les lignes de levés et les résultats de modélisation. Les réponses des modèles peuvent être affichées à une échelle choisie par l'utilisateur (Figure 3.3). Tous les paramètres du modèle peuvent être définis à partir de cet environnement qui offre également une flexibilité de rotation et de calcul automatique des réponses EM quand les paramètres changent.

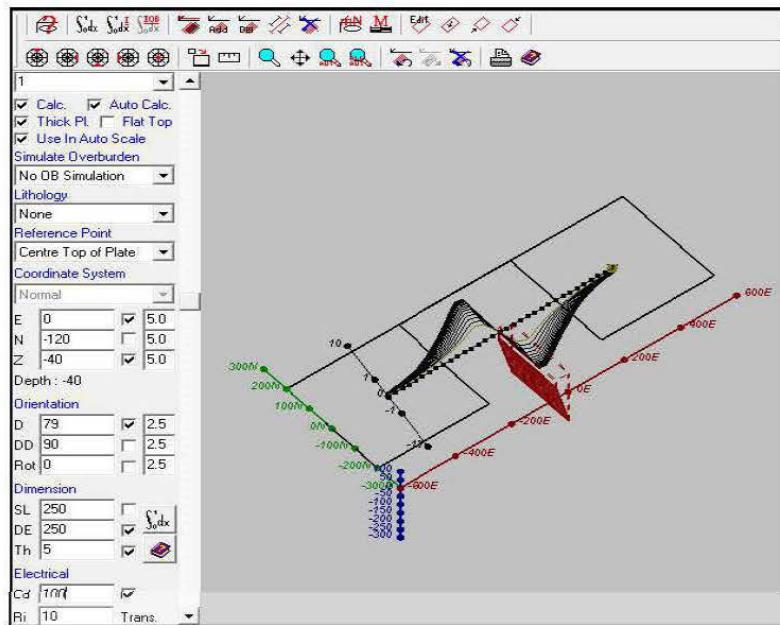


Figure 3.3 : Fenêtre du modèle et de l'anomalie observée

La configuration du transmetteur et du récepteur peut être ajustée manuellement en définissant les coordonnées (Figure 3.4) ce qui rend facile la conception de différents

émetteurs. En changeant la configuration du système d'InfiniTEM nous pouvons trouver la position optimale du récepteur par rapport à la position de transmetteur, et d'exploiter au maximum l'énergie émise par ce système en profondeur.

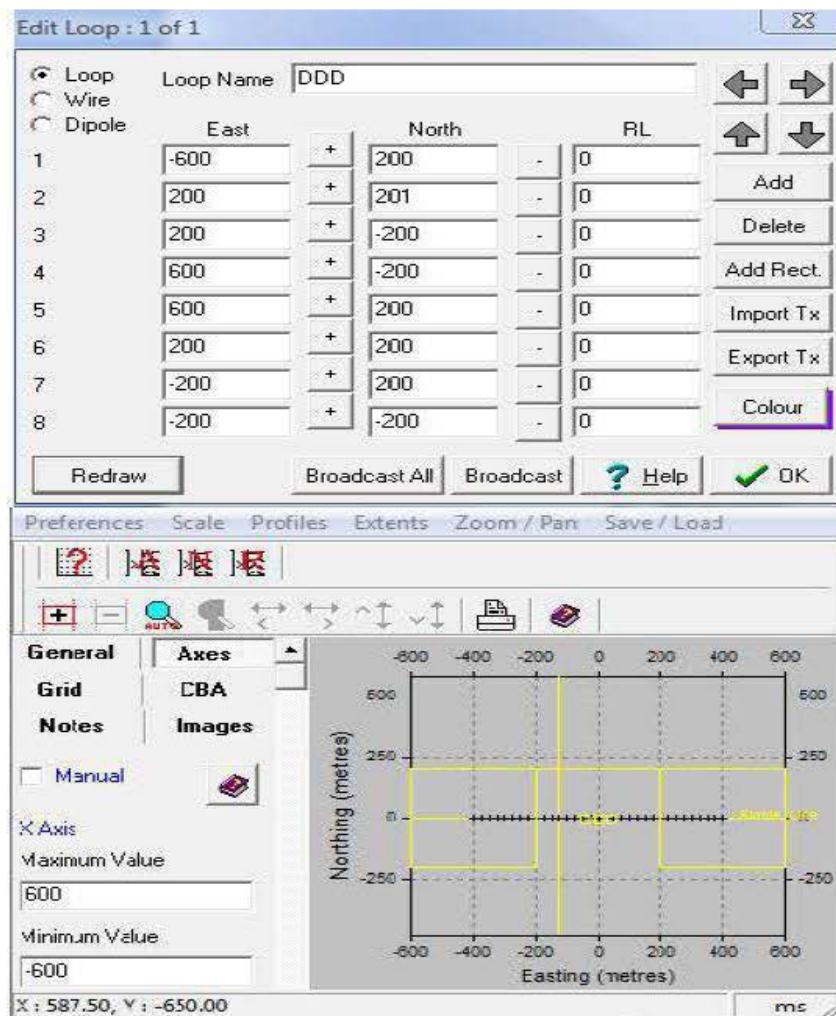


Figure 3.3 : Paramètres du système concerné

Le Maxwell permet de faire des modélisations de nombreux systèmes électromagnétiques, tel que le système aéroporté, système au sol et le système dans un trou de forage. Il suffit de définir les caractéristiques du système utilisé (figure

3.5), les fenêtres de temps, la forme d'onde, les composants (X,Y,Z) mesurés et l'unité de mesure etc.

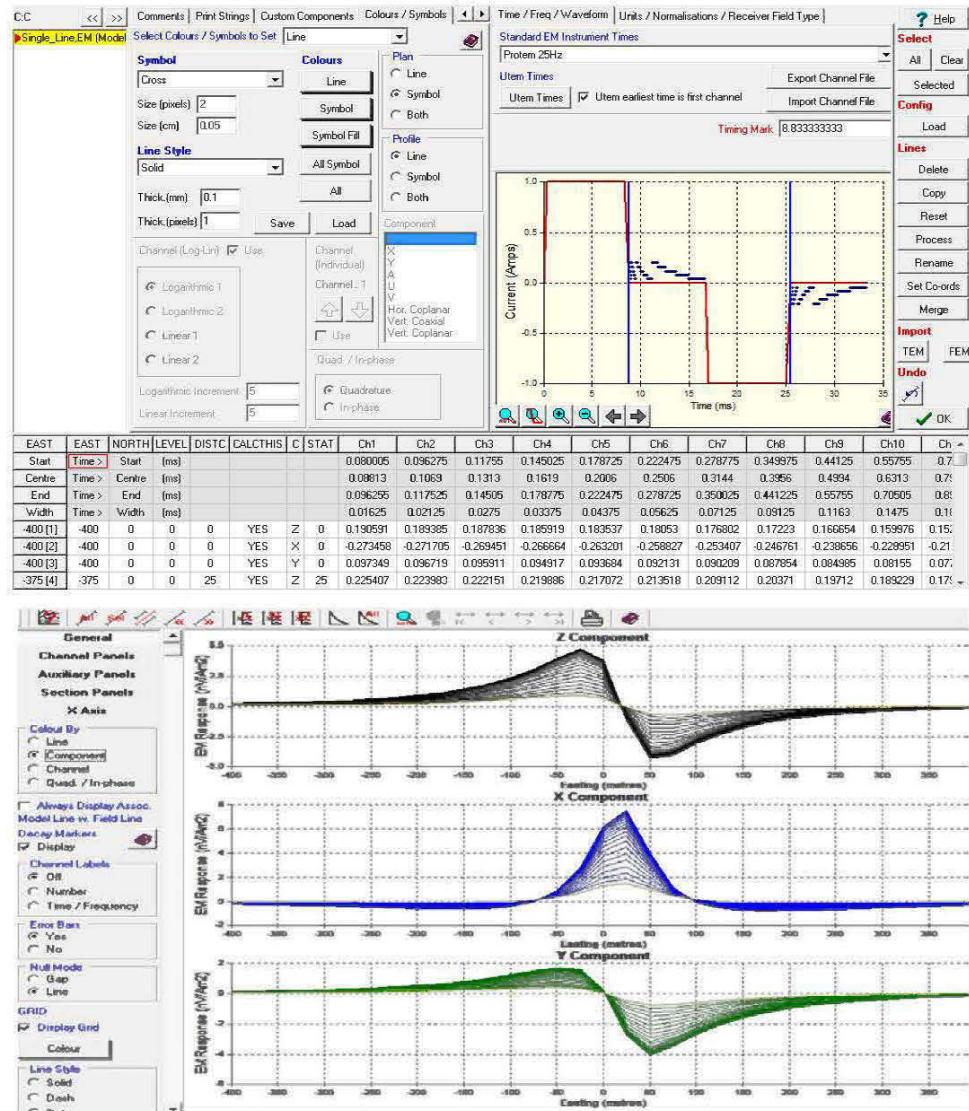


Figure 3.5 : Fenêtre de modélisation de la configuration du système

3.2.2 Signatures type des plaques minces générées par l'InfiniTEM

- **Conducteur vertical** : la figure 3.6 représente la réponse électromagnétique d'un conducteur de 200 mètres en longueur et en largeur. Le conducteur est localisé à 70

mètres de profondeur avec une conductance de 10 Siemens (S) et une inclinaison de 90 degrés.

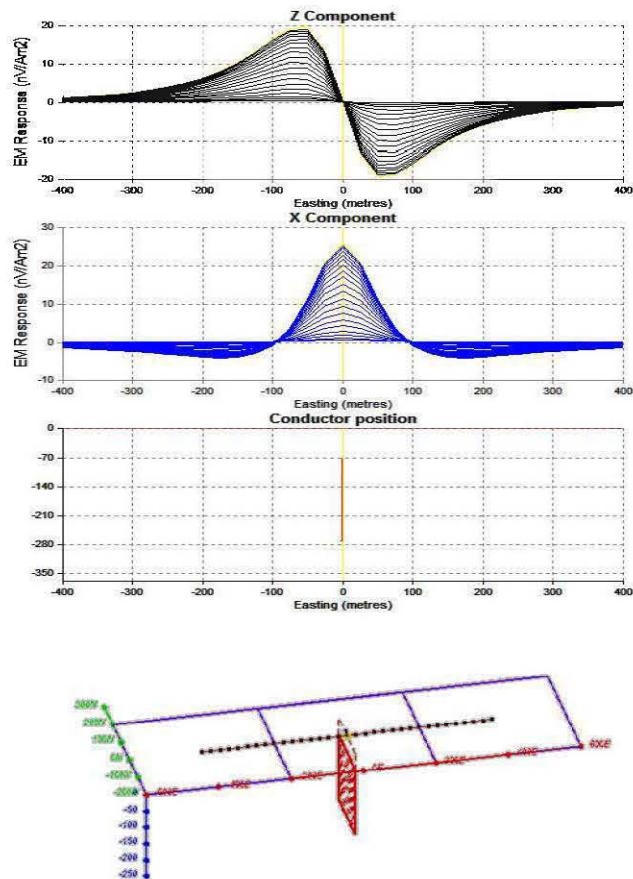


Figure 3.6 : Signature type d'un conducteur vertical

- **Conducteur horizontal** : la figure 3.7 représente la réponse électromagnétique d'un conducteur de 250 mètres en longueur et en largeur. Le conducteur est localisé à 50 mètres de profondeur avec une conductance de 70 Siemens (S) et une inclinaison de 0 degré.

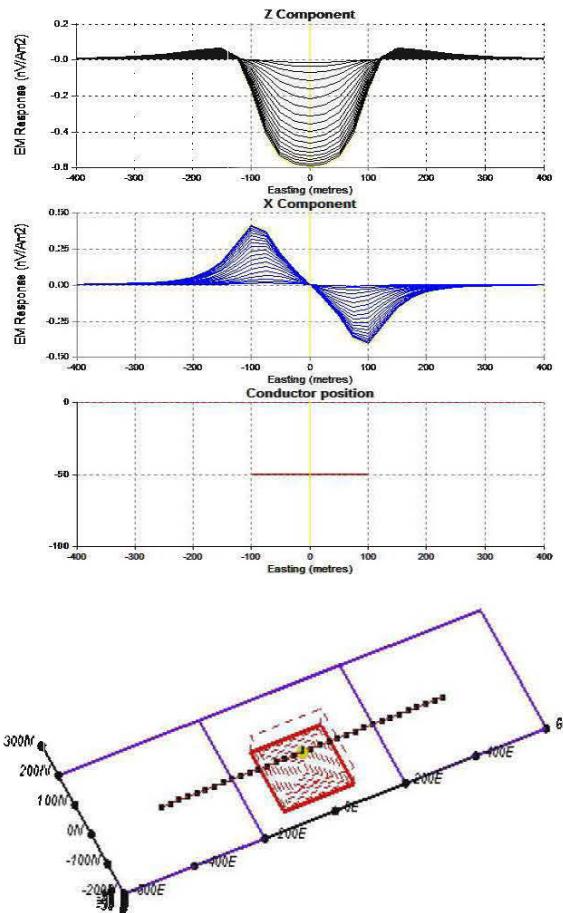


Figure 3.7 : Signature type d'un conducteur horizontal

- **Conducteur incliné** : La figure 3.8 et la figure 3.9 représentent

la réponse électromagnétique à différents pendages d'un conducteur de 200 mètres de longueur par 200 mètres de largeur localisé à une distance de -100 mètres, avec une conductance de 10 Siemens et une profondeur de 50 mètres pour la figure 3.8 et de 80 mètres de profondeur pour la figure 3.9.

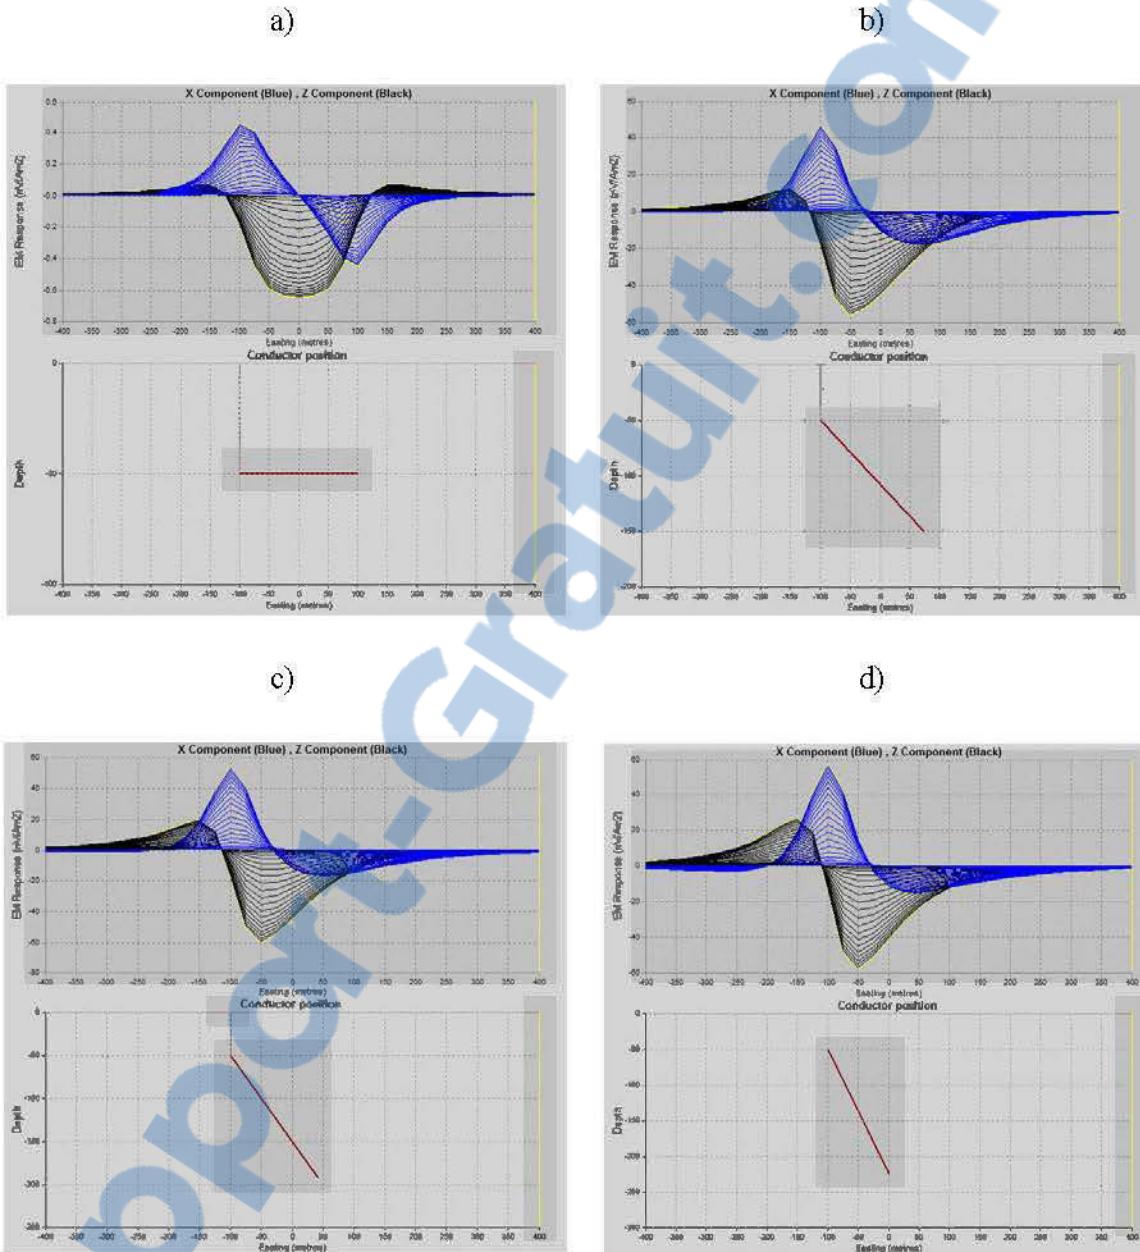
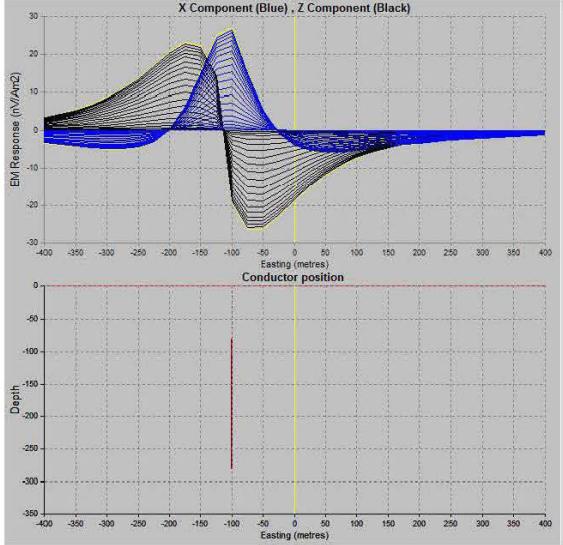
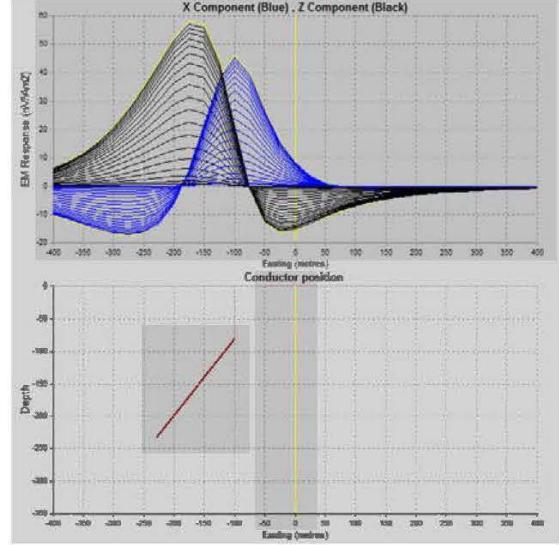


Figure 3.8 : Réponses InfiniTEM (fenêtres 1 à 20) pour des conducteurs à différent pendages 0 degré, b) 30 degrés, c) 45 degrés, d) 60 degrés

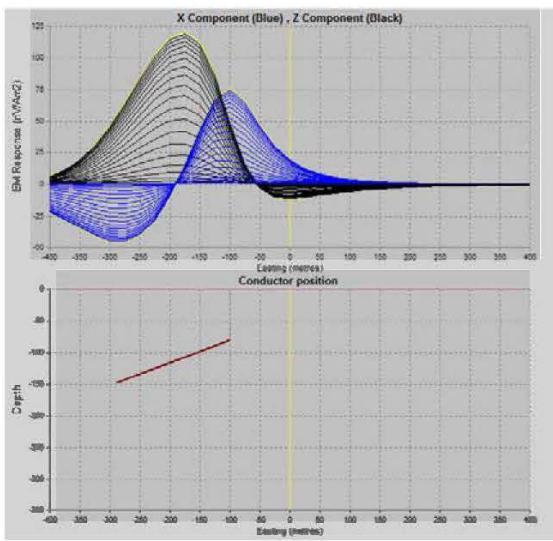
e)



f)



g)



h)

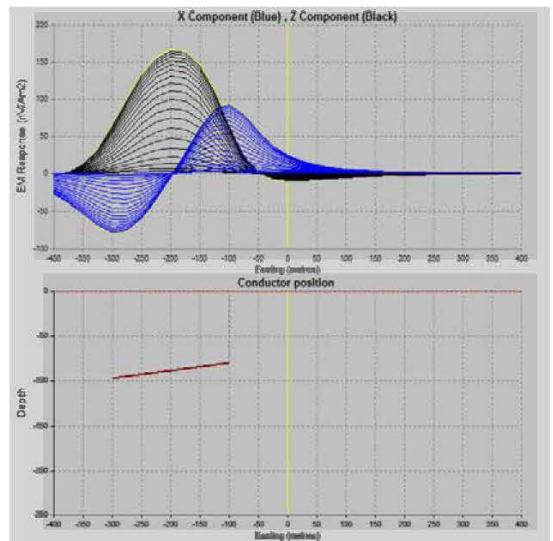


Figure 3.9 : Réponses InfiniTEM (fenêtres 1 à 20) pour des conducteurs à différent pendages e) 90 degré, f) 130 degrés, g) 150 degrés, h) 175 degrés

- **Cas de deux Conducteurs verticaux:** la figure 3.10 représente la réponse électromagnétique de deux conducteurs de même taille 200 mètres de longueur par 200 mètres de largeur, situés à 90 mètres de profondeur avec une conductance de 50 Siemens. Ces deux conducteurs sont séparés par un espacement respective de: 120 mètres, 200 mètres, 300 mètres, 500 mètres.
- **Cas de deux conducteurs à 45°:** la figure 3.11 représente la réponse électromagnétique de deux conducteurs de même taille 200 mètres de longueur par 200 mètres de largeur, situés à 90 mètres de profondeur avec une conductance de 50 Siemens. Ces deux conducteurs sont séparés par un espacement respective de: 120 mètres, 200 mètres, 300 mètres, 500 mètres.
- **Cas de deux conducteurs à 140°:** La figure 3.14 représente la réponse électromagnétique de deux conducteurs de même taille 200 mètres de longueur par 200 mètres de largeur, situés à 90 mètres de profondeur avec une conductance de 50 Siemens. Ces deux conducteurs sont séparés par un espacement respective de: 120 mètres, 200 mètres, 300 mètres, 500 mètres.

