

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



UNIVERSITE M'HAMED BOUGARA-BOUMERDES

Faculté des hydrocarbures et de la chimie

Département de géophysique



MEMOIRE DE FIN D'ETUDES

En vue de l'obtention du diplôme de master en géophysique.

THEME :

**Classification lithologique par les réseaux de neurones
artificiels de type MLP et cartes SOM en utilisant des
données de diagrapie. Application au champ de Bir-
Berkine**

Réalisé par :

GAHAM. Abbes

SI TAYEB. Abderrahmane

Encadré par :

M^{me}: ALIOUANE Leïla (FHC-UMBB)

BOUMERDES 2014/2015

Remerciements

En premier lieu, nous tenons à remercier notre DIEU "allah", notre créateur pour nous avoir donné la force pour accomplir ce travail.

Nous adressons nos vifs remerciements à notre promotrice consultante Dr. ALIOUANE leïla, enseignante à la FHC-UMBB, pour nous avoir dirigés tout au long de ce travail, pour sa compréhension, sa patience, sa compétence, et ses remarques qui nous ont été précieuses.

Nous présentons nos chaleureux remerciements aux enseignants du département géophysique pour leur aide et orientations durant notre formation.

Nos remerciements vont au Dr. OUADFEUL Sid Ali, Docteur chercheur à l'IAP Boumerdès pour sa contribution dans ce travail.

Nos remerciements vont aussi aux personnels de Sonatrach (DP-HMD) surtout l'ingénieur géologue BELAHMER Saleh.

Nos derniers remerciements, vont à tous ceux qui ont contribué de près ou de loin à l'aboutissement de ce travail.

DEDICACES

Je tiens à dédier ce modeste travail à tous ceux qui me sont chers :

*A mon **très cher père** et ma **très chère mère** pour qui je n'oublierai jamais leur grande affection ; leur soutien et leurs encouragements tous au long de mes études.*

A mes très chers frères et sœurs.

A mon très cher binôme Abderrahmane.

*A tous les amis de l'INH et groupe **IGP 08**.*

Et enfin à tous ceux qui m'ont aidé de prêt ou de loin.

Abbes

DEDICACES

Je dédie ce modeste travail à tous ceux qui me sont chers :

A ma mère et mon père pour qui je n'oublierai jamais leur grande affection ; leur soutien et leurs encouragements tous au long de mes études.

A mes très chers frères et sœurs.

A mon très cher binôme GAHAM Abbes.

A tous mes amis de l'INH et groupe IGP 08

Et enfin à tous ceux qui m'ont aidé de prêt ou de loin.

Abderrahmane. S

Sommaire

	Pages
Introduction générale.....	1

CHAPITRE. I : Présentation de la région d'étude

Introduction	2
I.1. Situation géographique	2
I.2. Situation géologique.....	2
I.3. Historique des travaux.....	5
I.4. Aspect stratigraphique.....	6
I.4.1.Le Socle.....	6
I.4.2.Le Paléozoïque.....	6
I.4.3. Le Mésozoïque.....	8
I.4.4. Le Cénozoïque.....	8
I.4.5. Le Quaternaire.....	9
I.4.6. La stratigraphie du Dévonien	10
I.5. Aspect structural	12
I.6. Le système pétrolier	13
I.6.1. Roches mères	13
I.6.2. Roches couvertures	14
I.6.3. Roches réservoirs	14

Sommaire

CHAPITE.II : Classification lithologique par les méthodes conventionnelles

Introduction.....	15
II.1. Diagraphies enregistrées	15
II.1.1. Notions pétrophysiques	16
II .1.1.1. Réservoirs	16
II.1.1.2. Porosité	17
II.1.1.3. Perméabilité	17
II.1.1.4. Saturation	17
II.1.2. Les diagraphies enregistrées	18
II.1.2.1. Diagraphie de résistivité	18
II.1.2.2. Diagraphie de rayonnement Gamma "GR"	20
II.1.2.3. Diagraphie de porosité	21
II.1.2.3.1. Diagraphie de densité	21
II.1.2.3.2. Diagraphie sonique	23
II.1.2.3.3. Diagraphie de neutron	26
II.1.3. Description de la carotte	27
II.1.4. Log de chantier (Master-log)	30
II.2. Procédure de la classification lithologique	31
II.2.1. Présentation des puits d'étude	31
II.2.2. Localisation du réservoir Siegenien	32
II.2.3. La classification lithologique au niveau du Siegenien.	34
II.2.3.1. La classification lithologique par les diagraphies	34

Sommaire

II.2.3.2. La classification lithologique par les carottes et master-log.....	37
II.2.3.3 Analyse de la classification lithologique.....	42
III.2.3.4 Interprétation des résultats.....	46
Conclusion	49

CHAPITE.III : Classification lithologique par les réseaux de neurones artificiels de type MLP

Introduction	50
III.1. Théorie des réseaux de neurones artificiels.....	50
III.1.1. Historique	50
III.1.2. Neurone biologique	51
III.1.3. Le neurone artificiel.....	53
III.1.3.1. Le neurone formel	53
III.1.3.2. Modélisation d'un neurone.....	54
III.1.3.3. Comparaison entre le neurone biologique et le neurone artificiel.....	55
III.1.3.4. Fonction de combinaison	55
III.1.3.5. La fonction d'activation	56
III.1.3.6. Types de fonctions d'activation.....	56
III.1.4. Le réseau de neurone artificiel.....	59
III.1.4.1. Structure du réseau de neurones artificiels.....	60
III.1.4.2. La topologie.....	61
III.1.4.3. Apprentissage de réseau de neurone.....	61
III.1.4.4. Type d'apprentissage.....	62

Sommaire

III.1.4.5. R�tro-propagation.....	63
III.1.5. Diff�rents types des r�seaux de neurones.....	63
III.1.5.1. Le perceptron.....	64
III.1.5.2. Perceptron multicouches.....	65
III.1.5.3. Le perceptron par l'algorithme de r�tro-propagation.....	66
III.2. classification lithologique par les r�seaux de neurone artificiels.....	67
III.2.1.La structure de r�seau perceptron multicouche.....	67
III.2.2. Apprentissage de r�seau MLP.....	68
III.2.2.1.Algorithme d'apprentissage OWO-HWO.....	68
III.2.2.2.Application de l'apprentissage supervis�.....	70
III.2.3. G�n�ralisation ou propagation.....	73
III.2.3.1.Comparaison de la lithologie carotte et log de chantier avec celle de MLP.....	75

CHAPITE. IV : Classification lithologique par les r seaux de neurones artificiels de type cartes SOM

Introduction	77
IV.1. Mod�le de Kohonen.....	77
IV.1.1.L'origine	77
IV.1. 1.2.Leur utilisation	79
IV.1.2. Architecture du r�seau	79
IV.1.3. Algorithme d'apprentissage.....	80
IV.1.3.1.Principe.....	80

Sommaire

IV.1.3.2. Formalisation mathématique.....	81
IV.1.3.3. la notion de voisinage.....	82
IV.1.4. Procédé de calcul des S.O.M.....	83
IV.1.4.1. Initialisation De Données.....	84
IV.1.4.2. Initialisation des poids neuraux.....	84
IV.1.4.3. Calcul de la distance euclidienne ou du produit scalaire et détermination du neurone gagnant.....	84
IV.1.4.4. L'adaptation des poids du nœud gagnant et de ses voisins	85
IV.1.4.5. Adaptation des nœuds voisins selon leurs distances par rapport au nœud gagnant..	85
IV.1.4.6. Adaptation du rayon associé à chaque nœud corrigé.....	85
IV.1.4.7. Contrôle de la convergence pour continuer ou pour interrompre l'itération.....	86
IV.1.4.8. Contrôle de qualité	86
IV.1.4.9. Enregistrement des poids calculés.....	86
IV.1.4.10. Classification de l'ensemble des données d'entrée	86
IV.1.4.11. Contrôle de validité des résultats.....	86
IV.2. Classification lithologique par les cartes SOM.....	87
IV.2.1. Application de l'apprentissage non supervisé.....	87
IV.2.2. Généralisation ou propagation.....	89
IV.2.3. Comparaison entre la lithologie carotte, MLP et SOM	90
Conclusion générale.....	92
Bibliographie.....	93

Les figures :

FigI.1 :Carte de situation géographique du bassin de Berkine (Wec 2007).....	3
Fig.I.2 :Carte de situation du bloc d'étude Bir-Berkine dans le bassin de Berkine. (Sonatrach/ Exploration 2003).....	4
Fig.I.3:Carte de situation géologique du bassin de Berkine (Sonatrach/PED2003).....	5
Fig.I.4 : La colonne stratigraphique du bassin de Berkine.(BHP Petroleum 2006).....	9
Fig.I.5 : La colonne stratigraphique de la région Bir-Berkine. (Document Sonatrach).....	11
FigI.6: Principales phases tectoniques pendant le Paleozoïque et le Meso-cénozoïque (Boujemaa, 1987).....	13
FigII.1:Premier log électrique (Oil Field Review 2008).....	15
FigII.2 :Onde primaire " P".....	24
FigII.3 : Onde secondaire "S"	24
FigII.4:Signal typique et séparation des différents types d'ondes.....	25
FigII.5 : Une description de la carotte de puits BBK-14 du champ Bir-Berkine (documentsonatrach).....	29
FigII.6 :Une partie de log de chantier de puits BBK-14 du champ Bir-Berkine (documentSonatrach)	30
FigII.7 : Carte de situation des puits d'étude.....	31
FigII.8 : Localisation des différentes formations traversées par le forage dans les puits d'étude.....	32
FigII.9:Log composite du puits BBK11 du champ Bir-Berkine.....	35
Fig.II.10 :Log composite du puits BBK14 du champ Bir-Berkine.....	36
Fig.II.11 : Description des carottes pour le puits BBK14 du champ Bir-Berkine.....	38
FigII.12 : Une partie de log de chantier utilisée BBK-14 du champ Bir-Berkine	39
FigII.13 : Colonne lithologique pour le puits BBK 11 du champ Bir-Berkine.....	40
Fig.II14 : Colonne lithologique pour le puits BBK 14 du champ Bir-Berkine.....	41
FigII.15 :Log composite et lithologie du puits BBK11.....	47
FigII.16 : Log composite et lithologie du puits BBK14.....	48
Fig.III.1 : Schéma simplifié de neurone biologique.....	52
Fig.III.2 : Représentation graphique d'un neurone formel.....	54
Fig.III.3 : Comparaison entre le neurone biologique et le neurone artificiel.....	55

Fig.III.4 : Graphe de la fonction sigmoïde.....	57
Fig.III.5 : Graphe de la fonction à seuil.....	58
Fig.III.6: Graphe de la fonction linéaire par partie.....	59
Fig.III.7: Structure de réseau de neurone.....	60
Fig.III.8 : Schéma de fonctionnement de l'apprentissage supervisé (Aliouane, 2013).....	62
Fig.III.9 : Principe de l'apprentissage non-supervisé.....	63
Fig.III.10 : L'architecture de perceptron.....	64
Fig.III.11 : Architecture du perceptron Multicouche.....	65
Fig.III.12 : Architecture d'un modèle de Rétro-propagation.....	66
Fig.III.13 : Structure de réseau MLP pour la classification lithologique.....	68
Fig.III.14 : schéma récapitulatif de l'apprentissage de réseau MLP.....	70
Fig.III.15 : Interface du logiciel NuMap.....	71
Fig.III.16 : les logs et la lithologie d'apprentissage avec la lithologie MLP de puits BBK14.....	72
Fig.III.17 : Erreur quadratique moyenne en fonction de nombre d'itération pendant la phase d'apprentissage.....	73
Fig.III.18 : représentation des logs d'entrés et la lithologie obtenue par MLP dans le puits BBK11.....	74
Fig.III.19 : comparaison entre la lithologie carotte et celle de MLP.....	75
Fig.IV.1 : Architecture des cartes auto-organisatrices.....	78
Fig.IV.2 : Représentation de l'algorithme d'auto-organisation pour le modèle de Kohonen...81	
Fig.IV.3 : Organigramme du programme SOM appliqué	83
Fig.IV.4: Principe de l'apprentissage non-supervisé	87
Fig.IV.5 : La lithologie carotte vs la lithologie SOM après l'apprentissage	88
Fig.IV.6 : La lithologie carotte vs la lithologie SOM après la généralisation	89
Fig.IV.7 : Comparaison entre la lithologie carotte MLP et SOM après la généralisation	90

Les tableaux :

TableauII.1: Situation des puits d'étude.....	31
TableauII.2 : Les profondeurs des formations traversées par le forage dans les puits d'étude.....	33
Tableau.II.3 : Les profondeurs et les épaisseurs des couches dans le niveau C de puits BBK11.....	42
Tableau.II.4 : Les profondeurs et les épaisseurs des couches dans le niveau D de puits BBK11.....	43
Tableau.II.5 : Les profondeurs et les épaisseurs des couches dans le niveau E de puits BBK11.....	43
Tableau.II.6 : Les profondeurs et les épaisseurs des couches dans le niveau F de puits BBK11.....	43
Tableau.II.7 : Les profondeurs et les épaisseurs des couches dans le niveau C de puits BBK14.....	44
Tableau.II.8 : Les profondeurs et les épaisseurs des couches dans le niveau D de puits BBK14.....	44
Tableau.II.9 : Les profondeurs et les épaisseurs des couches dans le niveau E de puits BBK14.....	45
Tableau.II.10 : Les profondeurs et les épaisseurs des couches dans le niveau F de puits BBK14.....	45
Tableau.II.11 : Les profondeurs des niveaux gréseux du Siegenien dans les puits d'étude...	46
Tableau.III.1 : caractéristiques de réseau MLP utilisé.....	66

Introduction générale

La connaissance de différentes formations de puits, plus particulièrement de réservoir, est importante durant toute la vie de puits. Pour cela on fait recours aux différentes méthodes de décompositions lithologiques. Parmi ces dernières, les méthodes conventionnelles qui se font à l'aide de la combinaison des différentes diagraphies directement liées à la lithologie et les master-log avec les descriptions des carottes.

Les diagraphies donnent une image continue et objective des séries traversées dans un puits de forage. Elles permettent aussi de localiser les réservoirs et de déterminer la nature des fluides qui s'y trouvent. Comme la Carotte est l'image vivante du sous-sol, elle nous permet l'établissement de la colonne lithologique de puits foré.

Il faut noter que les puits ne sont pas tous carottés et s'ils sont carottés pas tout le long de puits. Par conséquent on propose de faire appel aux méthodes d'intelligences artificielles, à savoir les réseaux de neurones artificiel pour faire une classification lithologique. Les techniques des réseaux de neurones artificiels ont été largement utilisées dans la caractérisation de réservoir, essentiellement, dans la classification des lithofaciès par les diagraphies.

Le sujet de notre travail est d'établir une classification lithologique par deux types de réseau de neurones artificiels. Il s'agit d'un réseau d'apprentissage supervisé à savoir le perceptron multicouche (MLP) et d'un autre réseau à apprentissage non supervisé qui est les cartes auto-organisatrices de Kohonen (Cartes SOM).

Cette étude comporte quatre chapitres :

- Le premier chapitre est réservé pour une brève présentation géologique et géographique de la région d'étude.
- Le deuxième chapitre comporte des notions sur les principales diagraphies utilisées dans cette étude, un aperçu sur les descriptions des carottes et les master-log ainsi qu'une application de ces deux méthodes pour la décomposition lithologique.
- Dans le troisième chapitre nous donnerons des notions sur les réseaux de neurones artificiels et faire une classification lithologique par RNA de type MLP
- Le quatrième chapitre on se propose de faire une classification lithologique en utilisant les cartes auto-organisatrices (cartes SOM).
- En fin, on termine par une conclusion générale.

Introduction

Dans ce chapitre nous allons présenter la région d'étude Bir-Berkine, géographiquement et géologiquement et on donnera aussi un bref aperçu sur l'historique des travaux réalisés dans ce champ pétrolier.

Etant donné que parmi les objectifs pétroliers de la région est le Dévonien, donc sa stratigraphie sera détaillée, essentiellement celle du Siegenien.

I.1.Situation géographique

Le bassin de Berkine (ex GHADAMES) se situe dans l'erg oriental, du Sahara Algérien entre les latitudes 29° et 32° Nord et les longitudes 6° et 10° Est (**Fig.I.1**). Ce bassin occupe une aire totale de près de 103.000 Km².

Le champ Bir-Berkine (subdivisé en BBK et BBK Nord) est situé au centre du bassin de Berkine, à environ 50km au Nord du gisement d'Ourhoud et à moins de 20km à l'Ouest de gisement de Hassi Berkine, il fait partie du bloc 404b (**Fig.I.2**), il est délimité par :

-Les puits ROM (Ourhoud Messaude), ZEA (Zmlet Adrek) et ZEK (Zemmoul El KBAR) au Nord.

-Les puits Hassi-Berkine (HBN) à l'Est.

- Les puits Hassi-Berkine-Sud (HBNS) au Sud.

