

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université DJILALI BOUNAAMA Khemis-miliana



Faculté des Sciences et de la Technologie
Département des Sciences de la Matière

MÉMOIRE

En vue de l'obtention d'un diplôme de **Master** en Physique
Spécialité: Physique du Globe

THEME

Caractérisation des réservoirs shale gas par intelligence artificielle

Présenté par:

Medjedoub Hadjer

Bellabbas Safia

Année universitaire : 2019 / 2020

Remerciement

*Nos remerciement premièrement et avant tous au Dieu qui nous a aidés
à réaliser ce travail.*

*Nous tenons à exprimer nos sincères remerciements à Monsieur
BENTRIDI qui a contribué à notre formation en master physique du
globe.*

*Nous remercions infiniment L'ensemble des enseignants de la faculté des
sciences et technologie de l'université de Djilali Bounaama Qui ont
contribué au développement de nos connaissances Dans ce domaine,
plus particulièrement*

M. OUADFEUL, M. BELJDOUDI, M. BOUGARA, M. FARHI, M.LAMALI

*Enfin, nous exprimons tous notre gratitude et notre respect à tous ceux
qui nous ont aidés dans notre étude.*

À nos très chers parents, vraiment merci pour vos encouragements et votre soutien tout au long de notre carrière universitaire.

Hadjer et Safia

Résumé

Dans ce travail, le réservoir de gaz de schiste de Lower Barnett a été caractérisé à partir des données des diagraphies en utilisant un réseau neurones artificielle.

Le réseau neuronal multicouche MLP ont été appliqués sur des données diagraphies (rayon Gamma, neutron porosité et les onde P et S) pour prédire le COT. Les résultats obtenus en les comparant avec les valeurs du COT calculées par la méthode de Schmoker, ont montré l'efficacité du réseau de neurones artificiels avec la topologie [4-10-1] et avec l'algorithme d'apprentissage Levenberg–Marquard à prédire le COT en l'absence de diagraphie de densité.

Mots clés: Shale gas, COT, RNA, Prédiction, Schmoker, Barnett.

Abstract

In this work, the Lower Barnett shale gas reservoir was characterized from log data using an artificial neural network.

Multilayer neural network MLP with three layers, were applied on log data (natural Gamma ray, Neutron porosity and sonic P and S wave slowness) to predict TOC. The results obtained by comparing them with the values of the TOC calculated by the Schmoker method, showed the efficiency of the artificial neural network with topology [4-10-1] and with the Levenberg–Marquardt (LM) training algorithm to predict the TOC in the absence of density logging.

Keywords: Shale gas, TOC, ANN, Prediction, Schmoker, Barnett.

المخلص

في هذا العمل ، تم وصف خزان الغاز الصخري السفلي لبارنت من بيانات السجل باستخدام شبكة عصبية اصطناعية.

تم تطبيق الشبكة العصبية متعددة الطبقات بثلاث طبقات على بيانات السجل: أشعة جاما، المسامية وبطء الموجة الصوتية للتنبؤ بإجمالي الكربون العضوي.

أظهرت النتائج التي تم الحصول عليها و من خلال مقارنتها مع قيم الكربون العضوي الكلي المحسوبة بطريقة شموكر كفاءة الشبكة العصبية الاصطناعية ذات طوبولوجيا [4-10-1] للتنبؤ بإجمالي الكربون العضوي الكلي في غياب سجل الكثافة.

الكلمات المفتاحية: الغاز الصخري، الشبكة العصبية الاصطناعية، إجمالي الكربون العضوي، التنبؤ، شموكر، بارنت.

Table des matières

Introduction générale.....	1
Chapitre I: Propriétés des réservoirs shale gas.....	2
Introduction:.....	2
I.1. Définition de Shale gas:.....	2
I.2. Définition des réservoirs Shale gas:.....	2
I.3. Carbone organique totale (COT) :.....	3
I.3.1. Définition de carbone organique totale :.....	3
I.3.2. Maturation de la matière organique :.....	4
I.3.3. Méthodes de Mesure de la matière organique :.....	5
I.4. Les propriétés pétrophysique des réservoirs shale gas:.....	7
I.4.1. Densité:.....	7
I.4.2. La porosité (\emptyset):.....	7
I.4.2.1. Types de porosité:.....	8
I.4.3. La perméabilité (k):.....	9
I.4.3.1. Types de perméabilité:.....	10
I.4.4. La relation entre la perméabilité et la porosité:.....	11
I.4.5. La saturation (S):.....	11
I.4.6. Résistivité (ρ):.....	12
I.5. Les propriétés geomécaniques des réservoirs shale gas:.....	13
I.5.1. Minéralogie:.....	13
I.5.2. Contrainte:.....	13
I.5.3. Module de Young (E):.....	15
I.5.4. Coefficient de Poisson (ν):.....	15
I.5.5. fragile/ductile:.....	16
Chapitre II: Généralistes sur les reseaux du neurones artificiels.....	17
Introduction:.....	16
II.1. Historique:.....	16
II.2. Le neurone biologique:.....	17
II.3. Le neurone formel:.....	18
II.4. Réseaux de neurones artificiels (RNA):.....	22

Table des matières

II.5. Configuration des réseaux de neurones artificiels:.....	22
II.6. Architecture des réseaux de neurones artificiels:.....	23
II.7.1. Réseaux non-récurrent « FEED-FORWARD »:.....	23
II.7.2. Les réseaux récurrents « FEED-BACK»:.....	24
II.8. Apprentissage des réseaux du neurones artificiels:.....	24
II.8.1. Apprentissage supervisé:.....	25
II.8.2. Apprentissage non supervisé:.....	25
II.9. Les réseaux à perceptron multicouches « PMC » :.....	27
II.10. Algorithme Levenberg-Marquardt:.....	28
Chapitre III: Prédiction du carbone organique totale par réseaux du neurones multicouches.....	30
Introduction:.....	30
Contexte géologique sur le shale de Barnett:.....	30
Méthode et traitement des données:.....	32
Résultat et Interprétation:.....	36
Conclusion:.....	Erreur ! Signet non défini.
Conclusion générale.....	37

Abréviation

ART	Adaptive Resonance Theory
COT	Carbone Organique Totale
LOM	Level Organic Maturity
PMC	Percptrone Multi-Couches
RBF	Radial Basic Function
RNA	Réseau de Neurones Artificiels
LM	Levenberg–Marquardt

Symboles et notation

Symbole	Désignation	Unité S.I	Unité usuelle
\emptyset	La porosité	-	%
V_p	Volume des pores	m^3	
V_t	Volume totale	m^3	
V_s	Volume des solides	m^3	
\emptyset_t	La porosité totale	-	
\emptyset_o	La porosité occluse	-	
\emptyset_e	La porosité effective	-	
k	La perméabilité	m/s	mD, D
Q	Le débit	m^3/s	
S	Section d'échange	m^2	
μ	La viscosité dynamique du fluide	Pa.s	
$\Delta P/\Delta x$	Gradient de pression	-	
S	La saturation	-	%
S_w	Saturation en eau (water)	-	%
S_g	Saturation en gaz (gas)	-	%
S_o	Saturation en huile (oil)	-	%
S_{wi}	Saturation en eau interstitielle	-	%
ρ	La résistivité	$\Omega.m$	
E	Module de young		
ν	Coefficient de poisson		
σ	Contrainte	Pascal	

Table des figures

Figure I.1: Position relative des différents types de kérogènes immatures.....	5
Figure I.2: Représentation des différentes phases du milieu poreux.....	7
Figure I.3: Echelle représente la perméabilité des différents types de réservoir.....	10
Figure I.4: les contraintes appliqué sur une roche.....	14
Figure I.5: Courbe contrainte-déformation.....	14
Figure II.1: Structure d'un neurone biologique.....	17
Figure II.2: Structure d'un neurone formel.....	18
Figure II.3: Fonction Sigmoidé.....	20
Figure II.4: Fonction linéaire à seuil.....	21
Figure II.5: Fonction Heaviside.....	21
Figure II.6: Fonction Signe.....	22
Figure II.7: La configuration des réseaux du neurones artificiels.....	23
Figure II.8: Classification les réseaux les plus utilisés selon leurs architecture.....	24
Figure II.13: Principe d'apprentissage supervisé.....	25
Figure II.14: Principe d'apprentissage supervisé.....	26
Figure II.9: Structure du perceptron monocouche.....	27
Figure II.10: Structure du perceptron multicouche.....	28
Figure III.1: Carte géologique de localisation de Baenett shale et le Colonne stratigraphique du Mississipien.....	31
Figure III.2: La minéralogie et le COT après Perez.....	32
Figure III.3: Les données de puits horizontale W01 pour l'apprentissage.....	33
Figure III.4: Architecture de réseau du neurones multicouches MLP élaboré.....	34
Figure III.5: Erreur quadratique moyenne par rapport au nombre d'itération.....	34
Figure III.6: Les données de puits horizontale W02 foré dans le voisinage du puits W01 pour la propagation.....	35
Figure III.7: COT calculé à l'aide du modèle de Schmoker comparé à la COT prédite à l'aide du MLP avec l'algorithme d'apprentissage Levenberg – Marquardt.....	36

Table des tableaux

Tableau I.1: Teneur en COT définissant le potentiel pétrolier d'une roche mère.....	4
Tableau I.2: Porosité, perméabilité et résistivité de différentes roches.	12
Tableau I.3: Module d'Young et coefficient de Poisson pour quelque roches.....	15
Tableau II.1: Analogie entre le neurone biologique et le neurone formel.....	18
Tableau II. : Classification des RNA les plus utilisé selon leurs types d'apprentissage.	26

Introduction générale

L'abondance de Shale gas aux quatre coins de la planète attiré l'attention et est perçu comme source d'énergétique pour les décennies à venir. Ce type de réservoirs non conventionnels nécessite l'utilisation de la technologie moderne et avancée, soit à l'exploration ou pour l'exploitation.

Des nombreuses outils de diagraphie servent a mesuré des propriétés caractéristique du réservoirs shale gas, et l'un des objectifs principaux des études géophysiques est d'appliquer des techniques mathématiques et statistiques appropriées afin d'extraire le maximum d'informations sur les propriétés du réservoir à partir du données de ces diagraphies. Parmi eux les méthodes appliquées pour calculer le carbone organique totale COT qui sont: le modèle de Pessey utilise la résistivité profonde (R_t) et l'onde lente P et S. Le deuxième modèle est appelé le modèle de Schmocker qui relie le COT à l'inverse de la densité apparente par une relation linéaire. Mais L'estimation du COT à l'aide du modèle de Schmoker nécessite une mesure continue de la densité apparente à chaque profondeur du réservoir, ce qui n'est pas toujours facile dans les données de puits. Les réseaux de neurones artificiels (RNA) a été utilisé pour prédire le COT en l'absence de log de densité ([Ouafeul et Aliouane, 2014](#)).

Les réseaux de neurones artificiels qu'ont réussi à rendre certaines tâches de traitement des données automatiques en géophysique, Il est intéressant de signaler que sont capable de résoudre des problèmes de prédiction de COT en cas d'absence de diagraphie de densité.

Alors dans notre présent mémoire on commençons d'expliquant quelques définitions des propriétés des réservoir shale gas. Après avoir une généralité sur les réseaux de neurones artificiels, la réseau proposé est appliquée pour prédire du carbone organique totale COT (cas de réservoir Barnett), nous terminons par l'interprétation des résultats, et une conclusion générale.

Chapitre I.

Propriétés des réservoirs
Shale gas

I. Propriétés des réservoirs shale gas

Introduction:

Les réservoirs non conventionnels du Shale gas désignent les ressources fossiles plus difficiles. Elles nécessitent des techniques d'exploitation complexes par fracturation hydraulique. Ces réservoirs sont caractérisées par des propriétés géochimiques, pétrophysiques et géomécaniques. En tant qu'indice fondamental et important, la présence de grandes quantités de matière organique représente le bon potentiel de génération d'hydrocarbures. Les paramètres porosité et perméabilité sont les deux principales propriétés pétrophysiques définissant la bonne qualité de la roche réservoir qui plus saturée en hydrocarbures. Aussi il faut comprendre le comportement mécanique des roches pour prédire le meilleur emplacement pour se fracturer le long du puits.

I.1. Définition de Shale gas:

Gaz de schiste ou Shale gas en anglais appartient à la famille des gaz de roche-mère, il est piégé dans les pores de la roche mère (généralement argileuse) qui n'a jamais représenté une migration primaire, à cause de formations de schiste qui sont remplies de fissures provenant de leurs structures stratifiées et fissiles, ces voies aboutissant à des impasses.

Ce gaz naturel se compose principalement de méthane, ainsi que d'autres hydrocarbures tels que le dioxyde de carbone, l'azote et des hydrocarbures plus lourds tels que l'éthane et le propane. Le composant méthane est généralement de 80% ou plus ([Shale gas hand-book, 2015](#)).

I.2. Définition des réservoirs Shale gas:

Les réservoirs shale gas sont des gisements non conventionnels s'étendant à une échelle régionale. Ces sédimentation argileuses sont saturé en hydrocarbures gazeux où les roches de schiste riches en matières organiques. Ces roches se sont progressivement enfoncées dans le sol et se sont solidifiée. Sous l'effet de la pression et de la température, les matières organiques contenues se sont transformées en gaz. Les roches

I. Propriétés des réservoirs shale gas

ont alors pris une structure compacte, très resserrée, et ont piégé le gaz dans des stockages très peu poreux et très peu perméables.