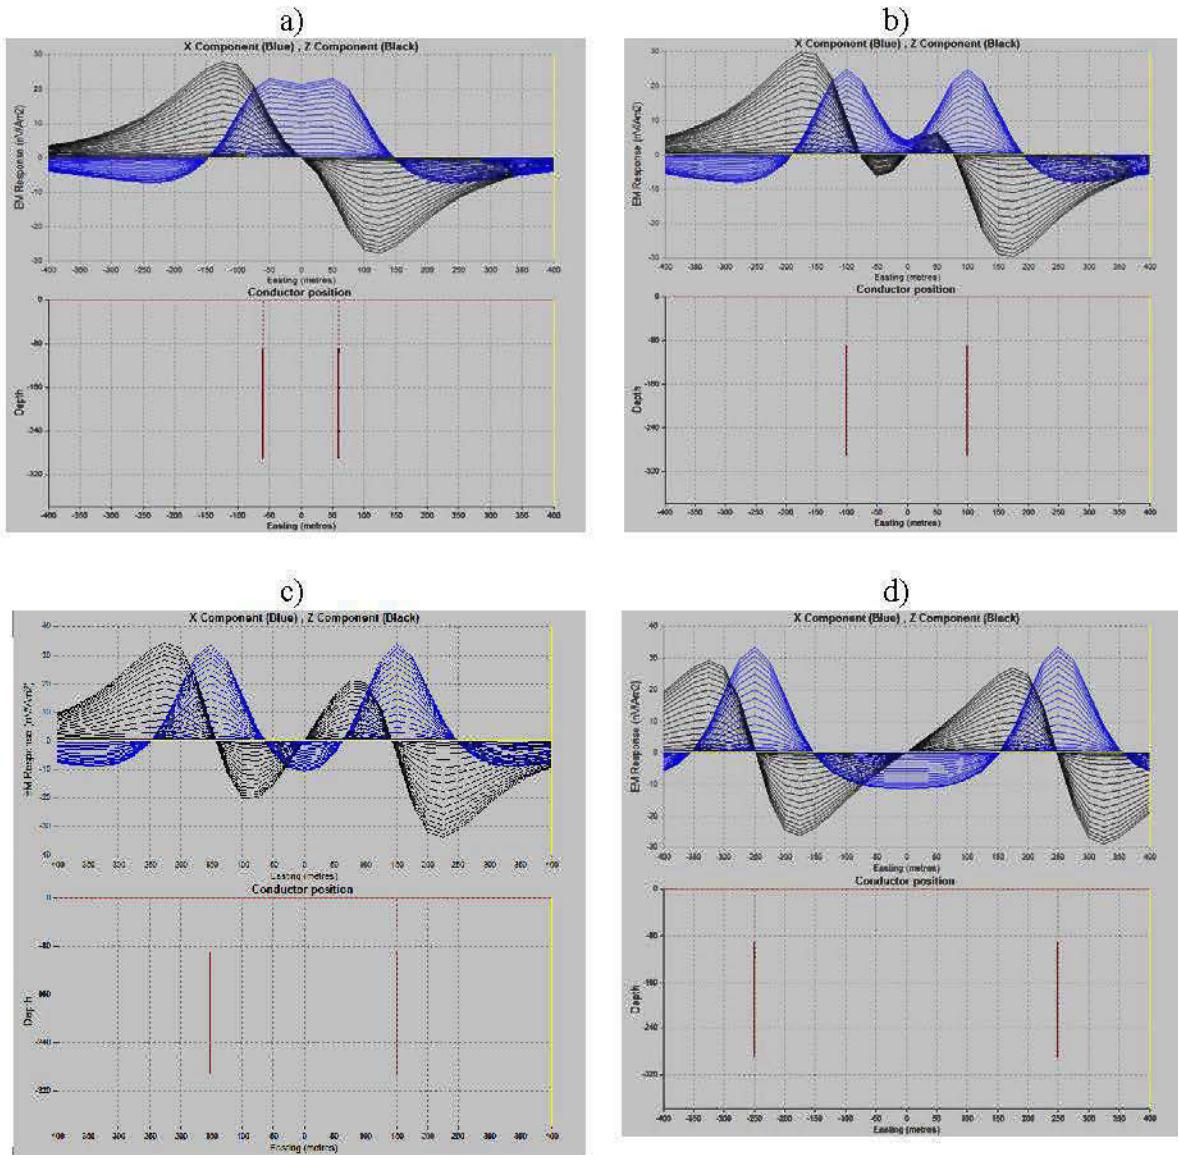


Figure 3.10 : Réponses InfiniTEM (fenêtres 1 à 20) pour deux conducteurs à différent espace a) 120 m, b) 200 m, c) 300 m, d) 500 m

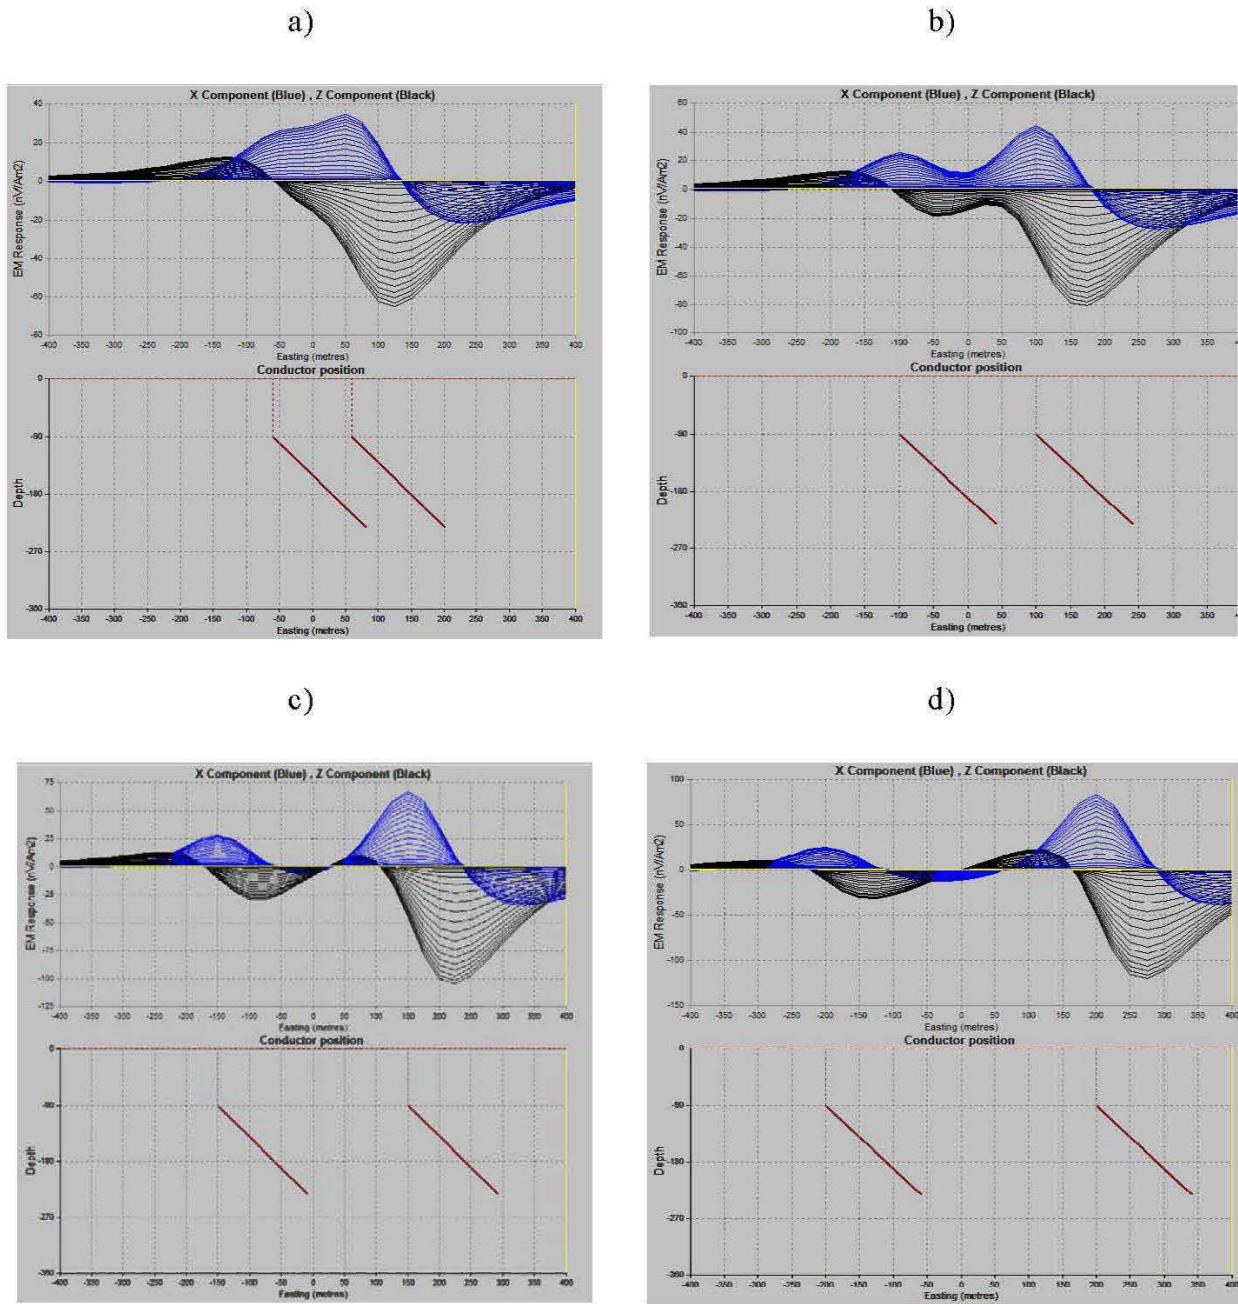


Figure 3.11 : Réponses InfiniTEM (fenêtres 1 à 20) pour deux conducteurs à 45° de pendage avec différent espacement a) 120 degré, b) 200 degrés, c) 300 degrés, d) 500 degrés

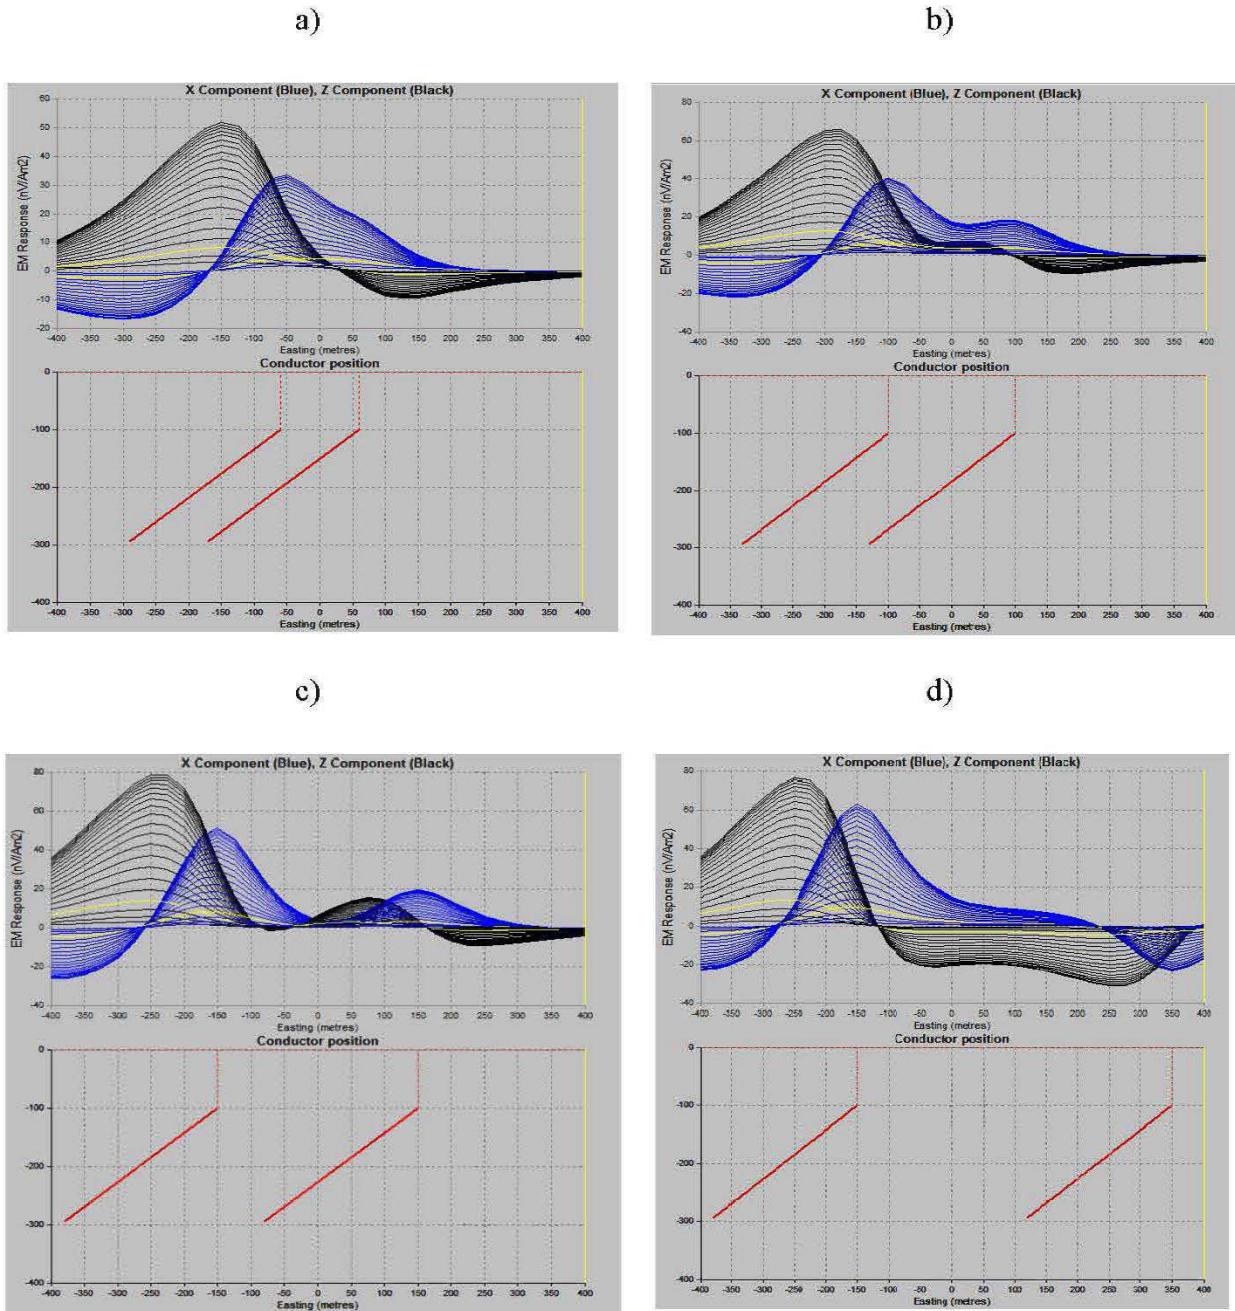


Figure 3.12 : Réponses InfiniTEM (fenêtres 1 à 20) pour deux conducteurs à 140° de pendage avec différent espace a) 120 degré, b) 200 degrés, c) 300 degrés, d) 500 degrés

- **Cas de trois conducteurs** : la figure 3.13 représente la réponse électromagnétique de trois conducteurs (fenêtres 1- 20) de même taille 200 mètres de longueur par 200 mètres de largeur situés à des différentes profondeurs avec des différentes conductances et pendage (tableau 3.1).

Tableau 3.1 : exemple de trois conducteurs à différent paramètres

	Taille (m)	Profondeur(m)	Pendage (°)	Conductance (S)
Conducteur 1	200 x 200	50	90	10
Conducteur 2	200 x 200	80	50	100
Conducteur 3	200 x 200	100	70	60

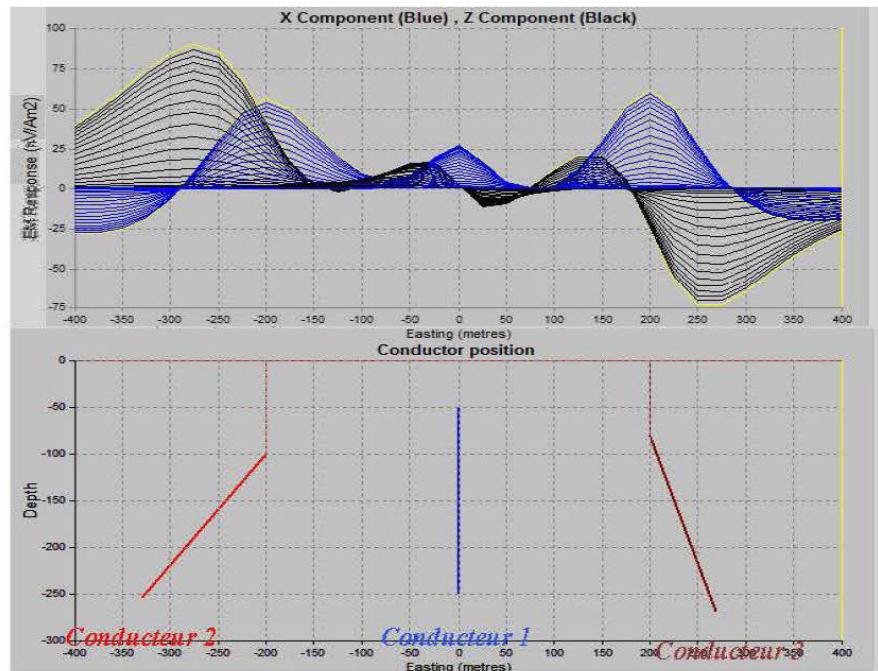


Figure 3.13 : Réponses InfiniTEM (fenêtres 1 à 20) de trois conducteurs à différent paramètres

La figure 3.14 représente la réponse électromagnétique de trois conducteurs de taille différente situés à différente profondeur avec différent conductance et pendage (tableau 3.2).