Il est compris entre les coordonnées **UTM32N** suivantes :

X = 395000 - 415000

Y = 3420000 - 3444000

I.2. Situation géologique

Le bassin de Berkine se situe dans l'erg oriental du Sahara algérien, géologiquement il est limité (**Fig.I.2**) par :

•A l'Est par, le bassin de Syrte entre la Tunisie et la Libye, avec une série de failles de direction NW-SE.

•Au Sud par le bassin d'Illizi.

•A l'Ouest par le môle d'Amghuid-El Biod-Hassi Messaoud.

•Au Nord par le bourrelet d'Ain-Roumana et la route de Dahar.





Fig.I.1 : Carte de situation géographique du bassin de Berkine. (WEC, 2007)

Les gisements Bir-Berkine (BBK) et Bir-Berkine-Nord (BBKN) font partie du bassin Paléozoïque de Berkine, sur la remontée structurale du paléozoïque vers le NW, dans un secteur où l'érosion hercynienne atteint le Frasnien.

La série comprise entre le Trias et le Siegenien est représentée par des argiles noires à passées carbonatées appartenant au Dévonien supérieur (Frasnien), Dévonien moyen et Emsien.

Cette série, régionalement tronquée sous la discordance Hercynienne, présente des épaisseurs variantes de 250m (BBKN-1) à 80m (BBKN-3).



La Légende




Fig.I.2: Carte de situation du bloc d'étude Bir-Berkine dans le bassin de Berkine.
(Sonatrach/ Exploration, 2003)

Le T.A.G.I est fortement réduit par l'érosion hercynienne (20 à 30m), alors que son épaisseur atteint et dépasse parfois les centaines de mètres à environ 30 à 40Km à l'Est, sur l'axe Ourhoud-El Borma. La structure globale des deux gisements est un horst de 2Km de large, limité par des failles majeures d'orientation NE-SO, affectée par des failles secondaires perpendiculaires aux failles majeures.




Fig.I.3: Carte de situation géologique du bassin de Berkine. (Sonatrach/PED, 2003)

I.3. Historique des travaux

Les gisements de Bir Berkine et Bir-Berkine Nord ont été découverts par l'association Sonatrach/Total Algérie, en réalisant les forages BBK-1 en mai **1984** et BBKN-1 en mai **1986**.

- **1992 et 1993:** Sonatrach a entrepris les premiers travaux de délinéations des gisements BBKN et BBK avec le forage respectif des puits BBKN-2 et BBK-2.
- **1997 :** C'est l'année de la reprise des travaux de délinéations avec le forage des puits BBK-3 et BBKN-3.

Depuis cette dernière année à ce jour-ci, le champ a connu une activité de délinéation et de développement intense et continue dans le temps. En effet, trente (30) autres forages, ont été réalisés, seize (16) puits sur BBK et quatorze (14) puits sur BBKN, selon un schéma de développement propre à ce champ.

Au départ, deux objectifs ont été fixés et atteints dans ces gisements. Ce sont des réservoirs à huile, le réservoir principal (Siegenien) qui appartient au Dévonien inférieur et du TAGI (Trias Argileux Gréseux Inférieur) considéré comme réservoir secondaire.

Le réservoir Gédinnien, sans intérêt dans les premiers puits, il a révélé, pour la première fois, la présence des hydrocarbures lors du forage du puits BBK-13, en juin 2005, ce réservoir est en cours de délinéation par le forage des puits de développement proposés.

I.4. Aspect stratigraphique

La colonne litho-stratigraphique traversée par les sondages du permis Bir-Berkine est en général analogue aux prévisions et aux puits de référence, avec toutefois de faibles variations latérales de faciès et d'épaisseur des formations. La série stratigraphique de la région est essentiellement composée de dépôts mésozoïques, reposant en discordance sur le Paléozoïque. Il y a aussi un faible épandage détritique d'âge tertiaire repose en discontinuité sur le Mésozoïque, (**Fig.I.4**).

I.4.1. Le Socle :

Le socle est composé de roches précambriennes sur lesquelles reposent en discordance les formations paléozoïques.

I.4.2. Le Paléozoïque :

Celui-ci est constitué par :

- a- Le Cambrien:** Ces dépôts reposent sur un socle précambrien, représenté par des grès et des quartzites à passées conglomératiques, avec une épaisseur moyenne de 300m.

b- L'Ordovicien: Qui repose sur le cambrien est composé d'une alternance des grès et d'argile :

- Les argiles d'El Gassi.
- Les grès d'El Atchane.
- Les quartzites de Hamra.
- Les grès d'Ouargla.
- Les argiles d'Azzel.
- Les grès d'Oued Saret.
- Les argiles micro conglomératiques.
- Les grès de Ramade.

c- Le Silurien: Reposant sur l'Ordovicien, il est composé d'argiles noires riches en matière organique qui forme une importante roche mère, celle-ci est surmontée par un important dépôt argilo-gréseux.

d- Le Dévonien: Il est formé par :

- **Dévonien inférieur :**

Il est composé d'une alternance argilo-gréseux.

- **Dévonien moyen :**

Il est caractérisé par un dépôt argileux, il comporte des intercalations de niveaux carbonaté.

- **Dévonien supérieur :**

Il est représenté par des argiles à passes de marnes, de calcaire et de dolomites, au sommet, on trouve des grès et des silt-stones.

e- Le Carbonifère: Il est constitué par:

- **Carbonifère inférieur:**

Qui débute par des argiles à passées des silt-stones et de calcaire. Au sommet, on distingue une alternance d'argiles de silt-stones et de grès avec des passées des roches carbonatées.

➤ **Carbonifère supérieur :**

Qui est représenté à la base par une alternance des grès et des argiles sauf dans la partie centrale, où, on observe des carbonates.

I.4.3. Le Mésozoïque: Il est formé par :

a- Le Trias :

➤ **le Trias Argilo-Gréseux inférieur (TAGI) :**

Il est constitué de grès gris blanc à blanc et gris vert, fin à moyen parfois grossier sub-arrondi à sub-anguleux, siliceux à silico-argileux, localement pyriteux, friables à moyennement consolidé avec intercalations d'argile brun rouge parfois gris-vert tendre à indurée silteuse. Traces de pyrite.

➤ **Le Trias Carbonaté :**

Il est constitué d'argile verte à gris verdâtre et brun rouge, tendre à indurée, silteuse localement dolomitique avec passées de dolomie blanc beige, tendre et de grès gris blanc à gris vert, très fin à fin, silico-argileux, moyennement dur.

➤ **le Trias Argilo-Gréseux supérieur (TAGS) :**

Il est constitué de grès gris blanc, très fin, siliceux à silico-argileux, dur avec intercalations d'argile brun rouge et gris vert, tendre à indurée, silteuse.

➤ **Le Trias Argileux :**

Il est constitué d'argile brun rouge et brunâtre, rarement gris vert, tendre à indurée silteuse avec traces d'anhydrite blanche, tendre, pulvérulente.

b- Le Jurassique : Il est constitué par le Lias, le Dogger lagunaire, le Dogger argileux et le Malm.

I.4.4. Le Cénozoïque:

Il est constitué de sable blanc à translucide, jaunâtre localement rougeâtre, rarement rosâtre fin à moyen, parfois grossier sub-arrondi à arrondi avec intercalations d'argile brun rouge sableuse, et présence de banc de calcaire argileux.

I.4.5. Le Quaternaire :

Ce sont des sables représentant des placages dunaires.




Fig.I.4 : La colonne stratigraphique du bassin de Berkine.

On note que la colonne stratigraphique établie à partir des sondages dans le champ Bir-Berkine (**FigI.5**), d'une façon générale, est la même par rapport à la colonne stratigraphique type du bassin de Berkine, mais il existe des variations, il est clair l'absence du Carbonifère et du Permien à cause de la discordance Hercynienne qui a même érodé le Frasnien qui se trouve dans le Dévonien supérieur. En outre, on remarque que la profondeur maximale des forages est le Silurien, autrement dit, le Socle, le Cambrien et l'Ordovicien n'ont jamais été atteints par le forage.

I.4.6. La stratigraphie du Dévonien

Le Dévonien est l'une des périodes du Paléozoïque. Dans la région Bir-Berkine, il est divisé en plusieurs étages qui sont :

- a- **Gédinnien**: il est formé d'un grès clair et beige, très fin à fin, compact, siliceux parfois silico-argileux avec des intercalations d'argiles gris-foncées à noires, indurées.
- b- **Siegenien**: il est composé de grès fin à moyen, siliceux à quartzitique avec intercalations d'argiles grises à noires, indurées. Le Siegenien est le réservoir principal dans la région, il est représenté par une alternance des grès fins à moyens et des argiles brunes.

Cette alternance a mis en place un réservoir gréseux multi-bancs, autrement dit le Siegenien est subdivisé en plusieurs niveaux gréseux qui sont :

Niveau "C" : C'est un ensemble des niveaux gréseux ($C_{1-4} - C_5 - C_{6-7}$) séparés par des bancs d'argiles, son épaisseur est de l'ordre de 48m.

Niveau "D" : Correspond à un ensemble de bancs de grès (D_1 et D_2) séparés par des bancs d'argile, dont son épaisseur est de l'ordre de 18m. Il constitue avec le niveau "C" le réservoir principal.

Niveau "E" : Composé par un ensemble de bancs gréseux (E_1 et E_{2-4}) séparés par des bancs d'argile, son épaisseur totale est de l'ordre de 24m.

Niveau "F" : Constitué par un ensemble de bancs gréseux ($F_1 - F_{2-4}$), séparés par des bancs d'argile, dont l'épaisseur est de l'ordre de 24m.

Niveau "G" : Constitué d'un seul banc de grès de 25m d'épaisseur au sommet du Gédinnien.




Fig.I.5 : La colonne stratigraphique de la région Bir-Berkine.

- c- **Emsien:** Caractérisé par une argile grise à gris-foncé silteuse tendre avec passées de silt-stones gris-clairs.
- d- **Eifélien:** Se compose de grès gris à gris-blanc, fin à très fin, argilo-carbonaté avec intercalations d'argiles gris-foncés à noires silteuses.
- e- **Givétien:** Argile noire et gris claire, silteuse, tendre, et noire indurée, et minces passées de calcaires blanchâtres à gris, argileux.
- f- **Frasnien:** Il est formé d'argile gris-noire et gris-claire, micacée, silteuse, avec minces passées de calcaires gris-clairs et blanchâtres et de la pyrite.

I.5.ASPECT STRUCTURAL

La série stratigraphique allant du Gédinnien au Quaternaire, présente des variations d'épaisseurs dues à la structure globale en horst des deux gisements (BBK et BBKN) qui sont affecté par des failles majeures de direction NE/SW.

L'interprétation des profils sismiques 2D de la région, elle nous a révélé l'existence de deux principales familles de failles, les failles orientées NW/SE et les NE/SW, ainsi que la présence de structures en fleurs qui peuvent représenter des pièges structuraux.

La discordance hercynienne représente l'événement majeur qui termine le cycle sédimentaire du Paléozoïque, elle est caractérisée par l'arrêt de la sédimentation carbonifère et des dépôts lagunaires (Argile rouge et Gypse). Cette phase tectonique a touché surtout le nord du bassin de Berkine, où l'érosion de l'étage carbonifère est presque entière. La discordance hercynienne a permis de mettre en contact le Trias et les roches mère du Silurien et du Frasnien. Les mouvements de cette phase ont joué un rôle important dans la structuration des bassins de la plateforme saharienne.

Les principales phases tectoniques dans le bassin de Berkine sont résumées dans la figure suivante : **(FigI.6)**

ERES	EPOQUE D'INTERVENTION MAXIMALE	NOMS DES PHASES	Nature et direction Des phases	EFFET SUR LES JEUX DE FAILLES
CENOZOIQUE	NEOGENE MIOCENE	ALPIN TARDIF TERTIAIRE	 N.O.60	Jeu en compression des accidents NO.60
	PALEOGENE EOCENE	ALPIN MOYEN EOCENE N.160	 N.160	Jeu en compression des accidents N.160 et création de nouvelles Structures
MESOZOIQUE	CRETACE	PHASE AUTRICHIENNE	 N.O.90	Jeu en invers sur les accidents NO.90
	JURASSIQUE	(ALPINPRECOCE)		
	TRIAS			
PALEOZOIQUE	PERMIEN	PHASE HERCYNIENNE TARDIVE	 N.120	Jeu en invers sur les failles NW-SE
	CARBONIFERE VISIEN	PHASE HERCYNIENNE PRECOCE	 N.O.40	Jeu en invers sur les failles NE-SE
	DEVONNIEN Superieur Moyen Inferieur	PHASE FRASNIEN	 NW-SE	Jeu en failles normale sur les failles NE-SW (variation de facies et d'épaisseur) (Volcanisme)
	SILURIEN	PHASE	 E.W ?	Jeu en inverse sur les failles N-S (Erosion sur les mole sub-méridien "Tihemboka")
	ORDOVICIEN	CALEDONIENNE		
	CAMBRIEN	PHASE PANAFRICAINNE TARDIVE	 E.W	Tectonique cassante réseau NE-SW Et NW-SE (Cratonisation du sahara central)

FigI.6: Principales phases tectoniques pendant le Paleozoique et le Meso-cenozoique.

(Boujemaa, 1987)

I.6. Le système pétrolier

I.6.1. Roches mères

Roche mère du Dévonien Supérieur: (Le Frasnien)

Le Frasnien n'est présent que sur le tiers Sud-est du bassin, son extension est liée à l'érosion Hercynienne. Il présente une forte épaisseur (291m) dans la région de Menzel Ledjmat (MLE-1), et une faible épaisseur dans la région de Bir- Berkine (13m dans BBKN-2), dans le reste du bassin l'épaisseur varie entre 150m à 200m.

Les études géochimiques montrent que, dans la région de Berkine la roche mère est actuellement en phase à huile à partir de 3120m de profondeur.

I.6.2-Roches couvertures

Généralement la couverture est assurée par des couches argileuses et argilo-salifères, la série salifère du Trias est une excellente couverture régionale pour l'ensemble des réservoirs Triasiques. La couverture des réservoirs de Siegenien est assurée par des intercalations entre les différents corps gréseux et les argiles qui constituent une couverture d'ordre régionale.

I.6.3.Roches réservoir

I.6.3.1-Trias

T.A.G.S: Il est constitué de grès moyen à grossier, déposé dans un milieu fluviatile en tresses passant progressivement vers le Nord-est à une sédimentation argileuse puis évaporitique. Au Nord l'équivalent du T.A.G.S se développe sous un faciès argilo-salifère, le Trias argileux à la base surmonté du Trias salifère S4.

T.A.G.I: Les principaux corps gréseux du T.A.G.I correspondent à des barres de chenaux à forte sinuosité, développaient dans les argiles de la plaine alluviale. Cette sédimentation correspond à un réseau fluviatile de type méandrique. L'épaisseur totale du T.A.G.I oscille entre 20 à 40m dans la zone d'étude et atteint 150m en dehors de la zone.

I.6.3.2-Siegenien

Le Siegenien est constitué d'argile silteuse dans laquelle s'intercalent de nombreux niveaux gréseux (C, D, E, F et G) métriques à décimétriques. Les niveaux C, D et E ce sont les principaux réservoirs du Siegenien, ils sont des bons producteurs de l'huile.

Introduction

Dans ce qui suit on va aborder la classification lithologique par les méthodes conventionnelles, à cet effet on va donner des notions sur les enregistrements des diagraphies utilisées dans notre étude.

On va aussi présenter l'application qui consiste à la classification lithologique à l'aide des diagraphies, master-log et carottes.

II.1. Diagraphies enregistrées

Depuis Septembre 1927, où les frères Conard et Marcel Schlumberger ont effectué l'enregistrement de la première diagraphie électrique (**Fig.II.1**) que l'on a appelée 'carottage éclectique' à Pechelbornn, en France, il est impensable de forer un puits sans effectuer une série de diagraphies. Cependant, l'enregistrement d'autres paramètres physiques est apparu avec les progrès techniques et scientifiques.




Fig.II.1 : Premier log électrique (Oil Field Review 2008).

Une diagraphie est un enregistrement continu, en fonction de la profondeur, d'un paramètre physique donné des formations géologiques traversées par le sondage. La mesure enregistrée se présente sous forme de courbe, la mesure physique obtenue peut être spontanée ou obtenue par excitation.

Les principaux utilisateurs de diagraphies, ce sont les pétroliers. Ils s'en servent pour le calcul des quantités d'hydrocarbures en place en évaluant les caractéristiques pétrophysiques des roches réservoirs.

Les diagraphies sont des techniques qui apportent immédiatement des informations inédites, en permettant notamment une différenciation qualitative des différentes unités

lithologiques, la connaissance des fluides présentant dans la formation et donc une évaluation de sa porosité.

Aussi, elles rendent possible les corrélations puits à puits, donc le suivi d'un horizon lithologique entre les sondages. C'est pourquoi elles revêtent une telle importance et qu'on ne peut plus concevoir de nos jours de synthèse géologique sans exploitation des données diagraphique. Les diagraphies traduisent en effet un état de fait qu'on ne peut changer. Elles établissent en quelque sorte un constat, elles sont donc la signature du terrain.