En générale, les formations de schiste dans lesquelles du gaz a été piégé se trouvent jusqu'à 2 à 3 km sous la surface de la Terre, bien que cela puisse varier considérablement en fonction des exigences et des influences géologiques ([Shale gas hand-book, 2015](#)).

I.3. Carbone organique totale (COT) :

La formation du pétrole et du gaz résulte de la dégradation thermique du kérogène sous l'influence de l'augmentation de la température (de 50 à 150°C, consécutive à l'enfouissement), de la pression (part mineure) et du temps (de 10 à 350Ma) ([Chadouli, K, 2013](#)).

I.3.1. Définition de carbone organique totale :

Le carbone organique total COT évalue la richesse de la roche mère en matière organique et sa prédisposition à générer des hydrocarbures. La teneur en COT permet de qualifier le potentiel roche mère, mais cette approche ne tient pas compte du fait que la teneur en COT diminue avec la maturation thermique et que la nature même de la matière organique est aussi un facteur qui contrôle son potentiel pétrologène.

La quantité minimale de COT que doit contenir une roche pour être qualifiée de roche mère à gaz est de 2 %.(Tableau 1).

La teneur en COT diminue avec la maturation thermique, la nature même de la matière organique est aussi un facteur qui contrôle son potentiel pétrolier. La teneur élevée en matière organique associée au shale est un bon indicateur du potentiel d'hydrocarbures des roches mères, elle est caractérisée par une résistivité élevée avec une certaine porosité apparente sur log analysis ([Brakik. I et Nassah. A, 2018](#)).

I. Propriétés des réservoirs shale gas

Tableau I.1: Teneur en COT définissant le potentiel pétrolier d'une roche mère.

Potentiel pétrolier	Teneur en carbone organique total (COT%)
Pauvre	0 - 0.5
Faible	0.5 - 1
Bon	1 - 2
Très bon	2 - 4
excellent	>4

I.3.2. Maturation de la matière organique :

L'évolution de la matière organique en kérogène puis en hydrocarbure, c'est-à-dire, sa maturation est le résultat d'un mécanisme physico-chimique complexe dont les principaux facteurs sont : l'enfouissement (pression) et la température (gradient géothermique). La maturité thermique mesure le degré d'exposition des formations la haute chaleur nécessaire pour la transformation de la matière organique en hydrocarbures. On distingue trois phases de maturation par lesquelles transite la matière organique depuis sa fossilisation jusqu'à sa dégradation finale. Les étapes successives sont : La diagenèse, La catagenèse et La métagenèse. (Brakik. I et Nassah. A, 2018)

La diagenèse : elle est caractérisée par une altération à basse température de la matière organique en dessous de 50°C (122°F) progressivement convertie en kérogène.

La catagenèse : se produit généralement lorsque l'enfouissement supplémentaire entraîne une augmentation de la pression, ce qui augmente la chaleur dans la plage d'environ 50 à 150°C (122 à 302°F), provoquant la décomposition des limites chimiques dans le schiste et le kérogène.

La métagenèse : est la dernière étape dans laquelle la chaleur et les changements chimiques entraînent presque la transformation du kérogène en carbone. Au cours de cette étape, le méthane tardif ou le gaz sec a évolué, avec des gaz non hydrocarbonés

I. Propriétés des réservoirs shale gas

tels que CO₂, N₂ et H₂S. Plage de température d'environ 150°C à 200°C (302 à 392°F).

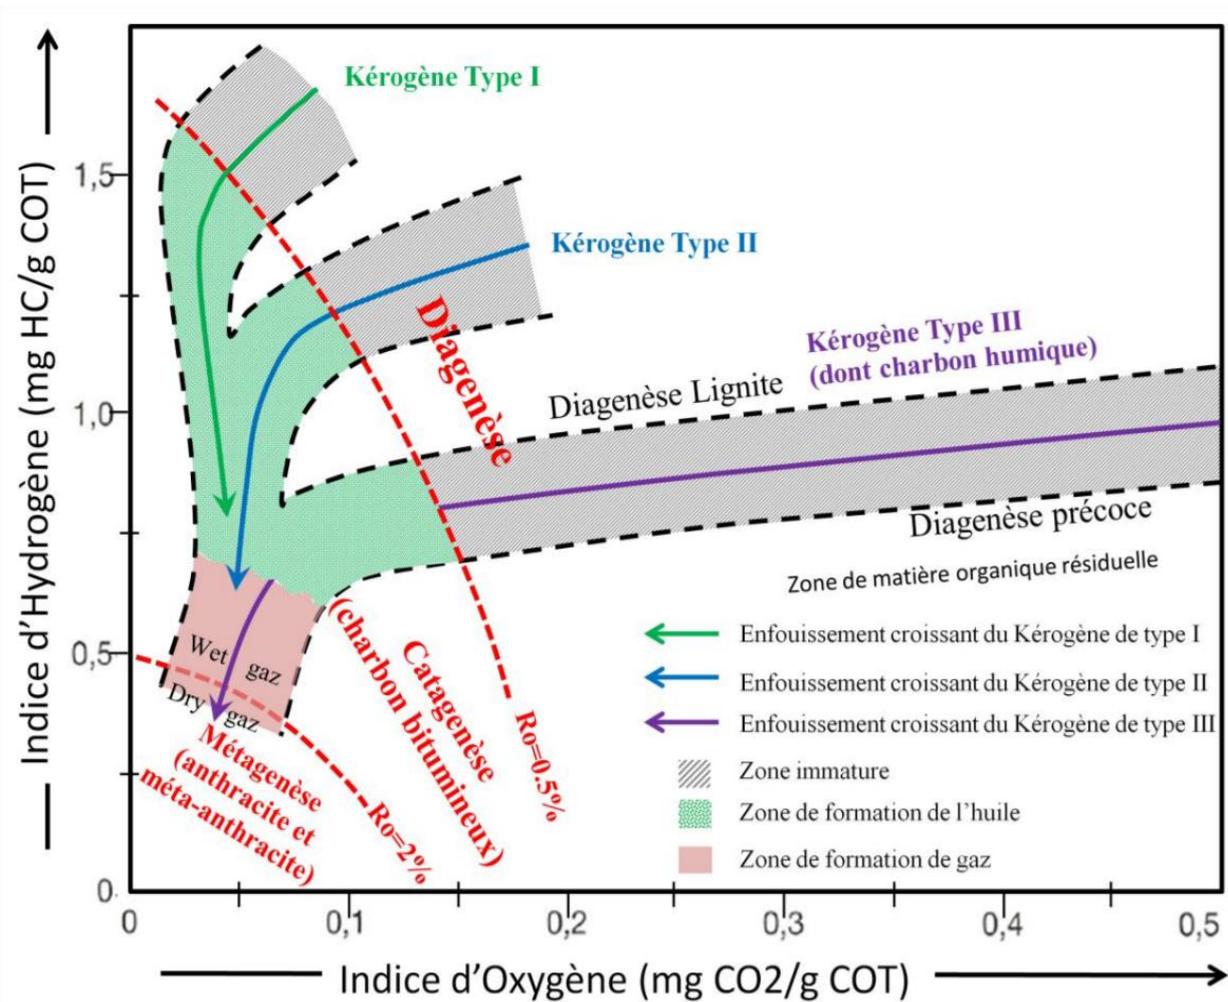


Figure I.1: Position relative des différents types de kérogènes immatures.

Le pétrole et le gaz condensats sont formés et expulsés en partie durant la catagenèse tandis que les gaz secs sont formés pendant la métagenèse (**Figure I.1**) (Chadouli, K, 2013).

I.3.3. Méthodes de Mesure de la matière organique :

On peut déterminer et estimer le COT d'un réservoir à partir de la méthode de mesure directe au laboratoire, en analysant la carotte. La seconde méthode est basée sur la mesure à l'aide d'un outil de diagrapie. Cette dernière est basée sur la mesure empirique,

I. Propriétés des réservoirs shale gas

dans ce cas deux modèles sont utilisées, le première modèle dite Passey et la seconde est appelé modèle de Schmoker (Ouafeul. S et Aliouane. L, 2014).

a. Méthode de Passey:

Passey est la méthode la plus utilisée pour la détermination du COT dans les gisements de Shale gas. Les trois diagraphies de puits de porosité, densité, neutron et sonique, peuvent être utilisées pour calculer le $\Delta\log R$ basé sur la séparation entre la courbe de résistivité profonde et les diagraphies de porosité, qui peuvent être convertis en COT via le paramètre de niveau de maturité organique (LOM). Habituellement, LOM a besoin d'une expérience de laboratoire pour mesurer. En pratique, le COT de base et le $\Delta\log R$ calculé aident à l'étalonnage pour estimer la LOM. Dans la technique $\Delta\log R$, les effets de porosité sont minimisés. Parfois, la détermination des lignes de base de diagraphie de Passey est très difficile. D'autre part, la technique $\Delta\log R$ peut être utilisée des logs de porosité multiple. Si elles sont utilisées, les valeurs de COT estimées peuvent être différentes.

b. Méthode de Schmoker:

La méthode de Schmoker basée sur la réponse de la mesure de la densité apparente à la matière organique de faible densité ($\sim 1,0 \text{ g / cm}^3$), calcule le COT:

$$TOC = \frac{154497}{\rho_b} - 57.261$$

Avec:

ρ_b : Densité apparente (bulk density) g/cm³;

TOC exprimé en %.

Cette équation suppose une composition minérale et une porosité constantes dans toute la formation. La méthode a été développée et affinée en fonction d'environnements spécifiques.

I.4. Les propriétés pétrophysique des réservoirs shale gas:

I.4.1. Densité:

La densité est définie comme la masse d'une substance par unité de volume. La densité des roches dépend de:

- La composition minérale (densités minérales et volume de grain);
- Porosité (pores, fractures)
- Densité des fluides interstitiels.

I.4.2. La porosité (Φ):

Les roches réservoir sont constituées par des particules, de forme quelconque, plus ou moins cimentées entre elles, et entre lesquels existent des espaces vides qui ont la faculté de contenir un ou plusieurs fluides interstitiels tels que de l'eau ou des hydrocarbures liquides ou gazeux.

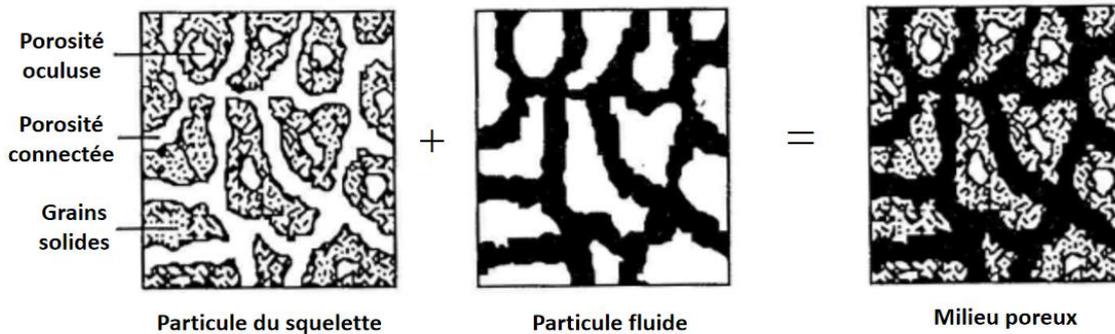


Figure I.2: Représentation des différentes phases du milieu poreux.

La porosité (Φ) le rapport entre le volume d'espaces libres V_p , non occupés par la matrice rocheuse, sur le volume total de la roche (Jonathan Schuite, 2016). Elle s'exprime en pourcentage %. son expression est:

$$\Phi = \frac{V_p}{V_t} = \frac{V_t - V_s}{V_t}$$

I. Propriétés des réservoirs shale gas

Avec:

V_p : Volume des pores;

V_t : Volume totale;

V_s : Volume des solides.

I.4.2.1. Types de porosité:

La porosité totale ou absolue (\emptyset_t): est le rapport de la volume total des espaces vides dans la roche réservoir, qu'elle contribue ou non à la rétention de gaz.

La porosité effective (\emptyset_e): est la mesure de l'espace vide qui est rempli par le gaz récupérables.

Porosité occluse (\emptyset_o): dans la plupart des milieux poreux naturels la porosité occluse est rare et non accessible aux fluides. Comme elle est totalement déconnectée du réseau poreux son importance est quasiment nulle.

La porosité efficace des roches varie entre $< 1\%$ et $> 40\%$ on dit souvent que la porosité est :

Faible si $\emptyset < 5\%$

Médiocre si $5\% < \emptyset < 10\%$

Moyenne si $10\% < \emptyset < 20\%$

Bonne si $20\% < \emptyset < 30\%$

Excellente si $\emptyset > 30\%$. (Boumad. B et Chicha. S, 2019)

Par exemple, le schiste de Barnett a une faible porosité de 2 à 6% et une teneur en gaz de 50 à 150 scf / tonne (Schlumberger, 2010).

I.4.3. La perméabilité (k):

La perméabilité d'une roche caractérise son aptitude à permettre l'écoulement des fluides contenus travers son espace poreux où ses pores sont reliés entre eux (la connexion entre les pores).

Plus précisément, la perméabilité (k) est un paramètre empiriquement dérivé de la loi Darcy, une loi qui prédit la décharge de fluide à travers un matériau granulaire.