Tableau 3.2 : exemple de trois conducteurs à différent paramètres

	Taille (m)	Profondeur(m)	Pendage (°)	Conductance (S)
Conducteur 1	250X250	50	0	70
Conducteur 2	400X400	80	35	100
Conducteur 3	350X320	120	70	85

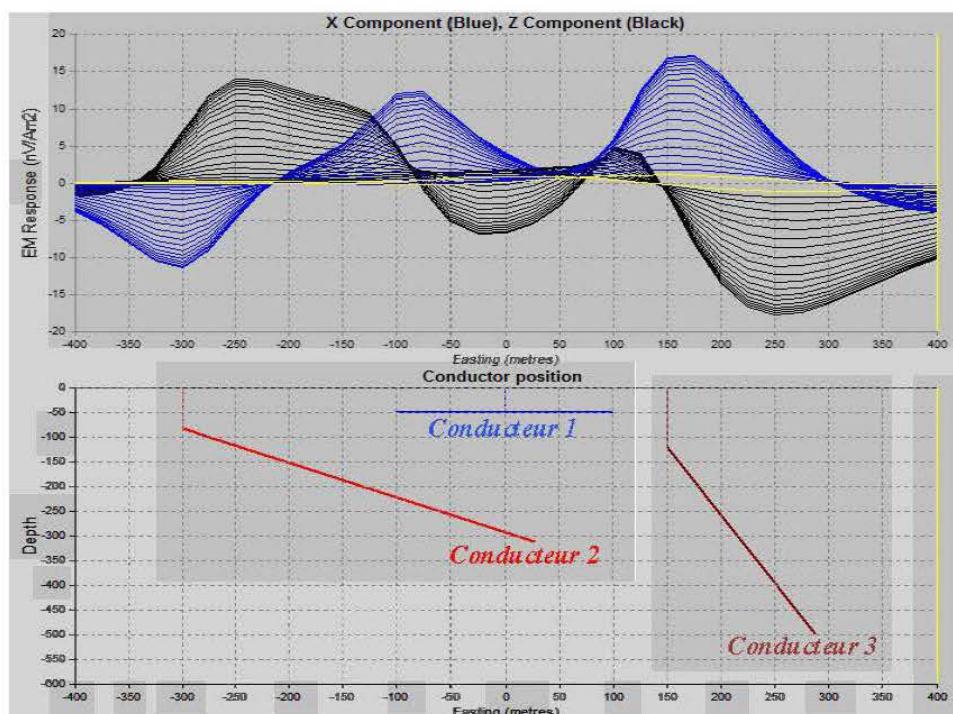


Figure 3.14 : Réponses InfiniTEM (fenêtres 1 à 20) de trois conducteurs à différent paramètres

En analysant les exemples précédents, nous constatons qu'il y a une grande variation sur la forme d'anomalie du système d'InfiniTEM. Plus la géologie est complexe, plus il est difficile d'identifier les sources d'anomalie comme le cas des conducteurs multiples.

3.2.3 Étude du comportement du système InfiniTEM

La position du conducteur par rapport au transmetteur et à la position de récepteur pourrait jouer un rôle critique dans la détection des cibles. Vue que la forme de l'anomalie d'InfiniTEM est aussi très variable (figures 3.6 à 3.14), nous avons effectué une série de modélisations en changeant les paramètres du conducteur ainsi que la configuration du système d'InfiniTEM afin de trouver des combinaisons optimales.

• Influence des paramètres sur les conducteurs verticaux

Tableau 3.3 : Séries de modèles avec variation de la taille

Série	Taille (m)	Profondeur (m)	Pendage (°)	Conductance (S)	Position E-O (m)
50	200 x 200	0 à 800	90	50	Centre
60	400 x 400	0 à 800	90	50	Centre
70	600 x 600	0 à 800	90	50	Centre
80	800 x 800	0 à 800	90	50	Centre

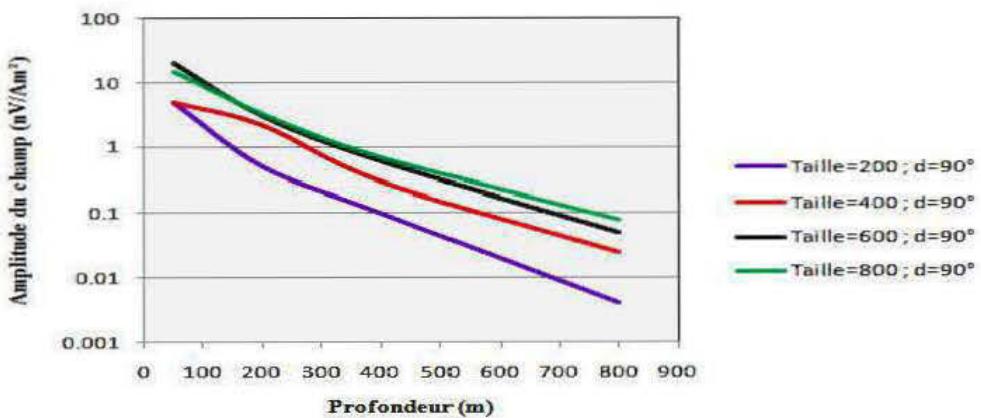


Figure 3.15 : Influence de la taille sur un conducteur vertical (canal 14)

Tableau 3.4 : Séries de modèles avec variation de la conductance

Série	Taille (m)	Profondeur (m)	Pendage (°)	Conductance (S)	Position E-O (m)
90	350 x 350	0 à 400	90	50	Centre
100	350 x 350	0 à 400	90	200	Centre
110	350 x 350	0 à 400	90	500	Centre

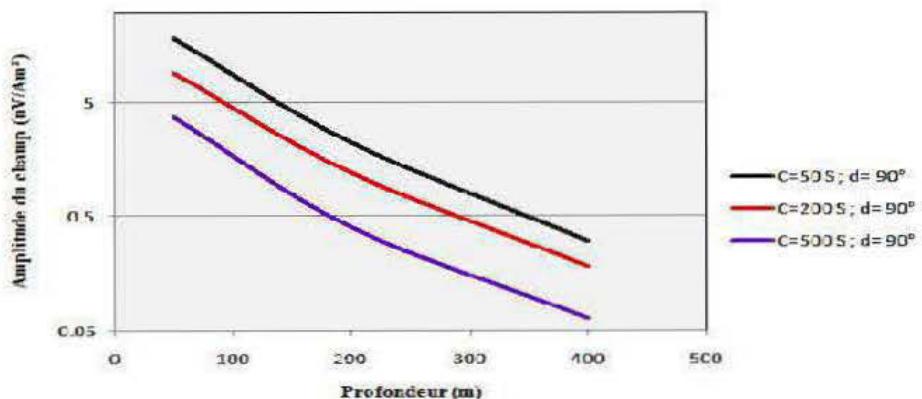


Figure 3.16 : Influence de la conductance sur un conducteur vertical (Canal 14)

Tableau 3.5: Séries de modèles avec variation de la position

Série	Taille (m)	Profondeur (m)	Pendage (°)	Conductance (S)	Position E-O (m)
120	400 x 400	0 à 400	90	50	300 Est
130	400 x 400	0 à 400	90	50	600 Est
140	400 x 400	0 à 400	90	50	900 Est

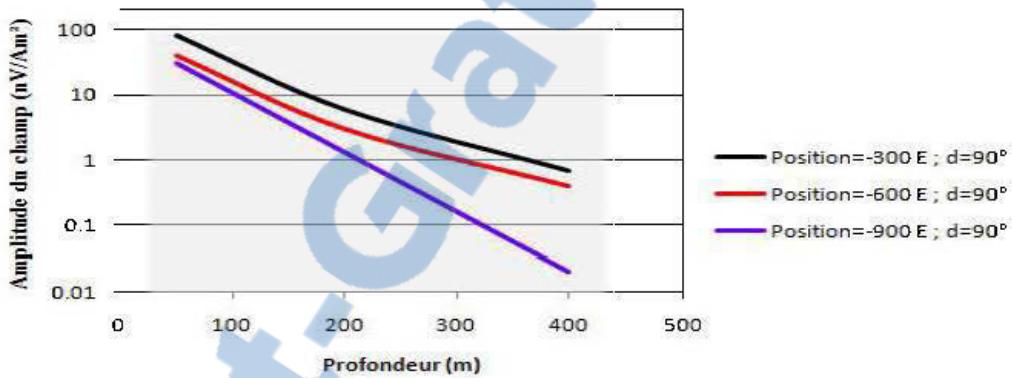


Figure 3.17 : Influence de la position sur un conducteur vertical (Canal 14)

• Influence des paramètres sur les conducteurs inclinés

Tableau 3.6 : Séries de modèles avec variation de la taille

Série	Taille (m)	Profondeur (m)	Pendage (°)	Conductance (S)	Position E-O (m)
150	200 x 200	0 à 800	45	50	Centre
160	400 x 400	0 à 800	45	50	Centre
170	600 x 600	0 à 800	45	50	Centre
180	800 x 800	0 à 800	45	50	Centre

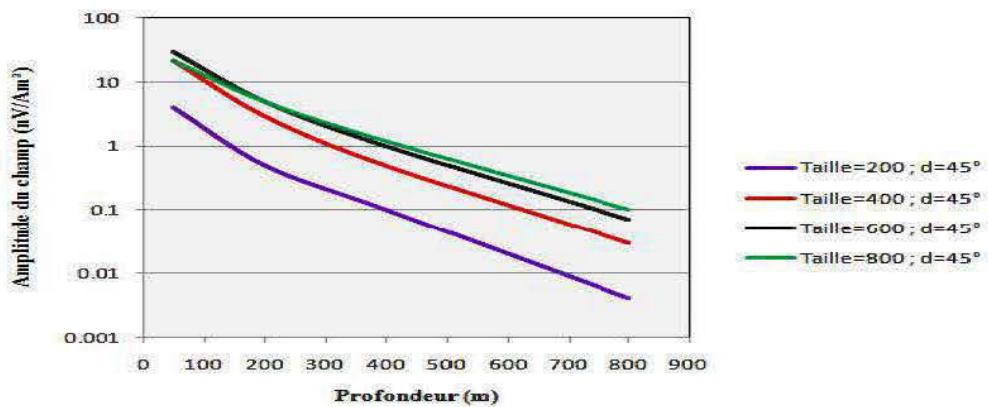


Figure 3.18 : Influence de la taille sur un conducteur incliné (Canal 14)

Tableau 3.7 : Séries de modèles avec variation de la conductance

Série	Taille (m)	Profondeur (m)	Pendage (°)	Conductance (S)	Position E-O (m)
190	350 x 350	0 à 400	45	50	Centre
200	350 x 350	0 à 400	45	200	Centre
210	350 x 350	0 à 400	45	500	Centre

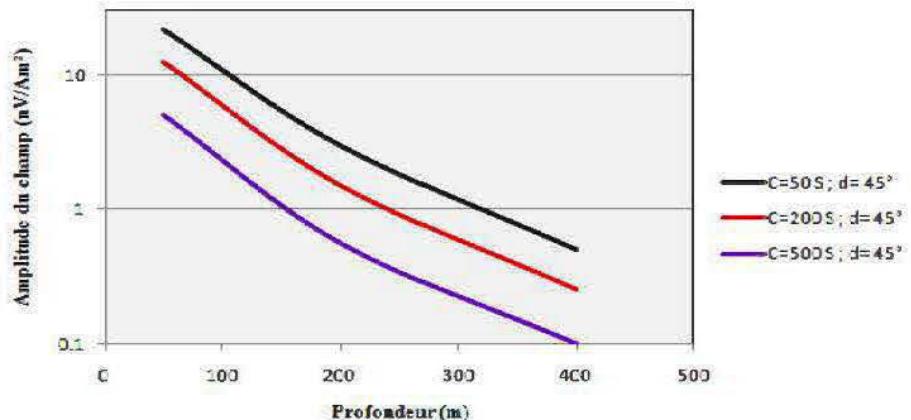


Figure 3.19 : Influence de la conductance sur un conducteur incliné (Canal 14)

Tableau 3.8: Séries de modèles avec variation de la position

Série	Taille (m)	Profondeur (m)	Pendage (°)	Conductance (S)	Position E-O (m)
220	400 x 400	0 à 400	45	50	300 Est
230	400 x 400	0 à 400	45	50	600 Est
240	400 x 400	0 à 400	45	50	900 Est

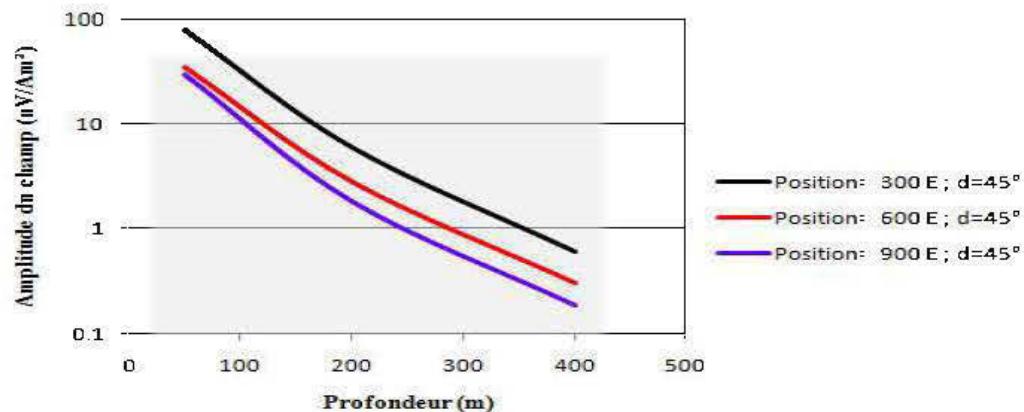


Figure 3.20 : Influence de la position sur un conducteur incliné (Canal 14)

• Influence des paramètres sur les conducteurs horizontaux

Tableau 3.9 : Séries de modèles avec variation de la taille

Série	Taille (m)	Profondeur (m)	Pendage (°)	Conductance (S)	Position E-O (m)
250	200 x 200	0 à 800	0	50	Centre
260	400 x 400	0 à 800	0	50	Centre
270	600 x 600	0 à 800	0	50	Centre
280	800 x 800	0 à 800	0	50	Centre

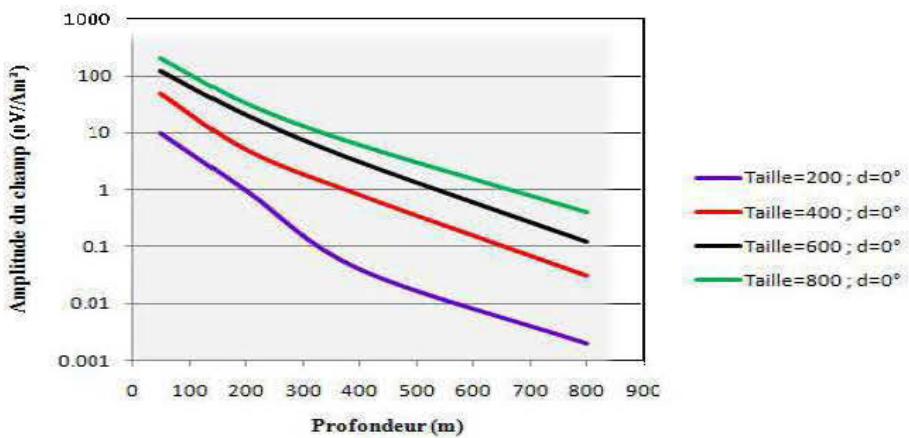


Figure 3.21 : Influence de la taille sur un conducteur horizontal (Canal 14)

Tableau 3.10 : Séries de modèles avec variation de la conductance

Série	Taille (m)	Profondeur (m)	Pendage (°)	Conductance (S)	Position E-O (m)
290	350 x 350	0 à 400	0	50	Centre
300	350 x 350	0 à 400	0	200	Centre
310	350 x 350	0 à 400	0	500	Centre

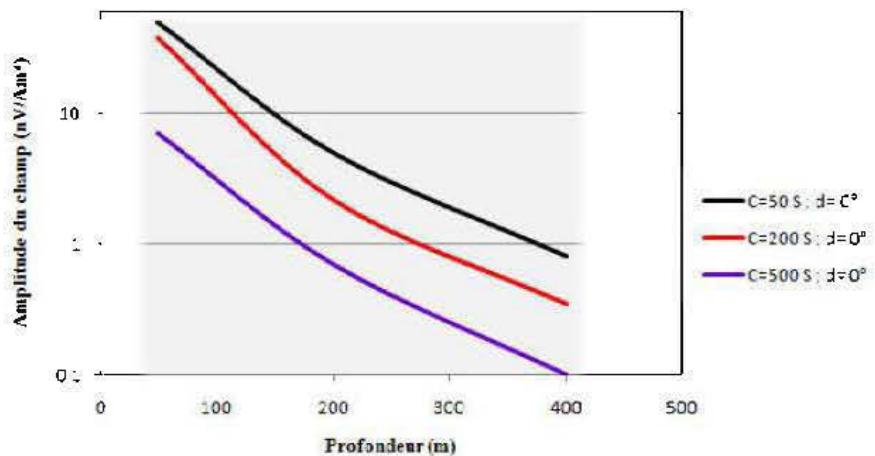


Figure 3.22 : Influence de la conductance sur un conducteur horizontal (Canal 14)

Tableau 3.11: Séries de modèles avec variation de la position

Série	Taille (m)	Profondeur (m)	Pendage (°)	Conductance (S)	Position E-O (m)
320	400 x 400	0 à 400	0	50	300 Est
330	400 x 400	0 à 400	0	50	600 Est
340	400 x 400	0 à 400	0	50	900 Est

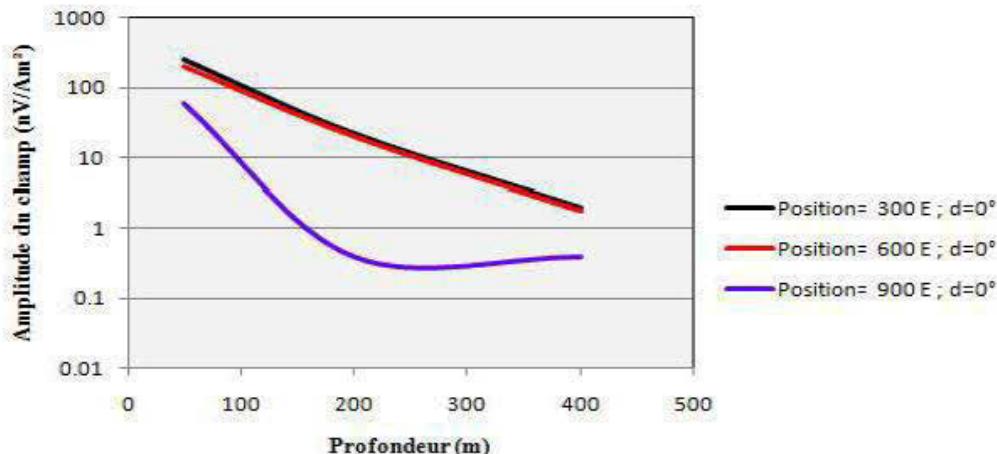


Figure 3.23 : Influence de la position sur un conducteur horizontal (Canal 14)

• Choix de la taille de la boucle

Tableau 3.12: Séries de modèles de la variation de l'espacement entre les demi-boucles pour un conducteur vertical

Série	Taille des demi-boucles (m)	Espacement entre les demi-boucles (m)	Profondeur (m)	Conductance (S)	Position E-O (m)
500	400 x 400	200	200	50	Centre
550	400 x 400	400	200	50	Centre
600	550 x 550	550	200	50	Centre

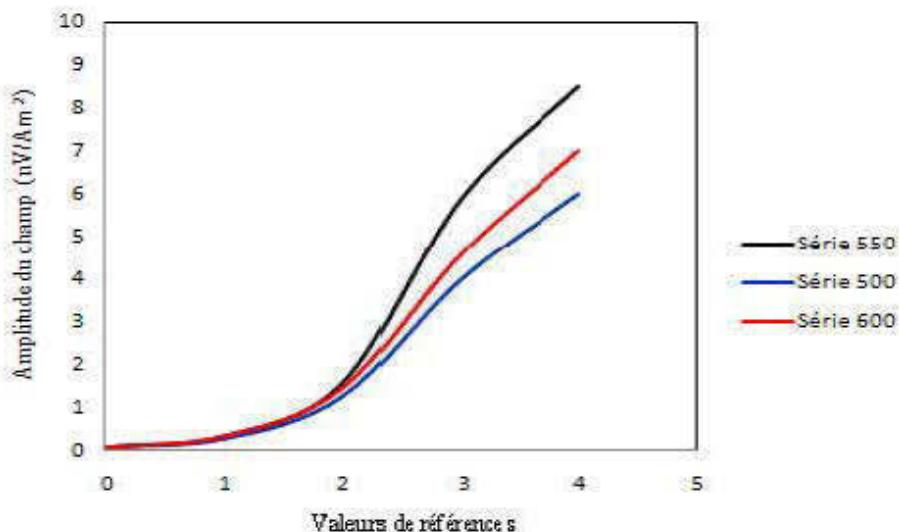


Figure 3.24 : Influence de l'espacement entre les deux demi-boucles (Canal 14)

Tableau 3.13: Séries de modèles de la variation de l'espacement entre les demi-boucles pour un conducteur vertical

Série	Taille des demi-boucles (m)	Espacement entre les demi-boucles (m)	Profondeur (°)	Conductance (S)	Position E-O (m)
650	400 x 400	200	350	50	Centre
700	400 x 400	400	350	50	Centre
750	550 x 550	550	350	50	Centre

