

N° Série : /2021

Université Kasdi Merbah Ouargla



Faculté des hydrocarbures, énergies renouvelables et science de
la terre et de l'univers



Département de production des hydrocarbures

MEMOIRE

Pour obtenir le Diplôme de Master

Option: Production Académique

Présenté Par :

AD DJAZERA & ARIG RAYANE

-THEME-

**EVALUATION DES PERFORMANCES ET
L'ESTIMATION DES RESERVES DE LA ZONE
FISSUREE DANS LE CHAMP DE HASSI MESSAOUD**

Soutenue publiquement le : 20/06/2020 devant la commission d'examen :

Président	Mehassouel Ammar	MCA	Univ. Kasdi Merbah Ouargla
Examineur	Remita A/Raouf	MAA	Univ. Kasdi Merbah Ouargla
Encadreur	Brahmia Nabil	MCB	Univ. Kasdi Merbah Ouargla
Co-encadreur	Adjou Zakaria	Doctorant	Univ. Kasdi Merbah Ouargla

2021/2022

Remerciements

Nous tenons tout d'abord à remercier ALLAH le clément de nous avoir donné la force, la chance et la patience pour terminer ce modeste travail.

*Nous exprimons toute notre gratitude à **MrBrahmia Nabil** et **Mr Adjou Zakaria** pour la confiance qui nous ont témoigné en acceptant de suivre ce thème, leurs conseils, leurs sérieux et leurs disponibilités.*

Nous remercions la commission d'examen, d'avoir accepté d'examiner ce travail, pour leurs soutiens et leurs observations constrictives.

*Nos remerciements vont également à tout le personnel de la direction Sonatrach DP à **Hassi Messaoud** qui nous a guidés de réaliser ce travail, pour leur suivi avec patience leurs remarques qui nous ont été précieuses.*

Nous tenons aussi à dire un grand merci pour tous les enseignants, sans oublier l'équipe administrative du département de production des hydrocarbures de l'université d'Ouargla qui ont participé de près ou de loin à notre formation durant notre cursus d'étude.

Enfin, nous remercions nos ami(e)s pour nous avoir soutenus et encouragés pendant toutes ces années

Dédicace

Je dédie ce travail

*A ma très chère mère ... Qui m'a soutenu et encouragé
durant ces années d'études. Qu'elle trouve ici le témoignage
de ma profonde reconnaissance.*

*A mon très cher père Tu as toujours été à mes côtés pour me
soutenir et m'encourager.*

Que ce travail traduit ma gratitude et mon affection

*A mes frères, ma chère sœur, mes grands parents et ceux qui
ont partagé avec moi tous les moments d'émotion lors de
la réalisation de ce travail .ils m'ont chaleureusement
supporté et encouragé tout au long de mon parcours .*

*A ma familles, mes proches et à ceux qui me donnent de
l'amour et de la vivacité.*

*A tous mes amis qui m'ont toujours encouragé, et à qui je
souhaite plus de succès.*

A tous ceux que j'aime .Merci

Rayane

Dédicace

*A mes chers « Mama » « Baba »,
pour tous leurs sacrifices, leurs amour,
leurs tendresse,
leurs soutien et leurs prières tout au long
de mes études ,
A tout ma famille et mes amis (tissa et zineb)
pour leurs soutien tout au long de mon parcours
universitaire..
Merci d'être toujours là pour moi.*

Djazera

Résumé

L'estimation de la porosité des fractures, reste jusqu'à présent mal évaluée dans ce type de réservoirs (réservoir fissurée) , à cause de l'hétérogénéité de la distribution des fissures, ainsi que la difficulté de la mesurer directement au laboratoire. Les données de diagraphies donnent la possibilité de calculer la porosité de fractures des puits , Dans cette mémoire , on a donné des notions générales sur les fractures des réservoirs pétroliers, ainsi que des notions fondamentales de logiciel des réseaux de neurones et de logique floue.