La loi de Darcy (Henry Darcy, 1856):

$$\frac{Q}{S} = \frac{k}{\mu} \frac{\Delta P}{\Delta x}$$

Avec:

Q : le débit (m³/s);

S : section d'échange (m²);

K : perméabilité (Darcy);

μ : la viscosité dynamique du fluide (Pa.s), (1 Pa.s = 1 Poiseuille = 10 poises);

ΔP/Δx : gradient de pression.

La perméabilité (**k**) est donc:

$$k = \frac{Q}{S} \frac{\Delta x}{\Delta P} \mu$$

La perméabilité (**k**) s'exprime également en **Darcy**. Avec l'équivalence 1 Darcy = 0,987. 10¹² m². On peut employer les termes suivants pour spécifier la valeur de la perméabilité:

< 1mD : très faible

1 à 10mD : faible

10 à 50mD : médiocre

50 à 200mD : moyenne

200 à 500mD : bonne

> 500mD : excellente. (Boumad. B et Chicha. S, 2019).

I. Propriétés des réservoirs shale gas

I.4.3.1. Types de perméabilité:

On distingue:

Perméabilité absolue: est la perméabilité du milieu poreux si un seul fluide s'écoule.

Perméabilité effective: est la mesure de la capacité de conductance du fluide d'un milieu poreux à un fluide particulier lorsque le milieu est saturé avec plus d'un fluide.

Perméabilité relative: est le rapport de la perméabilité effective à la perméabilité absolue. Elle est fonction de la saturation.

La perméabilité de shale est très faible, généralement elle est de l'ordre de 0.0001 à 0.001 mDa (Figure I-7) (Kenneth E. Williams, 2013). Par exemple, le shale de Barnett a généralement une perméabilité de 100 à 600 nano-Darcy (Schlumberger, 2010).

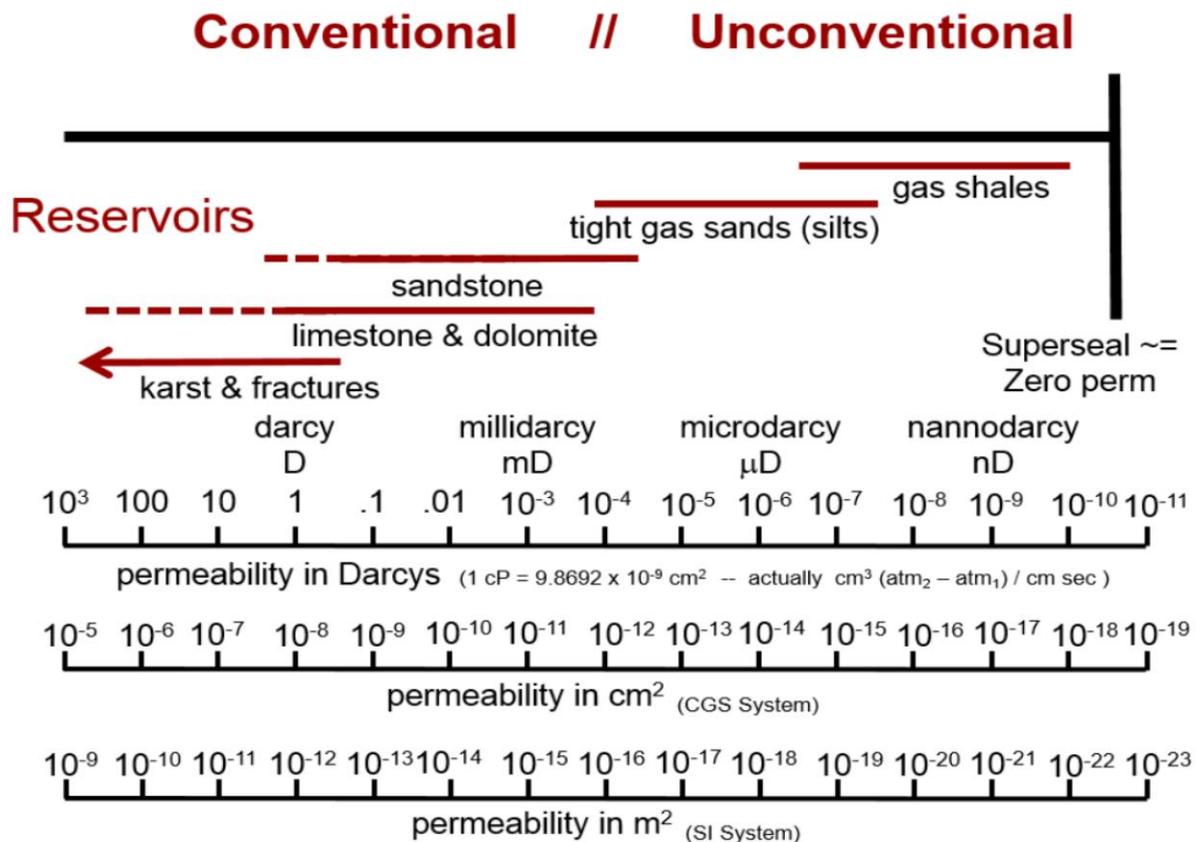


Figure I.3: Echelle représente la perméabilité des différents types de réservoir.

I. Propriétés des réservoirs shale gas

I.4.4. La relation entre la perméabilité et la porosité:

L'évolution de la perméabilité est très sensible à la porosité. en effet, la perméabilité dépend du nombre, de la géométrie, de la taille et surtout de l'interconnectivité des vides laissés entre les grains. la perméabilité diminue avec la porosité.

I.4.5. La saturation (S):

La porosité d'une roche réservoir est très importante parce qu'elle est une mesure de la capacité de cette roche à stocker les fluides (pétrole, gaz et eau).

Tout aussi important, la mesure relative dans laquelle les pores de la roche sont remplis de fluides spécifiques. Cette propriété est appelée saturation en fluide et est exprimée comme la fraction, ou pour cent, du volume total des pores occupés par le pétrole, le gaz ou l'eau ([Okba Dahnoun, 2019](#)).

Cette propriété est exprimée par la relation suivante:

$$Saturation = \frac{\text{volume de fluide}}{\text{volume des pores}}$$

Dans le cas d' un gisement à hydrocarbures, les pores contiennent de l' eau, de l' huile ou du gaz. On définit ainsi:

$$\text{Saturation en eau:} \quad S_w = \frac{V_w}{V_p}$$

$$\text{Saturation en gaz:} \quad S_g = \frac{V_g}{V_p}$$

$$\text{Saturation en huile:} \quad S_o = \frac{V_o}{V_p}$$

$$\text{Avec:} \quad S_w + S_g + S_o = 1 \text{ (ou 100\%)}$$

I. Propriétés des réservoirs shale gas

Les pores du roche réservoir reste toujours piégée l'eau, appelée eau interstitielle. La saturation en eau interstitielle (S_{wi}) varie entre 10 et 35%.

I.4.6. Résistivité (ρ):

La résistivité électrique d'une roche saturée de fluide est sa capacité à permettre au courant électrique de circuler à travers l'espace poreux de roche. Cette propriété est parmi les paramètres mesurés par les outils diagraphie. Sa unité ($\Omega.m$). La résistivité électrique d'une roche dépend à:

- Le type de fluide;
- La porosité et distribution des fluides;
- La saturation en eau S_w .

La valeur de la résistivité minimale dans le shale doit être supérieure à 15 Ohm.m (Shlumberger,).

Tableau I.2: Porosité, perméabilité et résistivité de différentes roches. (Brakik. I et Nassah. A, 2018)

Roches	Porosité (%)	Perméabilité (cm/s)	Résistivité ($\Omega.m$)
Argilite	35	$10^{-8} - 10^{-9}$	70 à 200
Craie	35	10^{-5}	30 à 300
Tuf volcanique	32	10^{-5}	20 à 300
Marnes	27	$10^{-7} - 10^{-9}$	20 à 100
Grés	3 à 35	$10^{-3} - 10^{-6}$	30 à 800
Dolomite	1 à 12	$10^{-5} - 10^{-7}$	200 à 10000
calcaire	3	$10^{-10} - 10^{-12}$	200 à 10000
Méta schiste	2.5	$10^{-4} - 10^{-9}$	300 à 800
Gneiss	1.5	10^{-8}	1000 à 20000
Quartz	<1	10^{-10}	1000 à 10000
Granite	1	$10^{-9} - 10^{-10}$	1000 à 15000
Gabbro	1 à 3	$10^{-4} - 10^{-9}$	6000 à 10000
Basalte	1.5	$10^{-9} - 10^{-8}$	800 à 15000

I. Propriétés des réservoirs shale gas

I.5. Les propriétés géomécaniques des réservoirs shale gas:

Les paramètres mécaniques de la roche sont des phases très importantes pour l'exploitation du réservoir, y compris la conception de programmes de forage, de complétion de puits et de production appropriés. Les principaux paramètres mécaniques sont : la minéralogie, les contraintes sur la roche, le module de Young (E), le coefficient de Poisson (ν), et la fragilité. Ces paramètres jouent un rôle important en aidant à anticiper et prévenir l'échec du forage. Ceci est une considération très importante depuis les réservoirs de schiste sont développés en utilisant de très longs trous de forage horizontaux. Et aider à déterminer l'orientation optimale du trou de forage par rapport aux complétions ([Gregory Chagnon, 2016](#)).

I.5.1. Minéralogie:

La composition minéralogique de la roche est un paramètre important à considérer dans l'exploration gazière d'un shale. Par exemple, son contenu en quartz ou en calcite peut avoir un impact sur la capacité à fracturer efficacement la roche lors de l'injection de fluide. Les valeurs limites des teneurs en substance minérales varient selon les régions et les bassins. L'illite est le minéral le plus abondant dans le shale, ensuite le smectite, kaolinite, chlorite et les autres minéraux. Le quartz est le minéral non argileux le plus abondant dans le shale ([Hiroki Sone, 2012](#)), par exemple le shale Branett a de limite du volume de Clay est définie de moins de 40% (**Annexe I**).

I.5.2. Contrainte:

la contrainte est une force appliquée sur une surface qui s'exprime en Pa. C'est l'équivalent d'une pression. $\sigma = dF / dS$. Les trois principales contraintes (σ) régissant le fardeau de la roche sont sachant que:

-Contrainte horizontal maximum : σ_{hmax}

-Contrainte horizontal minimum : σ_{hmin}

-La pression de surcharge : σ_{ov}

I. Propriétés des réservoirs shale gas

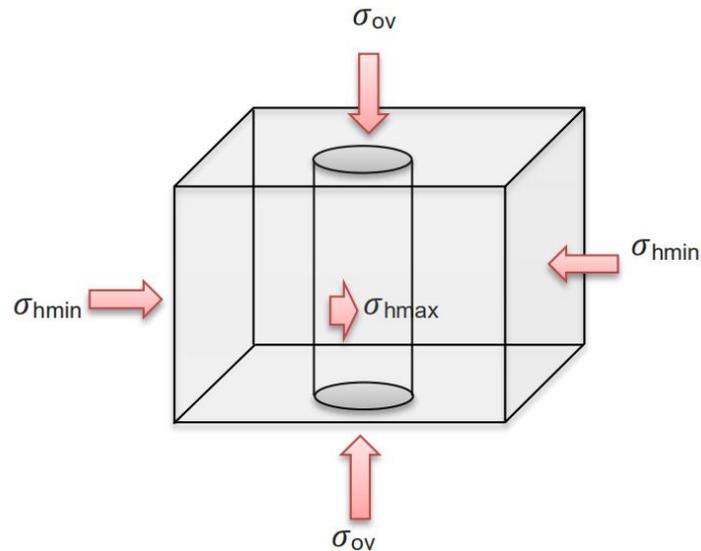


Figure I.4: les contraintes appliqué sur une roche.

Les roches peuvent être soumises à l'action des contraintes ce qui change leur forme initiale, elles se **déforment**. on distingue trois types de déformations (ϵ) : déformation élastique (réversible linéaire), déformation plastique (irréversible non linéaire) et déformation cassante atteint un seuil de rupture et il casse.

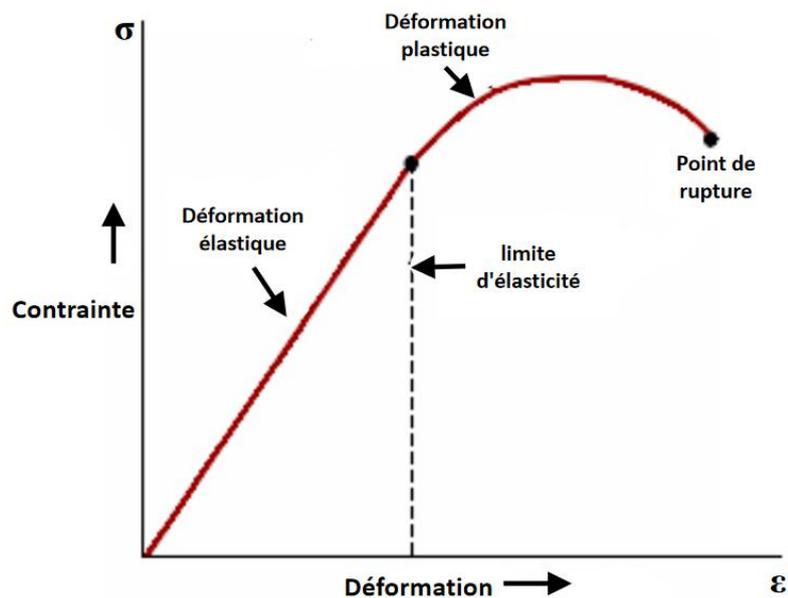


Figure I.5: Courbe contrainte-déformation.

la phase non linéaire de la roche argileuse permet une accumulation importante de déformations plastiques ($\approx 50\%$ de la déformation totale) avant la rupture. Cette déformation plastique se traduit par du plissement qui précéderaient la fracturation.