Dans ce travail, on va présenter les principaux types des diagraphies utilisés lors de la classification lithologique du réservoir Siegenien, dans la région Bir-Berkine.

II.1.1. NOTIONS PETROPHYSIQUES

II.1.1.1. Réservoir

Un réservoir est une formation du sous-sol poreuse et perméable, elle renferme, généralement, une accumulation naturelle d'hydrocarbure (huile et /ou gaz), limitée par une barrière aquifère et caractérisée par un système de pression unique. Cette définition renferme, donc, à la fois les concepts suivants :

- Paramètres pétrophysiques : porosité, perméabilité, et saturation.
- Accumulation naturelle d'hydrocarbures.
- Couverture-fermeture : barrière rocheuse ou aquifère.
- Régime de pression naturelle, avant exploitation.

Lorsque plusieurs réservoirs sont situés proches l'un de l'autre ou superposés, ils vont former ainsi un gisement. Un réservoir peut contenir soit de l'huile, soit du gaz ou les deux fluides superposés.

Les principaux réservoirs sont des réservoirs gréseux ou carbonatés, mais Il faut noter que les réservoirs gréseux sont les plus fréquents en Algérie spécialement à Bir-Berkine, par conséquent, on s'intéressera à l'interprétation de ces réservoirs.

Réservoir gréseux

La roche réservoir est formée de grains de quartz (silice SiO_2). Il s'agit des sables et des grès qui sont constitués, respectivement, de grains libres et de grains cimentés. Selon le type de ciment, on distingue plusieurs types de grès : grès argileux, grès carbonaté, ...

II.1.1.2 Porosité

C'est la fraction du volume des vides par rapport au volume total.

$$\Phi = (V_{\text{vides}} / V_{\text{total}}) * 100\%$$

La porosité accessible aux fluides libres (porosité effective) varie entre 1% et 40%.

Elle est : - Faible si $\Phi < 5\%$

-Médiocre si $5\% < \Phi < 10\%$

-Moyenne si $10\% < \Phi < 20\%$

-Bonne si $20\% < \Phi < 30\%$

-Excellente si $\Phi > 30\%$

II.1.1.3. Perméabilité

La perméabilité est la capacité d'une formation poreuse à laisser le fluide s'écouler lorsqu'un gradient de pression est appliqué. La perméabilité est désignée par K, et est exprimée en millidarcy (md).

Elle dépend fortement de la taille des grains dans la roche, de la porosité, et de la saturation irréductible.

La perméabilité est :-Très faible si $K < 1 \text{ md}$

- Faible si K compris entre 1md et 10md

- Médiocre si K est compris entre 10md et 50md

- Moyenne si K est compris entre 50md et 200md

- Bonne si K est compris entre 200md et 500md

-Excellente si $K > 500 \text{ md}$

II.1.1.4.Saturation

La saturation est le rapport entre les fluides qui contenus dans les pores et le volume des pores.

$$S = (\text{Volume des fluides} / \text{Volume des pores}) * 100\%$$

Dans la zone lavée, les pores sont remplis de filtrat de boue et résidus d'hydrocarbure.

On évalue, donc, les deux saturations, respectivement, **Sxt** et **Shres** par la formule :

$$S_{xt} + S_{hres} = 1$$

Dans la zone vierge, où les pores sont remplis d'eau et d'hydrocarbure, traduit par les deux saturations respectives, **Sw** et **Sh** et par la formule : **Sw + Sh = 1**

Dans le cas où les hydrocarbures sont composés d'huile et de gaz, ils sont traduits par les deux saturations respectives **So** et **Sg**, par la formule suivante : **Sh = So + Sg**

Remarque : Dans le cas d'un niveau réservoir aquifère : **Sw = 1** et **Sxt = 1**

II.1.2. Diagraphies enregistrées

II.1.2.1 Diagraphie de résistivité

Mesure la capacité de la formation à s'opposer à la circulation du courant électrique en fonction de la profondeur.

La résistivité dépend grossièrement de la composition de la roche en élément solide, et de la nature des fluides y sont contenus, on peut voir cela par :

- la composition de la roche, c'est-à-dire la nature et le pourcentage du « contenant », donc des éléments solides (grains, cristaux, ciments), et du « contenu », donc des fluides (eau et hydrocarbures) ; à de rares exceptions près (graphite, sulfures et éléments natifs), les minéraux entrant dans la constitution des roches sont pratiquement des isolants ; le gaz et le pétrole sont aussi des isolants ; en revanche, dans la mesure où elle contient des ions en solution, l'eau est conductrice ; cette conductivité augmente avec la teneur en sels.

- le pourcentage des fluides dans la roche (porosité) et dans les pores (saturation) ; la porosité est définie comme le rapport du volume des « vides » (pores) au volume total de la roche ; la saturation en un fluide (par exemple, l'eau) est définie comme le rapport du volume occupé par ce fluide au volume total des vides.

- la texture de la roche, c'est-à-dire la taille, la forme, l'arrangement, le classement, l'orientation des grains ou des cristaux, le volume de ciment ; tous ces paramètres conditionnent le volume des pores, leur taille, leur répartition, la taille des seuils ou des canalicules les reliant, et la connexion des pores entre eux ;

- la distribution des minéraux conducteurs dans la roche.

- la structure de la roche, ainsi que l'épaisseur des bancs.

- la température ; plus celle-ci est élevée, plus la formation est conductrice, toutes choses égales par ailleurs.

Ainsi, si une roche n'est pas isolante, c'est qu'elle est poreuse et que les pores sont connectés : le courant passe dans l'eau qui occupe les pores. Une formation poreuse ne contenant que de l'eau chargée en sels aura une résistivité beaucoup plus faible qu'une formation de même porosité contenant une petite fraction d'eau de même teneur en sels (eau irréductible) et des hydrocarbures, ce qui explique l'importance du paramètre résistivité.

Le principe fondamental de mesure des diagraphies de résistivité, consiste à envoyer un courant électrique par une source émettrice (électrode ou bobine), qui pénètre dans la

formation, et à travers un récepteur (électrode ou bobine) on enregistre la résistivité ou la conductivité des formations. La distance entre émetteur-récepteur est appelé espacement, Selon l'espacement, on distingue : les macro-dispositifs et les micro-dispositifs

a- Micro-dispositif

Ils sont caractérisés par des espacements relativement réduits, permettant de donner des informations sur la résistivité de la zone lavée R_{xo} . (MSFL, 6FF40, AIT....)

b- Macro-dispositif

Ils sont caractérisés par des espacements importants, permettant d'investir dans la zone profonde. Ils nous permettent de donner des informations sur la résistivité de la zone vierge R_t . Plusieurs outils ont été conçus dans ce but (DLL, AIT ...)

Les résistivités focalisées sont utilisées actuellement pour n'importe quel type de boue, en utilisant la focalisation du courant d'émission ou courant d'ajustement. Deux types de dispositifs focalisés, assez complexes, donnent satisfaction tant pour la profondeur d'investigation que pour la définition verticale, sont mis en œuvre. Il s'agit :

- Latéolog : utilisés dans le cas des boues salées.
- Inductolog : utilisés dans le cas des boues non conductrices.

Il est important donc de connaître la résistivité de la formation au-delà de la zone contaminée par le filtrat de boue, ce qui nécessite l'utilisation de dispositifs de mesure ayant une profondeur d'investigation suffisante. Il est en outre indispensable d'obtenir des mesures qui aient une bonne définition verticale ; l'instrument doit donc être capable de donner des mesures correctes dans le cas des couches minces et de suivre fidèlement les variations verticales rapides de résistivité.

Dans notre cas on a utilisé la boue à huile qui est une boue non conductrice à cette effet la résistivité enregistrée est la résistivité d'induction.

- **Résistivité d'induction**

Un courant de fréquence élevée passe dans un ensemble de bobines émettrices coaxiales. Les courants de Foucault induits dans la formation par le champ électromagnétique induisent à leur tour, dans un ensemble de bobines réceptrices coaxiales, un signal (force électromotrice) proportionnel à la conductivité (inverse de la résistivité).

Dans notre étude l'outil utilisé pour mesurer la résistivité est le **AIT (Array Induction Tool)**.

- **AIT (Array Induction Tool)**

L'outil **AIT** est utilisé dans la boue à base d'huile, il est conçu d'une grande précision de mesure de la conductivité dans la formation en trou ouvert à cinq profondeurs d'investigation différentes, il nous permet l'enregistrement de cinq courbes de résistivité à des profondeurs qui varient entre (10, 20, 30, et 90) pouces, en fonction de la profondeur, 1ft, 2ft et 4ft ; est disponible selon 3 solutions verticales :

- Un pied pour l'analyse des couches minces.
- 2 à 4 pieds pour la corrélation facile avec le log existant.
- La détermination de l'hétérogénéité proche du puits de forage.

Application

- La détermination des différentes résistivités R_t et R_{xo} .
- La détermination des différentes saturations.
- La détermination de la nature du fluide de la formation traversé par le forage.
- La détermination de la porosité utile.
- La détermination de la température.

II.1.1.2. Diagraphie de rayonnement gamma "GR"

Ces diagraphies mesurent la radioactivité naturelle des formations traversées par le forage. A cet effet, le capteur d'une sonde aux rayons Gamma est un détecteur à scintillation à l'iodure de sodium ou à l'iodure de césium descendu par un câble, les rayons gamma naturelles émis par les formations traversées par le forage, son symbole est le **GR** et son unité est l'**API**.

Le rayonnement gamma naturel est lié à la présence des trois éléments radioactifs : le Potassium, le Thorium et l'Uranium dans les roches sédimentaires.

Les facteurs influençant la mesure sont : la vitesse d'enregistrement, la constante du temps, le taux de comptage, le temps mort, la boue, le tubage, le ciment et les épaisseurs des bancs. Elle est enregistrée pour tous les puits d'études.

Application:

- La corrélation de puits à puits.
- L'évaluation des volumes et du type d'argiles (V_{sh}).

Sachant que le volume d'argiles $V_{sh}(\%)$ est exprimé par :

$$V_{sh}(\%) = 100 (GR_{lu} - GR_{min}) / (GR_{max} - GR_{min}).$$

GR_{lu} , GR_{min} et GR_{max} sont, respectivement, les radioactivités des niveaux où on désire calculer le V_{sh} , propre et totalement argileux.

- La détermination de la lithologie, en établissant un profil lithologique vertical.
- la délimitation des zones réservoirs (perméables) et celles imperméables. Pour cela, il est nécessaire de fixer une valeur limite dite ($GR_{cut-off}$).

$$GR_{cut-off} = V_{Sh\ cut-off} \cdot (GR_{max} - GR_{min}) + GR_{min}. \text{ Tq: } 35\% < V_{Sh\ cut-off} < 45\%.$$

II.1.2.3. Diagraphie de porosité

Pour l'estimation de la porosité utile des réservoirs (ϕ_u), on distingue trois outils aux principes de fonctionnement distincts :

- Le Sonique.
- La Densité.
- Le Neutron.

II.1.2.3.1 Diagraphie de densité

On soumet la formation à un rayonnement Gamma émis par une source spéciale ^{60}Co ou ^{137}Cs . Les rayons Gamma sont des particules sans masse, ils se propagent à la vitesse de la lumière.

Ces photons Gamma incidents entrent en collision avec la matière par conséquent trois types d'interactions peuvent se produire, suivant l'énergie du photon incident :

- * L'effet de production de paire.
- * L'effet photoélectrique.
- * L'effet Compton.

Ce sont ces deux derniers qui intéressent les diagraphies de densité. En effet dans le domaine des faibles énergies, caractérisé par l'effet photoélectrique pour mesurer l'effet photoélectrique on a utilisé la sonde Litho Density Tool.

- **LDT (Litho Density Tool)**

Cette sonde permet de déterminer l'énergie de la densité globale, l'obtention des coefficients d'absorption **P_e** (barns/é).

Ce dernier est proportionnel au nombre atomique moyen des éléments entrant dans la composition de la roche, il est donné par:

$$P_e = \left(\frac{Z}{10} \right)^{3,6}$$

Avec Z : numéro atomique. Pour une substance moléculaire la relation devient :

$$P_e = \sum A_i Z_i P_i / \sum A_i Z_i$$

A_i, Z_i et P_i sont, respectivement, la masse atomique, le numéro atomique et le facteur photoélectrique des éléments simples constituant la molécule.

Grâce à l'existence de deux détecteurs sur cette sonde, elle permet de minimiser les effets du mud-cake et des cavités, sa résolution verticale est égale à l'écartement entre les détecteurs avec un rayon d'investigation d'environ 10".

Cependant, Dans le domaine de l'effet Compton, les diagraphies de densité mesurent la densité globale de la formation ρ_b (g/cc). Dans le cas d'élément chimique simple, la densité globale est liée à la densité de l'électron ρ_e, par la relation : ρ_e = 2ρ_b (Z/A). Où A est la masse atomique.

Toutefois, pour la substance moléculaire, la relation est la suivante : ρ_e = ρ_b 2ΣZ_i/ M

Où M est la masse moléculaire.

Les diagraphies de densité sont sensibles aux rayons gamma liés aux effets Compton, de même pour des études minéralogiques, le développement des sondes de densité a rendu possible les énergies sensibles aux domaines photoélectriques.

Application

- Détermination une porosité densité indispensable à l'interprétation moderne.
- La comparaison du neutron, densité et résistivité permet une identification des fluides dans les réservoirs et la localisation des contacts gaz/huile et huile/eau.
- Détection de la présence de gaz dans la zone envahie car elle provoque une forte diminution de la densité, donc une porosité densité anormalement haute.

La densité exprimée en termes de porosité Φ_D par la relation :

$$\Phi_D = (\rho_b - \rho_{ma}) / (\rho_f - \rho_{ma})$$

Avec ρ_{ma} : densité de la matrice.

ρ_f : densité de la boue.

En présence des argiles, la porosité corrigée s'exprime par :

$$\Phi_{Dc} = \Phi_D - \Phi_{Dsh} \cdot V_{sh}$$

Avec Φ_D : porosité évaluée à partir d'un enregistrement de porosité densité.

V_{sh} : volume d'argiles.

Φ_{Dsh} : porosité densité des argiles

$\Phi_{Dsh} = (\rho_{sh} - \rho_{ma}) / (\rho_f - \rho_{ma})$ où ρ_{sh} est la densité des argiles.

II.1.2.3.2. Diagraphie sonique

Ces diagraphies sont basées essentiellement sur la mesure de temps de propagation d'une onde acoustique, le long des parois du puits, pour calculer la distance Emetteur-Récepteur. A propos des ondes acoustiques, on peut citer :

a. Onde de compression "P"

Cette onde primaire (**Fig.II.2**) est caractérisée par :

- ✓ Un mouvement de propagation des particules parallèle à la direction de propagation.
- ✓ Une plus grande vitesse de propagation, elle arrive donc la première.
- ✓ Une plus faible amplitude.
- ✓ Elle est la seule à se propager dans les liquides.




Fig.II.2: Onde primaire " P"

b. Onde de cisaillement "S"

Cette onde secondaire (Fig.II.3) est caractérisée par :

- ✓ Un mouvement des particules perpendiculaire à la direction de propagation.
- ✓ Sa vitesse est inférieure à celle de l'onde "P", elle arrive donc la deuxième.
- ✓ Son amplitude est supérieure à celle de l'onde "P".
- ✓ Elle ne se propage pas dans les liquides.




Fig.II.3 : Onde secondaire "S"

C- Ondes de surface

Généralement on s'intéresse aux ondes de Stoneley.

➤ **Les ondes de Stoneley**

Elles circulent à l'interface Liquide-Solide, elles résultent de l'interaction de l'onde "**P**" dans le liquide et de l'onde "**S**" dans le solide. Leur vitesse est inférieure à celle des ondes "**P**" et "**S**", elles arrivent donc les dernières. Leur amplitude est supérieure à celle des ondes "**P**" et "**S**".

Le schéma ci dessous (**Fig.II.4**) montre un signal typique enregistré et séparation des différents types d'ondes d'après leur temps de trajet et leur amplitude.




Fig.II.4 : Signal typique et séparation des différents types d'ondes

L'outil utilisé dans cette étude pour mesurer le temps de transit (Δt) des ondes de compressions est le Bore Hole Compesated (BHC).

- **BHC (Bore Hole Compensated)**

Afin d'effectuer une bonne mesure l'outil sonique avec compensation est muni de quatre bras qui permettent de le maintenir centré dans le trou.

Il est constitué de deux émetteurs disposés aux extrémités de la sonde, et de deux paires de récepteurs couplées chacune avec un émetteur. Ce dernier émet un train d'onde d'une fréquence moyenne de **20 à 40 KHz**.

La vitesse du son dépend de la matrice lithologique, de la distribution de la porosité primaire et du type de fluide dans le puits.

La porosité ralentit l'onde sonore donc augmente le temps de transite Δt . Cependant la courbe a pour unité $\mu\text{s}/\text{pied}$.

Le paramètre mesuré Δt est exploité pour la localisation des zones à pressions anormales ; étant donné sa bonne résolution verticale (60 cm), il est utilisé pour déterminer l'épaisseur des bancs.