Dans le cadre de ce travail, une méthodologie est proposée pour résoudre le problème de l'estimation de la porosité de fractures naturelles dans le cas d'absence d'enregistrement de diagraphies ou de paramètre de la boue de forage dans un puits pétrolier . Le méthode de classement flou est utilisé dans ce travail pour classer l'effet des données de diagraphies d'entrée du réseau de neurones (densité, gamma ray, porosité neutron et résistivité) sur la sortie désirée (porosité de fractures naturelles), et le réseau de neurones de type multicouche est utilisé pour déterminer la porosité des fissures à partir des données de diagraphies d'entrée.

Mots clés : réservoir fracturé, diagraphie, porosité de fractures, réseau de neurones, logique floue,

Abstract

The estimate of fracture porosity has so far remained poorly evaluated in this type of reservoir (cracked reservoir), due to the heterogeneity of the distribution of cracks, as well as the difficulty of measuring it directly in the laboratory. Logging data gives the possibility of calculating the porosity of well fractures In this thesis, we gave general notions on the fracturing of petroleum reservoirs, as well as fundamental notions of neural networks and fuzzy logique .

As part of this work, a methodology is proposed to solve the problem of estimating the porosity of natural fractures in the case of no logging or parameter recording of the drilling mud in an oil well. The fuzzy classification is used in this work to classify the effect of the neural network input log data (density, gamma ray, neutron porosity and resistivity) on the desired output (porosity of natural fractures), and the network of Multilayer type neurons are used to determine crack porosity from the input log **data.Key words:** fractured reservoir, logging, fracture porosity, neural network, fuzzy logic,

ملخص .

ان تقدير مسامية الكسر لم يتم تقييمه بشكل جيد حتى الآن في هذا النوع من الخزانات (الخزان المتصدع) ، وذلك بسبب عدم تجانس توزيع الشقوق ، وكذلك صعوبة قياسها مباشرة في المختبر. يوفر تسجيل البيانات القدرة على حساب مسامية كسر البئر ، في هذا العمل ، قدمنا مفاهيم عامة عن تصدعات الخزانات البترولية ، بالإضافة إلى المفاهيم الأساسية لبرنامج الشبكات العصبية والمنطق الضبابي . تم اقتراح منهجية لحل مشكلة تقدير مسامية الكسور الطبيعية في حالة عدم وجود التسجيلات البيانية أو تسجيل متغيرات طين الحفر في بئر النفط. تم استخدام طريقة التصنيف الغامض في هذا العمل لتصنيف تأثير بيانات الإدخال الشبكة العصبية (الكثافة ، أشعة جاما ، مسامية النيوترون والمقاومة) على المخرجات المرغوبة (مسامية الكسور الطبيعية) ، وشبكة الخلايا العصبية من النوع متعدد الطبقات. لتحديد مسامية الكسر من بيانات الإدخال .
الكلمات المفتاحية : الخزانات المتصدعة ، مسامية الشقوق ، برنامج الشبكات العصبونية، المنطق الضبابي،

Table des Matières

Remerciements	I
Dédicaces	II
Résumé	IV
Sommaire	V
Liste des figures	1
Liste des tables	1
Symboles – Abréviation	XII
Introduction générale	01

Chapitre I :

Présentation du champ Hassi Messaoud Et généralité sur les réserves fissurées

I.1. Introduction	03
I.1.1. Structure du champ	03
I.1.2. Représentation du réservoir	04
I.1.3. Caractéristiques du réservoir	04
I.1.4. Description de la série stratigraphie	05
I.2. Les réservoirs fissurés	06
I.2.1. Les fractures	06
I.2.2. Différents types de réservoir fracture	07
I.3. Méthodes d'estimation de la porosité	08
I.3.1. Les analyses des carottes	08
I.3.2. Les logs des diagraphies	09
I.3.3. Les tests de puits	09
I.4. Situation de la zone d'étude	10

Chapitre II :

Méthodes d'estimation de la porosité des fractures (logique floue & R.N.A)

II.1. Méthode du logique floue	11
II.1.1. Les avantages de la logique floue	11
II.1.2. Les Inconvénients de la logique floue	11