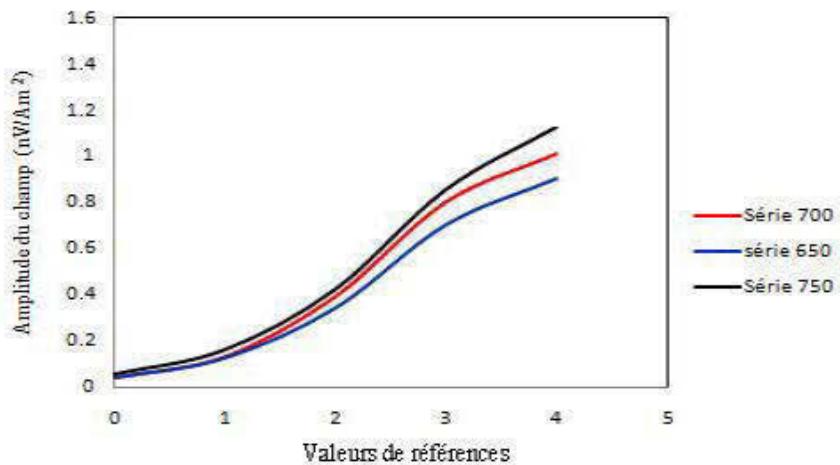


Figure 3.25 : Influence de l'espacement entre les deux demi-boucles (Canal 14)

Tableau 3.14: Séries de modèles de la variation de l'espacement entre les demi-boucles pour un conducteur vertical

Série	Taille des demi-boucles (m)	Espace- ment entre les demi-boucles (m)	Profondeur (°)	Conductance (S)	Position E-O (m)
800	400 x 400	200	620	50	Centre
850	400 x 400	400	620	50	Centre
900	550 x 550	550	620	50	Centre

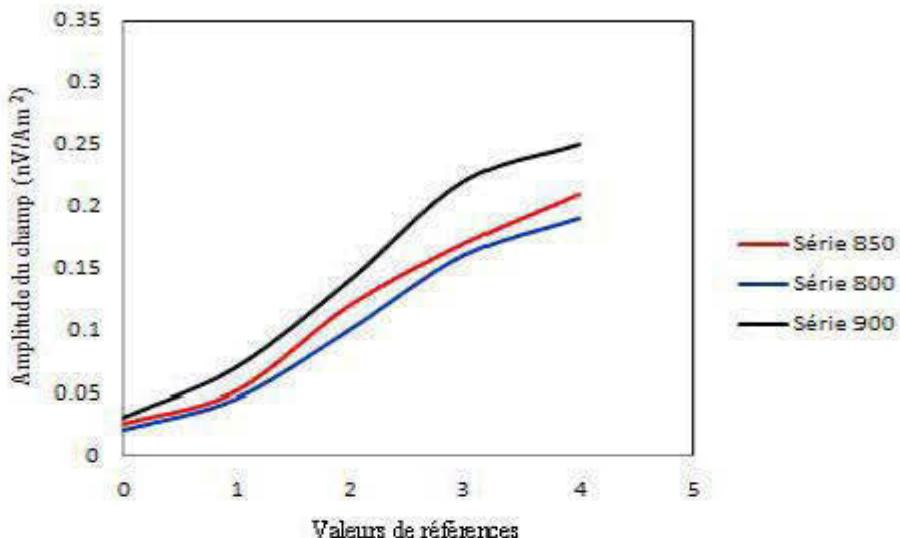


Figure 3.26 : Influence de l'espacement entre les deux demi-boucles (Canal 14)

3.2.3.1 Influence de la taille du conducteur à différents pendages

Les figures 3.15, 3.18 et 3.21 illustrent la réponse InfiniTEM des modèles de conducteurs caractérisés par des tailles de 200 m, 400 m, 600 m et 800 m à des profondeurs variables avec des pendages respectifs de 90°, 45° et 0°.

La figure 3.15 montre que pour un pendage de 90° les conducteurs de taille de 800 m et 600 m donnent une amplitude du champ électromagnétique maximum, puis celle-ci diminue progressivement en allant en profondeur.

L'amplitude du champ électromagnétique est moins importante pour les conducteurs de tailles 200 m et 400 m mais elles diminuent également en allant d'avantage profondeur.

Les figures 3.18 et 3.21 qui définissent respectivement les réponses électromagnétiques de conducteurs à différentes tailles (200 m, 400 m, 600 m et 800 m) avec des pendages respectifs de 45° et 0° sont très analogues à la figure 3.15 en termes d'allure de la courbe et décroissance d'amplitude de champs en fonction de la profondeur.

3.2.3.2 Influence de la conductance sur les conducteur à différents Pendages

Les figures 3.16, 3.19 et 3.22 illustrent la réponse d'InfiniTEM des modèles de conducteurs caractérisés par des conductances de 50 S, 200 S et 500 S à des profondeurs variables avec des pendages respectifs de 90°, 45° et 0 °.

La figure 3.16 montre que pour un pendage de 90° la conductance de 50S donne une amplitude maximum pour une profondeur de 50m, cette amplitude commence à diminuer en allant plus en profondeur.

L'amplitude du champ électromagnétique est moins importante pour les conductances respectives de 200S et 500S mais par contre elle diminue également en profondeur.

Les figures 3.19 et 3.22 qui définissent respectivement la réponse électromagnétique à des conductances de 50S, 200S et 500S pour les pendages de 45° et 0 °ont la même analogie que la figure 3.16 en termes d'allure de courbe et décroissance d'amplitude de champs.

3.2.3.3 Influence de la position latérale à différents pendages

La figure 3.17, 3.18 et 3.19 illustrent la réponse InfiniTEM des modèles de conducteur caractérisé par leurs positions latérales 300 E, 600 E, 900 E par rapport au centre de la boucle et à des profondeurs variables avec des pendages respectifs de 90°, 45° et 0 °.

La figure 3.17 montre que pour un pendage de 90° la position 300 E donne une amplitude du champ électromagnétique maximum, puis celle-ci diminue progressivement en allant en profondeur.

L'amplitude du champ électromagnétique est moins importante pour les conducteurs aux positions -600 E, -900 E mais elles diminuent également en allant d'avantage en profondeur.

Les figures 3.18 et 3.19 qui définissent respectivement la réponse électromagnétique de conducteurs aux positions 300 E, 600 E, 900 E à des pendages respectifs de 45°

et 0° sont très semblable à la figure 3.17 est présente la même allure de courbes et une décroissance similaire de l'amplitude.

3.2.3.4 Influence de la taille de la boucle émettrice

Les figures 3.24, 3.25 et 3.26 illustrent la réponse InfiniTEM des modèles de conducteur caractérisé par des boucles de différente taille et espacement à des profondeur respective de 200 m, 350 m, 620 m. L'espacement entre les deux demi boucle et de 200 m, 400 m, 550 m respectivement.

La figure 3.24 montre que pour la profondeur de 200 m l'amplitude de la réponse électromagnétique de la boucle de 400 m de taille et de 400 m d'espacement est plus importante tandis que la figure 3.25 montre que pour la profondeur de 350 m l'amplitude de la réponse électromagnétique de la boucle de 550 m de taille et de 550 m d'espacement est plus importante.

La figure 3.26 montre que pour la profondeur de 620 m l'amplitude de la réponse électromagnétique de la boucle de 550 m de taille et de 550 m d'espacement est plus importante.

3.2.4 Banque de données pour l'application des RNA

Afin d'appliquer la méthode des réseaux de neurone artificiel (RNA) à la prédiction des conducteurs décrits par les anomalies que nous avons présentées, une banque de données contenant 854 modèles a été générée en faisant varier les paramètres physiques et géométriques du conducteur (tableau 3.4).

Nous avons divisé les modèles en 22 séries et 4 groupes. Nous varions systématiquement les quatre paramètres principaux (pendage, taille, conductance et profondeur) qui sont essentiels pour caractériser un conducteur et à l'intérieur de chaque groupe nous varions aussi les autres paramètres afin d'avoir une banque de données la plus complexe possible.

Tableau 3.15: Banque de données pour l'application des RNA

Séries	Variables	Paramètres Fixe ($m, S, ^\circ$)	Intervalle des Valeur ($m, S, ^\circ$)	Incrément	Nombre de modèles
1	Pendage	Taille = 250X250 m Profondeur = 50 m Conductance = 50 S	0 – 90 °	5 °	19
2	Pendage	Taille = 300X300 m Profondeur = 80 m Conductance = 50 S	0 – 90 °	5 °	19
3	Pendage	Taille = 300X200 m Profondeur = 120 m Conductance = 50 S	0 – 90 °	5 °	19
4	Pendage	Taille = 300X300 m Profondeur = 120 m Conductance = 50 S	0 – 90 °	5 °	19
5	Pendage	Taille = 350X350 m Profondeur = 120 m Conductance = 50 S	0 – 90 °	5 °	19
6	Pendage	Taille = 300X300 m Profondeur = 150 m Conductance = 50 S	0 – 90 °	5 °	19
7	Taille	Pendage = 90 ° Profondeur = 120 m Conductance = 50 S	10 – 400 m	10 m	40
8	Taille	Pendage = 90 ° Profondeur = 50 m Conductance = 50 S	10 – 400 m	10 m	40
9	Taille	Pendage = 90 ° Profondeur = 50 m Conductance = 50 S	10 – 400 m	10 m	40
10	Taille	Pendage = 45 ° Profondeur = 50 m Conductance = 50 S	10 – 400 m	10 m	40
11	Taille	Pendage = 45 ° Profondeur = 100 m Conductance = 50 S	10 – 400 m	10 m	40
12	Taille	Pendage = 45 ° Profondeur = 150 m Conductance = 50 S	10 – 400 m	10 m	40
13	Conductance	Taille = 300X300 m Profondeur = 50 m Pendage = 90 °	10 – 500 S	10 S	50
14	Conductance	Taille = 300X300 m Profondeur = 50 m Pendage = 45 °	10 – 500 S	10 S	50
15	Conductance	Taille = 300X300 m Profondeur = 50 m Pendage = 0 °	10 – 500 S	10 S	50

Séries	Variables	Paramètres Fixe (m, S, °)	Intervalle des Valeur (m, S, °)	Incrément	Nombre de modèles
16	Conductance	Taille = 300X300 m Profondeur = 100 m Pendage = 0 °	10 – 500 S	10 S	50
17	Conductance	Taille = 400X400 m Profondeur = 200 m Pendage = 90 °	10 – 500 S	10 S	50
18	Conductance	Taille = 400X400 m Profondeur = 200 m Pendage = 45 °	10 – 500 S	10 S	50
19	Profondeur	Taille = 250X250 m Conductance = 50 S Pendage = 0 °	10 – 500 m	10 m	50
20	Profondeur	Taille = 250X250 m Conductance = 90 S Pendage = 45 °	10 – 500 m	10 m	50
21	Profondeur	Taille = 350X350 m Conductance = 50 S Pendage = 90 °	10 – 500 m	10 m	50
22	Profondeur	Taille = 400X400 m Conductance = 50 S Pendage = 90 °	10 – 500 m	10 m	50

CHAPITRE IV

Application des RNA sur les données InfiniTEM

4.1 Processus du système RNA utilisé

Pour la plupart des architectures des RNA, l'apprentissage se traduit par une modification des poids synaptiques, c'est-à-dire par un changement dans la valeur des poids qui relient les neurones d'une couche à l'autre (Parizeau, 2004). Le processus d'entraînement de notre système de RNA consiste en plusieurs étapes (Figure 4.1) qui peuvent être résumées comme suit :

- Le choix des variables d'entrée et de sortie basé sur la banque des données générées dans le chapitre précédent;
- la détermination du nombre de couches cachées, le nombre de neurones dans chaque couche cachée et le nombre d'itérations nécessaire pour atteindre à une solution stable ;
- l'apprentissage du système de RNA basé sur la rétro-propagation de l'erreur dans les poids synaptiques.

Le type d'apprentissage utilisé dans notre application est l'apprentissage supervisé. Comme nous l'avons déjà expliqué dans la section 2.4.1, dans ce type d'apprentissage, on cherche à imposer au réseau un fonctionnement donné en forçant les sorties des réseaux à prendre des valeurs bien définies (choisies par l'opérateur) et ce en modifiant les poids synaptiques.

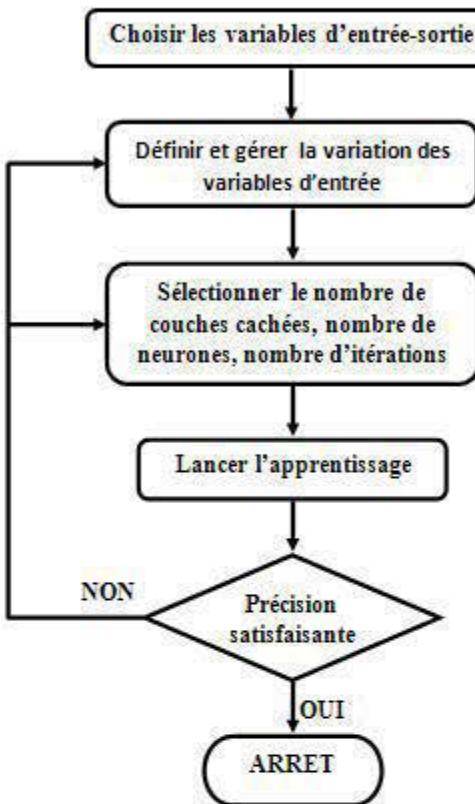


Figure 4.1 : Schéma de la procédure d'apprentissage de notre RNA

4.1.1 Choix des paramètres d'entrée et de sortie

Dans le chapitre précédent une banque des données de 854 modèles avait été créée pour jouer le rôle de base de données de notre entraînement de RNA. La réponse électromagnétique de ces modèles va constituer notre entrée pour le système de RNA et les paramètres du modèle vont constituer notre sortie (figure 4.2), donc l'entraînement de notre RNA revient à choisir les paramètres idéals pour prédire les propriétés des conducteurs recherchés.

La profondeur, l'inclinaison et la conductance, sont trois paramètres fondamentaux pour caractériser un conducteur enfoui dans le sous-sol. Par un modèle de plaque mince nous avons démontré, dans le chapitre 3, que la variation de ces trois facteurs

affecte d'une manière significative la forme de la réponse d'InfiniTEM. Avant l'entraînement du système de RNA, la première question qui se pose est : quel est l'attribut de l'anomalie d'InfiniTEM que l'on doit utiliser comme paramètre dans les données d'entrée. Après un multiple de tests et de simulations, nous avons observé que l'amplitude forte de l'anomalie nous permet d'avoir une bonne sortie (prédiction satisfaisante), comme nous allons le voir dans le prochain chapitre.

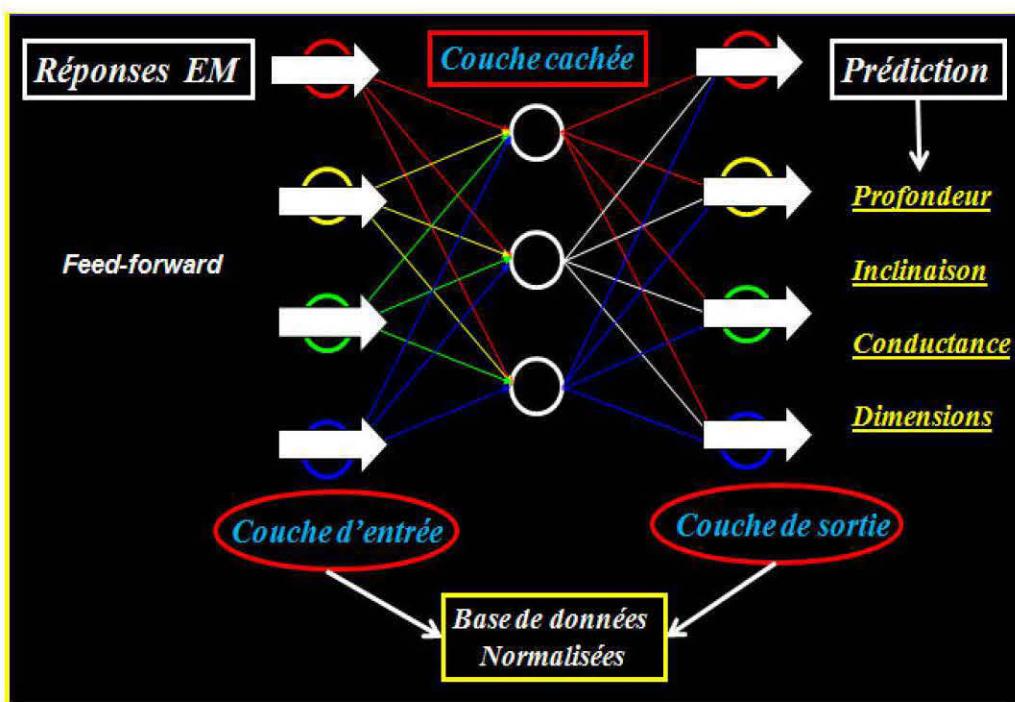


Figure 4.2 : Processus du modèle RNA

4.1.2 Choix des paramètres du modèle RNA

Le choix des paramètres d'un réseau de neurones dépend principalement du problème à résoudre. Il n'existe donc pas de règle globale pour déterminer avec exactitude les paramètres à adopter pour résoudre un problème donné (Coulibaly et al 1998).

Le nombre de neurones en entrée et sortie est généralement déterminé par la taille du fichier à analyser (Rumelhart et al. 1986; Hassoum 1995).

Le nombre de couches intermédiaires (couches cachées) varie en fonction de la complexité du problème et de l'objectif recherché (prédiction souhaiter). La distribution de ces données (distribution uniforme, non uniforme, aléatoire,...) dépend du problème à modéliser, toutefois la distribution uniforme est le plus retenu par les concepteurs en absence d'informations préalables des problèmes à modéliser (Zhang et al., 2000, Devabhaktuni et al., 2001).

Afin de déterminer les meilleurs paramètres du réseau (nombre de neurones cachés, nombre de couches cachées, nombre d'itérations) qui donne une prédiction satisfaisante, nous avons fait une série de tests pour le nombre de neurones cachés variant entre 5 et 35 neurones, pour des couches cachées variant entre 1 à 4 qui sont régis par des itérations allant de 1000 à 3000 comme l'indique le tableau 4.1.

Tableau 4.1 : Les paramètres du modèle RNA

Nombre de couches cachés	Nombre d'itérations utilisées	Intervalle du nombre de neurones cachés
1	1000 - 2000 - 3000	[5- 35]
2	1000 - 2000 - 3000	[5- 35]
3	1000 - 2000 - 3000	[5- 35]
4	1000 - 2000 - 3000	[5- 35]

Résultat du nombre des neurones cachés et des couches cachées

La variation du nombre de neurones pour le cas d'une couche cachée est illustrée par la figure 4.3 où on remarque que l'erreur diminue en augmentant le nombre de

neurones cachés ainsi que le nombre d'itérations. L'erreur devient plus stable et constante à partir de 25 neurones cachés.

Pour le cas de deux couches cachées qui est illustré par la figure 4.4 on voit une diminution significative de l'erreur entre 5 et 10 neurones, cette diminution devient moins importante entre 10 et 15 neurones pour qu'elle devienne par la suite plus constante à partir du 15éme neurones.

Le cas de trois couches est présenté par la figure 4.5, qui est semblable au deux cas précédent en termes de la forme de courbe. On remarque que l'erreur diminue d'une manière importante au début pour qu'elle se stabilise à partir du 20éme neurones.

Finalement le dernier cas de quatre couches cachées présenté par la figure 4.6 est presque identique à celui de trois couches cachées où l'erreur est considérée optimale à partir du 20éme neurones.

En analysant ces résultats des nombres de neurones cachés d'une façon conjointe on peut dire qu'un nombre de 25 neurones cachés constitue pour notre étude une valeur suffisante pour l'entraînement du réseau. On peut également voir que le nombre d'itération joue un rôle dans l'optimisation de l'erreur.