I. Propriétés des réservoirs shale gas

I.5.3. Module de Young (E):

Exprime la rigidité d'un matériau, il est caractérisé par la pente de la courbe $\sigma = F(\epsilon)$. L'augmentation du module de Young, implique une diminution de la largeur de la fracture et augmentation de la longueur de cette dernière.

I.5.4. Coefficient de Poisson (ν):

Coefficient sans dimension, défini comme étant le rapport entre la variation de la déformation latérale et la variation de la déformation axiale ou longitudinale, lorsque l'échantillon est soumis à une compression.

Tableau I.3: Module d'Young et coefficient de Poisson pour quelque roches

Roche	Module de Young (Mpsi)	Coefficient de Poisson
Calcaire	5 - 13	0.30 - 0.35
Sable	0.2 - 1.3	0.25 - 0.35
Grés	1 - 8	0.15 - 0.30
Silt	4 - 8	0.20 - 0.30
Argile	1 - 5	0.25 - 0.45
Charbon	0.1 - 5	0.35 - 0.45

Le module d'Young des roches argileuses est deux à quatre fois plus petit que celui des roches carbonatées. Ces valeurs varient légèrement suivant le type de roches argileuses, elles diminuent légèrement avec la saturation en eau de la roche et augmente avec la teneur en calcite donc la diminution de la pression de confinement.

Le coefficient de Poisson des roches argileuses est en moyenne légèrement plus faible que celui des roches carbonatées. Le coefficient de Poisson est indépendant de la minéralogie, il augmente légèrement avec la saturation en eau de la roche et avec la pression de confinements ([Abbouche Karima et Bensadi Walid, 2016](#)).

I. Propriétés des réservoirs shale gas

I.5.5. fragile/ductile:

La roche est cassant si, lorsqu'il est soumis à une contrainte, il se brise le long de surfaces discrètes sans déformation interne faible ou nulle entre les surfaces. Inversement, la ductilité d'une roche se réfère à sa tendance à l'échec par une déformation interne en masse plutôt que par des fractures discrètes. Le comportement des roches évolue d'un comportement cassant à ductile en fonction de la température et de la pression de confinement (la pression nécessaire pour fracturer la roche) ainsi la composition minéralogique. La fragilité des zones à l'intérieur des réservoirs de schiste est une importance cruciale pour initier des réseaux de fractures lors des fractures, des complétions et pour maintenir des fractures ouvertes qui ne souffrent pas d'un enfoncement excessif du proppant.

Chapitre II.

Généralistes sur les réseaux de neurones artificiels

II. Généralistes sur les réseaux de neurones artificiels

Introduction:

Les réseaux de neurones artificiels dans leur mécanisme de fonctionnement sont principalement inspirés du cerveau humain. Les RNA utilisent un schéma d'apprentissage « Learning » qui consiste à élaborer des relations entre un nombre suffisamment élevé des entrants « Inputs » et des sortants « Outputs », permettant d'acquérir des informations importantes sur le problème en question. La capacité d'apprentissage et d'adaptation de ces modèles permet d'être attractifs pour des applications en géophysique. Cette technique a été également utilisée dans l'interprétation de diagraphie et dans la caractérisation des réservoirs.

II.1. Historique:

Le champ des réseaux neuronaux va démarrer par la présentation en 1943 par W. MCCulloch et W. Pitts du neurone formel qui est une abstraction du neurone physiologique.

En 1949, D. Hebb présente dans son ouvrage "The Organization of Behavior" une règle d'apprentissage. De nombreux modèles de réseaux aujourd'hui s'inspirent encore de la règle de Hebb.

En 1958, F. Rosenblatt développe le modèle du Perceptron. C'est un réseau de neurones inspiré du système visuel. Il possède deux couches de neurones : une couche de perception et une couche liée à la prise de décision. C'est le premier système artificiel capable d'apprendre par expérience.

Dans la même période, Le modèle de L'Adaline (Adaptive Linear Element) a été présenté par B. Widrow. Ce modèle sera par la suite le modèle de base des réseaux multi-couches.

En 1969, M. Minsky et S. Papert publient une critique des propriétés du Perceptron. Cela va avoir une grande incidence sur la recherche dans ce domaine. Elle va fortement diminuer jusqu'en 1972, où T. Kohonen présente ses travaux sur

II. Généralistes sur les réseaux de neurones artificiels

les mémoires associatives. et propose des applications à la reconnaissance de formes.

C'est en 1982 que J. Hopfield présente son étude d'un réseau complètement rebouclé, dont il analyse la dynamique.

II.2. Le neurone biologique:

Les cellules nerveuses, appelées neurones, sont les éléments de base du système nerveux. Le cerveau humain contient environ 10^{11} neurones et 10^{14} à 10^{15} connexion. Le neurone biologique comporte trois types de composants principaux, qui ont un intérêt particulier dans la compréhension d'un neurone artificiel et ils sont responsables de la transmission de l'information (**Figure II.1**). C'est par les **dendrites** que l'information est circuler de l'extérieur vers le **soma (corps cellulaire)**, ensuite elle est traitée par le neurone et cheminée le long de l'**axone** pour être transmise aux autres neurones. La transmission entre deux neurones n'est pas directe, la cellule nerveuse est séparée par un espace appelé **fente synaptique** que l'influx électrique ne peut pas traverser, la liaison s'effectue par l'intermédiaire d'un médiateur chimique. Le mécanisme de flux du signal, se fait par échange d'ions qui se déplacent par diffusion d'ions quand l'influx nerveux reçoit un certain seuil ([Ali Zerrouki Ahmed, 2015](#)).

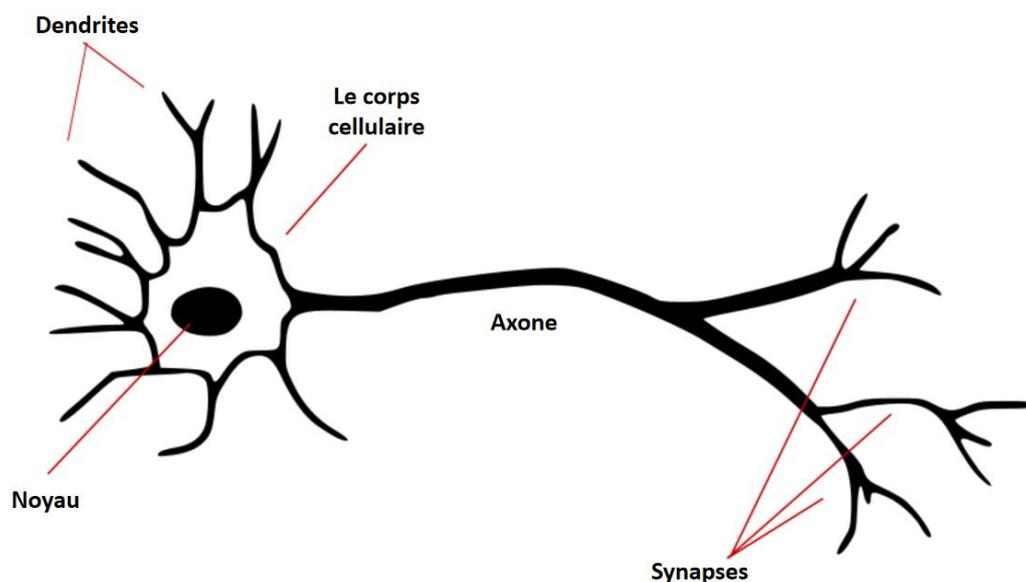


Figure II.1: Structure d'un neurone biologique.

II. Généralistes sur les réseaux de neurones artificiels

II.3. Le neurone formel:

Le neurone formel est un processeur très simple imitant grossièrement la structure et le fonctionnement d'un neurone biologique (**Tableau II.1**).

Tableau II.1: Analogie entre le neurone biologique et le neurone formel (El Mahdi Berkani, 2011).

Neurone artificiel	Neurone biologique
Poids de connexion	Synapses
Signal de sortie	Axones
Signal d'entrée	Dendrites
Fonction d'activation	Le corps cellulaire (soma)

La première version du neural formel est celle de Mc.culloche et Pitts qui est largement utilisée. Un neurone formel est un opérateur effectuant la somme pondérée de ses entrées externes puis elle s'active suivant la valeur de cette sommation pondéré puis modulée par une fonction d'activation (Medjili Fayçal, 2010).

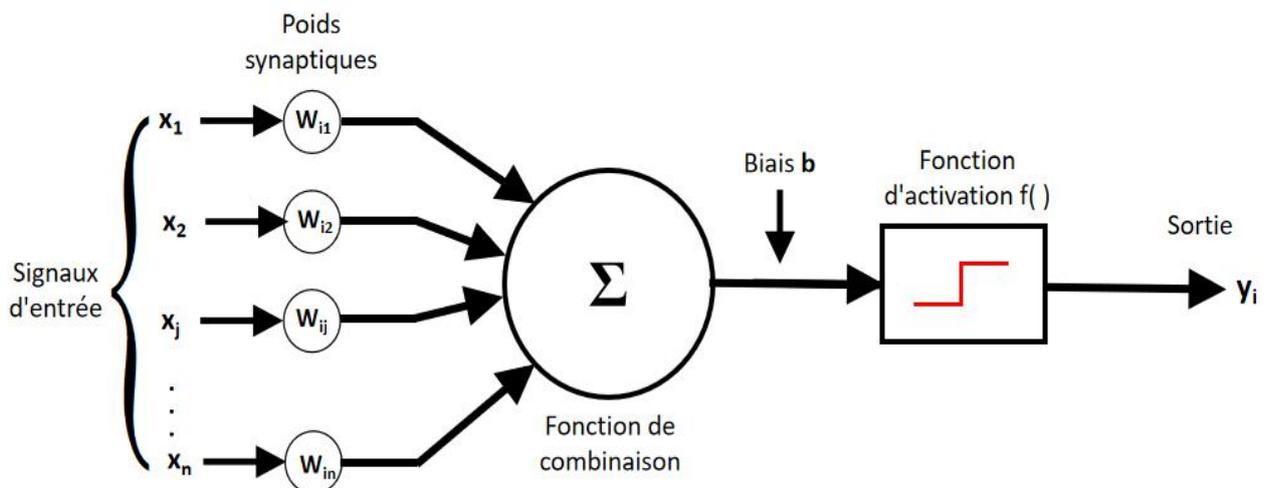


Figure II.2: Structure d'un neurone formel.

II. Généralistes sur les réseaux de neurones artificiels

Mathématiquement, tel qu'illustré par la **Figure II.2**, chaque 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 (fonction d'activation).

Signification mathématique:

$$y_i = f\left(b + \sum_{j=1} w_{ij} x_j\right) = f(A_i)$$

x_i : Les entrées au neurone qui proviennent de l'environnement externe au réseau ou d'autres neurones;

w_{ij} : Poids synaptiques associés à chaque connexion qui peut varier au cours du temps pour certains modèles;

A_i : l'activité de la cellule i ;

f : fonction d'activation;

b : le biais du neurone.

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

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

1. En dessous du seuil, le neurone est considéré comme non-actif

II. Généralistes sur les réseaux de neurones artificiels

2. Aux alentours du seuil, le neurone est considéré en phase de transition.
3. Au-dessus du seuil, le neurone est considéré comme actif.

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

a) La fonction non linéaire sigmoïde:

La fonction non linéaire sigmoïde est fréquemment utilisée dans les RNA, particulièrement dans les réseaux utilisant l'algorithme de rétro-propagation car contrairement à la fonction sigmoïde, les autres fonctions donnent seulement une sortie binaire ce qui rend plus difficile à estimer les poids optimaux, définie par:

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

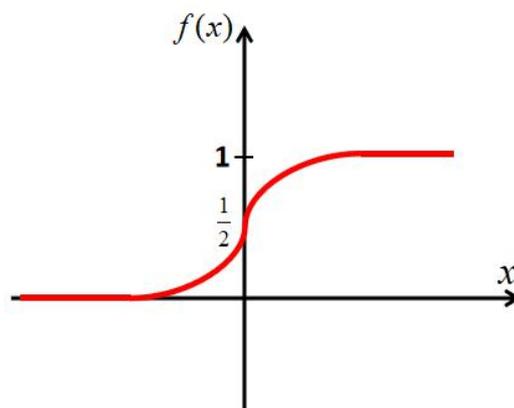


Figure II.3: Fonction Sigmoïde.

b) La fonction linéaire à seuil:

On peut la définir comme suit :

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

II. Généralistes sur les réseaux de neurones artificiels

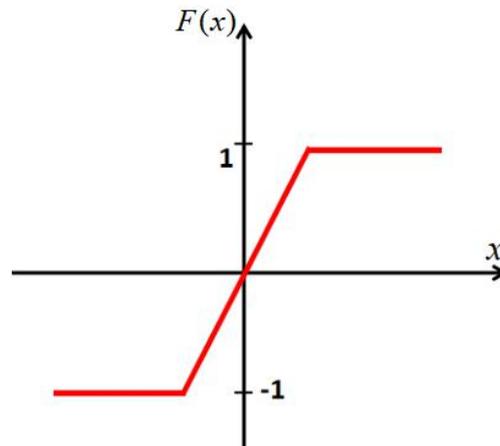


Figure II.4: Fonction linéaire à seuil

c) La fonction à seuil:

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

a. Fonction Heaviside:

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

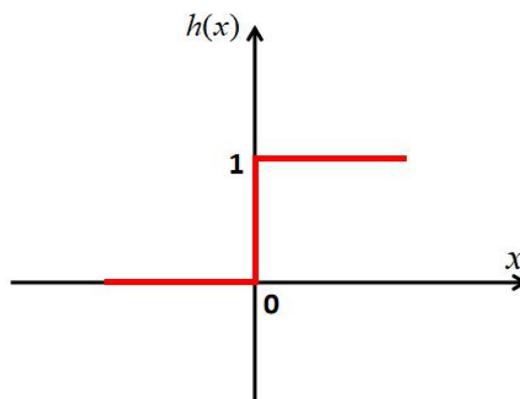


Figure II.5: Fonction Heaviside.

b. Fonction Signe :

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

II. Généralistes sur les réseaux de neurones artificiels

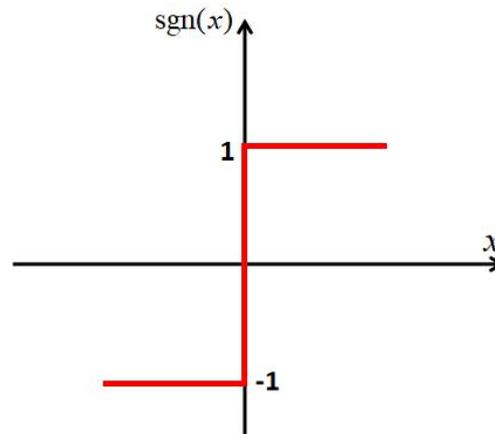


Figure II.6: Fonction Signe.