II.1.3. Les domaines d'applications de la logique floue	12
II.2.Sous-ensemble floue	12
II.2.1.Opérations sur les sous-ensembles flous	13
II.3.Système de logique floue	14
II.3.1. fuzzification	15
II.3.2. Les règles d'inférence floues	16
II.3.3. Défuzzification	16
II.4. Théorie du Classement floue	17
II.4.1. les application de classement floue	18
II.4.2. Normalisation des données	19
II.4.3. Algorithme	19
II.5.Méthode du réseau de neurones artificiel	20
II.5.1. les avantages des réseaux de neurones artificiels	21
II.5.2. L' inconvénients des réseaux de neurones artificiel	21
II.5.3 Conception d'un réseau de neurones	21
II.5.4. Principe du neurone artificiel	22
II.5.5. Architecture des réseaux de neurones	24
II.5.6. Les types d'apprentissage de réseaux de neurones	25
II.5.7.L'Algorithme de rétro propagation du gradient d'erreur	27

Chapitre III :

Application de la logique floue et des réseaux de neurones pour prédire la porosité de fractures naturelles (cas du la zone 1A .champ HMD)

Partie I : Analyse des données de diagraphies	29
Partie II : Présentation du logiciel de simulation (Mathlab)	30
Partie III : Application de la logique floue et des réseaux de neurones pour prédire la porosité de fractures naturelles	32
III.3.5. Méthode du classement floue	32
III.3.6.Méthode du réseau de neurones artificiel	35
Conclusion générale	40
Bibliographie	41

Liste des figures

Figure I.1. Situation géologique de CHAMP HASSI MESSOUDE	03
Figure I.2.Colonne Stratigraphie du champ HMD	05
Figure..I.3. Exemple de réservoir fracturé avec un réseau généré	07
Figure.I.4.Types de réservoirs fracturés	08
Figure I.5.Exemple Fractures enregistrées par l’outil UBI	09
Figure II.1.Représentation du sous-ensemble flou des petits entiers	13
Figure II.2.Exemple d’Operations sur des ensembles flous	14
Figure II.3.Fonctionnement d'un système flou	15
Figure II.4.Neurone artificiel	22
Figure II.5.Différents types de fonction de transfert pour le neurone artificiel	23
Figure II.6.Topologie des réseaux de neurones : (a) réseau de neurones non bouclé et (b) réseau de neurons	25
Figure II.7.Organigramme de conception d’un réseau de neurones	26
Figure III.1.Les données de diagraphies du puits#1	30
Figure III.2.fuzzy_logic designer	31
Figure III.3.neuro_fuzzy designer	31
Figure III.4.Corrélations entre porosité de fractures naturelles et données de diagraphies.	33
Figure III.5.Les courbes floues des données de diagraphies d’entrées.	34
Figure III.6.Performance du RNA après l’apprentissage	36
Figure III.7.Corrélation entre la porosité des fractures obtenue par réseau de neurones et celle calculée par diagraphie (phase d’apprentissage (puits#1))	36
Figure III.8.Corrélation entre la porosité de fractures naturelles obtenue par réseau de neurones et celle calculée par diagraphie : (a) phase d’apprentissage, (b) phase de test et (c) phase de généralisation	38
Figure III.9.Corrélation entre la porosité des fractures obtenue par réseau de neurones et celle calculée par diagraphie (phase de généralisation (puits#2))	39

Liste des tables

Tableau III.1. Classement des entrées diagraphiques par logique floue.	34
--	----

Symboles – Abréviation

HMD: Hassi Messaoud Est ;

X, Y: coordonnées [UTM] ;

K: perméabilité [mD] ;

Φ : porosité [%] ;

Nphi: porosité neutron [%] ;

ΔT : temps de transit [$\mu\text{s}/\text{ft}$] ;

Sw: saturation en eau [%] ;

Rhob: densité globale [g/cm^3] ;

GR: Rayons gamma [API] ;