Application

- Détermination de la porosité.
- Détermination de la lithologie par la combinaison avec d'autres types de diagraphies.
- Evaluation des vitesses utiles à l'interprétation sismique.
- Estimation de la porosité secondaire.

Le temps de parcours Δt ($\mu\text{s}/\text{ft}$) dépend de la nature lithologique, de la porosité et du type de fluides contenus dans les pores.

Le temps de parcours est traduit en porosité sonique par la relation :

$$\Phi_S = (\Delta t - \Delta t_{ma}) / (\Delta t_f - \Delta t_{ma})$$

Avec Δt_{ma} : temps de parcours de la matrice

Δt_f : temps de parcours de la boue.

Dans le cas des formations argileuses, la porosité sonique corrigée Φ_{SC} est exprimée par :

$$\Phi_{SC} = \Phi_S - V_{sh} \cdot \Phi_{Ssh}$$

Où Φ_{Ssh} est la porosité sonique des argiles :

$$\Phi_{Ssh} = (\Delta t_{sh} - \Delta t_{ma}) / (\Delta t_f - \Delta t_{ma}) \text{ où } \Delta t_{sh} \text{ est le temps de parcours des argiles.}$$

Les applications des diagraphies soniques sont similaires à celles des diagraphies neutrons et de densité.

II.1.2.4.3. Diagraphie de neutron

A l'aide de sources appropriées on soumet les formations à un bombardement intense de neutrons rapides, d'énergie initiale comprise entre 2.5 et 6 MeV.

Grâce à leur vitesse initiale élevée (14.000 Km/s), les neutrons rapides ont un grand pouvoir de pénétration. Ils vont entrer, de ce fait, en collision avec les noyaux des atomes des formations qu'ils traversent et perdent progressivement leur énergie.

L'hydrogène est l'élément dont le pouvoir de ralentissement est le plus fort. Comme cet élément se trouve présent dans de nombreuses substances, la mesure traduit essentiellement la concentration de la formation en atomes d'hydrogènes. Les substances qui en contiennent le plus sont l'eau et les liquides.

La mesure de $\emptyset_n$ ou I_{H_n} dépend en quelque sorte du nombre d'atomes d'hydrogène par l'unité de volume dans la formation, ceux-ci étant soit liés à l'eau ou aux l'hydrocarbure (donc à la porosité et à la saturation), soit à la composition moléculaire de la roche, mais aussi à un moindre degré, des autres atomes entrant dans la composition de la roche soit par suite de leur pouvoir ralentisseur, soit par leur pouvoir absorbant. Les courbes neutrons enregistrées ont une échelle qui varie entre - 0,15m³/m³ et 0,45.

Dans le cas des formations argileuses, la porosité Φ_{NC} est liée au volume d'argiles V_{sh} par la relation :

$$\Phi_{NC} = \Phi_N - V_{sh} \cdot \Phi_{Nsh}$$

Φ_{Nsh} est la porosité neutron des argiles.

La sonde utilisée dans notre étude est CNL (Compensated Neutron Log)

- **CNL (Compensated Neutron Log)**

A l'aide d'une source radioactive à base de Béryllium, la formation est soumise à un bombardement intense de neutron à grande énergie, le nombre de neutron thermique augmente avec la quantité d'hydrogène présente dans les fluides, d'où la notion d'indice hydrogène neutron $(IH)_n$ donc sa mesure sera liée à celle de la porosité.

La relation entre neutron thermique, indice hydrogène et porosité est :

$$\text{Log}(IH)_n = A - B \cdot N_a$$

Tel que :

N_a : Amplitude de la courbe neutron.

A et **B** : Constantes reliées à l'outil et aux paramètres du trou (boue, diamètre...etc.)

La porosité neutron est déduite de l'équation précédente et est donnée en unité porosité (Porosity unit PU).

On remarque toujours dans cette équation que la saturation est donnée dans la zone lavée, car l'outil a un rayon d'investigation très voisin de la zone en question et sa définition verticale est égale à l'écartement entre les détecteurs.

Application

Les principales applications des diagraphies neutrons sont :

- L'évaluation de la porosité des roches de réservoirs.
- Combiné avec d'autres outils, il permet d'identifier la lithologie.
- Combiner avec le LDT pour les poches de gaz.
- Evaluation de la densité des hydrocarbures.
- Bon critère de corrélation de puits à puits.

II.1.3. Description de la carotte

L'étude d'une carotte nécessite une description claire et relativement détaillée des faciès sédimentaires existant dans la carotte, cette analyse sédimentologique servira de point de départ de toutes études ultérieures sur la carotte ; il est donc important que la description

englobe tous les éléments lithologiques essentiels visibles et qu'elle soit compréhensible pour les géologues n'ayant pas vu la carotte. Il est donc proposé une méthodologie qui pourra servir de langage commun aux utilisateurs.

Il est important de souligner que l'étude sédimentologique d'une carotte sert à améliorer l'utilisation des diagraphies électriques. En effet, les puits ne sont carottés que sur des intervalles limités et la bonne observation de ces carottes doit permettre d'améliorer l'interprétation qualitative des diagraphies, de comparer des séquences de dépôts et les séquences électriques, et, dans certains cas favorables, d'étalonner les diagraphies. De la précision des descriptions sédimentologiques des carottes dépendra la possibilité d'interpréter, de faire parler les diagraphies et de reconstituer l'histoire sédimentaire sur des intervalles dépassant largement les zones carottées. La prise de carotte sur chantier répond en général à plusieurs impératifs géologiques et de production :

- Reconnaissance des lithologies
- Examen sédimentologique des séries traversées
- Comparaison avec les diagraphies
- Caractéristique des qualités réservoirs
- Prélèvements d'échantillons en vue de la complétion

Dans la plupart des cas, la lithologie des sédiments clastiques se décrit en fonction de la granulométrie, en distinguant une suite de type de sédiments, de plus fin en plus grossier. Par ailleurs, il est nécessaire de catégoriser deux types de sédiments caractéristiques d'environnement particuliers : les argiles organiques et le charbon.

Dans la fiche de description, les différents types de sédiment clastique sont placés en ordre granulométrique croissant :

- Charbon
- Argile organique
- Argile
- Argile sableuse
- Sable fin (les grains < 0.250mm)
- Sable moyen (0.250 < les grains < 0.500mm)
- Sable grossier (0.500 < les grains < 2mm)
- Conglomérat (les grains > 2mm)

Voici un exemple d'une description de la carotte faite sur le puits BBK-14 du champ de Bir-Berkine au niveau de Siegenien (3727m-3736)(Fig.II.5):




Fig.II.5: Une description de la carotte de puits BBK-14 du champ Bir-Berkine(document Sonatrach, 1999)

II.1.4. Log de chantier (Master log)

C'est un document qui comporte deux types d'informations ; le taux d'avancement de forage et la description lithologique des formations traversées par le forage, cette dernière est obtenue à partir des analyses des déblais remontés par la boue de forage à la surface.

Un extrait de master log de puits BBK-14 (**Fig.II.6**) au niveau de réservoir (3630m à 3700m):




Fig. II.6: Une partie de log de chantier de puits BBK-14 du champ Bir-Berkiné (document sonatrach, 1999)

II.2. Procédure de la classification lithologique

II.2.1.Présentation des puits d'étude

Dans cette étude on doit exploiter les données de diagraphies, carotte et master-log des deux puits BBK-11 et BBK-14 situés dans la région Bir-Berkine, leur situation géographique est illustrée dans (Tableau.II.1) et (Fig.II.7) :

Puits	X(M)	Y(M)	Z _{table} (M)	Z _{Sol} (M)
BBK11	403653.96 E	3431762.70 N	195.38	187.73
BBK14	402148.186 E	4341747.54 N	196.81	189.16

Tableau.II.1 : Situation des puits d'étude





Fig.II.7: Carte de situation des puits d'étude

II.2.2. Localisation du réservoir Sieginien

La figure suivante (Fig.II.8) présente la localisation et la délimitation du réservoir Sieginien ainsi que les différentes unités pour les puits BBK11 et BBK14.



La légende :

Argile
Grès

Fig.II.8: Localisation des différentes formations traversées par le forage dans les puits d'étude.

A partir de la corrélation entre les puits BBK-11 et BBK-14 du champ Bir-Berkine, on remarque avant la discordance Hercynienne que l'épaisseur des formations est presque constante entre les deux puits, même chose pour leur profondeur où il y a un petit décalage de profondeur ne dépasse pas les 5m. Après la discordance hercynienne qui se trouve à 3315m de profondeur pour le puits BBK-11 et à 3320m de profondeur pour le puits BBK-14, il est clair que l'absence du Frasnien est dû à l'érosion. Les couches n'étaient pas érodées de même épaisseur, ce qui a provoqué une différence d'épaisseur des bancs dans les deux puits et un décalage de profondeur des couches sus-jacentes. De plus on observe que le marquer Siegenien se situe à 3515m pour le puits BBK-11 et à la profondeur 3480 m pour le puits BBK-14, ce marquer est identifié par une brusque chute de la valeur de DT (sonique). On note que dans le puits BBK-11 le Gedinien n'était pas atteint par le forage or que dans le puits BBK-14 la profondeur du forage a dépassé les 3900m ce qui a donné une épaisseur du Gidenien dépasse 200m (Tableau.II.2).

Puits	Formation	Toit(M)	Mur(M)	Epaisseur(m)
BBK11	Trias S4	3137	3171	34
	Trias argileux	3171	3211.4	40.4
	Trias cabronate	3211.4	3296.4	85
	TAGI	3296.4	3317.7	21.3
	Eif-Gevitien	3398	3489.5	91.5
	Emsien	3489.5	3515	25.5
	Siegenien	3515	3715	200
	Gedinien	-	-	-
BBK14	Trias S4	3138	3177.4	39.4
	Trias argileux	3177.4	3217.4	40
	Trias carbonate	3217.4	3305.3	87.9
	TAGI	3305.3	3320.5	15.2
	Eif-Gevitien	3360	3429.5	69.5
	Emsien	3429.5	3479.5	50
	Siegenien	3479.5	3731	251.5
	Gedinien	3731	3943	212

Tableau.II.2 : Les profondeurs des formations traversées par le forage dans les puits d'étude.

II.2.3. La classification lithologique au niveau du Siegenien

Dans cette section on va procéder à une classification lithologique du réservoir Siegenien par les diagraphies et la combinaison entre la description des carottes et le log du chantier (master-log).

II.2.3.1. La classification lithologique par les diagraphies

Les diagraphies enregistrées sont toutes liées à la lithologie il s'agit des log de Gamma ray, Sonique, Densité, Porosité et résistivité qui ont pour but d'établir une colonne lithologique. On sait que notre réservoir est argileux-gréseux donc on a que de grès et d'argile de tel sorte que :

- Tout d'abord on s'intéresse à faire la différence entre les formations argileuses et les formations gréseuses. Sachant que l'argile est plus radioactive donc sa réponse en GR est plus grande à celle du grès (Voir **Fig.II.9** et **Fig.II.10**). (Sierra, 1985).
- Ensuite on va s'intéresser à la taille des grains, le jeu de log de sonique (DT), porosité neutron (CN), densité (ZDEN), et la résistivité (M2R9) permet de dire que la granulométrie est fine ou moyenne.

Le grès moyen est caractérisé par un sonique relativement élevé, une faible densité et résistivité, dans l'intervalle [3550m-3555m]. (**Fig.II.9**). Il est aussi caractérisé par un sonique faible, une faible densité et une résistivité élevée, dans l'intervalle [3562m-3566m]. (**Fig.II.9**).

Le grès fin est caractérisé par un sonique et une densité élevés et une faible résistivité, dans l'intervalle [3570m-3575m]. (**Fig.II.10**). Il est aussi situé dans l'intervalle [355m-3555m] où le sonique et la résistivité sont faible et la densité est élevée.




Fig.II.9 : Log composite au niveau de réservoir siegenien du puits BBK-11 du champ Bir-Berkine.




Fig. II.10: Log composite au niveau de réservoir siegenien du puits BBK-14 du champ Bir-Berkine

II.2.3.2. La classification lithologique par les carottes et master-log

On a utilisé les descriptions des carottes et les master-log pour établir la colonne lithologique au niveau du Siegenien en tenant compte seulement de trois formations (Argile, Grès fin et Grès moyen), En procédant comme suit :

- La première étape consiste à établir la colonne lithologique au niveau du Siegenien pour les deux puits BBK-11 (**Fig.II.13**) et BBK-14 (**Fig.II.14**) à partir d'une combinaison entre les descriptions des carottes (**Fig.II.11**) et le master-log (**Fig.II.12**) en donnant plus d'importance à la description des carottes car elles sont plus précises, autrement dit on a utilisé les master-log pour les profondeurs non carottées. On a dit que les descriptions des carottes sont plus précise car la carotte est l'image vivante du sous-sol de plus elle est à l'échelle centimétrique, mais il existe une concordance entre la lithologie données par les carottes et celle données par les master-log c'est-à-dire que la lithologie données par les master-log est aussi juste.

-Ensuite on a numérisé cette colonne lithologique pour qu'on puisse l'introduire dans le logiciel **IP** (Interactive petrophysics).

- A la fin, on a utilisé les enregistrements de diagraphies liées directement à la lithologie (Gamma ray, Sonique, Densité, Porosité, Résistivité) en face cette colonne lithologique établie par les carottes et master-log, pour le puits BBK-11 (**FigII.15**) et pour le puits BBK-14 (**Fig.II.16**). Cette étape a pour but de tester la fiabilité de la lithologie donnée par les diagraphies. Il faut noter qu'il existe un décalage entre les cotes sondeur(les profondeurs données par les master-log) et les cotes électriques (les profondeurs données par les diagraphies) par conséquent on doit déplacer les profondeurs des formations données par les cotes sondeurs pour qu'elle soit la même à celles données par les cotes électriques.

-Dans le puits BBK-11 : On trouve que le toit du Siegenien est à 3513m de profondeur pour les cotes sondeurs or qu'il est à la profondeur 3516m pour les cotes électriques donc pour trouver la vraie profondeur donnée par les master-log on ajoute 3m.

-Dans le puits BBK-14 : Le toit du Siegenien est à 3482m de profondeur pour les cotes sondeurs mais pour les cotes électriques il se trouve à la profondeur 3478m par conséquent dans les master-log pour obtenir la vraie profondeur on diminue 4m.




Fig.II.11 : Description des carottes au niveau de réservoir siegenien pour le puits BBK-14 du champ Bir-Berkine




Fig.II.12: Une partie de log de chantier utilisée BBK-14 du champ Bir-Berkiné

La combinaison entre les descriptions des carottes (**Fig.II.11**) et les master-log (**Fig.II.12**) donne une colonne lithologique non numérisée on va l'introduire dans le logiciel **IP** (Interactive petrophysics) pour établir une colonne lithologique pour le puits BBK14(**Fig.II.14**) et BBK11(**Fig.II.13**).




Fig. II.13: Colonne lithologique faite par les descriptions des carottes et log de chantier pour le puits BBK-11 du champ Bir-Berkine.




Fig. II.14: Colonne lithologique faite par les descriptions des carottes et le log de chantier pour le puits BBK-14 du champ Bir-Berkine.

II.2.3.3. Analyse de la classification lithologique

Sachant que le Siegenien est subdivisé en plusieurs niveaux gréseux C, D, E, F et G. Mais ces niveaux peuvent être absents dans certains puits de la région Bir-Berkine.

BBK-11

D'après la colonne lithologique (**Fig. II.13**) on remarque que le niveau gréseux G est absent car il n'est pas atteint par le forage. Les facies présents au niveau du Siegenien dans ce puits sont les suivants ;

- **Argile.**
- **Grès fin.**
- **Grès moyen.**

Le toit du Siegenien est à 3516m de profondeur il est caractérisé par l'abondance d'Argile avec des intercalations des bancs gréseux d'épaisseur maximale de 3m jusqu'à atteindre le niveau C à la profondeur 3553m.

- **Le niveau C :** Le toit du niveau C est à la profondeur 3553m, il a une épaisseur est 46m, il est subdivisé en quatre couches gréseuses de grès moyen **C₁**, **C₂**, **C₃** et **C₄** (**Tableau.II.3**)

Niveau C	Toit (m)	Epaisseur (m)
C₁	3553	5
C₂	3561	7
C₃	3576	6
C₄	3596	3

Tableau.II.3: Les profondeurs et les épaisseurs des couches dans le niveau C de puits BBK11.

On note que les couches **C₁** et **C₂** sont intercalées par 1m d'argile dans chaque couche.

Entre les niveaux C et D il y a un banc argileux d'une épaisseur de 13m avec trois petites intercalations gréseuses.

- **Le niveau D :** Le toit du niveau D est à 3612m de profondeur et son mur se trouve à 3652m, il se subdivise en deux bancs gréseux **D₁** de grès fin et **D₂** d'un mélange entre le grès fin et le moyen. (**Tableau.II.4**). Le début du niveau **D** est caractérisé par une alternance d'argile et de grès moyen jusqu'à la profondeur 3618m où il commence le niveau **D₁**.