II.4. Réseaux de neurones artificiels (RNA):

Un réseau de neurones artificiels (RNA) est une succession de neurones formels associés en couches et fonctionnant en parallèle, de manière à ce que chaque neurone tienne son entrée de la sortie du neurone précédant. En ce sens, les RNA ressemblent donc au cerveau car non seulement, la connaissance est acquise à travers l'apprentissage mais de plus, ces réseaux ont la capacité de stocker de la connaissance empirique dans les connexions entre les entités, soit dans les poids synaptiques qui sont obtenus par des processus d'adaptation ou d'apprentissage de la rendre disponible à l'usage ([Kamel Karim, 2005](#)).

II.5. Configuration des réseaux de neurones artificiels:

Réseaux centralisé: tous les neurones d'une couche sont connectés aux neurones de la couche en aval.

Réseaux décentralisé: partiellement connectés où Chaque neurone est relié à quelques neurones localisés dans son périmètre.

Réseaux distribué: connexion complètes où chaque neurone est lié à tous les autres neurones du réseau.

II. Généralistes sur les réseaux de neurones artificiels

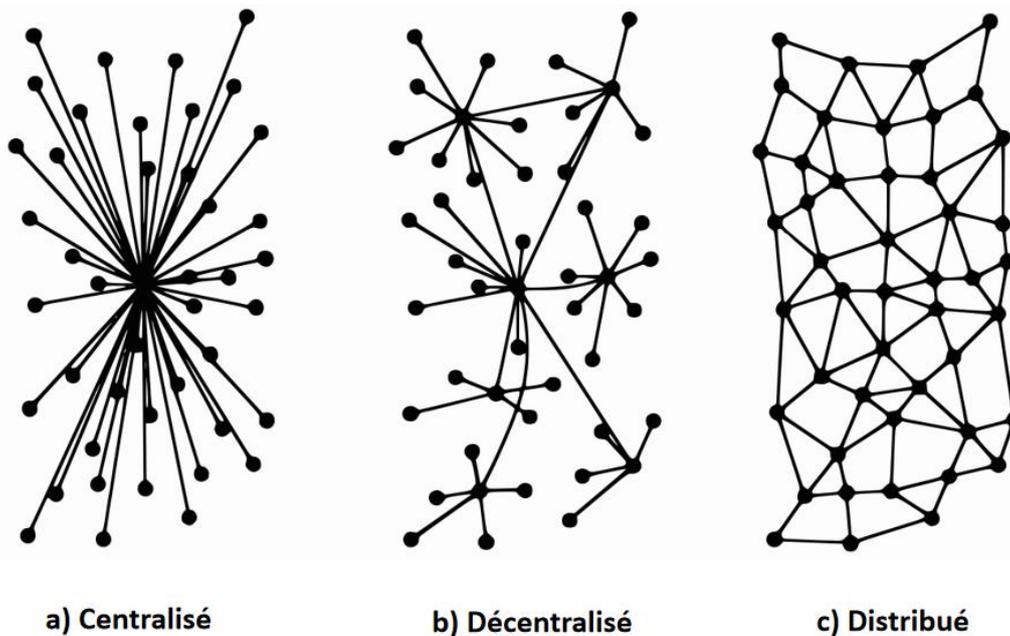


Figure II.7: La configuration des réseaux du neurones artificiels.

II.6. Architecture des réseaux de neurones artificiels:

Un réseau de neurones peut prendre des formes différentes selon l'objet de la donnée qu'il traite et selon sa complexité et la méthode de traitement de la donnée. Les architectures ont leurs forces peuvent être combinées pour optimiser les résultats. Le choix de l'architecture s'avère ainsi crucial et il est déterminé principalement par l'objectif. Les architectures de réseaux neuronaux est un concept très important qui joue un rôle déterminant dans la classification des RNA, On distingue deux grandes familles :

- Réseaux de neurones à propagation avant (Feed-forwarded);
- Réseaux de neurones récurrent (Feed-back);

II.7.1. Réseaux non-récurrent « FEED-FORWARD »:

Appelé aussi les réseaux non bouclées, la particularité de ces réseaux est que l'information se propage dans un sens unique, tout simplement les données traverse le réseau d'entrée à la sortie sans retour en arrière de l'information.

II. Généralistes sur les réseaux de neurones artificiels

II.7.2. Les réseaux récurrents « FEED-BACK»:

Appelé aussi les réseaux bouclés, ce genre de réseaux est caractérisé par le pouvoir de laisser l'information circuler récursivement d'une manière partielle ou bien total (El Mahdi Berkani, 2011).

Les réseaux de neurones les plus utilisés dans la littérature sont représentés sur la figure II.8. Cependant, dans ce qui suit, nous allons faire une description détaillée que des MLP compte tenu que ce sont les réseaux qui vont être appliqués dans ce travail.

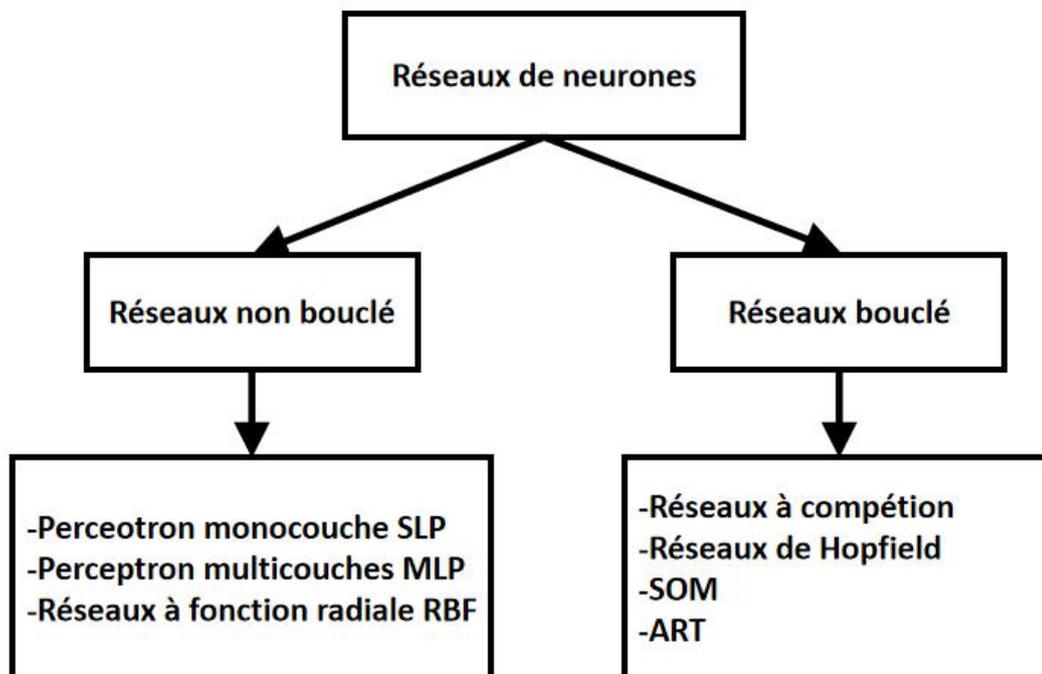


Figure II.8: Classification les réseaux les plus utilisés selon leurs architecture.

II.8. Apprentissage des réseaux du neurones artificiels:

L'apprentissage est vraisemblablement la propriété la plus intéressante dans les réseaux neuronaux, cette technique permet de conserver au réseau un comportement adapté malgré les fluctuations dans les données d'entrées. On ajoute souvent à la description du modèle l'algorithme d'apprentissage. Dans la majorité des algorithmes actuels, les variables modifiées pendant l'apprentissage sont les poids des

II. Généralistes sur les réseaux de neurones artificiels

connexions du réseau, où elle sont modifiées jusqu'à l'obtention du comportement désiré du réseau.

Au niveau des algorithmes d'apprentissage, il a été défini deux grandes classes selon que l'apprentissage est dit supervisé ou non supervisé. Les deux types sont caractérisés par une phase d'apprentissage, dans la quelle on présente au réseau des formes d'entrées extraites d'une base d'apprentissage (Claude TOUZET, 1992).

II.8.1. Apprentissage supervisé:

Dans ce type d'apprentissage, un fonctionnement donné est imposée au réseau. les poids synaptiques modifiant pour minimiser l'erreur entre la sortie désirée et l'actuelle sortie du réseau. L'apprentissage est répété plusieurs fois jusqu'à ce que le réseau atteigne un état d'équilibre où il n'y a pas encore d'avantage de changer les poids. Le réseau se comporte alors comme un filtre dont les paramètres de transfert sont ajustés à partir des couples entrées/sorties présentés.

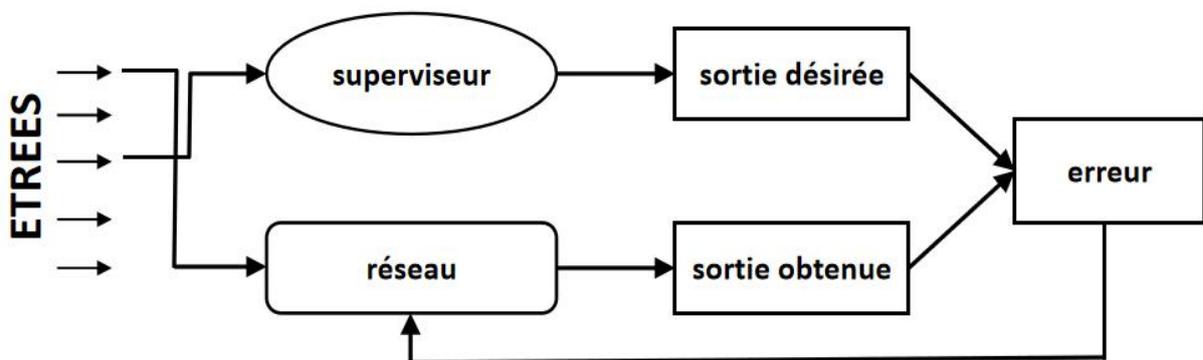


Figure II.13: Principe d'apprentissage supervisé.

II.8.2. Apprentissage non supervisé:

L'apprentissage non supervisé est un technique d'apprentissage automatique. Le RNA explore la structure sous-jacente dans les données, ou des corrélations entre les tendances dans les données, et organise des modèles en des catégories à partir de ces corrélations. Dans ce type d'apprentissage la sortie désirée du réseau n'est pas fixée.

II. Généralistes sur les réseaux de neurones artificiels

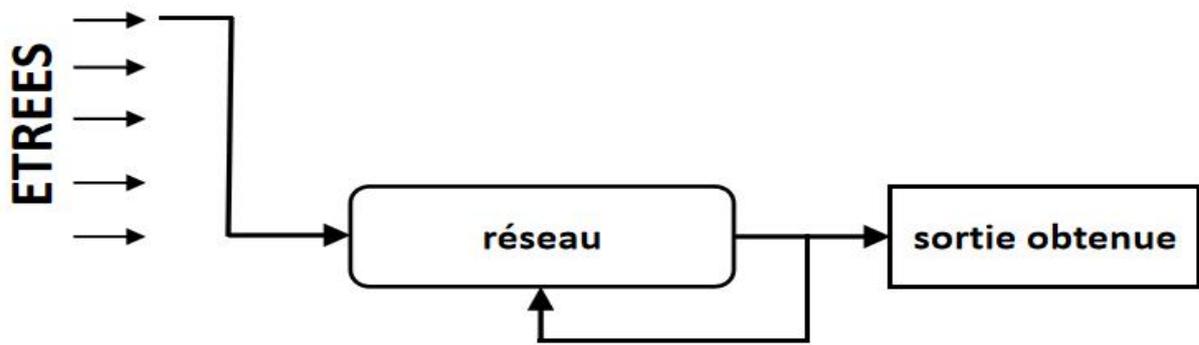


Figure II.14: Principe d'apprentissage supervisé.