RT: resistivity vraie [$\Omega \text{ m}$] ;

RN: Réseaux de neurones (neural network) ;

Nf: Neuro-flou (neuro-Fuzzy) ;

Yi: Y valeur à N ème échantillon; :

Y mean: Valeur moyenne des échantillons;

SSTotal: Somme totale des erreurs quadratiques;

CorPor: Porosité carotte;

MSE ; L'erreur quadratique moyenne

P_i^k : potentiel du neurone i pour l'exemple k,

W_U : poids de la connexion du neurone j vers le neurone i,

δ_i : seuil du neurone i,

S_i^k : signal de sortie du neurone i pour l'exemple k,

\emptyset : fonction de transfert.

RNA : réseaux de neurones artificiel

Introduction

Les énergies fossiles restent jusqu'à présent la source d'énergie la plus utilisée dans le monde et la demande sur cette matière fossilifère ne cesse d'augmenter. A cause des faibles découvertes de nouveaux champs pétroliers

L'intérêt actuel est de mieux exploiter les réservoirs prouvés, surtout les réservoirs non conventionnels. Les réservoirs généralement fracturées forment une catégorie de réservoirs tout à fait particulière, ils se caractérisent par une excellente productivité du pétrole,

En outre leur étude est très spécifique et complexe, dûe à l'existence d'une porosité et d'une perméabilité secondaire. L'étude de la fracturation des réservoirs est basée sur les différentes sources des données obtenues. [4] Ont estimé les fractures à partir des données sismiques, [9] ont utilisé des données de diagraphies de production pour estimer les dimensions des fractures. [18] Ont combiné les données géologiques, diagraphies d'imagerie, sismique induite et profil sismique vertical pour élaborer un modèle de fractures en 3D. Plusieurs techniques sont appliquées pour les estimer. [17] Ont détecté des fractures en appliquant la méthode de classements flous et les réseaux de neurones artificiels.

Problématique

Dans le champ de Hassi Messaoud, comme dans d'autres champs pétroliers beaucoup des puits forés, manquent l'un des enregistrements diagraphiques, ce qui rend le calcul de cette porosité par diagraphie impossible. La plupart de ces puits, sont soit en production, soit cimentés, ce qui rend l'enregistrement des paramètres diagraphiques manquant à nouveau difficile et coûteux.

Ce travail s'intègre dans la volonté de chercher les améliorations possibles qu'on peut utiliser pour estimer la porosité des fractures naturelles par le classement flou et les reseaux de neurones.

Méthodologie

Dans le cadre de ce travail, pour la première fois a notre connaissance, une méthodologie est proposée pour résoudre le problème de l'estimation de la porosité de fractures naturelles dans le cas d'absence d'enregistrement de diagraphies ou de paramètre de la boue de forage dans un puits pétrolier, en se basant sur le classement flou et les réseaux de neurones multicouches. Les données de diagraphies sont utilisées habituellement pour déterminer la

lithologie, la minéralogie et les paramètres pétrophysiques des puits. Le classement flou est utilisé dans ce travail pour classer l'effet des données de diagraphies d'entrée du réseau de neurones (densité, gamma ray, porosité neutron et résistivité) sur la sortie désirée (porosité de fractures naturelles), et le réseau de neurones de type multicouche est utilisé pour déterminer la porosité des fissures à partir des données de diagraphies d'entrée.

Objectifs de la recherche

Les principaux objectifs de ce travail sont :

- L'étude de la zone 1A dans le champ Hassi Messaoud
- Classer les données diagraphiques par la méthode de classement flou
- Estimation et généralisation de la porosité des fractures naturelles dans la zone 1A par la méthode de réseaux de neurones artificielles

Organisation du mémoire

Ce mémoire est structuré en trois chapitres, encadré par une introduction générale et une conclusion générale et recommandations :

Chapitre(I): Présentation du champ Hassi Messaoud

Chapitre(II): Méthodes d'estimation de la porosité des fractures naturelles

Chapitre(III) : Application de la logique floue et des réseaux de neurones pour prédire la porosité de fractures naturelles