Niveau D	Toit (m)	Epaisseur (m)
D ₁	3618	11
D ₂	3650	2

Tableau.II.4 : Les profondeurs et les épaisseurs des couches dans le niveau D de puits BBK11.

Entre le niveau **D** et le niveau **E** il existe une alternance entre l'argile et le grès moyen avec une légère abondance de l'argile.

- **Le niveau E** : Il est subdivisé en quatre lits gréseux de grès moyen, **E₁**, **E₂**, **E₃** et **E₄** de petites épaisseurs maximum 5m (**Tableau.II.5**). Le toit du niveau **E** se situe à la profondeur 3677m, son épaisseur est 23m.

Niveau E	Toit (m)	Epaisseur (m)
E ₁	3678	5
E ₂	3686	2
E ₃	3691	2
E ₄	3697	3

Tableau.II.5: Les profondeurs et les épaisseurs des couches dans le niveau E de puits BBK11.

Il faut noter que le lit **E₁** est intercalé par 1m d'argile.

Entre le niveau **E** et le niveau **F** il y a que 1m d'argile.

- **Le niveau F** : Le toit du niveau **F** se trouve à la profondeur 3701m son toit se trouve à 3713m donc son épaisseur est de 12m. Il est subdivisé en deux bancs gréseux de grès moyen **F₁** et **F₂** (**Tableau.II.6**).

Niveau E	Toit (m)	Epaisseur (m)
F ₁	3701	5
F ₂	3711	2

Tableau.II.6: Les profondeurs et les épaisseurs des couches dans le niveau F de puits BBK11.

Le mur du Sieginien se situe à la profondeur 3713m.

BBK-14

A partir de la colonne lithologique (**Fig. II.14**) on remarque que tous les niveaux gréseux(C, D, E, F et G) sont présents. Tous le long du Siegenien on trouve les formations suivantes :

- **Argile.**
- **Grès fin.**
- **Grès moyen.**

Au toit du Siegenien qui est à la profondeur 3478m le grès fin est le plus abondant, cette abondance va se poursuivre même dans le niveau C qui est à 3512m de profondeur.

- **Le niveau C** : Le toit du niveau C se trouve à 3512m de profondeur son épaisseur est 32m. Il est subdivisé en trois bancs gréseux de grès fin avec des intercalations centimétriques d'argile **C₁, C₂ et C₃**(**Tableau.II.7**)

Niveau C	Toit (m)	Epaisseur (m)
C₁	3512	12
C₂	3526	6
C₃	3537	7

Tableau.II.7: Les profondeurs et les épaisseurs des couches dans le niveau C de puits BBK14.

Il existe entre le niveau C et le niveau D il existe une alternance entre des bancs gréseux de grès fin et des bancs argileux jusqu'à la profondeur 3562m où il se trouve le niveau D.

- **Le niveau D** : Il se situe à la profondeur 3562m il a une épaisseur de de 25m, il est subdivisé en deux niveaux gréseux **D₁** de grès moyen avec quatre intercalations centimétriques d'argile et **D₂** de grès moyen. (**Tableau.II.8**)

Niveau D	Toit (m)	Epaisseur (m)
D₁	3563	9
D₂	3575	6

Tableau.II.8: Les profondeurs et les épaisseurs des couches dans le niveau D de puits BBK14.

Le mur du niveau D est à 3587m de profondeur. Entre le niveau D et le niveau E existe une alternance entre des lits argileux et des lits gréseux de grès fin jusqu'à la profondeur 3600m où il se situe le niveau gréseux E.

- **Le niveau E** : Se situe à 3600m de profondeur son épaisseur est 24m il est subdivisé en trois niveaux gréseux de grès fin **E₁**, **E₂** et **E₃**. (**Tableau.II.9**).

Niveau E	Toit (m)	Epaisseur (m)
E₁	3600	4
E₂	3608	7
E₃	3621	2

Tableau.II.9: Les profondeurs et les épaisseurs des couches dans le niveau E de puits BBK14.

Le mur du niveau **E** se trouve à la profondeur 3624m. Le niveau **F** est séparé du niveau **E** par des bancs argileux et des bancs gréseux de grès fin avec une abondance d'argile jusqu'à atteindre la profondeur 3640m où il se trouve le niveau **F**.

- **Le niveau F** : Il se situe à 3640m de profondeur il a une épaisseur de 23m il est subdivisé en trois niveaux gréseux de grès fin **F₁**, **F₂** et **F₃** avec une épaisseur maximale de 4m. (**Tableau.II.10**).

Niveau F	Toit (m)	Epaisseur (m)
F₁	3643	2
F₂	3651	4
F₃	3656	2

Tableau.II.10: Les profondeurs et les épaisseurs des couches dans le niveau F de puits BBK14.

Le mur du niveau **F** est à 3663m de profondeur. Il existe entre le niveau **F** et le niveau **G** plusieurs bancs argileux et gréseux (parmi ces bancs gréseux il y a qu'un seul banc de grès moyen) avec une légère abondance d'argile jusqu'à la profondeur 3707m où il se situe le toit du niveau **G**.

- **Le niveau G** : Il est à 3707m de profondeur caractérisé par une alternance entre le grès moyen et l'argile jusqu'à la profondeur 3715m où il existe **G₁** qui est le banc gréseux principal du niveau **G**. **G₁** a une épaisseur de 6m de grès moyen. Le mur du niveau **G** se situe à la profondeur 3725m.

Le tableau suivant (**Tableau.II.11**) résume les profondeurs des toits et des murs du Siegenien et des différents niveaux gréseux et leurs épaisseurs dans chaque puits :

Puits	Formation	Toit(M)	Mur(M)	Epaisseur(M)
BBK 11	Siegenien	3516	3713	197
	C	3553	3599	46
	D	3612	3652	40
	E	3677	3700	23
	F	3701	3713	11
	G	-	-	-
BBK 14	Siegenien	3478	3729	251
	C	3512	3544	32
	D	3562	3587	15
	E	3600	3624	24
	F	3640	3663	23
	G	3707	3725	17

Tableau.II.11 : Les profondeurs des niveaux gréseux du Siegenien dans les puits d'étude.

II.2.3.4.Interprétation des résultats

On veut comparer la lithologie établie par les descriptions des carottes et master-log avec celle obtenue par les diagraphies dans les deux puits BBK-11 et BBK-14.

Il est clair que les bancs argileux sont plus radioactifs par rapport aux bancs gréseux (**Fig.II.15**et **Fig.II.16**).

En tenant compte maintenant de la taille des grains des grès on remarque que le Grès moyen est caractérisé par un sonique élevé, une densité et une résistivité faibles, dans l'intervalle [3673m-3676m] (**Fig.II.15**), et dans l'intervalle [3575m-3580m] (**Fig.II.16**), il est aussi caractérisé par des fortes valeurs de densité et des faibles valeurs de résistivité et de sonique dans l'intervalle [3697m-3701m] (**Fig.II.15**), et dans l'intervalle [3700m-3710m] (**Fig.II.16**).

Pour le grès fin il est caractérisé par des fortes valeurs de sonique et de densité au même temps de faible résistivité dans l'intervalle [3615m-3630m] (**Fig.II.15**), et dans l'intervalle [3570m-3575m]. (**Fig.II.16**).




Fig.II.15: Log composite et lithologie de puits BBK-11




Fig.II.16: Log composite et lithologie de puits BBK14.

Conclusion

Dans notre étude, on remarque que les diagraphies conventionnelles permettent d'établir une classification lithologique du réservoir.

La lithologie obtenue par les diagraphies conventionnelles est proche à celle établie par les descriptions des carottes et les master-log. Cependant les descriptions des carottes et les master-log sont utilisés pour affiner la lithologie.

Etant donné que les descriptions des carottes sont très coûteuses et parfois ne sont pas disponible, on propose d'utiliser autres méthodes de classification lithologiques à savoir les réseaux de neurones artificiels. Ceci fera l'objet du chapitre suivant.

Introduction

Dans ce chapitre, on va procéder à une classification lithologique à l'aide des réseaux de neurones artificiels, pour cela on va commencer par une présentation sur les notions théoriques de cette méthode, ensuite on va exposer les différentes étapes de son application. En fin, on discute la comparaison de classification faite en combinant les descriptions des carottes et le log de chantier avec celle obtenue par les réseaux de neurones artificiels.

Le réseau de neurones artificiels comprend plusieurs modèles, dans ce qui suit on va utiliser le réseau MLP (perceptron multicouches).

III.1. Théorie des réseaux de neurones artificiels

III.1.1. Historique

Les neurologues Warren McCulloch et Walter Pitts ont publié, en 1943, les premiers travaux sur les réseaux de neurones, avec un article fondateur : What the frog's eye tells to the frog's brain. Ils ont constitué ensuite un modèle simplifié de neurone biologique communément appelé neurone formel. Ils ont montré que des réseaux de neurones formels simples peuvent théoriquement réaliser des fonctions logiques, arithmétiques et symboliques complexes.

Les travaux de McCulloch et Pitts n'ont pas donné d'indication sur une méthode pour adapter les coefficients synaptiques. Cette question au cœur des réflexions sur l'apprentissage a connu un début de réponse grâce aux travaux du physiologiste canadien Donald Hebb sur l'apprentissage en 1949 décrits dans son ouvrage The Organization of Behaviour. Hebb a proposé une règle simple qui permet de modifier la valeur des coefficients synaptiques en fonction de l'activité des unités qu'ils relient. Cette règle aujourd'hui connue sous le nom de « règle de Hebb » est presque partout présente dans les modèles actuels, même les plus sophistiqués.

A partir de cet article, l'idée s'est semée au fil du temps dans les esprits, et elle a germé dans l'esprit de Franck Rosenblatt en 1957 avec le modèle du perceptron. C'est le premier système artificiel capable d'apprendre par expérience,

En 1969, un coup grave est porté à la communauté scientifique gravitant autour des réseaux de neurones : Marvin Lee Minsky et Seymour Papert ont publié un ouvrage mettant

en exergue quelques limitations théoriques du Perceptron, et plus généralement des classifieurs linéaires, notamment l'impossibilité de traiter des problèmes non linéaires ou de connexité. Ils ont étendu implicitement ces limitations à tous les modèles de réseaux de neurones artificiels. Cependant, les solides qualités de certains réseaux de neurones en matière adaptative (e.g. Adaline), leur permettant de modéliser de façon évolutive des phénomènes eux-mêmes évolutifs, les amèneront à être intégrés sous des formes plus ou moins explicites dans le corpus des systèmes adaptatifs; utilisés dans le domaine des télécommunications ou celui du contrôle de processus industriels.

En 1982, John Joseph Hopfield, physicien reconnu, a donné un nouveau souffle au neuronal en publiant un article introduisant un nouveau modèle de réseau de neurones (complètement récurrent). Cet article a eu du succès pour plusieurs raisons, dont la principale était de teinter la théorie des réseaux de neurones de la rigueur propre aux physiciens. Le neuronal est redevenu un sujet d'étude acceptable, bien que le modèle de Hopfield souffrit des principales limitations des modèles des années 1960, notamment l'impossibilité de traiter les problèmes non-linéaires.

La recherche a été relancée et l'industrie a repris quelque intérêt au neuronal. En 1984, c'est le système de rétro propagation du gradient de l'erreur qui est le sujet le plus débattu dans le domaine.

Une révolution survient alors dans le domaine des réseaux de neurones artificiels : une nouvelle génération de réseaux de neurones, capables de traiter avec succès des phénomènes non-linéaires : le perceptron multicouche ne possède pas les défauts mis en évidence par Marvin Minsky. Proposé pour la première fois par Werbos, le Perceptron Multicouche apparaît en 1986 introduit par Rumelhart, et, simultanément, sous une appellation voisine, chez Yann LeCun. Ces systèmes reposent sur la rétro-propagation du gradient de l'erreur dans des systèmes à plusieurs couches.

III.1.2. Le neurone biologique

Un neurone, ou cellule nerveuse, est une cellule excitable constituant l'unité fonctionnelle de base du système nerveux. Les neurones assurent la transmission d'un signal bioélectrique appelé influx nerveux. Le neurone est une cellule composée d'un corps cellulaire et d'un noyau. Le corps cellulaire se ramifie pour former ce que l'on nomme les dendrites. C'est par les dendrites que l'information est acheminée de l'extérieur vers le soma.

L'information traitée par le neurone chemine ensuite le long de l'axone pour être transmise aux autres neurones. La transmission entre deux neurones n'est pas directe. Il existe un espace intercellulaire de quelques dizaines d'Angström (10^{-9}m) entre l'axone du neurone afférent et les dendrites du neurone efférent. La jonction entre deux neurones est appelée la synapse (fig.III.1).




Fig.III.1 : Schéma simplifié de neurone biologique (Mihoubi, 2008)

Le neurone reçoit en continu des entrées, le corps cellulaire du neurone, centre de contrôle, concentre les informations reçues pour ensuite être traitée, la réponse unique à ces signaux est envoyée au travers de l'axone. L'axone transmet le message aux autres neurones. Le signal transmis peut avoir un effet excitateur ou inhibiteur. Le traitement simple réalisé par chaque neurone indique que l'information n'est pas stockée dans les neurones, mais est plutôt le résultat du comportement de toute la structure interconnectée, l'information est, principalement, dans l'architecture des connexions et dans la force de ces connexions.

L'ensemble des signaux d'entrée (excités et inhibés) sont combinés, si cette combinaison est suffisamment importante sur un laps de temps très court, la cellule délivre un signal électrique aux cellules voisines par l'intermédiaire de son axone.

Les impulsions délivrées (ou potentiel d'action) sont du type tout ou rien, cela signifie que les neurones se communiquent en langage binaire. Les réseaux neuronaux sont basés sur cette logique.

Les neurones ont deux propriétés physiologiques : l'excitabilité, c'est-à-dire la capacité de répondre aux stimulations et de convertir celles-ci en impulsions nerveuses, et la conductivité, c'est-à-dire la capacité de transmettre les impulsions.

III.1.3. Le neurone artificiel

Le réseau de neurones artificiels est basé sur un modèle simplifié du neurone, on l'appelle le neurone formel, ce modèle permet de réaliser certaines fonctions du cerveau. Parmi ces fonctions la mémorisation associative, l'apprentissage par expérience, le travail en parallèle. Cependant le neurone formel ne possède pas toutes les capacités des neurones biologiques (comme le partage de synapses, l'activation membranaire ou la structuration prénatale des neurones). Par conséquent les réseaux de neurones artificiels actuels sont loin d'intégrer toutes les fonctions du cerveau.

III.1.3.1. Le neurone formel

Un neurone formel est une représentation mathématique et informatique d'un neurone biologique. Le neurone formel possède généralement plusieurs entrées et une sortie qui correspondent respectivement aux dendrites et au cône d'émergence du neurone biologique (point de départ de l'axone). Les actions excitatrices et inhibitrices des synapses sont représentées, la plupart du temps, par des coefficients numériques (les poids synaptiques) associés aux entrées. Les valeurs numériques de ces coefficients sont ajustées dans une phase d'apprentissage. Dans sa version la plus simple, un neurone formel calcule la somme pondérée des entrées reçues, puis applique à cette valeur une fonction d'activation, généralement non linéaire. La valeur finale obtenue est la sortie du neurone.

Le neurone formel est l'unité élémentaire des réseaux de neurones artificiels dans lesquels il est associé à ses semblables pour calculer des fonctions arbitrairement complexes,

utilisées pour diverses applications en intelligence artificielle. Mathématiquement, le neurone formel est une fonction à plusieurs variables et à valeurs réelles.

Le neurone artificiel s'inspire largement du neurone naturel. Il est donc constitué d'entrées et d'une sortie qui peut être dédoublée. La valeur de sortie est en fonction de la somme pondérée des valeurs d'entrée qui est modulée par une fonction d'activation généralement sigmoïde. On obtient donc un intégrateur dont la sortie se déclenche si la somme des entrées est supérieure à un seuil.

III.1.3.2. Modélisation d'un neurone

Un neurone se compose généralement d'une entrée formée des variables sur lesquelles opère ce neurone et une sortie représentant la valeur de la fonction réalisée (fonction d'activation). La sortie du neurone est une fonction non linéaire d'une combinaison des entrées x_i (signaux d'entrées) pondérées par les paramètres W_i (poids synaptiques).

Le neurone est modélisé par deux opérateurs :

- Un opérateur de sommation qui élabore un potentiel égale à la somme pondérée des entrées de la cellule.
- Un opérateur calculant l'état de la sortie du neurone en fonction de son potentiel via une fonction d'activation (**fig.III.2**).




Fig.III.2 : Représentation graphique d'un neurone formel

Mathématiquement le neurone est une fonction algébrique non linéaire paramétrée, à valeurs bornées. La sortie du neurone est donnée par l'expression suivante :

$$Y_k = \varphi \left(\sum w_{kj} * x_j - \theta_k \right)$$

Où : $x_1, x_2, x_3, \dots, x_p$: entrées,

$w_{k1}, w_{k2}, w_{k3}, \dots, w_{kp}$: Poids synaptiques du neurone k ,

y_k : est la sortie d'activation,

θ_k : Le Seuil

$\varphi(\cdot)$: La fonction d'activation,

III.1.3.3 : Comparaison entre le neurone biologique et le neurone artificiel

Chaque neurone artificiel est un processeur élémentaire. Il reçoit un nombre variable d'entrées en provenance de neurones en amont ou des capteurs composant la machine dont il fait partie. A chacune de ces entrées est associé un poids représentatif de la force de la connexion. Chaque processeur élémentaire est doté d'une sortie unique, qui se ramifie ensuite pour alimenter un nombre variable de neurones en aval. A chaque connexion est associé un poids. Tout d'abord on additionne les entrées avec leurs poids respectifs, puis une fonction de transfert calcule la valeur de l'état du neurone (**Fig.III.3**).