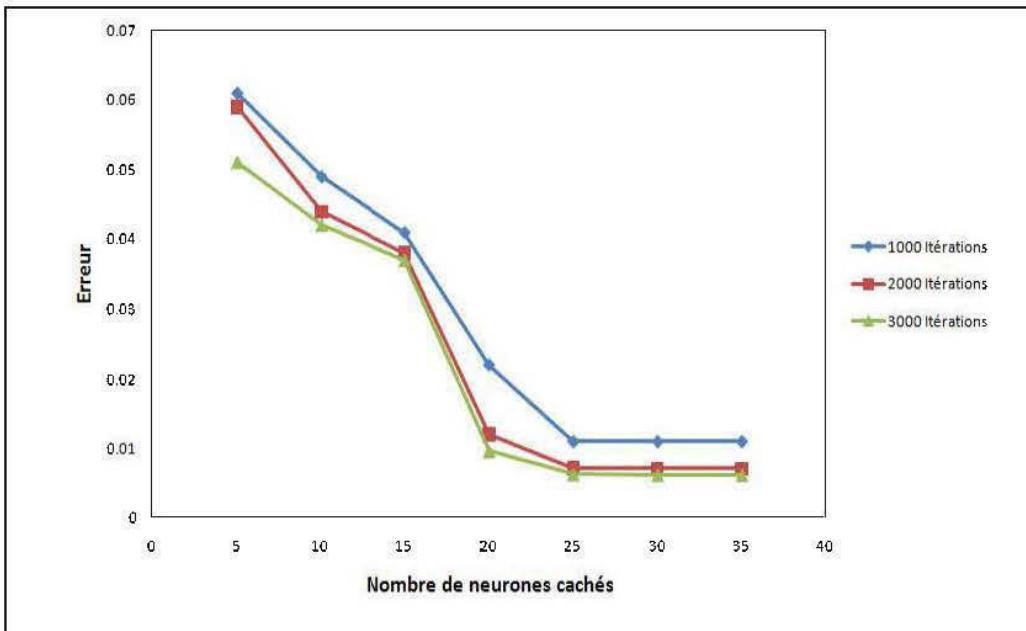


Figure 4.3: Variation de l'erreur en fonction du nombre de neurones pour une couche cachée

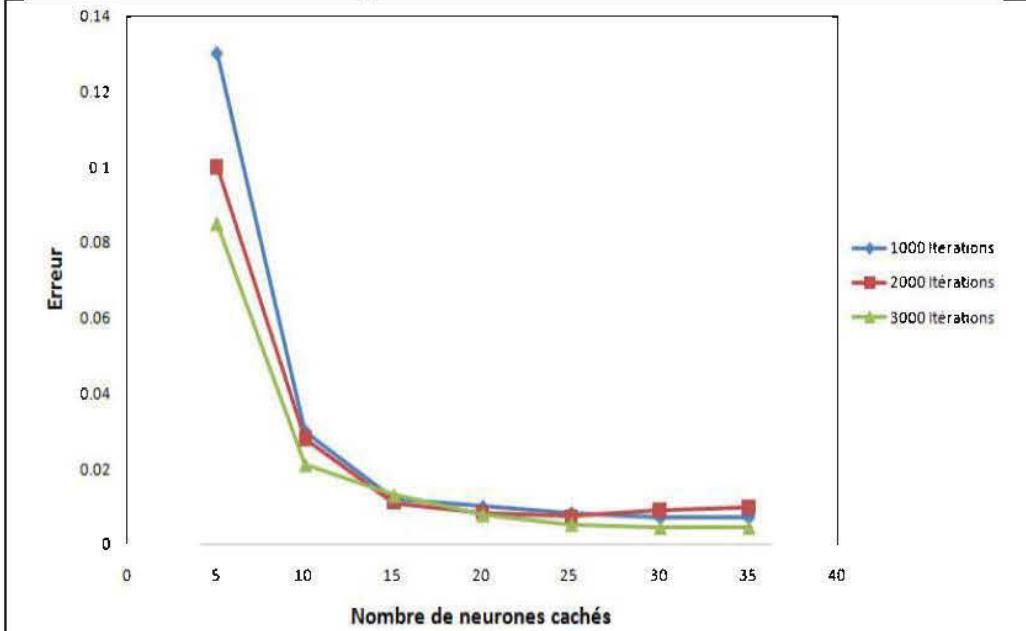


Figure 4.4 : Variation de l'erreur en fonction du nombre de neurones pour 2 couches cachées

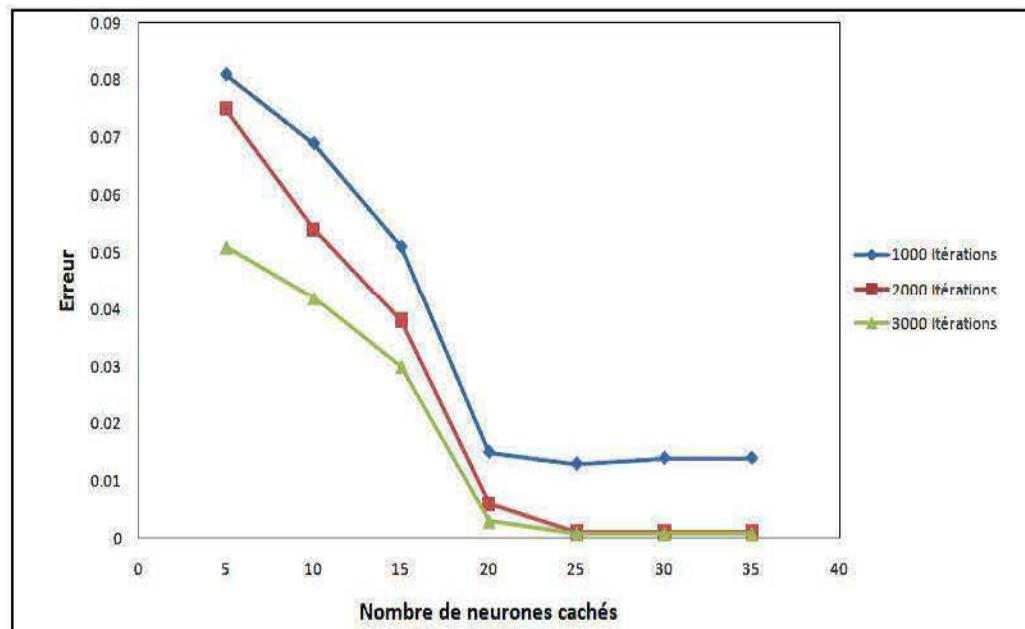


Figure 4.4 : Variation de l'erreur en fonction du nombre de neurones pour 3 couches cachées

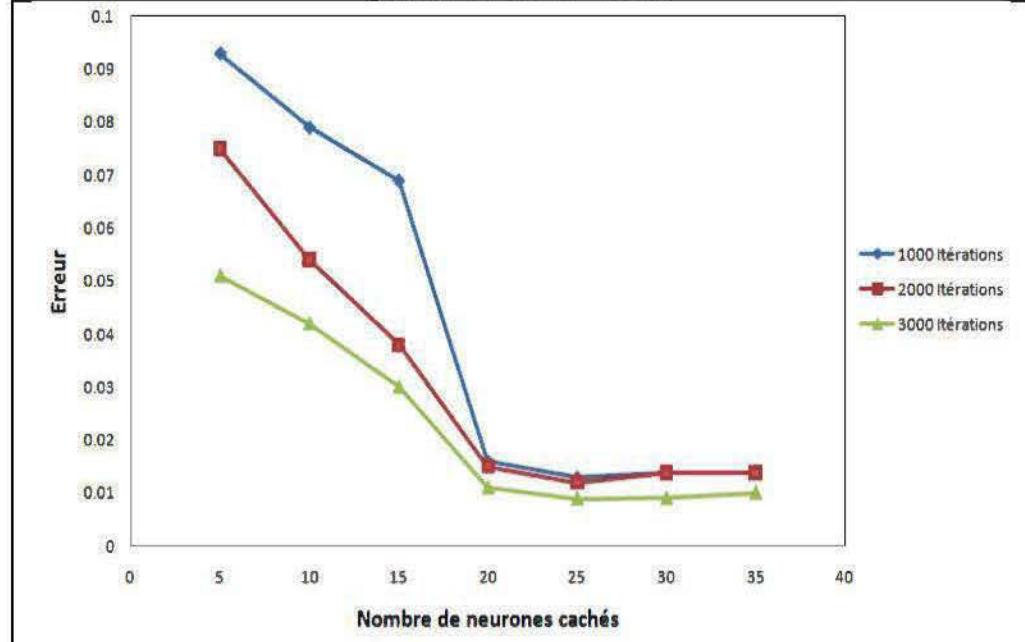


Figure 4.6 : Variation de l'erreur en fonction du nombre de neurones pour 4 couches cachées

Résultat du nombre d'itérations

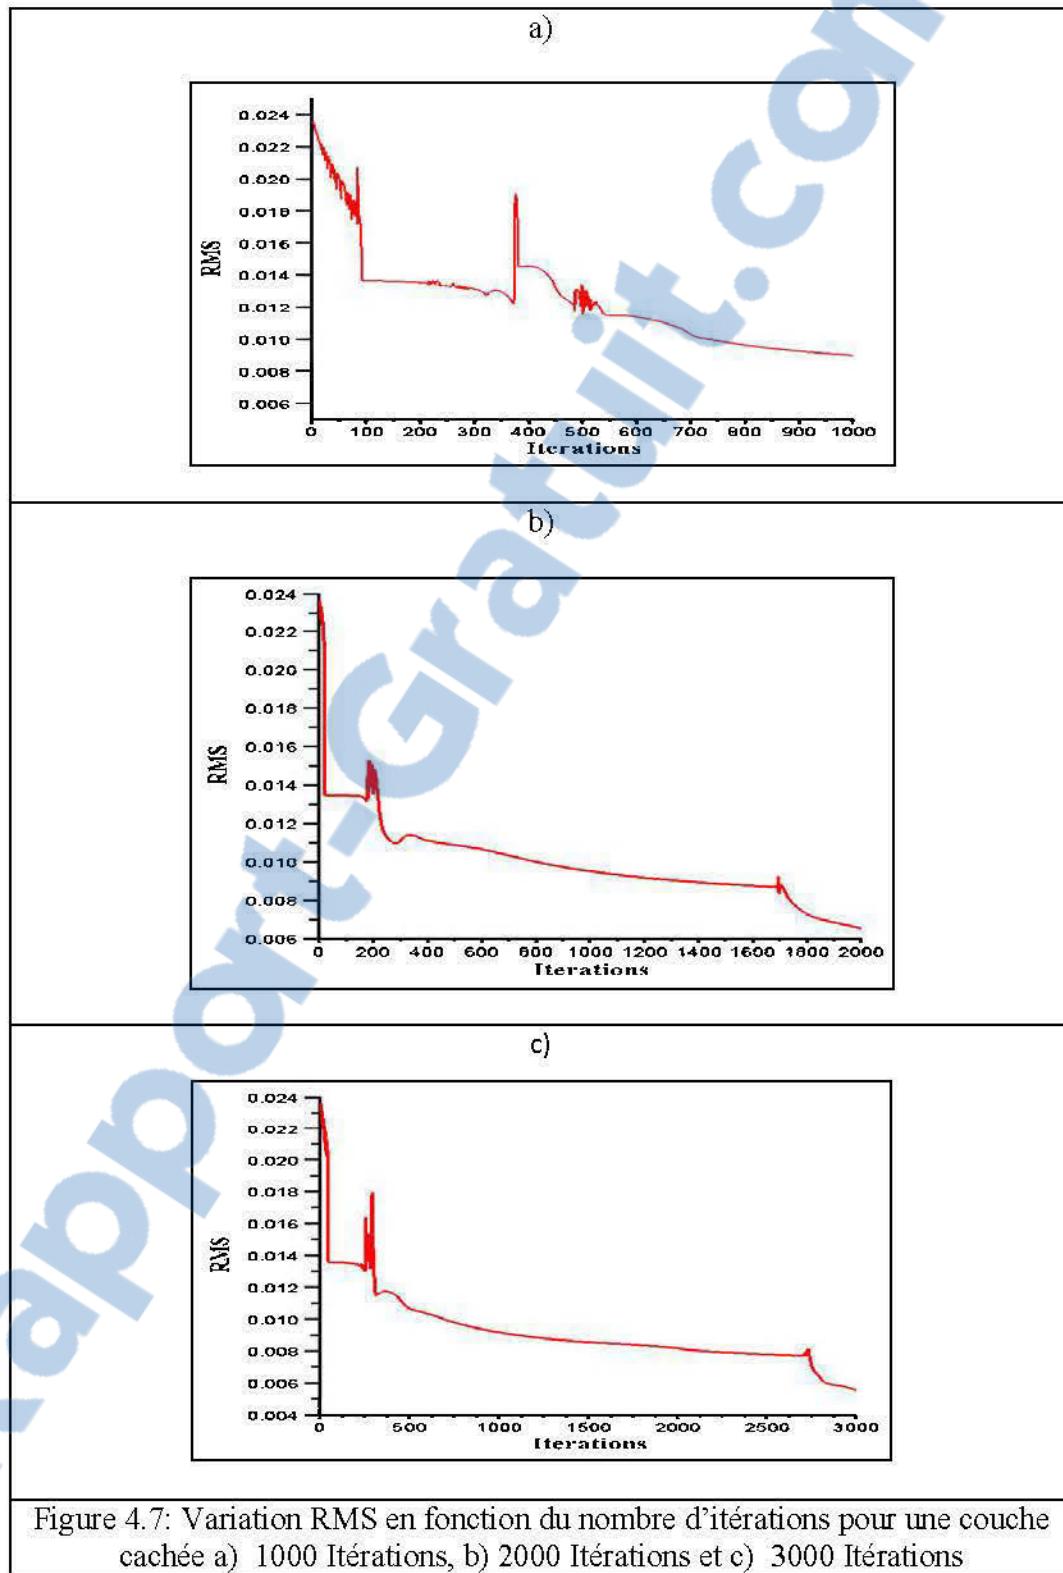
Les résultats qui décrivent la variation de l'erreur RMS en fonction des nombre d'itérations sont illustrés par les figures 4.7, 4.8, 4.9 et 4.10.

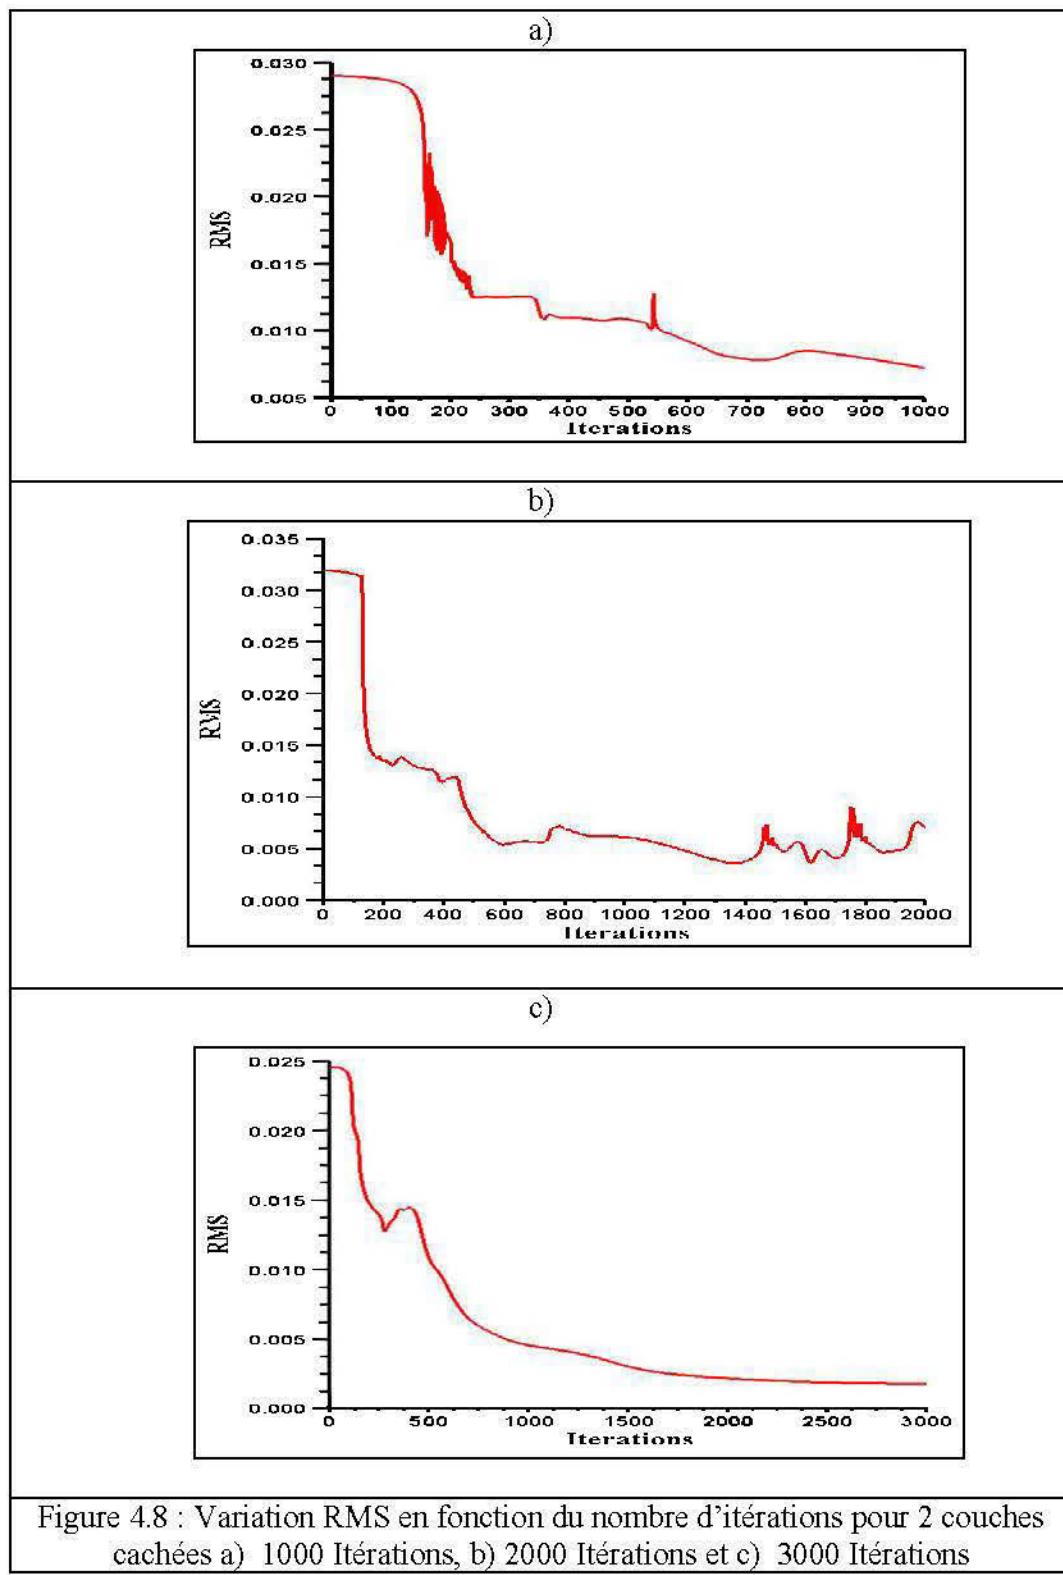
Pour le cas d'une seule couche cachée illustré par la figure 4.7 on remarque que l'erreur est instable dans les 100 premières itérations, elle prend par la suite une forme plus régulière et diminue de façon significative jusqu'à ce qu'elle atteigne une valeur faible. On remarque aussi que plus le nombre d'itérations augmente plus l'erreur diminue ; donc à 3000 itérations, l'erreur est jugée très acceptable.

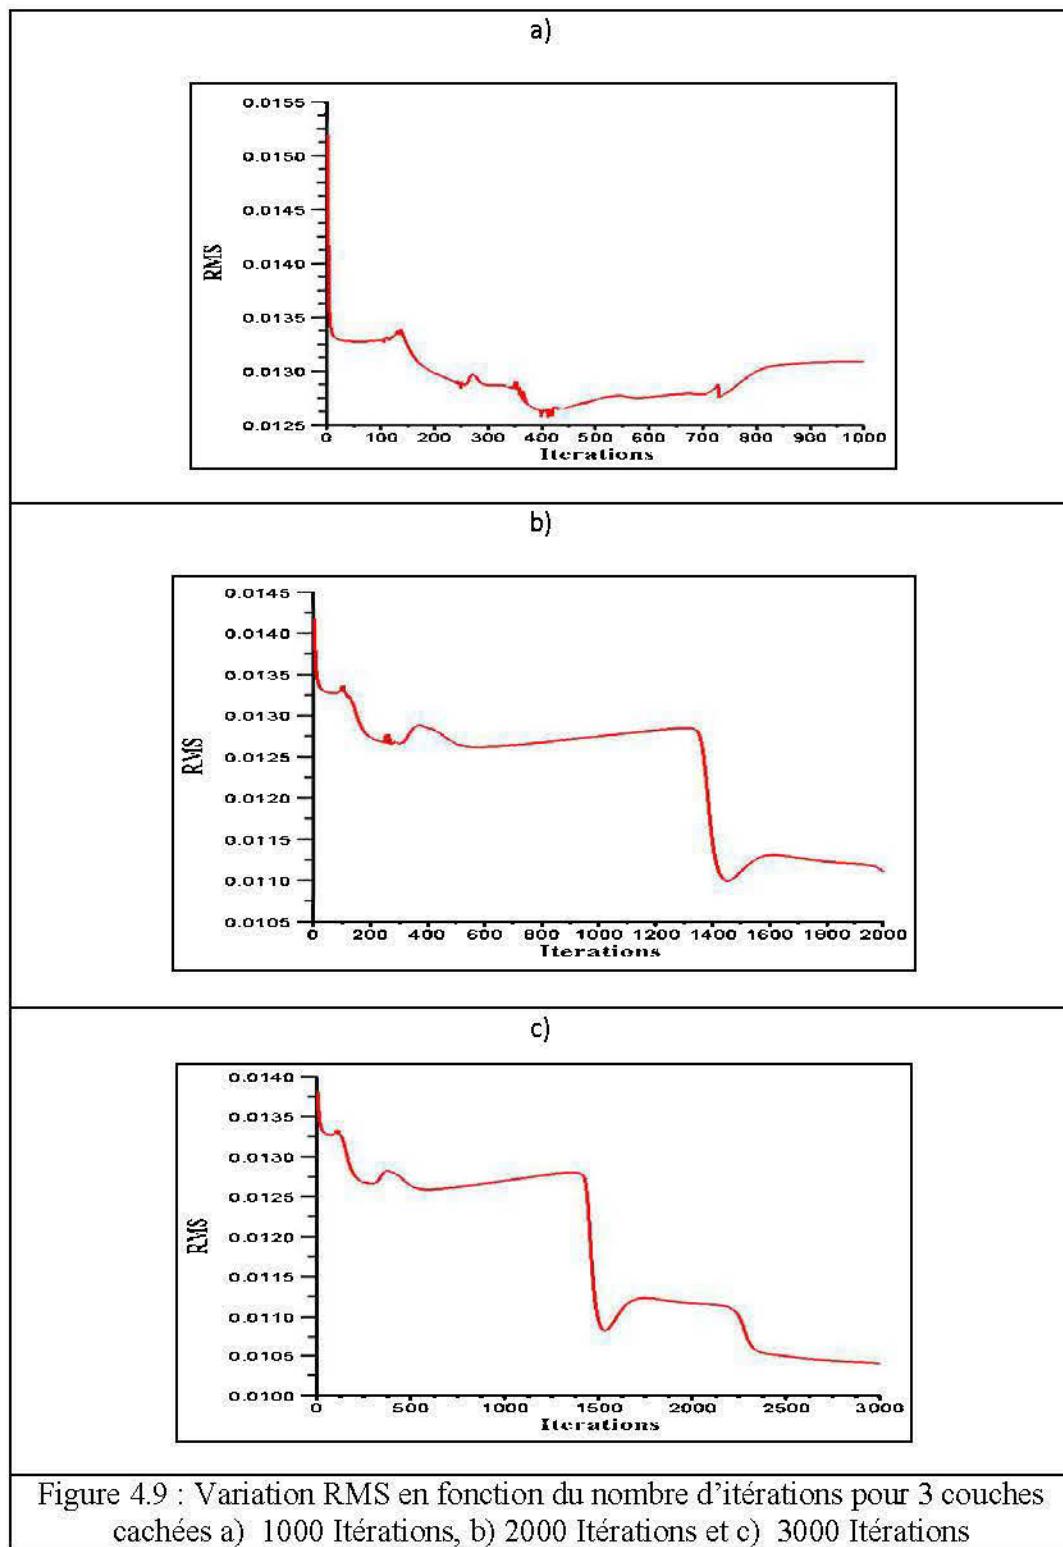
Pour le cas de deux couches cachées l'erreur est très irrégulière pour 1000 itérations (figure 4.8- a) et 2000 itérations (figure 4.8 -b) tandis que pour 3000 itérations (figure 4.8-c) l'erreur diminue d'une façon plus régulière et devient plus stable à partir de la 2500éme itérations.