Tableau II. : Classification des RNA les plus utilisés selon leurs types d'apprentissage.

Apprentissage	RNA
Supervisé	-Perceptron mono-couche SLP -Perceptron multicouches MLP -le réseaux RBF
Non-Supervisé	-Les cartes auto-organisatrices de Kohonen -Le réseau de Hopfield -Les réseaux ART

Les algorithmes d'apprentissages donnent de meilleurs résultats lorsqu'on leur fournit des exemples multiples et variés; ainsi le réseau peut assimiler toutes les connaissances. Ils existent différentes règles d'apprentissages parmi lesquelles on peut distinguer:

La règle de Widrow-Hoff,

La règle de Hebb,

La règle de Perceptron,

La règle de Grossberg,

II. Généralistes sur les réseaux de neurones artificiels

Algorithme rétro-propagation, ect...

Dans ce travail, nous appliquerons les réseaux MLP avec l'algorithme Levenberg-Marquardt.

II.9. Les réseaux à perceptron multicouches « PMC » :

Perceptron: est la forme la plus simple de réseau neuronal artificiel était composée d'un seul neurone modifié par des pondérations et doté d'une valeur seuil. Désormais, le terme « Perceptron » désigne aussi les réseaux à propagation avant à couche unique (perceptron monocouche).

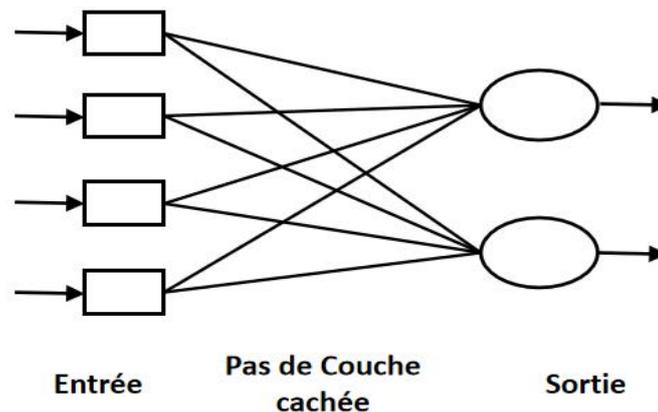


Figure II.9: Structure du perceptron monocouche.

Le PMC est une extension du perceptron monocouche qui dispose d'une ou de plusieurs couches cachées entre l'entrée et la sortie. Chaque neurone dans une couche est connecté à tous les neurones de la couche précédente et de la couche suivante (excepté pour les couches d'entrée et de sortie) et il n'y a pas de connexions entre les cellules d'une même couche. Le choix du nombre de couches cachées dépend généralement de la complexité du problème à résoudre. Les fonctions d'activation utilisées dans ce type de réseaux sont principalement les fonctions à seuil ou sigmoïdes.

II. Généralistes sur les réseaux de neurones artificiels

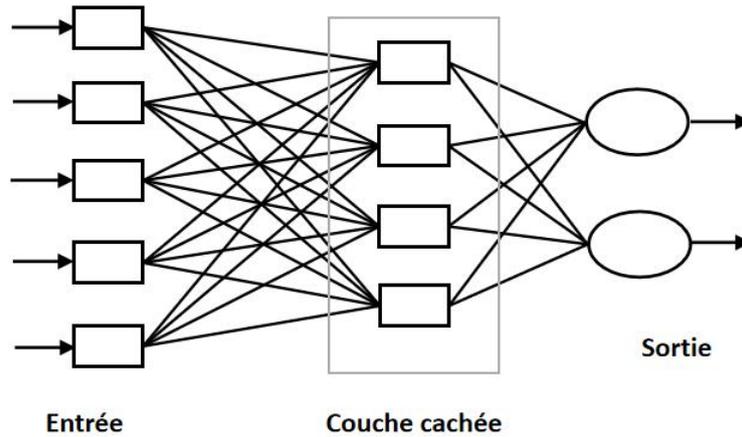


Figure II.10: Structure du perceptron multicouche.

II.10. Algorithme Levenberg-Marquardt:

L'algorithme d'apprentissage de Levenberg-Marquardt (LM) est une approximation de la méthode de Newton pour le réseau de neurones artificiels. La technique LM est connue pour être le meilleur algorithme pour les problèmes d'optimisation appliqués au réseau de neurones artificiels.

Lorsque la fonction de performance a la forme d'une somme de carrés (comme c'est généralement le cas dans la formation des réseaux anticipés), la matrice de Hessian peut être approximée comme suit:

$$H = j * j^T$$

et le gradient peut être calculé comme suit:

$$g = J^T e$$

L'algorithme de Levenberg-Marquardt utilise cette approximation de la matrice de Hessian dans la mise à jour de type Newton suivante:

$$X_{k+1} = X_k - [J * J + \mu I]^{-1} * J^T e$$

II. Généralistes sur les réseaux de neurones artificiels

En pratique, cet algorithme, en particulier dans le cas des réseaux de neurones, peut converger avec beaucoup moins d'itérations. Mais chaque itération nécessite plus de calculs, notamment pour l'inversion de la matrice, et donc, son utilisation est limitée aux cas où le nombre de paramètres à optimiser n'est pas très élevé. En effet, le nombre d'opérations nécessaires à une inversion de matrice est proportionnel à, comme la taille de la matrice, et également à la taille du vecteur ([Oudfeul, Aliouane, 2015](#)).

Chapitre III.

Prédiction du Carbone Organique Total par réseaux de neurones multicouches

III. Prédiction du carbone organique totale par réseaux de neurones multicouches

Introduction:

L'objectif principal de ce chapitre est de prédire le carbone organique total (COT) par les réseaux neurones multicouches (MLP). Le type de réseaux proposée est appliquée aux données de diagraphie de deux puits horizontaux forés dans le shale de Barnett.

Contexte géologique sur le shale de Barnett:

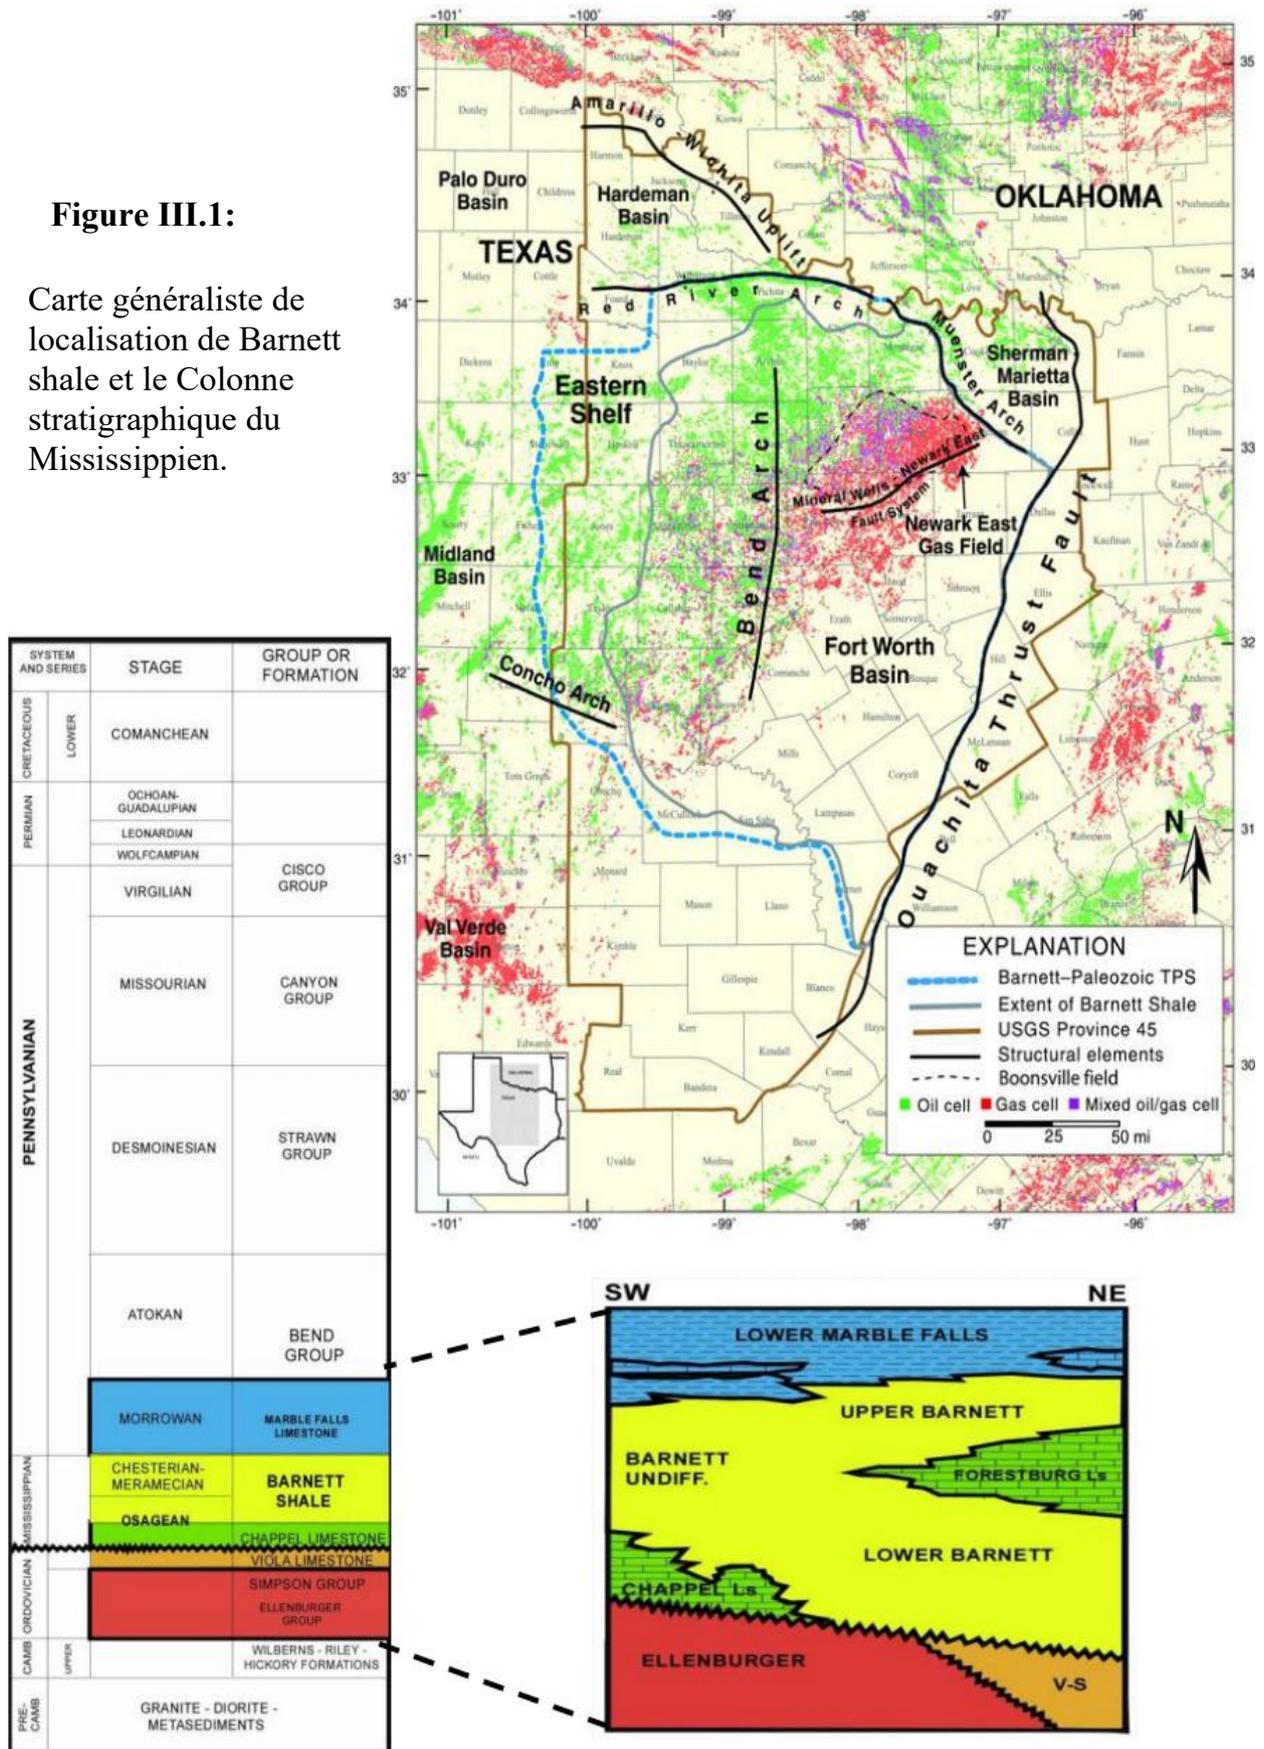
Le shale de Barnett est un dépôt située dans le bassin de Bend Arch-Fort Worth actuel le centre-nord du Texas à l'États Unis; été déposé à la fin de l'ère du Mississippien à une époque de transgression marine causée par la fermeture du bassin océanique d'Iapetus. vers le nord, le schiste de Barnett s'épaissit progressivement, atteignant plus de 400 pieds (122 m) dans le champ Newark East et plus de 1000 pieds (305 m) juste au sud de l'arche de Münster. Le Basin Fort Worth est délimité au nord, au nord-est et à l'est par des failles le soulèvement du sous-sol de l'Arche de la rivière Rouge, de l'arche de Muenster et du front structural d'Ouachita. La limite sud est définie par Llano Uplift (**Figure III.1**). Le shale de Barnett est le plus épais dans la partie nord-est du bassin de Fort Worth, où il est divisé en Upper et Lower Barnett par la formation calcaire intermédiaire de Forestburg ([Kent Bowker, 2009](#)).