Fig.III.3 : Comparaison entre le neurone biologique et le neurone artificiel
(Rayane, 2006)

III.1.3.4. Fonction de combinaison

Considérons un neurone quelconque.

Il reçoit des neurones en amont un certain nombre de valeurs via ses connexions synaptiques, et il produit une certaine valeur en utilisant une fonction de combinaison. Cette fonction peut donc être formalisée comme étant une fonction vecteur-à-scalaire, notamment :

Les réseaux de type MLP (Multi-Layer Perceptron) calculent une combinaison linéaire des entrées, c'est-à-dire que la fonction de combinaison renvoie le produit scalaire entre le vecteur des entrées et le vecteur des poids synaptiques.

III.1.3.5. La fonction d'activation

La fonction d'activation (ou fonction de seuillage, ou encore fonction de transfert) sert à introduire une non-linéarité dans le fonctionnement du neurone.

La fonction d'activation définit la valeur de la sortie d'un neurone en termes des niveaux d'activité de ses entrées.

III.1.3.6. Types de fonctions d'activations

La fonction d'activation considère différentes formes selon l'utilisation du réseau et selon sa nature, continue ou discrète. La plupart des neurones formels utilisés actuellement sont des variantes du neurone de McCulloch et Pitts dans lesquels la fonction de Heaviside est remplacée par une autre fonction d'activation. Les fonctions les plus utilisées sont :

- la fonction sigmoïde, c'est la fonction d'activation la plus répandue dans les réseaux de neurones artificiels ;
- la fonction tangente hyperbolique ;
- fonction à seuil (fonction échelon) ;
- fonctions linéaires par parties.

Ces choix sont motivés par des considérations théoriques et pratiques. Les propriétés de la fonction d'activation influent en effet sur celles du neurone formel et il est donc important de bien choisir celle-ci pour obtenir un modèle utile en pratique.

Quand les neurones sont combinés en un réseau de neurones formels, il est important par exemple que la fonction d'activation de certains d'entre eux ne soit pas un polynôme sous réserve de limiter la puissance de calcul du réseau obtenu. Un cas caricatural de puissance limitée correspond à l'utilisation d'une fonction d'activation linéaire, comme la fonction identité : dans une telle situation le calcul global réalisé par le réseau est lui aussi linéaire et il est donc parfaitement inutile d'utiliser plusieurs neurones, un seul donnant des résultats strictement équivalents.

Cependant, les fonctions de type sigmoïde sont généralement bornées. Dans certaines applications, il est important que les sorties du réseau de neurones ne soient pas limitées a priori : certains neurones du réseau doivent alors utiliser une fonction d'activation non bornée. On choisit généralement la fonction identité.

Il est aussi utile en pratique que la fonction d'activation présente une certaine forme de régularité. Pour calculer le gradient de l'erreur commise par un réseau de neurones, lors de son apprentissage, il faut que la fonction d'activation soit dérivable. Pour calculer la matrice de l'erreur, ce qui est utile pour certaines analyses d'erreur, il faut que la fonction d'activation soit dérivable deux fois. Comme elles comportent généralement des points singuliers, les fonctions linéaires par morceaux sont relativement peu utilisées en pratique.

La fonction sigmoïde

La fonction sigmoïde, définie par la formule (III.1) et représentée par le graphe possède les propriétés importantes évoquées précédemment Fig.III.4. (Elle n'est pas polynomiale et est indéfiniment continûment dérivable).
$$\varphi(\gamma) = \frac{1}{(1+e^{-\gamma})} \quad (\text{III.1})$$




Fig.III.4. Graphe de la fonction sigmoïde

En outre, une propriété simple permet d'accélérer le calcul de sa dérivée, ce qui réduit le temps calcul nécessaire à l'apprentissage d'un réseau de neurones. On a en effet

$$\frac{d\varphi(v)}{dv} = \varphi(v)(1 - \varphi(v))$$

On peut donc calculer la dérivée de cette fonction en un point de façon très efficace à partir de sa valeur en ce point. De plus, la fonction sigmoïde est à valeurs dans l'intervalle $[0,1]$, ce qui permet d'interpréter la sortie du neurone comme une probabilité.

La fonction tangente hyperbolique

La fonction tangente hyperbolique, définie par la formule (III.2)

$$\varphi(v) = \frac{e^v - e^{-v}}{e^v + e^{-v}} \quad (\text{III.2})$$

Elle est aussi très utilisée en pratique, car elle partage avec la fonction sigmoïde certaines caractéristiques pratiques :

- non polynomiale
- indéfiniment continûment dérivable
- calcul rapide de la dérivée par la formule

$$\frac{d\varphi(v)}{dv} = 1 - (\varphi(v))^2$$

La fonction à seuil

Certains auteurs utilisent les neurones à sortie binaire. La fonction d'activation est alors la fonction signe (-1 ou +1) ou la fonction échelon (0 ou +1), la fonction est représentée dans la figure (Fig.III.5).

$$\varphi(v_k) = \begin{cases} 1 & \text{si } v_k \geq 0 \\ 0 & \text{si } v_k < 0 \end{cases}$$




Fig.III.5 : Graphe de la fonction à seuil

La fonction linéaire par parties

Ses modèles peuvent être décrits par une partie linéaire à pente constante et une valeur de saturation (**Fig.III.6**).

$$\varphi(v) = \begin{cases} 1 & \text{si } v \geq \alpha \\ v & \text{si } \alpha > v > \beta \\ 0 & \text{si } v \leq \beta \end{cases}$$




Fig.III.6: Graphe de la fonction linéaire par partie

III.4. Le réseau de neurones artificiels

Les réseaux de neurones, en tant que système capable d'apprendre, mettent en œuvre le principe de l'induction, c'est-à-dire l'apprentissage par l'expérience. Par confrontation avec des situations ponctuelles, ils infèrent un système de décision intégré dont le caractère générique est en fonction du nombre de cas d'apprentissages rencontrés et de leur complexité par rapport à la complexité du problème à résoudre. Par opposition, les systèmes symboliques capables d'apprentissage, s'ils implémentent également l'induction, le font sur base de la logique algorithmique, par complexification d'un ensemble de règles déductives.

Grâce à leur capacité de classification et de généralisation, les réseaux de neurones sont généralement utilisés dans des problèmes de nature statistique, tels que la classification automatique de codes postaux ou la prise de décision concernant un achat boursier en fonction de l'évolution des cours. Autre exemple, une banque peut créer un jeu de données sur les clients qui ont effectué un emprunt constitué : de leur revenu, de leur âge, du nombre d'enfants à charge... et s'il s'agit d'un bon client. Si ce jeu de données est suffisamment grand, il peut être utilisé pour l'entraînement d'un réseau de neurones. La banque pourra alors présenter les caractéristiques d'un potentiel nouveau client, et le réseau répondra s'il sera bon client ou non, en généralisant à partir des cas qu'il connaît.

Si le réseau de neurones fonctionne avec des nombres réels, la réponse traduit une probabilité de certitude. Par exemple : 1 pour « sûr qu'il sera un bon client », -1 pour « sûr qu'il sera mauvais client », 0 pour « aucune idée », 0,9 pour « presque sûr qu'il sera bon client ».

Le réseau de neurones ne fournit pas toujours de règle exploitable par un humain. Le réseau reste souvent une boîte noire qui fournit une réponse quand on lui présente une donnée, mais le réseau ne fournit pas de justification facile à interpréter.

III.1.4.1. Structure du réseau de neurones artificiels

Un réseau de neurones est en général composé d'une succession de couches dont chacune prend ses entrées sur les sorties de la précédente. Chaque couche (i) est composée de N_i neurones, prenant leurs entrées sur les N_{i-1} neurones de la couche précédente. À chaque synapse est associé un poids synaptique, de sorte que les N_{i-1} sont multipliés par ce poids, puis additionnés par les neurones de niveau i, ce qui est équivalent à multiplier le vecteur d'entrée par une matrice de transformation. Mettre l'une derrière l'autre les différentes couches d'un réseau de neurones reviendrait à mettre en cascade plusieurs matrices de transformation et pourrait se ramener à une seule matrice, produit des autres, s'il n'y avait à chaque couche, la fonction de sortie qui introduit une non linéarité à chaque étape. Ceci montre l'importance du choix judicieux d'une bonne fonction de sortie : un réseau de neurones dont les sorties seraient linéaires n'aurait aucun intérêt (Fig.III.7).




Fig.III.7 : Structure de réseau de neurones artificiels

L'ensemble des poids des liaisons synaptiques détermine le fonctionnement du réseau de neurones. Les motifs sont présentés à un sous-ensemble du réseau de neurones : la couche d'entrée. Lorsqu'on applique un motif à un réseau, celui-ci cherche à atteindre un état stable. Lorsqu'il est atteint, les valeurs d'activation des neurones de sortie constituent le résultat. Les neurones qui ne font ni partie de la couche d'entrée ni de la couche de sortie sont dits neurones cachés.

Les types de réseau de neurones diffèrent par plusieurs paramètres :

- la topologie des connexions entre les neurones ;
- la fonction d'agrégation utilisée (somme pondérée, distance pseudo-euclidienne...)
- la fonction de seuillage utilisée (sigmoïde, échelon, fonction linéaire, fonction de Gauss, ...)
- l'algorithme d'apprentissage (rétro-propagation du gradient, cascade corrélation)

III.1.4.2. La topologie de réseau

Architecture est le terme le plus général pour désigner la façon dont sont disposés et connectés les différents neurones qui composent un réseau. On parle également de topologie (terme emprunté de la théorie des graphes). Au niveau des neurones on parle plutôt de voisinage. Ce terme fait allusion à la façon dont un neurone est connecté à d'autres neurones. Il est donc en rapport direct avec l'architecture du réseau.

III.1.4.3. Apprentissage de réseau de neurone

Base théorique :

La notion d'apprentissage, bien que connue déjà depuis Sumer, n'est pas modélisable dans le cadre de la logique déductive : celle-ci en effet procède à partir de connaissances déjà établies dont on tire des connaissances dérivées. Or il s'agit ici de la démarche inverse : par observations limitées, tirer des généralisations plausibles : c'est un procédé par induction.

La notion d'apprentissage recouvre deux réalités souvent traitées de façon successive :

- mémorisation : le fait d'assimiler sous une forme dense des exemples éventuellement nombreux,
- généralisation : le fait d'être capable, grâce aux exemples appris, de traiter des exemples distincts, encore non rencontrés, mais similaires.

Dans le cas des systèmes d'apprentissage statistique, utilisés pour optimiser les modèles statistiques classiques, réseaux de neurones, c'est la généralisation qui est l'objet de toute l'attention.

Cette notion de généralisation est traitée de façon plus ou moins complète par plusieurs approches théoriques.

- possibles ; on retrouve alors la problématique de l'augmentation progressive de la capacité d'apprentissage, concept fondamental au cœur de la théorie de la régularisation statistique.

III.1.4.4.Type d'apprentissage

Il y a deux modes, supervisé et non supervisé

Apprentissage supervisé

L'apprentissage supervisé est une technique d'apprentissage automatique où l'on cherche à produire automatiquement des règles à partir d'une base de données d'apprentissage contenant des exemples en général des cas déjà traités et validés.

Un apprentissage est dit supervisé lorsque l'on force le réseau à converger vers un état final précis, en même temps qu'on lui présente un motif (**Fig.III.8**).




Fig.III.8 : Schéma de fonctionnement de l'apprentissage supervisé (Aliouane, 2013)

Apprentissage non supervisé

Dans le domaine informatique, l'apprentissage non supervisé (parfois dénommé clustering) est une méthode d'apprentissage automatique. Il s'agit pour un logiciel de diviser un groupe hétérogène de données, en sous-groupes de manière à ce que les données considérées comme les plus similaires soient associées au sein d'un groupe homogène et qu'au

contraire les données considérées comme différentes se retrouvent dans d'autres groupes distincts; l'objectif étant de permettre une extraction de connaissance organisée à partir de ces données.

A l'inverse, lors d'un apprentissage non-supervisé, le réseau est laissé libre de converger vers n'importe quel état final lorsqu'on lui présente un motif. Cette méthode se distingue de l'apprentissage supervisé par le fait qu'il n'y a pas de sortie a priori (**Fig.III.9**).




Fig.III.9 : Principe de l'apprentissage non-supervisé

III.1.4.5. Rétro-propagation

La rétro-propagation consiste à rétro-propager l'erreur commise par un neurone à ses synapses et aux neurones qui y sont reliés. Pour les réseaux de neurones, on utilise habituellement la rétro-propagation du gradient de l'erreur, qui consiste à corriger les erreurs selon l'importance des éléments qui ont justement participé à la réalisation de ces erreurs : les poids synaptiques qui contribuent à engendrer une erreur importante se verront modifiés de manière plus significative que les poids qui ont engendré une erreur marginale. Cette technique consiste à corriger les erreurs selon l'importance des éléments qui ont justement participé à la réalisation de ces erreurs.

III.1.5. Différents types des réseaux de neurones artificiels

Par définition, un réseau de neurones est constitué d'un assemblage d'éléments, d'unités ou de nœuds processeurs pour lequel un sous-groupe effectue un traitement indépendant et transmet le résultat à un deuxième sous-groupe et ainsi de suite (cas d'un réseau à couches multiples). Les capacités de traitement du réseau dépendent des poids W_i auxquels sont affectées des valeurs produisant un filtre affectant la capacité d'apprentissage du réseau.

Les réseaux de neurones artificiels sont caractérisés par plusieurs paramètres à savoir le nombre de couches, de nombre de neurones dans chaque couche, la fonction d'activation,

l'algorithme d'apprentissage, le type d'apprentissage, et la topologie...etc. en variant ces paramètres les réseaux se différencient, pour cela il existe plusieurs modèles.

III.1.5.1. Le perceptron

Le perceptron est un réseau de neurones très simple. Il est linéaire et monocouche, acceptant uniquement des valeurs d'entrées et de sorties binaires (0 ou 1), (**Fig.III.10**). Il est inventé par le psychologue Frank Rosenblatt et inspiré du système visuel. Le procédé d'apprentissage est supervisé et le réseau est capable de résoudre des opérations logiques simples comme les opérations "ET logique" ou "OU logique". Ces réseaux sont efficaces pourvu que les données traitées soient des vecteurs orthogonaux ou linéairement indépendants. Ce que l'on entend par méthode d'apprentissage supervisé est que les sorties du réseau sont comparées avec des sorties cibles. Ce type de réseau est aussi utilisé pour la classification. Les opérations logiques plus compliquées comme un problème "XOR" (OU Exclusif) ne peuvent pas être résolues par un perceptron. L'algorithme d'apprentissage est la règle d'apprentissage de Hebb qui affecte le changement des poids en multipliant l'entrée d'un neurone par sa sortie et le taux d'apprentissage du réseau.




Fig.III.10: L'architecture de perceptron

Un réseau "feedforward" à une seule couche (perceptron) peut uniquement représenter des fonctions linéairement séparables. C'est-à-dire celles pour lesquelles la surface de décision séparant les cas positifs des cas négatifs est un (hyper-)plan.

La sortie du perceptron dépend de la somme des composantes x_i du vecteur d'entrée, pondérées par des poids réels W_i . Conformément aux notations utilisées dans ce travail, nous appellerons un potentiel, la somme pondérée notée par 'net', suivante.

$$\text{net}_k = \sum_{i=0}^n w_{ki} x_i$$

La sortie du réseau sera désignée par 'O'. Elle sera de la forme suivante :

$$O_k = \begin{cases} 1 & \text{si } \text{net}_k \geq \theta_k \\ 0 & \text{si } \text{net}_k < \theta_k \end{cases}$$

w_{ji} : Coefficients synaptiques de j vers i, x_i : sortie(ou état) de j, et θ_k : seuil

III.1.5.2. Perceptron multicouches

Les réseaux multicouches sont actuellement les plus employés. Plusieurs couches de traitement leur permettent de réaliser des associations non linéaires entre l'entrée et la sortie.

Le perceptron à niveaux multiples (perceptron multi couche 'PMC' ou 'MLP' en anglais) est une extension du perceptron qui a une ou plusieurs sous-couches cachées entre ses couches d'entrée et de sortie (Fig.III.11). A cause de sa structure étendue, un perceptron à niveaux multiples est capable de résoudre toute opération logique incluant le problème XOR. La méthode d'apprentissage est supervisée. L'algorithme d'apprentissage est la règle d'apprentissage delta (Δ) qui affecte le changement des poids en multipliant l'entrée d'un neurone par la différence entre la sortie réelle et la sortie désirée et le taux d'apprentissage du réseau.