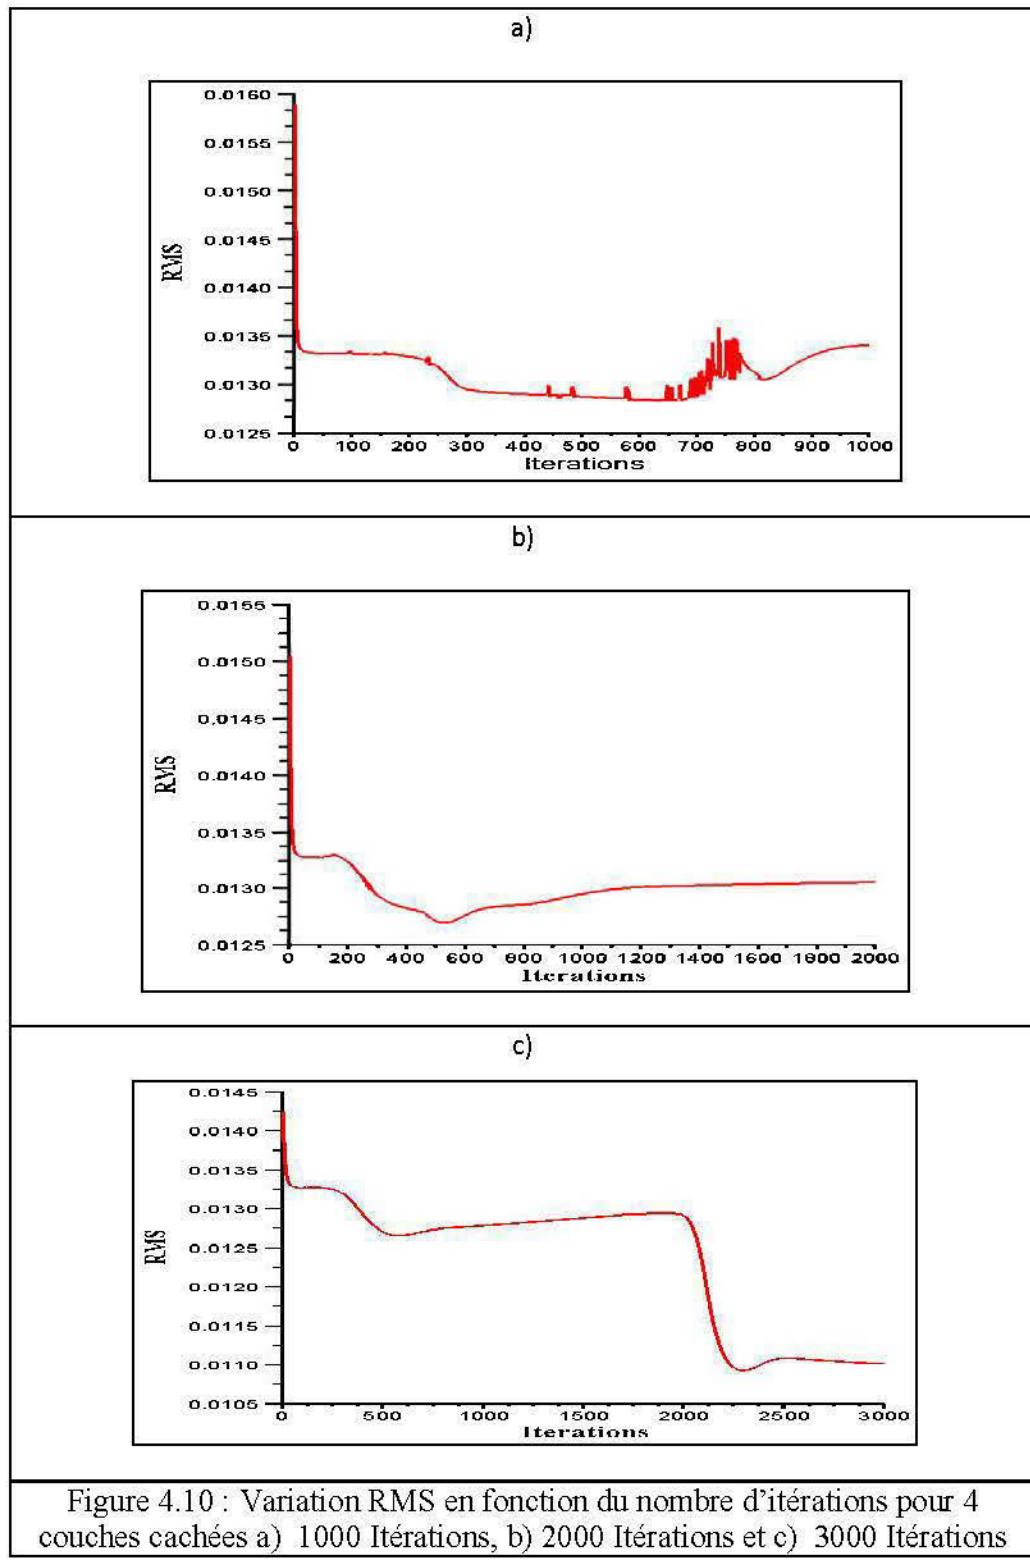
Le cas de trois couches cachés illustré par la figure 4.9 est semblable au cas précédent (2 couches) où l'erreur débute par des fluctuations pour devenir plus régulière et petite à partir de la 2600éme itérations.

Finalement le cas de quatre couches décrit par la figure 4.10 respecte la même analogie des cas précédents où l'erreur est perturbée au début pour atteindre des valeurs minimums pour les grandes itérations.









4.2 L'apprentissage du système de RNA utilisé

L'apprentissage de notre système de RNA consiste à introduire des données en entrée dont la sortie est bien connue, puis on fait entrainer le réseau jusqu'à ce qu'on obtienne notre sortie désirée. Pour ce faire, nous utilisons un algorithme d'apprentissage supervisé (rétro-propagation) qui consiste à imposer au réseau des entrées (dans notre cas ça sera les amplitudes électromagnétiques des modèles géologiques) et des sorties (paramètres du modèle géologique). Une estimation sur l'erreur est calculée pour les couches d'entrée et sortie au début pour qu'une mise à jour des poids soit effectuée par la suite et enfin répétée ce processus jusqu'à ce que l'erreur soit acceptable et la prédiction soit satisfaisante. Les premières valeurs des poids (connexion) sont initialisés aléatoirement puis ils seront mis à jour tous au long du processus (Mustapha C. E. Yagoub 2004).

4.3 Résultats de prédiction

En tenant compte des tests précédents qui sont le nombre de neurones cachés, le nombre de couches cachées et le nombre d'itérations, les résultats de prédiction ont été calculé et sont présentés par la figure 4.11, figure 4.12 et figure 4.13.

La figure 4.11 illustre le résultat de la prédiction de l'inclinaison d'un conducteur calculé pour 1, 2, 3 et 4 couches cachées avec des itérations respective de 1000, 2000 et 3000 itérations.

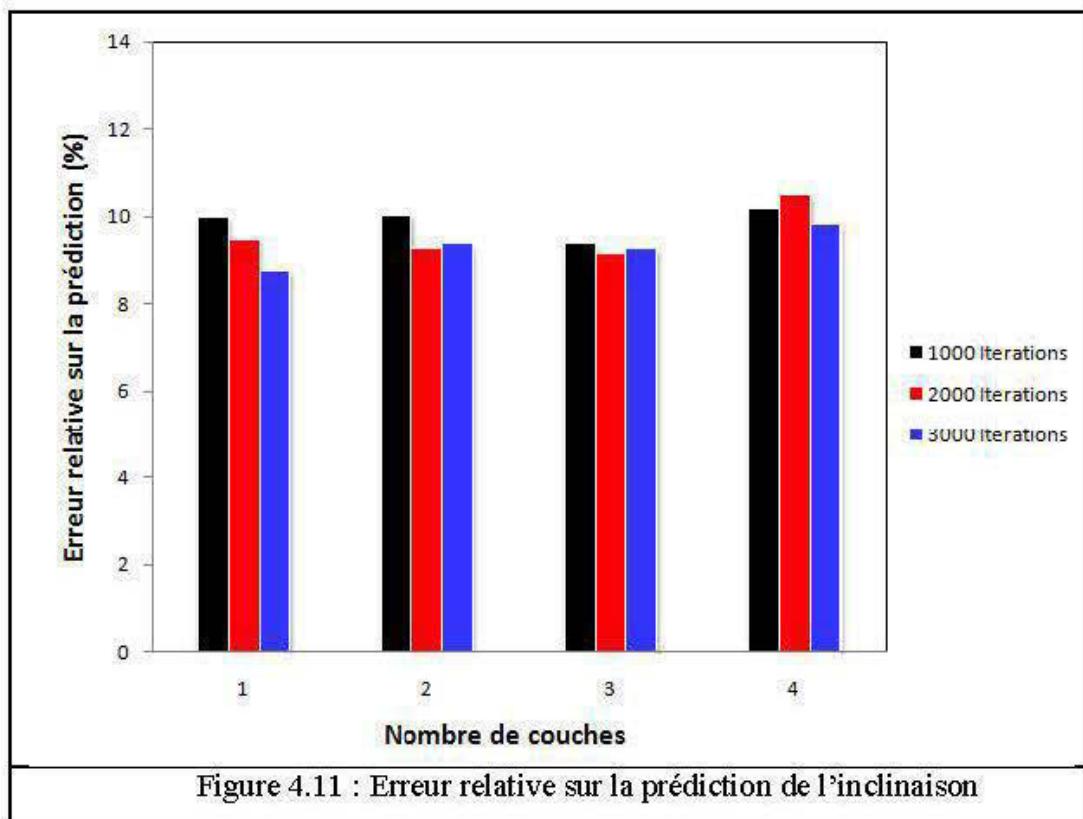
La figure 4.12 illustre le résultat de la prédiction du paramètre de la conductance calculé pour 1, 2, 3 et 4 couches cachées avec des itérations respective de 1000, 2000 et 3000 itérations.

La figure 4.13 illustre le résultat de la prédiction de la profondeur d'un conducteur calculé pour 1, 2, 3 et 4 couches cachées avec des itérations respective de 1000, 2000 et 3000 itérations.

Après l'analyse de l'erreur relative sur la prédiction de ces différents paramètres du conducteur géologique (inclinaison, conductance, profondeur) on peut voir que la

précision de la prédiction n'est pas la même et dépend essentiellement des paramètres analysés précédemment.

En moyenne, l'erreur relative est inférieure à 10%. La prédiction des paramètres du modèle qui sont l'inclinaison, la conductance et la profondeur, démontre l'utilisation d'un modèle de RNA à trois couches est un choix optimal. En combinant les résultats de ce chapitre, les paramètres d'apprentissage qui nous permet d'avoir une prédiction satisfaisante sont: trois couches cachées avec un nombre de neurones cachés avoisinant les 25 neurones pour plus de 2000 itérations.



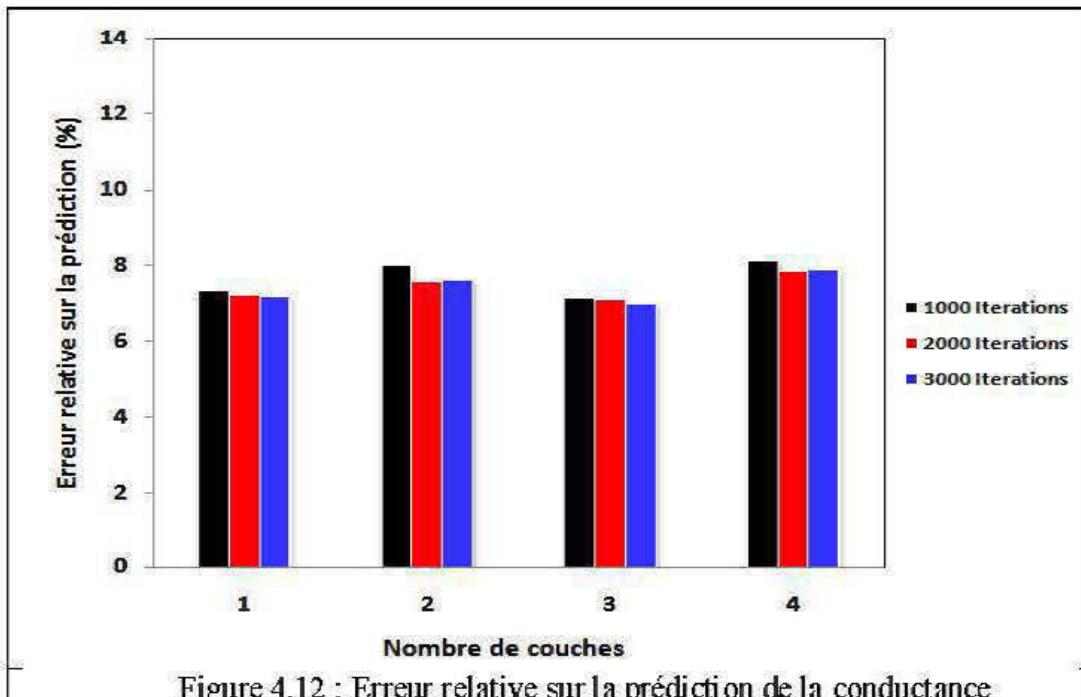


Figure 4.12 : Erreur relative sur la prédition de la conductance

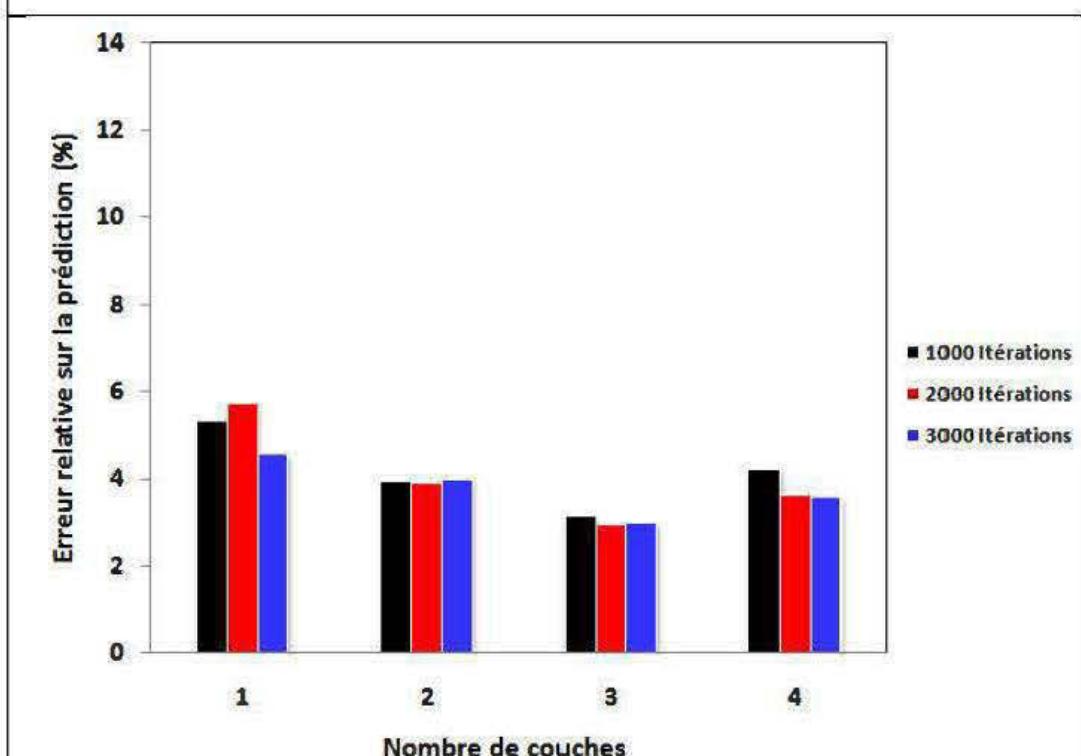


Figure 4.13 : Erreur relative sur la prédition de la Profondeur

4.4 Discussion

- Discussion sur la configuration d'InfiniTEM

Les centaines de modélisations réalisées montrent que la de la configuration InfiniTEM renferme toute l'information essentiel pour caractérisée un conducteur géologique enfoui.

La forme de la boucle émettrice ainsi que la position du conducteur par rapport à l'émetteur joue un rôle déterminant dans la performance de cette configuration, cependant les tests effectuer sur l'influence de la taille de la boucle émettrice on révélés que la boucle à dimension égale donne de meilleurs résultats.

Les figures 3.15 à 3.26 montrent clairement que cette configuration est très sensible aux variations des propriétés physiques et géométriques des conducteurs et particulièrement les conducteurs sub-verticaux.

- Discussion sur les résultats des RNA

Les résultats obtenus sont très variables et dépendent directement des paramètres du réseau. Les simulations réalisées afin de déterminer le nombre de neurones nécessaire pour une prédiction satisfaisante des paramètres d'un conducteur géologique ont montré que l'erreur peut être optimisée en choisissant la bonne configuration du réseau. Les simulations précédentes montrent que l'erreur diminue de manière significative à chaque fois qu'on augmente le nombre de neurones cachées, puis cette erreur est de plus en plus petite, ce qui permet au réseau d'approcher les résultats rechercher, mais une fois le nombre de neurones cachées est fixé à 25 neurones, on constate que l'erreur se stabilise même si on augmente d'avantage le nombre de neurones, cela se répercute sur le réseau par une prédiction assez stable à partir de 25 neurones cachées, cette stabilité de l'erreur montre que les poids sont assez bien entrainé et que cela ne sert à rien de les entraîner d'avantage.

Les modélisations réalisées afin de déterminer le nombre de couche cachées nécessaire pour une prédiction satisfaisante des paramètres d'un conducteur géologique ont dévoilé que l'erreur RMS diminue en général de manière significative au début (100 première itérations), puis cette erreur commence à fluctuer jusqu'à ce qu'elle devienne assez stable et optimale, cela montre clairement que la résolution de notre problème nécessite plus d'une couche cachée. L'étude de l'erreur RMS en fonction du nombre d'itérations révèle que ce dernier joue un rôle très important dans la stabilité du réseau, cependant le nombre d'itérations peut être fixer lorsque l'erreur est petite et les sorties sont satisfaisante. Une fois qu'on a une bonne prédiction cela ne sert à rien d'utilisé un nombre d'itérations plus grand.