Les schiste de Barnett sont des roches mères couvrent une superficie relative d'environ 5000 milles carrés à l'intérieur et autour de Fort Worth. Sur le plan lithologique, le shale de Barnett se compose de schiste siliceux, de calcaire et de dolomite mineure. En général, la formation est relativement riche en silice (35–50%, en volume), pauvre en minéraux argileux (<35%), riche en matière organique (TOC >4%) ([Kent Bowker, 2009](#)), une perméabilité de 100 à 600 nano-Darcies, une porosité de 2 à 6% et une teneur en gaz de 50 à 150 scf / tonne ([Schlumberger, 2010](#)). Le shale de Barnett est l'une des plus grandes réserves et des plus prospères aux États-Unis. Avant 2009, 70% de toute la production de gaz de schiste aux États-Unis provenait de Barnett ([Shale hand-book, 2015](#)). La zone la plus activement forée est le champ Newark-East.

III. Prédiction du carbone organique totale par réseaux de neurones multicouches

Figure III.1:

Carte généraliste de localisation de Barnett shale et le Colonne stratigraphique du Mississippien.



III. Prédiction du carbone organique totale par réseaux de neurones multicouches

Méthode et traitement des données:

Les données utilisées proviennent de de deux puits horizontaux forés dans lower Barnett. **Figure III.2**, montre la minéralogie et le COT après Perez, nous pouvons observer que lower Barnett est caractérisé par un COT élevé à bon. Les traces de minéralogie montrent qu'il est caractérisé par une forte teneur en quartz, ce qui est bon pour la fracture hydraulique. Le pourcentage de calcite est très faible; cependant, il a une teneur moyenne en argile. L'indice de brillance du lower Barnett est très élevé et toutes ces propriétés font du Barnett un bon shale play.

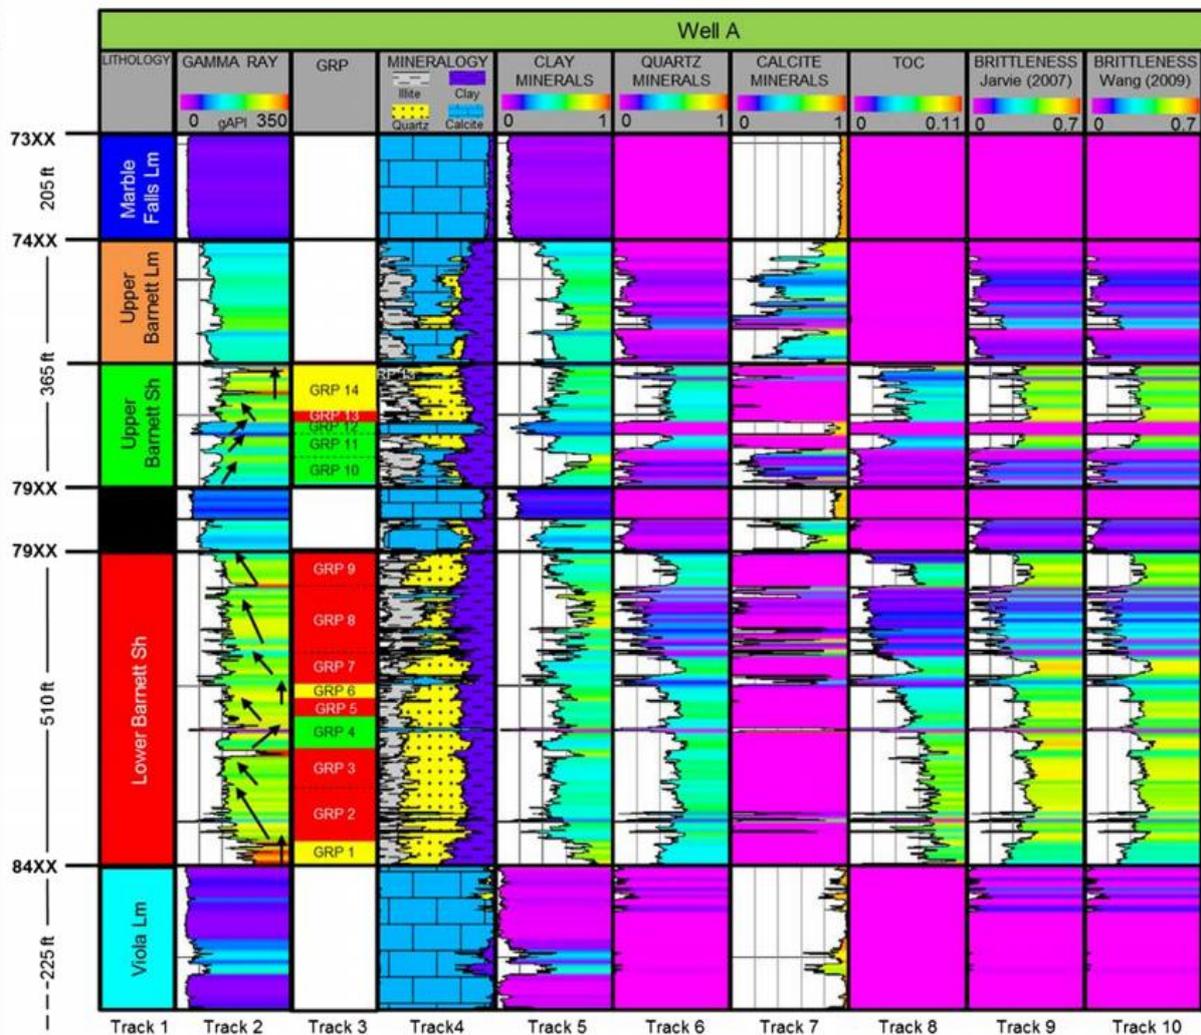


Figure III.2: La minéralogie et le COT après Perez.

III. Prédiction du carbone organique totale par réseaux de neurones multicouches

Les données du premier puits W01 utilisée pour l'apprentissage (**Figure III.3**), où la première piste présente la profondeur, la deuxième est le log Gamma, la troisième log est de densité apparente, la quatrième log est la porosité des neutrons, les cinquième et sixième pistes montrent les logs des ondes P et S, le dernier piste est le COT calculé en utilisant le modèle de Schmoker. Et les données du second puits W02 (**Figure III.6**) foré dans le voisinage du puits W01 sont utilisées pour la propagation.

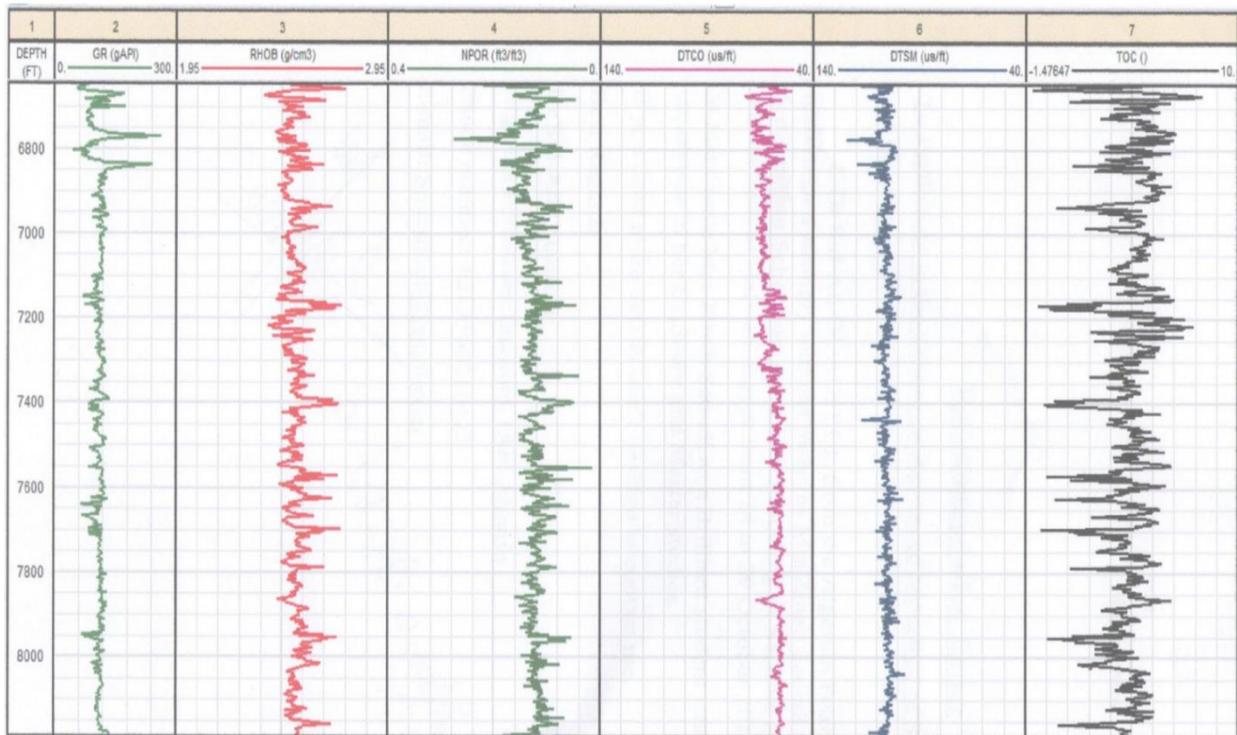


Figure III.3: Les données de puits horizontales W01 pour l'apprentissage.

Les Données de puits **W01** utilisées comme des entrées d'une machine MLP composée de trois couches, une couche d'entrée avec quatre neurones, une couche de sortie avec un neurone et une couche cachée avec dix neurones, et ce nombre est calculé après de nombreuses expériences numériques.

Dans ce cas, nous supposons que nous n'avons pas de log de densité (Rhob), et utilise les quatre diagraphies (GR), (NPOR), (DTCO) et (DTSM) comme entées et le table de COT qui obtenue à l'aide du modèle de Schmoker comme sortie pour entraîner le réseau de neurones MLP avec l'algorithme d'apprentissage de Levenberg–Marquardt.

III. Prédiction du carbone organique totale par réseaux de neurones multicouches

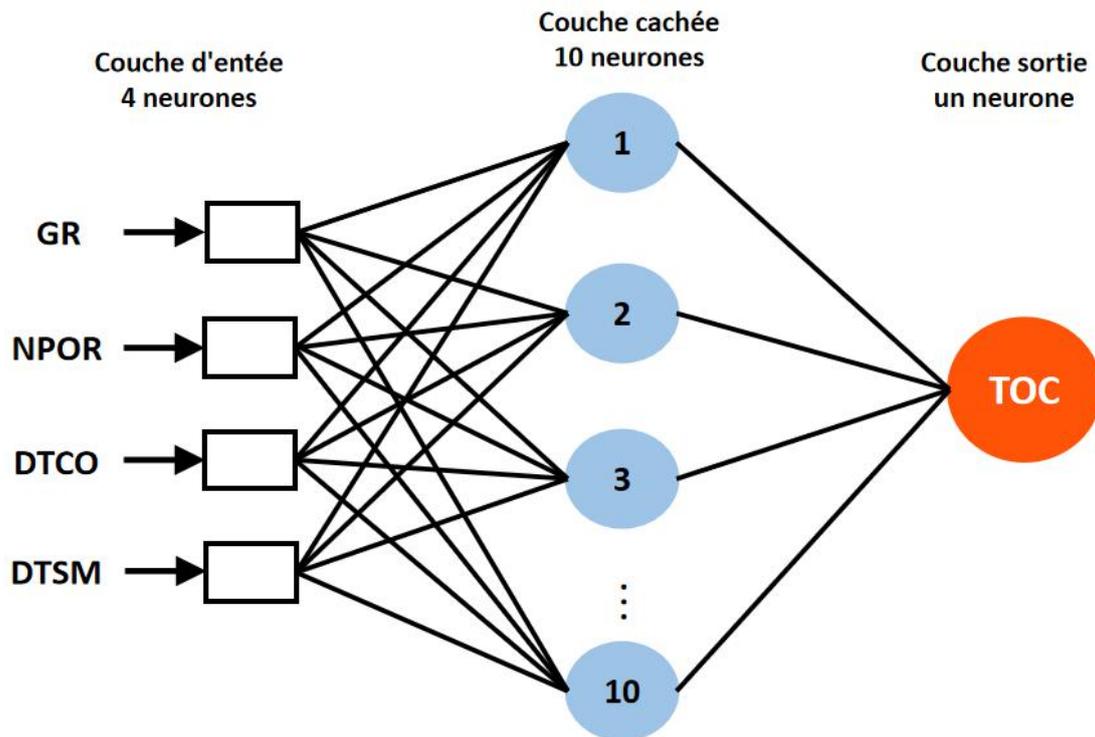


Figure III.4: Architecture de réseau du neurones multicouches MLP élaboré.

Au cours de l'apprentissage, l'erreur quadratique moyenne entre les sorties calculées et souhaitées est calculée (**Figure III.5**).