Fig.III.11 : Architecture du perceptron Multicouche

Le perceptron a les caractéristiques suivantes :

- Le perceptron multicouche est une suite de couches contenant chacune des neurones formels.
- Les entrées de la couche n sont les sorties de la couche n-1.
- Les neurones de la première couche sont reliés à l'extérieur et reçoivent tous la même entrée (vectorielle).
- La sortie du perceptron multicouches est un vecteur constitué des sorties des neurones de la dernière couche.

III.1.5.3. le perceptron multicouche par l'algorithme de rétro-propagation

Ce type de réseau est l'un des plus puissants réseaux de neurones (**Fig.III.12**). Il a la même structure que le perceptron à niveaux multiples et utilise l'algorithme de rétro-propagation (back propagation). La méthode d'apprentissage est sous contrôle supervisé. On utilise fréquemment des neurones avec une caractéristique entrée-sortie de type sigmoïde.

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




Fig.III.12: Architecture d'un modèle de Rétro-propagation

III.2. Classification lithologique par les réseaux de neurone artificiels

Dans ce qui suit, qu'on va utiliser le perceptron multicouches pour faire une classification lithologique.

III.2.1. Structure de réseau perceptron multicouche

Un réseau de neurones est en général composé d'une succession de couches dont chacune prend ses entrées sur les sorties de la précédente. Dans notre cas, on a utilisé un réseau qui se compose de trois couches, une couche d'entrée qui comprend huit neurones, une couche cachée qui comprend aussi huit neurones, et une couche de sortie qui comprend uniquement un seul neurone. La fonction d'activation des neurones utilisée par le réseau est la fonction sigmoïde (**Fig.III.13**) et (**Tableau.III.1**).

Nombre de neurones dans la couche d'entrée	Nombre de neurones dans la couche de sortie	Nombre de couches cachées	Nombre de neurones dans la couche cachée	La fonction de transfert (activation)
8	1	1	8	Fonction sigmoïde

Tableau.III.1 : caractéristiques de réseau MLP utilisé

Le choix de nombre de neurones dans la couche d'entrée est fait selon deux critères, le premier, c'est à la base des diagraphies qui participent le plus dans la classification de la lithologie, le deuxième, c'est la disponibilité de ces diagraphies dans les puits d'étude. Pour la couche de sortie, on a pris un seul neurone, car chaque profondeur représente une seule classe lithologique. Comme le réseau à une seule couche cachée donne des bons résultats, pour cet effet, notre réseau comprend une seule couche cachée.

Quant au nombre de neurones dans la couche cachée, il est déterminé par une série de tests, c'est-à-dire, on varie le nombre de neurones dans cette couche jusqu'à ce que l'on obtient une erreur minimale entre la sortie calculée et la sortie désirée




Fig.III.13 : Structure de réseau MLP pour la classification lithologique

III.2.2. Apprentissage de réseau MLP

III.2.2.1. Algorithme d'apprentissage OWO-HWO

Plusieurs auteurs ont utilisés le réseau MLP avec l'algorithme de rétro-propagation pour la classification lithologique (Aliouane, 2013 ; Chikhi et Batouche, 2005), où les résultats n'étaient satisfaisants. Pour cela, on se propose de tester le réseau MLP avec un autre algorithme d'apprentissage. IL s'agit d'algorithme d'optimisation local OWO-HWO (Output Weight Optimization-Hidden Weight Optimization). Cet algorithme a été proposé par Changhua et Michael en 2002 dans le domaine du Génie Electrique.

La large majorité des réseaux de neurones possède un algorithme « d'entraînement » qui consiste à modifier les poids synaptiques en fonction d'un jeu de données présentées en entrée du réseau. Le but de cet entraînement est de permettre au réseau de neurones « d'apprendre » à partir des exemples. Si l'entraînement est correctement réalisé, le réseau est capable de fournir des réponses en sortie très proches des valeurs d'origines du jeu de données d'entraînement. Mais tout l'intérêt des réseaux de neurones réside dans leur capacité à généraliser à partir du jeu de test.

Comme la couche de sortie a une fonction d'activation non linéaire, l'algorithme d'optimisation des poids de sorties OWO (output weight optimization) peut être réalisé par la résolution des équations non linéaires.

Dans l'algorithme d'optimisation des poids cachés HWO (Hidden Weight Optimization), les poids sont modifiés en minimisant la fonction d'erreur pour chaque couche cachée. Ces fonctions d'erreurs utilisent la différence entre les sorties désirées et les sorties calculées. Pour les j couches cachées et les p modèles, la sortie désirée ($net_{pd}(j)$) est définie comme suivant :

$$net_{pd}(j) \cong net_p(j) + Z * \delta_p(j)$$

Z est le le taux d'apprentissage et δ_p est la fonction delta, elle est définie comme suit

$$\delta_p = f'(net_p(j)) \sum_n \delta_{po}(n) w_{oh}(n, j)$$

Où « n » est l'indice les neurones de la couche d'entrée qui sont connectés à « j » couche cachée et $\delta_{po}(n)$ est la fonction delta de la couche de sortie

$$\delta_{po}(n) = t_p(n) - y_p(n)$$

Les poids cachés sont corrigés comme suit :

$$w(j, i) \leftarrow w(j, i) + Z * e(j, i)$$

Où $e(j, i)$ est le cache qu'on a corrigé..?

$$net_{pd}(j) \cong \sum_{i=1}^{N+1} [w(j, i) + Z * e(j, i)] * X_p(i)$$

On obtient:

$$\delta_p(j) \cong \sum_{i=1}^{N+1} e(j, i) * X_p(i)$$

En utilisant la fonction précédente, la fonction de l'erreur pour la couche cachée « j » est écrite comme suit :

$$E_{\delta}(j) = \sum_p^N [\delta_p(j) - \sum_i e(j, i) * X_p(i)]^2$$

III.2.2.2. Application de l'apprentissage supervisé

Cet étape sera faite sur le puits BBK-14 au niveau de réservoir Siegenien en procédant comme suit, on introduit dans notre réseau comme données d'entrée les huit diagraphies conventionnelles qui caractérisent la lithologie avec l'ordre suivant : gamma ray (GR), sonique (DT), densité neutron (ZDEN), porosité neutron (CN), résistivité (M2R9), photoélectrique (PE), potassium (K), et uranium (U), et comme donnée de sortie désirée du réseau la lithologie obtenue à partir les descriptions des carottes et le log de chantier(**Fig.III.14**).

Avant l'apprentissage le réseau a des poids synaptique aléatoires, et après qu'on a lancé l'apprentissage, le réseau calcule avec les poids synaptique initiaux pour chaque vecteur des diagraphies d'entrées une sortie calculée qui représente la lithologie, le réseau compare entre les deux sorties désirée et calculée, tant qu'il y a une différence entre ces deux dernières, le réseau corrige les poids synaptiques initiaux pour la couche de sortie et intermédiaire ou cachée , le réseau refait la même itération jusqu'à ce que on aura une erreur minimale entre les deux sorties désirée et calculée. Quand l'erreur entre la sortie calculée et celle désirée est minimisée, la phase d'apprentissage s'arrête.




Fig.III.14 : Schéma récapitulatif de l'apprentissage de réseau MLP

Chapitre III: Classification lithologique par les Réseaux de neurones artificiels de type MLP

L'apprentissage de notre réseau est fait à l'aide du logiciel NuMap version 7.1 (Fig.III.15), ce logiciel est conçu au laboratoire de traitement d'image des réseaux de neurones dans l'université de Texas.




Fig.III.15 : Interface du logiciel NuMap

Le réseau donne à la fin de l'apprentissage une sortie calculée qui est la plus proche de la sortie désirée, c'est-à-dire le réseau détermine la lithologie la plus proche, ou bien qui converge le plus vers celle qu'on lui a présenté comme donnée de sortie (Fig.III.16).

Chapitre III: Classification lithologique par les Réseaux de neurones artificiels de type MLP




Fig.III.16 : les logs et la lithologie d'apprentissage avec la lithologie MLP de puits BBK-14

On teste maintenant la fiabilité de l'apprentissage, en calculant l'erreur quadratique moyenne qu'on va tracer dans un graphe (**Fig.III.17**).




Fig.III.17 : Erreur quadratique moyenne en fonction de nombre d'itération pendant la phase d'apprentissage

Discussion de niveau d'apprentissage

D'après le graphe de l'erreur quadratique moyenne en fonction des nombres d'itérations (**Fig.III.17**) on remarque que cette erreur diminue avec l'augmentation du nombre d'itération jusqu'à atteindre l'itération numéro **134** où l'erreur quadratique moyenne est égale à **0.27**, après cette itération on remarque que l'erreur quadratique moyenne est constante. Par conséquent on dit que la fonction d'erreur de réseau converge.

D'autre part on remarque que l'apprentissage de notre réseau a donné une classification lithologique presque identique à celle établie par les carottes et le master-log. Donc notre réseau a bien appris, et il est prêt à généraliser ou bien à propager dans le puits BBK-11.

III.2.3. Généralisation ou propagation

Après avoir fini la phase d'apprentissage de notre réseau dans le puits BBK-14, on va procéder à la propagation de l'information sur le puits BBK-11, toujours au niveau de réservoir Siegenien. Dans cette étape, on procède comme suit :

On introduit dans le réseau MLP comme données d'entrées les huit diagraphies conventionnelles de BBK-11 (les mêmes diagraphies qu'on a utilisées dans la phase d'apprentissage dans BBK-14 et même ordre aussi), ensuite on lance le réseau.

Chapitre III: Classification lithologique par les Réseaux de neurones artificiels de type MLP

L'output de ce réseau est la colonne lithologique au niveau du Siegenien de puits BBK11 (Fig.III.18).




Fig.III.18 : représentation des logs d'entrées et la lithologie obtenue par MLP dans le puits BBK-11

III.2.3.1. Comparaison de la lithologie carotte et log de chantier avec celle de MLP

On remarque que les classes lithologique obtenue par le réseau MLP sont les mêmes aux celles établies par les carottes et master-log (argile, grès fin, grès moyen), le réseau MLP n'a pas donné une nouvelle classe de même il n'a pas supprimé un type de classe (**Fig.III.19**).




Fig.III.19 : comparaison entre la lithologie carotte et celle de MLP

La lithologie obtenue par le réseau MLP dans la plupart des profondeurs n'est pas complètement identique à celle qu'on a faite à partir des descriptions des carottes et log de chantier, le réseau MLP a fait apparaître des intercalations que l'on ne trouve pas dans la lithologie carotte, de même ce réseau a modifié les épaisseurs des bancs, comme il montre la figure ci-dessous (**Fig.III.19**). La lithologie obtenue par les deux méthodes se diffère dans l'intervalle [3519m-3521m] où le MLP a donné de grès fin et la lithologie des carottes est une argile et dans l'intervalle [3541m-3543m] la lithologie donnée par le MLP est un grès moyen, par contre celle établie par les carottes est une argile. On remarque aussi une différence de lithologie dans le banc [3643m-3675m] où la lithologie de l'MLP est un grès moyen et la lithologie carotte est une argile, et dans l'intervalle [3692m-3695m] dans cette intervalle la lithologie carotte est une argile par contre celle de l'MLP est un grès fin.

Cependant il existe plusieurs bancs où la lithologie obtenue par les deux méthodes est identique, cette ressemblance est claire dans les intervalles [3520m-3523m] où la formation est argileuse, [3553m-3555m] la lithologie dans cette intervalle est un grès moyen, [3619m-3624m] où il s'agit d'un grès fin. Cette concordance est remarquée aussi dans les intervalles [3630m-3636m] et [3642m-3644m] dans ces deux intervalles la lithologie s'agit d'une argile.

Dans l'ensemble la lithologie, obtenue par le MLP se concorde avec celle établie par les carottes et le master-log.

Introduction

Dans ce chapitre nous développons le principe des cartes auto-organisatrices de Kohonen, leurs fondements théoriques et leur méthodologie d'application. Notre application a comme objet une classification lithologique en utilisant les diagraphies comme données d'entrée et les cartes de Kohonen comme outil de classification.

IV.1. Modèle de Kohonen

IV.1.1.L'origine

Les neurones sont modélisés de la façon la plus simple possible, on recherche ici un modèle de neurone proche de la réalité. Ces réseaux sont inspirés des observations biologiques du fonctionnement des systèmes nerveux de perception des mammifères.

En effet, il existe des zones du cerveau (dans le cortex visuel par exemple) qui présentent la même topologie que les capteurs sensoriels, c'est à dire deux zones proches dans le cortex visuel correspondent à deux zones proches dans la rétine. Ces propriétés se retrouvent avec le bulbe olfactif, ou l'appareil auditif. Il est intéressant de souligner que ces dispositions au sein du cerveau ne sont pas génétiques, mais sont dues à un apprentissage.

A la suite de ces observations, Kohonen proposa un modèle de carte topologique auto-adaptative. Seules les entrées modifient le processus, l'apprentissage est donc non-supervisé. Il s'agit de reproduire le principe neuronal du cerveau des vertébrés : des stimuli de même nature excitent une région du cerveau bien particulière. Les neurones sont organisés dans le cortex de façon à interpréter tous les types de stimuli imaginables. De la même manière, la carte auto adaptative se déploie de façon à représenter un ensemble des données, et chaque neurone se spécialise pour représenter un groupe bien particulier des données selon les points communs qui les rassemblent. Elle permet une visualisation en dimension multiple de données croisées.

Techniquement, la carte réalise une quantification vectorielle de l'espace de données. Cela signifie discrétiser l'espace ; c'est-à-dire le diviser en zones, et assigner à chaque zone un point significatif dit vecteur référent.




Fig.IV.1 : Architecture des cartes auto-organisatrices.

L'espace d'entrée V est divisé en plusieurs zones. W_r représente un vecteur référent associé à une petite zone de l'espace V_M^r et $r(2,3)$ représente son neurone associé dans la grille. Chaque zone peut être adressée facilement par les index des neurones dans la grille.

IV.1. 1.2. Leur utilisation

Les cartes de Kohonen peuvent être utilisées dans le cadre de la projection de données multi-variées, d'approximation de densité ou de classification. Elles ont été utilisées avec succès en reconnaissance de la parole, classification et traitement d'images, robotique, contrôle de processus, l'aide à la décision et l'optimisation. Les paramètres à définir dans ce cas sont :

- la dimension des tableaux de cellules.
- le nombre de cellules dans chaque dimension.
- la forme du voisinage.
- l'échéancier de réduction de la taille du voisinage.
- le coefficient d'apprentissage.

IV.1.2. Architecture du réseau

D'un point de vue architectural, les « cartes auto-organisatrices de Kohonen » sont constituées d'une grille (le plus souvent uni- ou bidimensionnelle). Dans chaque nœud de la grille se trouve un « neurone ». Chaque neurone est lié à un vecteur référent, responsable d'une zone dans l'espace des données (appelé encore espace d'entrée).

Dans une carte auto-organisatrice, les vecteurs référents fournissent une représentation discrète de l'espace d'entrée. Ils sont positionnés de telle façon qu'ils conservent la forme topologique de l'espace d'entrée. En gardant les relations de voisinage dans la grille, ils permettent une indexation facile (via les coordonnées dans la grille).

Ceci s'avère utile dans divers domaines, comme la classification de textures, l'interpolation entre des données, la visualisation des données multidimensionnelles.

Soit A la grille neuronale rectangulaire d'une carte auto-organisatrice. Une carte de neurones assigne à chaque vecteur d'entrée $\vec{v} \in V$ un neurone $r \in A$ désigné par son vecteur de position $\vec{r}$, tel que le vecteur référent w_r est le plus proche dev.

Mathématiquement, on exprime cette association par une fonction:

$$\phi_w: V \rightarrow A$$

$$r = \phi_w(v) = \arg \min_{r \in A} \|v - w_r\|$$

Cette fonction permet de définir les applications de la carte.

- quantificateur vectoriel: on approxime chaque point dans l'espace d'entrée par le vecteur référent le plus proche par

$$w_r = \phi_w^{-1}(\phi_w(v))$$

- classificateur en utilisant la fonction $r = \phi_w(v)$

On assigne à chaque neurone de la grille une étiquette correspondante à une classe; tous les points de l'espace d'entrée qui se projettent sur un même neurone appartiennent à la même classe. Une même classe peut être associée à plusieurs neurones.

IV.1.3. Algorithme d'apprentissage

IV.1.3.1.Principe

Après une initialisation aléatoire des valeurs de chaque neurone, on soumet une à une les données à la carte auto adaptative. Selon les valeurs des neurones, il y en a un qui va répondre le mieux au stimulus. Celui dont la valeur sera la plus proche de la donnée présentée. Alors ce neurone sera gratifié d'un changement de valeur pour qu'il réponde encore mieux à un autre stimulus de même nature que le précédent. Par là même, on gratifie un peu aussi les neurones voisins du gagnant avec un facteur multiplicatif du gain inférieur à un. Ainsi, c'est toute la région de la carte autour du neurone gagnant qui se spécialise. Enfin d'algorithme, lorsque les neurones ne bougent plus, ou bougent très peu, à chaque itération, la carte auto organisatrice recouvre toute la topologie des données.