Les modélisations effectuées précédemment on démontrées la complexité de trouvé une bonne combinaison entre le nombre de couches cachées, nombre de neurones cachés et nombre d'itérations qui mènent à la prédiction de tous les paramètres rechercher. La combinaison que nous avons trouvée est valable pour notre problématique mais rien ne prouve qu'elle puisse donner les mêmes résultats pour un autre système d'acquisition ou une autre problématique.

Finalement les résultats de prédiction obtenue par la combinaison des paramètres cités précédemment (25 neurones cachés, 3 couches cachées et plus de 2000 itérations) répondent parfaitement à notre problématique voir une erreur acceptable sur la prédiction des paramètres physique du conducteur.

CHAPITRE V

CONCLUSION ET RECOMMANDATION

En conclusion de ce travail, une banque de données a été créée pour caractériser des conducteurs géologiques ayant différentes occurrences sous différentes configurations d'InfiniTEM, ceux-ci nous a permis de visualiser et de définir une grande variété de types de signatures de conducteurs localisés à des différentes positions. L'InfiniTEM est un système très robuste pour la détection des cibles sub-verticales localisées à des grandes profondeurs grâce à sa forme de la boucle émettrice.

Un outil mathématique qui contribue à l'interprétation des propriétés des conducteurs géologiques de type plaque mince a été adapté avec succès pour le système d'InfiniTEM. L'application d'une architecture de PMC sur les caractéristiques des conducteurs géologiques modélisés a permis d'obtenir des résultats de prédiction satisfaisants pour trois paramètres. L'erreur relative sur la prédiction de la conductance est inférieure à 7% tandis que l'erreur relative sur la prédiction de l'inclinaison est inférieure à 10% et finalement l'erreur relative sur la prédiction de la profondeur est inférieure à 4%, ce qui constitue pour nous un excellent résultat.

Le choix du nombre de couches cachées, nombre de neurones cachés et le nombre d'itérations constitue un élément clé pour le bon fonctionnement du réseau. La combinaison qui définit le bon fonctionnement de réseau est : trois couches cachées, 35 neurones cachées, 3000 itérations.

Cet excellent outil de prédiction de RNA peut être utilisé pour interpréter les anomalies électromagnétiques de façon plus rapide. L'étude réalisée dans le cadre de ce mémoire a contribué à l'élargissement des connaissances sur le comportement du

système d'InfiniTEM, ainsi qu'au développement de la méthodologie des outils d'interprétation de données géophysiques.

• Recommandation :

Les résultats que nous avons obtenus nous encouragent à réfléchir subséquemment sur la méthode qui nous permet d'améliorer ce que nous avons accomplie jusqu'à présent. Il serait très intéressant par exemple d'étudier la possibilité de prédire plus de trois paramètres à la fois, ou bien de développer un outil qui nous permette une généralisation pour d'autres configurations de systèmes d'acquisitions. Pour cela nous proposons:

- recalculer une base de données de manière à ce que les paramètres de départ des modèles soient tirées des résultats de prédiction des conducteurs afin d'essayer d'améliorer la précision ;
- essayer cette approche pour une autre configuration EM afin de comparer les paramètres des RNA ;
- Utiliser les résultats de prédiction dans le processus d'inversion électromagnétique lors du choix du modèle initial afin de voir si les RNA utilisée aident à approcher la solution.
- tester une autre architecture de RNA afin de voir laquelle des architectures fournit un meilleur résultat.

BIBLIOGRAPHIE

- Baum, E. et Haussler, D. (1989). What size net gives valid generalization? *Neural Computation*, 1(1): 151–160.
- Boné, R. et Cardot.H. (2005). Time Delay Learning by Gradient Descent in Recurrent Neural Networks, International Conference on Artificial Neural Networks (ICANN), Lecture Notes in Computer Science, Vol. 3697,
- Billings,S.D., Pasion,L.R., Beran, L., Lhomme,L., Song,L., Douglas W. Oldenburg,D.W., Kingdon, L., Sinex,D .et Jacobson, J . (2010). Unexploded ordnance discrimination using magnetic and electromagnetic sensors: Case study from a former military site, *Geophysics* 75, B103, DOI:10.1190/1.3377009
- Cagniard, L. (1953). Basic theory of magnetotelluric method of geophysical prospecting. *Geophysics* 18, 605-635
- Cooper, N.J et Swift. R.(1994). The application of TEM to Cyprus-type massive sulfide exploration in Cyprus, *Geophysics* 59, 202, DOI:10.1190/1.1443582
- Cottrell, M., Girard, B., Girard, Y., Mangeas, M. et Muller, C. (1995). Neural modeling for time series: a statistical stepwise method for weight elimination. *IEEE Transactions on Neural Networks*.
- Coulibaly, P., Anctil, F. et Bobée, B. (1998). Real time neural network- based forecasting system for hydropower reservoirs. Proceedings of the First International Conference on New Information Technologies for Decision Making in Civil Engineering, (Montreal, 1998), Vol. 2. École de Technologie Supérieure, Montréal. pp. 1001–1011.
- Cubero, R.G. (1991). Neural networks for water demand time series forecasting. Dans *Artificial Neural Networks, Proceedings of the International Workshop IWANN'91*. Éditeur: A. Prieto. Springer-Verlag, Berlin. pp. 453–460.
- Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function: *Math. Control, Signals and Systems*, 2, 303–314.
- Davalos, E. et Naim, P. (1989). Des réseaux de neurones, Editions Eyrolles.
- Devabhaktuni, V.K., CHATTARAJ, B., YAGOUB, M.C.E. et ZHANG, Q.J. (2002). Advanced microwave modeling framework exploiting automatic model generation,

knowledge neural networks and space mapping, IEEE MTTInt. Microwave Syrup, pp. 1098-1100.

DREW, P.J. et MONSON, J.R.T. (2000). Artificial neural networks, *Surgery* 127: 3-11.

Elman, J.L. (1990). Finding structure in time. *Cognitive Science*, 14: 179–211.

Erchiqui F., Nahi, K. (2004). Neuronal Networks Application for Characterization of Softened lymers". Society of Plastics Engineering SPE ANTEC', Session: Thermoforming Technology, Vol.1, pp. 937-941, 16-20 May 2004, Chicago (USA).

Erchiqui F., Ozdemir, Z ., Souli, M., Ezzaidi ,H. et Ngoma, D. (2011). Neural network approach for characterisation of viscoelastic polymers. ISI Journal Citation Reports © Ranking: 2010: 84/134 (Engineering Chemical) . Online ISSN: 1939-019X

Fausett, L. (1994). *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*, Englewood Cliffs (NJ), Prentice Hall.

Fischer, G., Schneg, P.A., Peguiron,M. et Le Quang, B.V.(1981). An analytic onedimensional magnetotelluric inversion scheme. *Geophysical Jornal of the royal Astronomical Society* 67,257-278.

Fischer, G., Le Quang, B.V. et Müller, I . (1983). VLF ground surveys, a powerfull tool the study of shallow two-dimensional structures. *Geophysical prospecting* 31, 977-991.

Graf, H.P ., Lawrence D.J ., Wayne E.H. (1988). VLSI Implementation of neural Network Model. *IEEE Computer*, vol 21, n0. 3 pp. 41-49.

Gross, G.W., Boone, J.M. et Bishop, D.M. (1995). ediatric skeletal age: determination with neural network s, *Radiology* 195 : 689-695.

Grossberg, S. (1982). *Studies of mind and brain*. D. Reidel Publishing Co., Boston.

Grossberg, S. (1988). *Neural networks and natural intelligence*. MIT Press, Cambridge.

Hagan, M.T., Demuth, H.B. et Beale, M. (1996). *Neural network design*. PWS Publishing Company, Boston, Massachusetts.

Harada, K., Wada, K et Fukuda, M. (2000). Permafrost mapping by transient electromagnetic method, *Permafrost and Periglac. Process* 11, 71-84.

Hassoum, M.H. (1995). Fundamentals of artificial neural networks. MIT Press, Cambridge.

Hanneson, J et WEST, G. (1984). The horizontal loop electromagnetic response of a thin plate in a conductive earth: Part ii - computational results and examples, *Geophysics* 49, 421-432.

Hauck, C., Guglielmin, M., Isaksen, K et Mühl, D.V. (2001), Applicability of frequency- domain and time-domain electromagnetic methods for mountain permafrost studies, *Permafrost and Periglac. Process* 12, 39-52.

Hautot, S., Tarits, P., Perrier, F., Tarits, C. Et and Trique, M. (2002). Groundwater electromagnetic imaging in complex geological and topographical regions: A case study of a tectonic boundary in the French Alps, *Geophysics* 67, 1048, DOI:10.1190/1.1500365

Haykin, S. (1999). Neural networks A comprehensive foundation, 2nd ed.: Prentice Hall.

Haykin, S. (1994). Neural Networks: A Comprehensive Foundation, Upper Saddle River, NJ: Prentice Hall.

Hebb, D. (1949). The organization of the behavior. Wiley, New York.

Hertz, J., Krogh, A. et Palmer, R.G. (1991). Introduction to the theory of neural computation. Addison-Wesley, Reading, assachusetts.

Hecht-Nielsen, R. (1987). Komogorov's mapping neural network existence theorem. Dans Proceedings of the International Conference on Neural Networks. Vol. 3. IEEE Press, New York. pp. 11–13.

Huang, Z., Shimeld, J., Williamson, M. et Katsube, J. (1996). Permeability prediction with artificial neural network modeling in the Venture gas field, offshore eastern Canada: *Geophysics*, 61, 422–436.

Jacobs, R.A., Peng, F. et Tanner, M.A. (1997). A Bayesian approach to model selection in hierarchical mixtures-of-experts architectures. *Neural Networks*, 10(2): 231–241.

Johnson, T.C., Versteeg, R.J., Ward, A., Day-Lewis, F.D. et Revil, A. (2010). Improved hydrogeophysical characterization and monitoring through parallel modeling and inversion of time-domain resistivity and induced-polarization data, *Geophysics* 75, WA27, DOI:10.1190/1.3475513

Kasabov, N.K. (1996). Foundations of neural networks, fuzzy systems, and knowledge engineering. The MIT Press, Cambridge, Massachusetts.

Keller, G.V. (1988). Rock and mineral properties. Electromagnetic methods in applied geophysics1 : Theory, chapter 2, Nabighian M.N. (ed), SEG Publ., 13-51.

Kohonen, T (1988). Learning Vector Quantization. *Neural Networks*, 1 (Suppl.1), 303

Kohonen, T. (1995). *Self-organizing maps*, Berlin, Springer Verlag.

Langer, H., Nunnari, G. et Occhipinti, L. (1996). Estimation of seismic waveform governing parameters with neural networks. *J. Geophysics. Res.*, 101, 20109-20118.

Lippmann, R.P. (1987). An introduction to computing with neural nets. *IEEE Acoustics, Speech and Signal Processing Magazine*, 4: 4-22.

Mackay, D.J.C. (1991). Bayesian interpretation, *neural Computation* 4(3): 415-447.

Maren, A.J., Harston, C.T. et Pap, R.M. (1990). *Handbook of neural computing applications*. Academic Press Inc., San-Diego, California.

Massey Louis, 2002. Auto-organisation et exploration de collections textuelles avec les réseaux de neurones à résonance adaptative. Document de Collège Militaire Royal de Kingston. p. 27.

McCormack, M., Zaucha, D. et Dushek, D. (1993). First-break refraction picking and seismic data trace editing using neural network. *Geophysics*, 34, 255-270.

McNeill, J.D. (1980). Electrical conductivity of soil and rocks, Tech. report, Technical Notes TN-5, Geonics Limited, b.

McNeill, J.D. (1980). Electromagnetic terrain conductivity measurement at low induction numbers, Tech. report, Technical Notes TN-6, Geonics Limited, a.

Mead, C. (1989). *Analog VLSI and neural systems*. Reading, MA: Addison-Wesley.

Mitsuhata, Y., Uchida, T., Matsuo, K., Marui, A. Et Kusunose, K(2006). Various-scale electromagnetic investigations of high-salinity zones in a coastal plain, Geophysics 71, B167, DOI:10.1190/1.2335658

Murat, M. et Rudman, A. (1992). Automated first arrival picking: a neural network approach. Geophys. Prosp., 40, 587-604.

Murata, N.M., Yoshizawa, S. et Amari, S. (1994). Network information criterion—determining the number of hidden units for an artificial neural network model. IEEE Transactions on Neural Networks, 5(6): 865–872.

Murray, A.F. (1989). Pulse Arithmetic in VLSI Neural Networks, IEEE MICRO, vol. 9, no. 6, pp. 64-74

Mustapha, C.E. et Yagoub. (2004). Optimisation des performances de modules multipuces Modélisation par réseaux de neurones. Annals of Telecommunications, 2004, Volume 59, Numbers 9-10, Pages 1092-1117.

NABIGHIAN, M.N. et MACNAE, J.C. (1991). Time domain electromagnetic prospecting methods. Dans Electromagnetic Methods in Applied Geophysics, M.N. Nabighian, ed. SEG, vol. 2, p. 426-520.

Parizeau, Marc, 2004. RÉSEAUX DE NEURONES. GIF-21140 et GIF-64326. Université de Laval.

Parasnis, D.S. (1986). Principles of applied geophysics, Fourth Edition. Chapman and Hall Editions, London, New-York, 236p.

Pettersson, J. K. et Nobes, D. C. (2003). Environmental geophysics at scott base: ground penetrating radar and electromagnetic induction as tools for mapping contaminated ground at Antarctic research bases, Cold Regions Science and Technology 37, 187-195.

Poulton M., Sternbeg, K. et Glass, C. (1992). Neural network pattern recording of the subsurface EM images. Journal of Applied Geophysics, 29, 21-36.

Poulton, M., Ed. (2001). Computational neural networks for geophysical data processing: Pergamon.

Reynolds, J.M. (1997). An introduction to applied and environmental geophysics, john willey and sons inc. new york ed., no. 12.

- Raudys, J. (1998). Evolution and generalization of a single neurone. I. single-layer perceptron as seven statistical classifiers. *Neural Networks*, 11, 283–296.
- Röth, G. et Tarantola, A. (1994). Neural networks and inversion of seismic data. *J. Geophys. Res.*, 99, 811-822.
- Rudolph, S. (1997). On topology, size and generalization of non-linear feed-forward neural networks. *Neurocomputing*, 16: 1–22.
- Rumelhart, D.E., Hinton, E. et Williams, J. (1986). Learning internal representation by error propagation. *Dans Parallel distributed processing. Vol.1*. MIT Press, Cambridge, Massachusetts. pp. 318–362.
- Sanger, T. D. (1989). Optimal unsupervised learning in a single-layer linear feed-forward neural network. *Neural Networks* 2, 459-473.
- Sarle, W.S. (1994). Neural networks and statistical models. *Proceedings of the Nineteenth Annual SAS Users Group International Conference* (SAS Institute), Cary, North Carolina, pp. 1538–1550.
- Seshagiri, S. et Khalil, H.K. (2000). Output feedback control of nonlinear systems using RBF neural networks, *IEEE Trans. Neural Networks*, vol. 11, pp. 69–79.
- SPIES, B.R.(1975). The dual loop configuration of the transient electromagnetic method. *Geophysics* 40, 1051-1057.
- Spies, R.B. et Frischknecht, F.C. (1991). Electromagnetic Sounding. *Electromagnetic methods in applied geophysics 2 : application*, chapter 5, Nabighian M.N (ed). SEG Publ., 285-422
- Strangway, D.C., Swift Jr, C.M. et Holmer, R.C.(1973). The application of audiofrequency magnetotelluric (AMT) to terminal exploration. *Geophysics* 38, 1159-1175
- Wang, L.X. et Mendel, J.M. (1992). Adaptive minimum prediction error deconvolution and source wavelet estimation using Hopfield neural networks. *Geophysics*, 57, 670-679.
- Ward, H.S. et Hohmann, W.G. (1988). Electromagnetic theory for geophysical application. *Electromagnetic methods in applied geophysics 1: Theory*, chapter 4, Nabighian M.N (ed), SEG Publ., 131-308

- Weiss, S.M. et Kulikowski, C.A. (1991). Computer systems that learn. Morgan Kaufmann Publishers Inc., San Mateo, California.
- Widrow, B. et Lehr, M.A. (1990). 30 years of adaptive neural networks: perceptron, madaline and backpropagation. *Proceedings of the IEEE*, 78(9): 1415–1442.
- Van der Baan, M. et Jutten, C. (2000). Neural networks in geophysical applications. *Geophysics*, 65(4). pp. 1032-1047. ISSN 0016-8033.
- Zhang, Y. et Paulson, K.V. (1997). Magnetotelluric inversion using regularized Hopfield neural networks. *Geophys. Prosp.*, 45, 725-743.
- Zhang, Q.J. et GUPTA, K.C. (2000). Neural Networks for RF and Microwave Design, Norwood, MA: Artech House.
- Zurada, J.M. (1992). Introduction to artificial neural systems. West Publishing Co., Saint Paul, Minnesota.

ANNEXE I

Réponse InfiniTEM des conducteurs à différents pendages

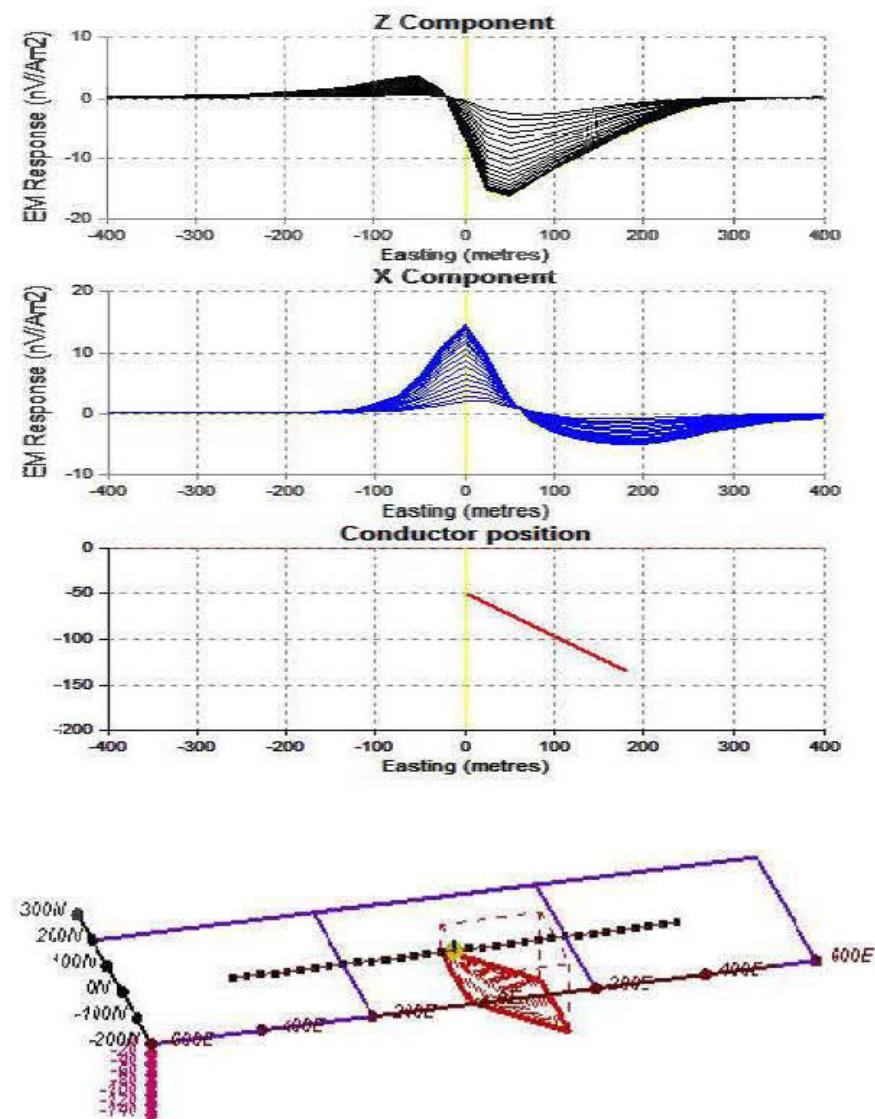


Figure A1.1 : Réponse InfiniTEM d'un conducteur à 25 degrés pour les canaux 1 à 20