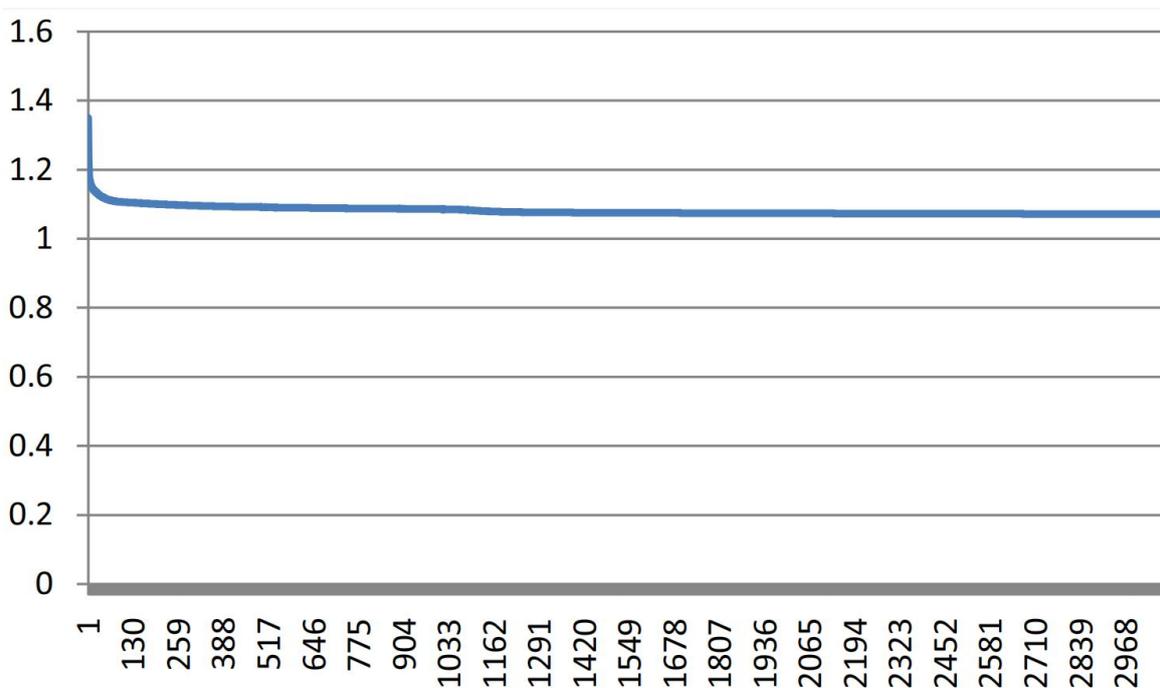


Figure III.5: Erreur quadratique moyenne par rapport au nombre d'itération.

III. Prédiction du carbone organique totale par réseaux de neurones multicouches

Pour vérifier l'efficacité de la machine du réseau neuronal, les données du deuxième puits horizontal W02 sont propagées à travers la machine neuronale en utilisant les poids de connexions calculés précédemment. Les données propagées à travers la machine neuronale ont le même type que celles utilisées comme entrée (**Figure III.6**).

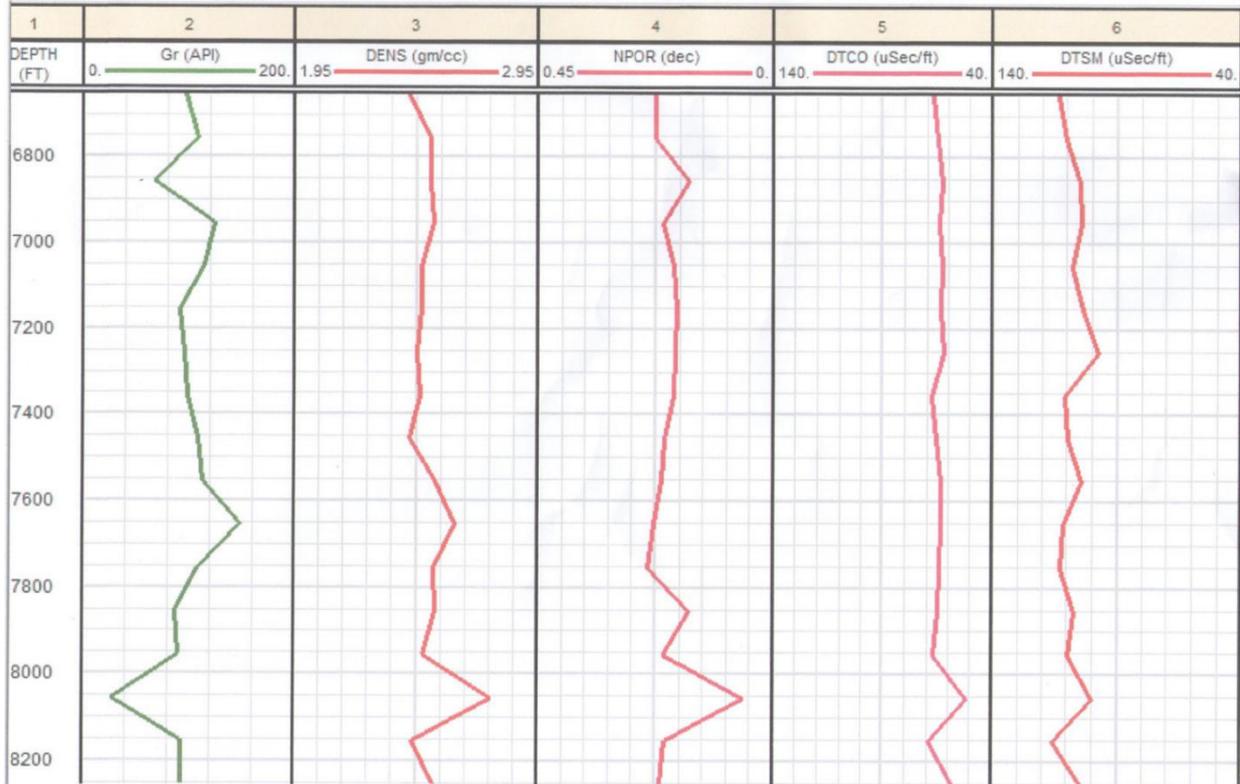


Figure III.6: Les données de puits horizontale **W02** foré dans le voisinage du puits **W01** pour la propagation.

III. Prédiction du carbone organique totale par réseaux de neurones multicouches

Résultat et Interprétation:

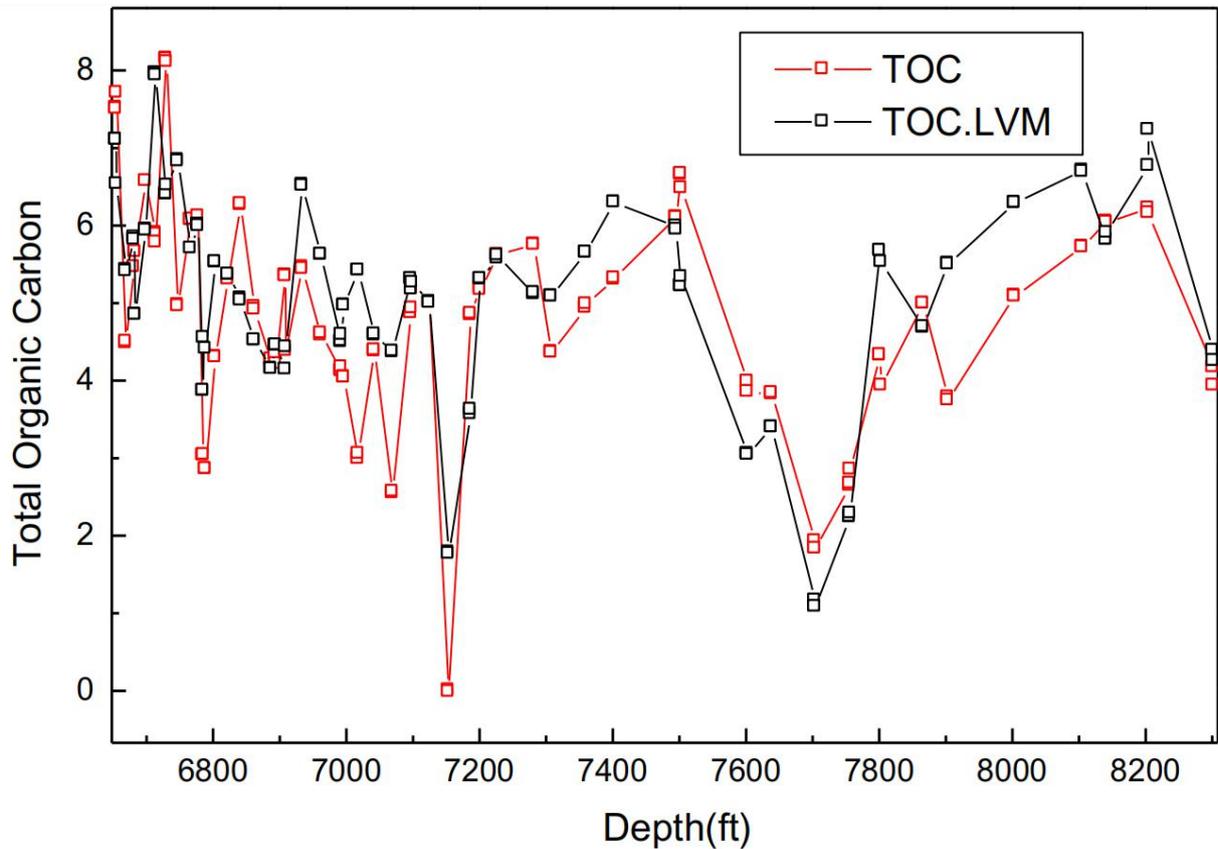


Figure III.7: COT calculé à l'aide du modèle de Schmoker comparé à la COT prédite à l'aide du MLP avec l'algorithme d'apprentissage Levenberg – Marquardt.

La figure III.7 montre clairement que la courbe du COT prédite par MLP avec l'algorithme d'apprentissage Levenberg–Marquardt dans le deuxième puits horizontal est presque totalement superposée sur le courbe du COT calculé à l'aide du modèle de Schmoker.

Conclusion générale

Conclusion générale

Les systèmes d'intelligences artificiels telle que les réseaux de neurones artificiels constituent des moyens très efficaces dans plusieurs domaines car ils offrent des possibilités intéressantes pour former des systèmes intégrés de bases de connaissances et qui sera le but d'un prochain travail. Les RNAs ont certaines caractéristiques puissantes dans le traitement des données et des informations et sont capables d'apprendre et de généraliser à partir d'exemples et d'expériences.

Ce travail a pour but de trouver une solution du problème de prédiction de carbone organique total (COT) dans les réservoirs shale gas à partir de données diagraphies à l'aide d'un réseau neurones multicouches en cas de l'absence de diagraphie de densité.

Avec les résultats obtenus, il est bien clair que la réseau de neurones multicouches MLP avec la topologie [4-10-1] et avec l'algorithme d'apprentissage Levenberg-Marquardt, a réussi à prédire le COT sans mesurer la densité apparente. Donc ce réseau de neurones présentant ces avantages peut être largement utilisée pour remplacer le modèle de Schmoker et pour fournir une valeur du COT en cas d'absence du diagraphie de densité ou d'une mesure discontinue de ce diagraphie.

Abbas Nassim et Djaalab Hamza, 2017, caractérisation des réservoirs compacts naturellement fracturés. cas du réservoir F6-1 du dévonien inférieur des gisements Ledjmet Hassi Messoud, mémoire de fin d'étude.

Achi N., 2015, Caractérisation d'un réservoir gréseux par simulation de Carottes Artificielles, mémoire de fin d'étude.

Ali Zerrouki Ahmed, 2015, Contribution à la caractérisation des réservoirs fissurés du champ de Hassi Messaoud par classement flou, réseaux de neurones artificiels et magnétisme des roches, thèse doctorat.

Boumad, B et Chicha. S, 2019, Caractérisation pétrophysique des réservoirs shale gaz, mémoire de fin d'étude.

Brakik, I & Nessah, A., 2018, Apport des données de diagraphies dans la caractérisation des réservoirs shale gaz : Cas du Lower Barnett USA, mémoire de fin d'étude.

Chabou Moulley Charaf, La Tectonique : déformation des matériaux de l'écorce terrestre, notion de cours.

Chadouli. K, 2013, Caractérisation pétrographique appliquée à la modélisation pétrolière : Etudes de cas.

Claude Touzet, 1992, Les réseaux de neurones artificiels.

El Mahdi Berkani, 2011, Réseaux de neurones artificiels appliqués à la méthode électromagnétique transitoire infini, Mémoire présenté à l'université du Québec à Chicoutimi comme exigence partielle de la maîtrise en ingénierie.

Gregory Chagnon, 2016, Characterization of rock mechanical properties using Lab Tests and Numerical Interpretation model of Well Logs.

Hiroki Sone, 2012, Mechanical properties of Shale gas reservoir rocks and its relation to the in-situ stress variation observed in Shale gas reservoirs,

Jonathan schuite, 2016, Apports des mesures de déformation de surface et de l'inclinométrie à la caractérisation pluri-échelle des réservoirs géologiques fracturés, Thèse de doctorat.

Kenneth E. Williams, 2013, Source Rock Reservoirs are a Unique Petroleum System, Halliburton.

Medjili Fayçal 2010, Modélisation par Réseaux de Neurones Artificiels (RNA) et commande Prédictive non linéaire d'une station de production d'eau froide, Mémoire de magister.

Références

Ouadfeul. S et Aliouane. L, 2014, Shale gas reservoirs characterization using Neural Network.

Shale gas handbook, 2015, A Norton Rose Fulbright guide.