Fig.IV.2 : Représentation de l'algorithme d'auto-organisation pour le modèle de Kohonen.

Chaque neurone a un vecteur référent qui le représente dans l'espace d'entrée. Un vecteur d'entrée v est présenté. v sélectionne le neurone vainqueur s , le plus proche dans l'espace d'entrée. Le vecteur référent du vainqueur w_s est rapproché de v . Les vecteurs référents des autres neurones sont aussi déplacés vers v , mais avec une amplitude moins importante.

IV.1.3.2. Formalisation mathématique

La cartographie de l'espace d'entrée est réalisée en adaptant les vecteurs référents w_r . L'adaptation est faite par un algorithme d'apprentissage dont la puissance réside dans la compétition entre neurones et dans l'importance donnée à la notion de voisinage.

Une séquence aléatoire de vecteurs d'entrée est présentée pendant l'apprentissage. Avec chaque vecteur, un nouveau cycle d'adaptation est démarré. Pour chaque vecteur v dans la

séquence, on détermine le neurone vainqueur, c'est-à-dire le neurone dont le vecteur référent approche v le mieux possible :

$$S = \underset{r \in A}{\operatorname{arg\,min}} ||v - w_r||$$

Le neurone vainqueur s et ses voisins (définis par une fonction d'appartenance au voisinage) déplacent leurs vecteurs référents vers le vecteur d'entrée.

$$w_r^{t+1} = w_r^t + \Delta w_r^t$$

avec

$$w_r^t = \varepsilon \cdot h \cdot (v - w_r^t)$$

où $\varepsilon = \varepsilon(t)$: représente le coefficient d'apprentissage et $h = h(r, s, t)$: la fonction qui définit l'appartenance au voisinage.

Le coefficient d'apprentissage définit l'amplitude du déplacement global de la carte.

IV.1.3.3. la notion de voisinage

Tout comme dans le cortex, les neurones sont reliés les uns aux autres, c'est la topologie de la carte. La forme de la carte définit les voisinages des neurones et donc les liaisons entre neurones. La fonction de voisinage décrit comment les neurones dans la proximité des vainqueurs sont entraînés dans le mouvement de correction. On utilise en général :

$$h(r, s, t) = \exp\left(-\frac{\|r-s\|}{2\sigma_{(t)}^2}\right)$$

Où σ s'appelle coefficient de voisinage, son rôle est de déterminer un rayon de voisinage autour du neurone vainqueur.

La fonction de voisinage h force les neurones qui se trouvent dans le voisinage de s à rapprocher leurs vecteurs référents du vecteur d'entrée v . Moins un neurone est proche du vainqueur dans la grille, moins son déplacement est important.

La correction de vecteurs référents est pondérée par les distances dans la grille. Cela fait apparaître, dans l'espace d'entrée, les relations d'ordre dans la grille. Pendant l'apprentissage la carte décrite par les vecteurs référents du réseau évolue d'un état aléatoire vers un état de

stabilité dans lequel elle décrit la topologie de l'espace d'entrée tout en respectant les relations d'ordre dans la grille.

IV.1.4. Procédé de calcul des SOM

L'application des cartes auto-organisatrices de Kohonen (SOM) pour une classification lithologie peut être résumée sous forme d'un algorithme descriptif organisé par un organigramme suivant :




Fig.IV.3: Organigramme du programme SOM appliqué

IV.1.4.1. Initialisation De Données

Une fois que le groupe des diagraphies à utiliser dans la classification est sélectionné, chaque diagraphie doit être normalisée ($RMS=1$). Ceci empêche n'importe quelle diagraphie de maîtriser le reste du groupe pendant les étapes de la classification. Si, cependant, nous considérons quelques diagraphies plus diagnostiques que les autres, nous pouvons ajuster leurs amplitudes RMS qui rendront la distance de cette diagraphie particulière plus importante que le reste, par conséquent la minimisation sera affectée par cette diagraphie.

IV.1.4.2. Initialisation des poids neuraux

Chaque neurone aura un poids pour chaque diagraphie. Au départ nous affectons de petits nombres aléatoires à chacun des poids et nous initialisons également le rayon de voisinage. Ce rayon sera grand au début pour couvrir un plus grand nombre de nœuds adjacents. Avec l'augmentation des itérations, ce rayon peut être systématiquement réduit à une distance égale à l'unité. Nous initialisons également un ensemble de compteurs qui indiqueront le nombre de fois consécutives qu'un neurone est déclaré gagnant. Dans l'algorithme de "conscience ", si un neurone gagne excessivement il permet à d'autres neurones de gagner.

IV.1.4.3. Calcul de la distance euclidienne ou du produit scalaire et détermination du neurone gagnant

La distance euclidienne ou le produit scalaire sont calculés entre l'ensemble des données d'entrée (vecteur) et chacun des nœuds neuraux. Le nœud muni de la distance euclidienne minimale ou du produit scalaire maximum est déclaré gagnant. Ceci détermine le nœud avec les poids les plus semblables aux valeurs d'entrée. Avant que le nœud gagnant ne soit déterminé, son nombre de "victoires" consécutives est vérifié. Si le nœud dépasse une limite définie, alors les résultats sont réduits proportionnellement pour permettre à un autre nœud de "gagner". Les compteurs des nœuds perdants sont remis à zéro et le compteur du nœud gagnant est incrémenté d'une unité.

IV.1.4.4. L'adaptation des poids du nœud gagnant et de ses voisins

Les poids des nœuds gagnants sont modifiés comme suit;

$$W_{(n+1)}(k,j) = W_n(k,j) + \eta(n)[x(j) - W_n(k,j)]$$

Où : n : le nombre d'itérations, k : le nœud gagnant, j : le $j^{\text{ème}}$ l'attribut.

η : le poids modifié sous forme d'une fonction décroissante du nombre d'itérations appelé aussi taux d'apprentissage.

Tous les nœuds associés à ce même nœud gagnant seront également modifiés, par une quantité inversement proportionnelle à la distance sur la carte. Si nous attribuons une dimension de l'ordre de un, de deux ou d'une dimension plus élevée pour chaque nœud, nous pouvons calculer la distance relative du nœud gagnant par rapport à n'importe quel autre nœud et calculer facilement les modifications.

IV.1.4.5. Adaptation des nœuds voisins selon leurs distances par rapport au nœud gagnant

L'adaptation des nœuds voisins du nœud gagnant selon leurs distances par rapport à ce dernier sera faite par la formule suivante :

$$W_{(n+1)}(m,j) = W_n(m,j) + d(m,k,n). \eta(n)[x(j) - W_n(m,j)].$$

où : $d(m, k, n)$ est une fonction du nombre d'itérations n et de la distance entre le nœud gagnant k et son nœud voisin m . Tous les autres nœuds en dehors du rayon associé à un nœud gagnant n'auront aucune correction.

w_n : Le poids du $n^{\text{ième}}$ nœud

IV.1.4.6. Adaptation du rayon associé à chaque nœud corrigé

Généralement, on considère un rayon initial assez long pour couvrir la plupart des nœuds neuronaux, ce rayon diminue en fonction de l'augmentation du nombre d'itérations. La fonction $d(m,k,n)$ peut rendre n'importe quelle fonction inversement proportionnelle au nombre d'itérations n , et à la distance entre le nœud gagnant k et le nœud à ajuster m .

IV.1.4.7. Contrôle de la convergence pour continuer ou pour interrompre l'itération

On calcule l'erreur RMS (la racine carrée de la somme des carrés des erreurs. C'est-à-dire le carré de la distance entre les données d'entrée et les poids des neurones gagnants sur le nombre des données d'entrées) et le contrôler s'il est au-dessous d'un certain niveau prédéfini. Si ce test est vrai, alors l'objectif est atteint (les poids désirés), ces poids peuvent être utilisés pour la classification. Si non, on poursuit avec une nouvelle série d'itérations.

IV.1.4.8. Contrôle de qualité

L'une des caractéristiques principales des cartes de Kohonen est la détermination des neurones avec les poids associés. Le premier Contrôle à faire est de voir si les distances euclidiennes calculées entre les nœuds neuronaux sont proportionnelles aux distances topologiques de la carte désirée. Si cette condition n'est pas satisfaite, une série d'itérations additionnelle sera nécessaire.

IV.1.4.9. Enregistrement des poids calculés

Les poids des nœuds neuronaux calculés sont des fonctions mémorisées qui seront employées pour la classification. Ces poids peuvent avoir de petites différences entre les neurones adjacents.

IV.1.4.10. Classification de l'ensemble des données d'entrée

Dans l'étape de classification pour chaque entrée, nous calculons la distance euclidienne de chaque nœud neural et classifions l'entrée en tant que membre de la classe représentée par le nœud gagnant.

IV.1.4.11. Contrôle de validité des résultats

Après chaque itération une nouvelle carte de densité de population des différentes classes sera présentée. La forme de cette carte change en fonction de l'évolution du processus de la classification. Dans le cas idéal tous les nœuds convergent vers un seul point d'où la notion du neurone gagnant. En plus du résultat graphique, d'autres paramètres sont également imprimés pour le contrôle et la surveillance de l'évolution du réseau. Le pas d'apprentissage, la correction du rayon entre deux neurones voisins, la largeur de la base de la carte SOM et l'erreur RMS de chaque passe (itération) sont les principaux paramètres de contrôle utilisés.

IV.2. Classification lithologique par les cartes SOM

Dans ce qui suit, qu'on va utiliser les cartes auto organisatrices de Kohonen pour faire une classification lithologique.

IV.2.1. Application de l'apprentissage non supervisé

Cette étape sera faite sur le puits BBK-14, au niveau de réservoir Siegenien de la même manière que lors de l'utilisation du MLP, de tel sorte que on va introduire les huit diagraphies conventionnelles utilisées auparavant avec le même ordre précédent : gamma ray (GR), sonique (DT), densité neutron (ZDEN), porosité neutron (CN), résistivité (M2R9), photoélectrique (PE), potassium (K), et uranium (U), et comme donnée de sortie désirée des cartes SOM, la lithologie obtenue à partir les descriptions des carottes et le log de chantier associé à la lithologie de MLP (**Fig.IV.5**).

L'apprentissage dans les cartes SOM est non supervisé, contrairement à celui de MLP qui est supervisé (on a une sortie désiré).

Dans le domaine informatique, l'apprentissage non supervisé parfois dénommé (clustering) est une méthode d'apprentissage automatique. Il s'agit pour un logiciel de diviser un groupe hétérogène de données, en sous-groupes de manière à ce que les données considérées comme les plus similaires soient associées au sein d'un groupe homogène et qu'au contraire les données considérées comme différentes se retrouvent dans d'autres groupes distincts; l'objectif étant de permettre une extraction de connaissance organisée à partir de ces données. A l'inverse, lors d'un apprentissage non-supervisé, le réseau est laissé libre de converger vers n'importe quel état final lorsqu'on lui présente un motif. Cette méthode se distingue de l'apprentissage supervisé par le fait qu'il n'y a pas de sortie a priori (**Fig.IV.4**).




Fig.IV.4: Principe de l'apprentissage non-supervisé

L'apprentissage de notre réseau est aussi fait à l'aide du logiciel NuMap version 7.1 (**Fig.III.15**), c'est le même logiciel utilisé pour faire la classification avec le MLP.

Le réseau donne à la fin de l'apprentissage une sortie calculée qu'on va introduire dans l'IP (Interactive petrophysics) à fin d'avoir une classification lithologique la plus proche à celle des carottes (**Fig.IV.5**).




Fig.IV.5 : La lithologie carotte vs la lithologie SOM après l'apprentissage.

D'après la figure précédente (**Fig.IV.5**) on remarque que l'apprentissage de notre réseau a donné une classification lithologique semblable à celle établie par les carottes et le master-log. On peut conclure que notre réseau a bien appris, et il est prêt à généraliser ou bien à propager dans le puits BBK-11.

IV.2.2. Généralisation ou propagation

Une fois terminé la phase d'apprentissage de notre réseau dans le puits BBK-14, on va entamer la propagation de l'information sur le puits BBK-11, toujours au niveau de réservoir Siegenien. Dans cette étape, on procède comme suit :

On introduit dans le réseau carte SOM comme données d'entrées les huit diagraphies conventionnelles de BBK-11 (les mêmes diagraphies qu'on a utilisées dans la phase d'apprentissage dans BBK-14 et avec le même ordre aussi), ensuite on lance le réseau.

L'output de ce réseau est la colonne lithologique au niveau du Siegenien de puits BBK-11 (**Fig.IV.6**).




Fig.IV.6: La lithologie carotte vs la lithologie SOM après la généralisation.

IV.2.3. Comparaison entre la lithologie carotte, MLP et SOM

On remarque que les classes lithologiques obtenues par les réseaux MLP et cartes SOM sont les mêmes aux celles établies par les carottes et master-log (argile, grès fin, grès moyen), donc les deux réseaux n'ont pas donné une nouvelle classe de même ils n'ont pas supprimé un type de classe (**Fig.IV.7**).




Fig.IV.7 : Comparaison entre la lithologie carotte MLP et SOM après la généralisation.

La lithologie obtenue que ce soit par le réseau MLP ou par les cartes SOM dans la plupart des profondeurs n'est pas complètement identique à celle qu'on a faite à partir des descriptions des carottes et log de chantier. Mais il est clair que la lithologie obtenue par les cartes SOM est plus semblable à que celle obtenue par le réseau MLP.

Conclusion générale

Le but de notre travail est de faire une classification lithologique qui est considérée comme la première étape de la caractérisation du réservoir, et pour cela, il existe plusieurs méthodes conventionnelles d'y procéder ; une classification par les diagraphies classiques et les diagraphies d'imageries, une classification par les descriptions des carottes et le log de chantier.

Dans notre travail, nous avons voulu expérimenter une nouvelle méthode de classification lithologique et de voir sa contribution et évaluer son apport positif dans la caractérisation du réservoir. Cette nouvelle méthode se base sur des réseaux de neurones artificiels, ces derniers sont placés d'une part dans la famille des applications statistiques, et d'autre part dans la famille des méthodes de l'intelligence artificielle.

Grâce à leur capacité de classification et de généralisation, les réseaux de neurones sont généralement utilisés dans des problèmes de nature statistique. Les réseaux de neurones, en tant que système capable d'apprendre, c'est-à-dire l'apprentissage par l'expérience et par la confrontation avec des situations ponctuelles a fait ses preuves dans plusieurs domaines, par conséquent on a voulu appliquer cette méthode dans la classification lithologique.

En premier lieu, deux classifications ont été faites par les méthodes conventionnelles, la première en exploitant les diagraphies conventionnelles et la deuxième en utilisant à fois les descriptions des carottes et le log de chantier.

Il faut noter que les diagraphies conventionnelles sont fiables pour établir une classification lithologique, et toutefois des carottes et le log de chantier ont été employés afin d'affiner cette classification.

En deuxième lieu, il y a aussi deux classifications qui ont été réalisés par deux types de réseaux de neurones artificiels différents. Une par un réseau à apprentissage supervisé qui est le Perceptron Multicouches (MLP) et la deuxième par le réseau à apprentissage non supervisé, il s'agit des cartes auto-organisatrice (SOM).

La lithologie obtenue par le réseau MLP correspond dans l'ensemble à celle établie par les méthodes conventionnelles.

Le réseau de Kohonen présente des résultats meilleurs que ceux obtenus par le réseau MLP tout en comparant avec la classification lithologique donnée par les méthodes conventionnelles. Cela nous mène à dire que le réseau de Kohonen est fiable et donne bon résultat en classification lithologique, par conséquent il peut être exploité dans la caractérisation du réservoir.

- Aliouane L., 2013. Utilisation des réseaux de neurones artificiels en traitement des données de géophysique : prédiction et reconstitution des faciès lithologiques. Application aux données de puits. Thèse de Doctorat, USTHB.
- Boudjama A., 1987. Evolution structural du bassin pétrolier triasique du Sahara nord oriental (Algérie). Thèse de doctorat, Université de Paris XI (Orsay).
- Changhua Y., Michael T., 2002. A Modified hidden weight optimization algorithm for feed-forward neural network.. Université de Texas.
- Mejia C., 1992. Architectures neuronales pour l'approximation des fonctions de transferts: application à la télédiction. Thèse de Doctorat, Université de Paris sud centre d'Orsay.
- Mihoubi A., 2008. Classification lithologique des attributs sismiques par les réseaux de neurones artificiels comparaison entre les cartes auto-organisatrices de Kohonen et le perceptron multicouches. Thèse de Magister. Université de Boumerdes (UMBB).
- Rayane T., 2006. Les réseaux de neurones artificiels appliqués à la prédiction des IPRs des puits horizontaux, Master, Institut Algérien de Pétrol.
- Schlumberger, 2008. Oil Field Review.
- Serra O, 1979. Acquisition des données diagaphiques. Tome 1, Edition Technip.
- Serra O, 1985. L'interprétation des données diagaphiques. Tome 2, Edition Technip.
- Sonatrach et Schlumberger, 2007. Well Evaluation Conference (WEC) OF ALGERIA.