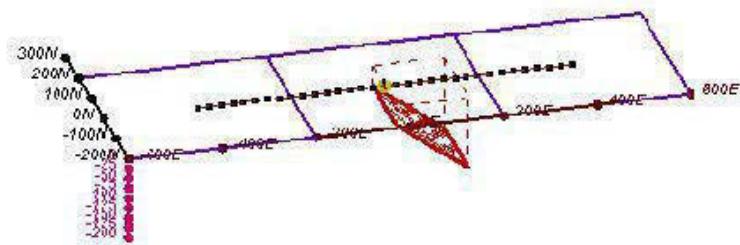
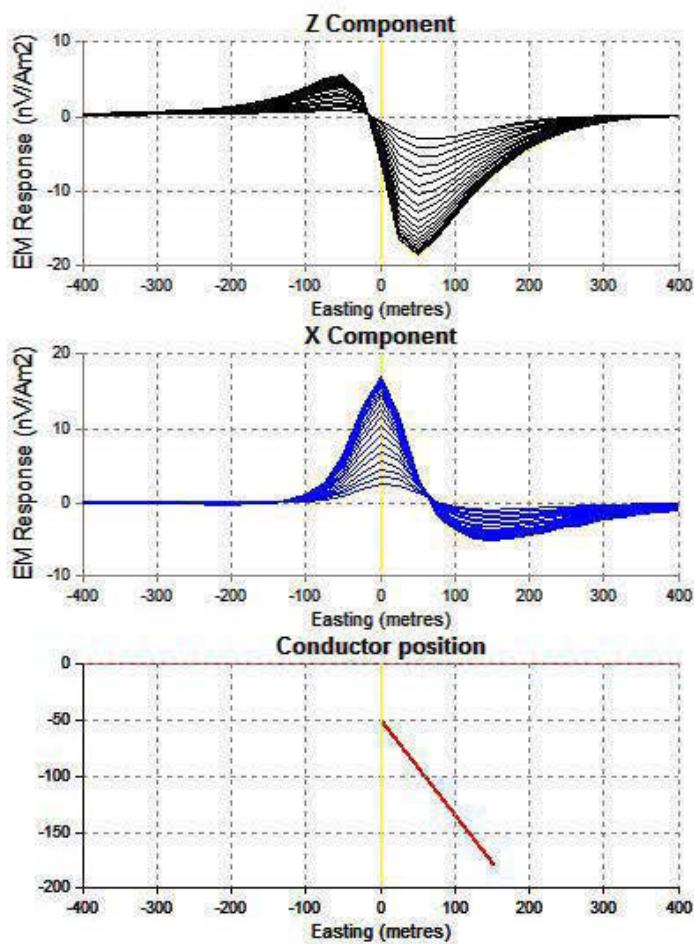


Figure A1.2 : Réponse InfiniTEM d'un conducteur à 40 degrés pour les canaux 1 à 20

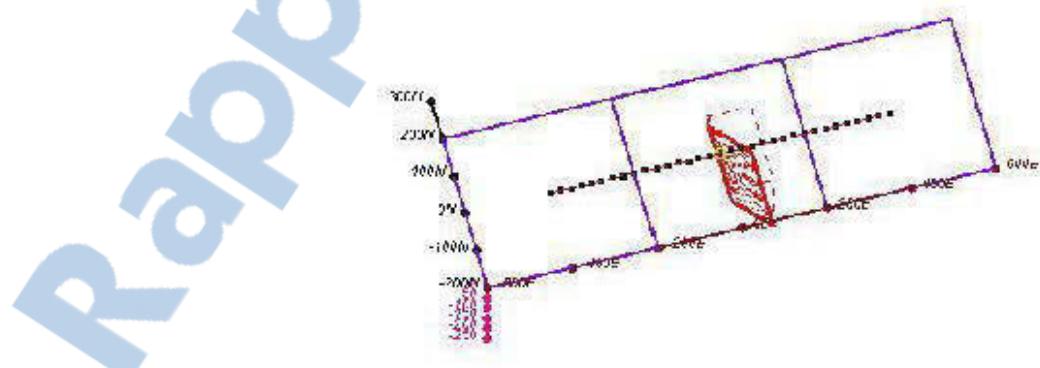
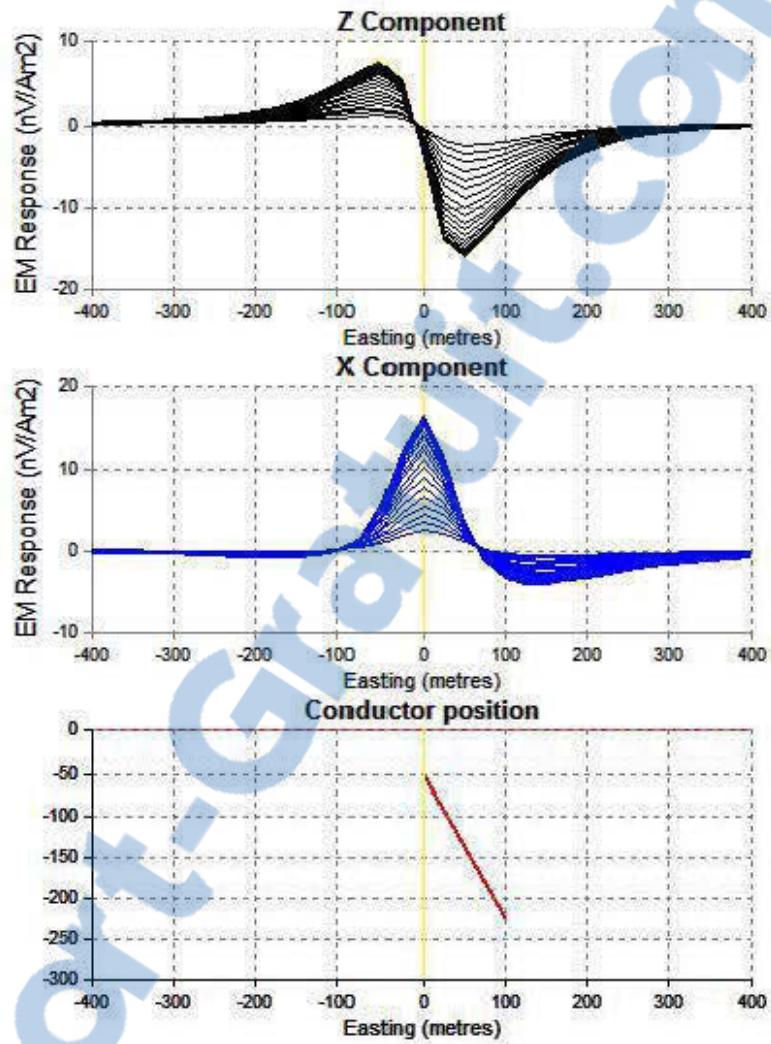


Figure A1.3 : Réponse InfiniTEM d'un conducteur à 55 degrés pour les canaux 1 à 20

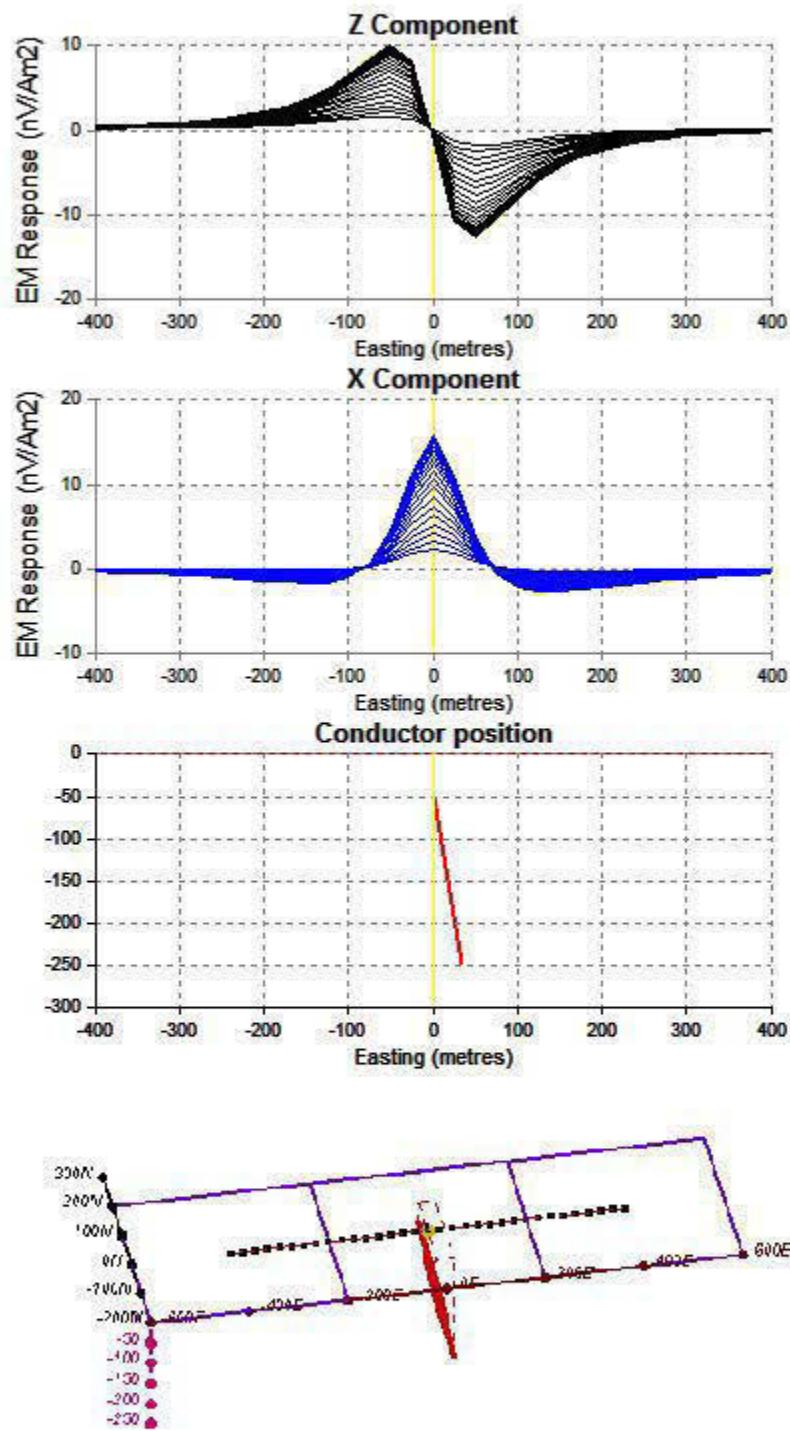


Figure A1.4 : Réponse InfiniTEM d'un conducteur à 80 degrés pour les canaux 1 à 20

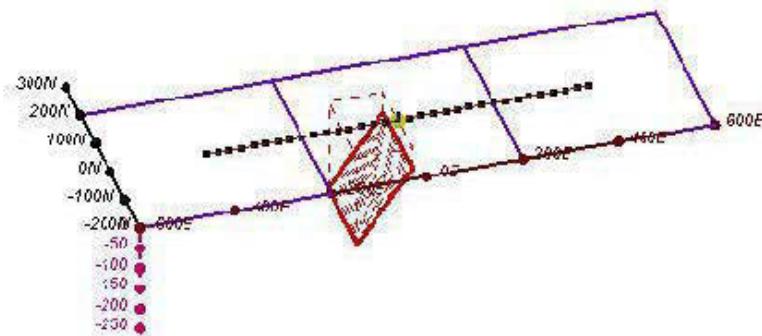
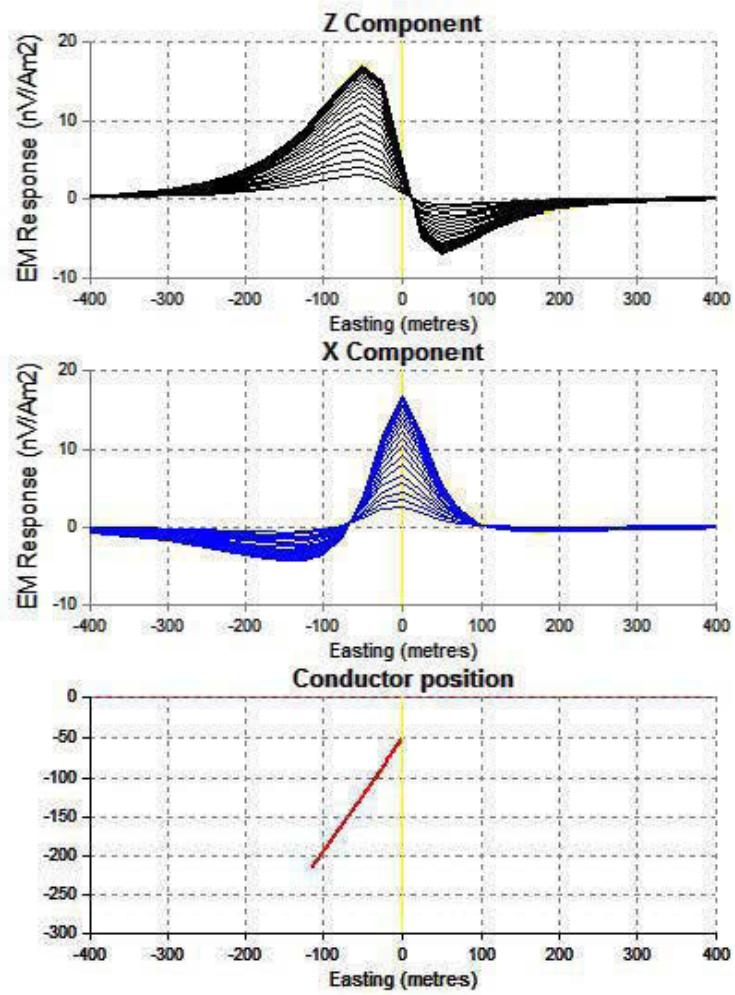


Figure A1.4 : Réponse InfiniTEM d'un conducteur à 125 degrés pour les canaux 1 à 20

j

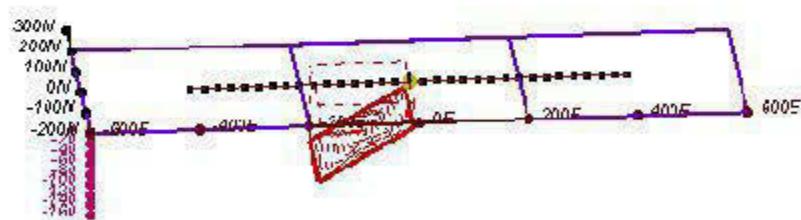
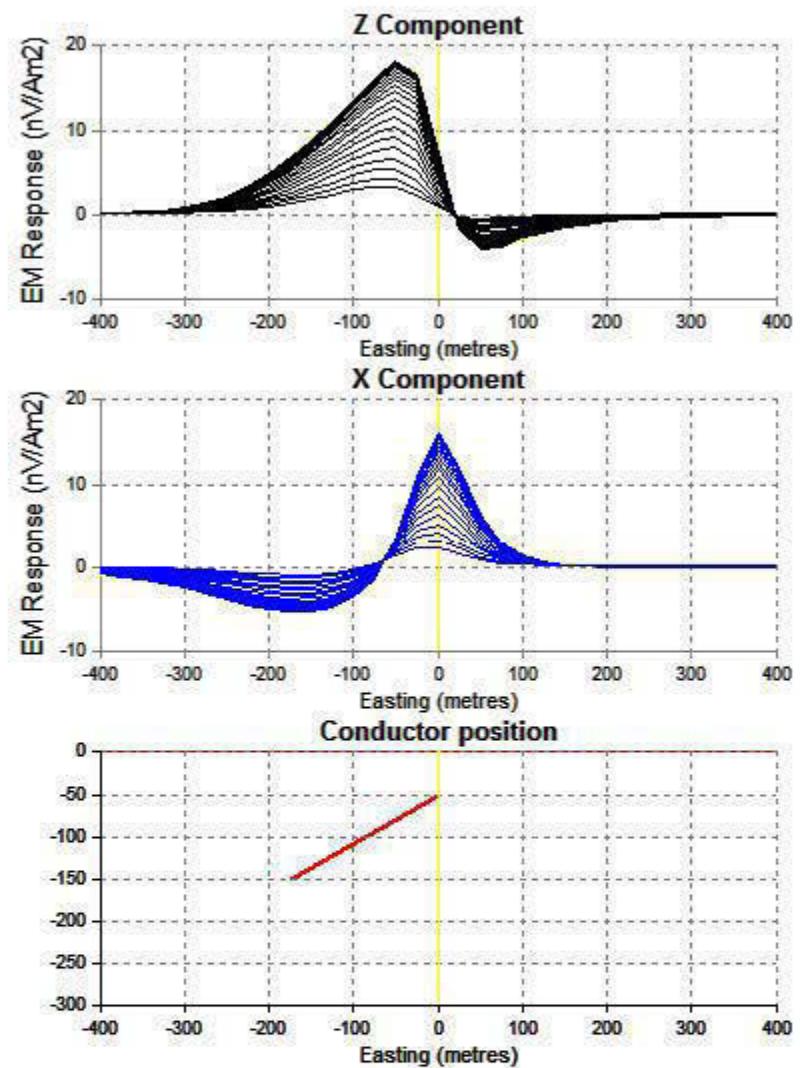


Figure A1.5 : Réponse InfiniTEM d'un conducteur à 150 degrés pour les canaux 1 à 20

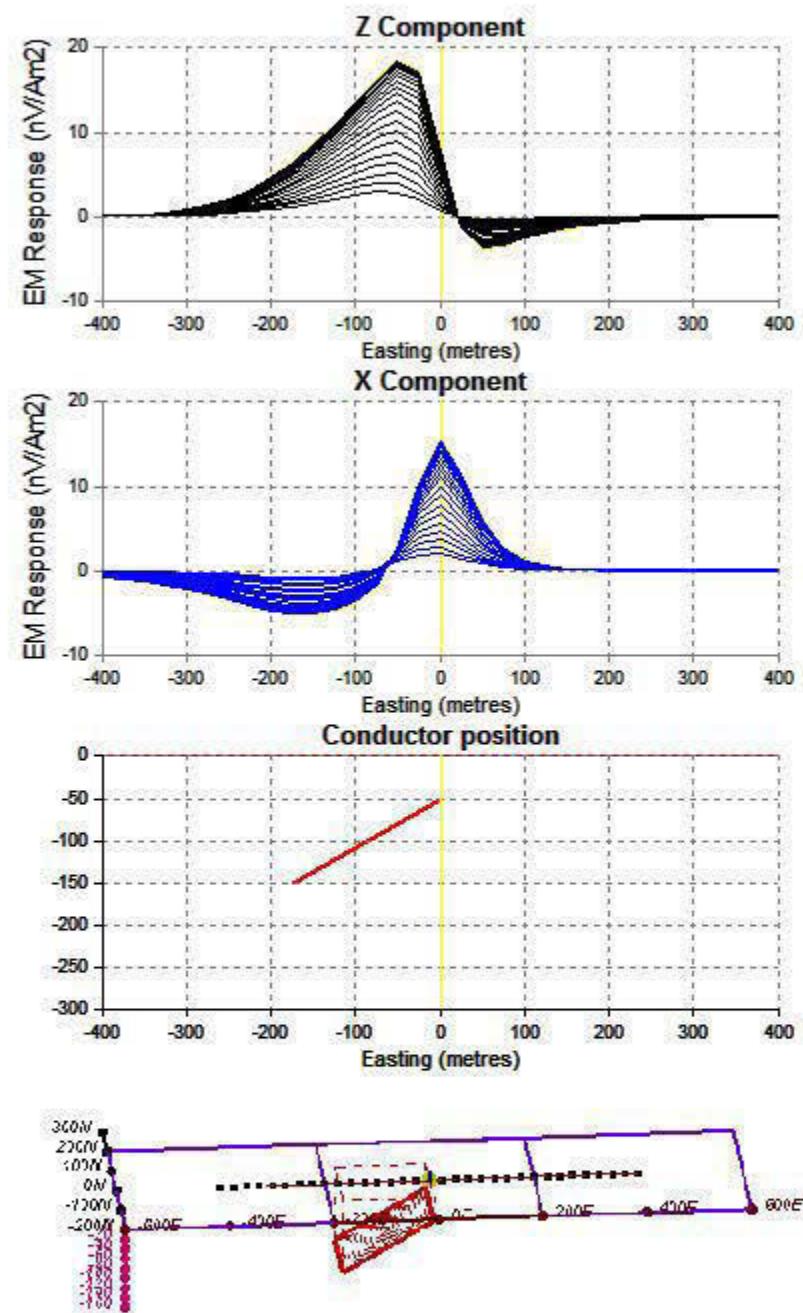


Figure A.1.6: Réponse InfiniTEM d'un conducteur à 150 degrés pour les canaux 1 à 20

ANNEXE II

Canaux d'échantillonnage pour l'InfiniTEM

Tableau A2.1 : Canaux d'échantillonnage pour l'InfiniTEM avec une fréquence de base de 30 Hz.

Numéro du canal	Valeurs de départ	Valeurs intermédiaires	Valeurs de fin	Largeur de la fenêtre
1	0.0800	0.0881	0.0962	0.0163
2	0.0962	0.1069	0.1175	0.0213
3	0.1176	0.1313	0.1450	0.0275
4	0.1450	0.1619	0.1787	0.0338
5	0.1787	0.2006	0.2225	0.0437
6	0.2225	0.2506	0.2787	0.0562
7	0.2788	0.3144	0.3500	0.0712
8	0.3499	0.3956	0.4412	0.0913
9	0.4412	0.4994	0.5575	0.1163
10	0.5576	0.6313	0.7050	0.1475
11	0.7050	0.7994	0.8938	0.1888
12	0.8940	1.0140	1.1340	0.2400
13	1.1339	1.2870	1.4401	0.3063
14	1.4403	1.6360	1.8317	0.3913
15	1.8316	2.0810	2.3304	0.4988
16	2.3295	2.6480	2.9661	0.6363
17	2.9667	3.3730	3.7792	0.8125
18	3.7790	4.2970	4.8150	1.0360
19	4.8145	5.4750	6.1355	1.3210
20	6.1355	6.9780	7.8205	1.6850