C H A P I T R E

I

*Présentation du champ Hassi
Messaoud*

*Et généralité sur les réserves
fissurées*

I.1. Introduction

Le champ de Hassi Messaoud représente l'un des champs le plus complexes du monde, durant l'histoire géologique ce champ a subi d'une part une évolution tectonique intense caractérisée par des phases compressives et distinctives. D'autre par la transformation diagenétique dans le réservoir lors de son enfouissement au cours du temps géologiques, jusqu'au ce que le gisement a pris une forme tel qu'est représenté par la configuration actuelle. Ces évènements peuvent quelques fois améliorer les paramètres petro physiques (fracturation hydraulique naturelle, la dissolution etc....).

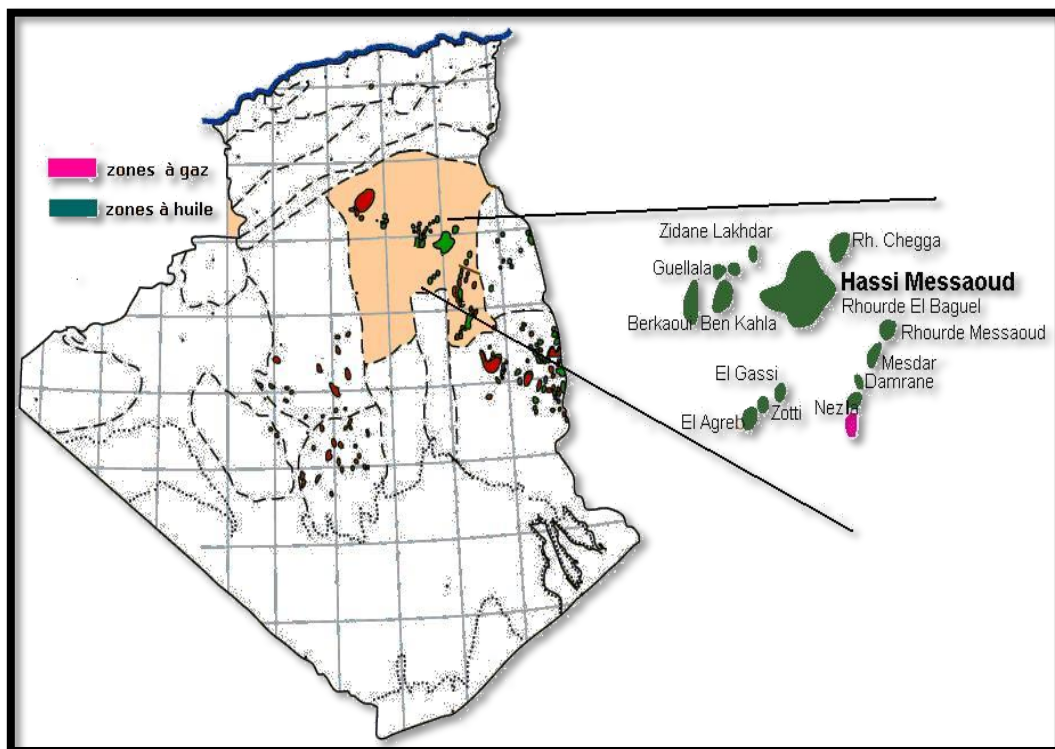


Figure I.1. Situation géologique de CHAMP HASSI MESSOUDE [4]

Le champ de Hassi Messaoud se situe à 650 km Sud / Sud-est d'Alger et à 350 km de la frontière tunisienne, sa localisation en coordonnées Lambert Sud Algérie est comme suite :

X = [790.000 - 840.000] Est.

Y = [110.000 - 150.000] Nord

I.1.1. Structure du champ

La structure de Hassi Messaoud se développe en un vaste anticlinal sub circulaire de 45 km de diamètre, de direction : Nord – Est/ SUD- Ouest. Il est

partiellement fissuré et les fissures sont dues aux mouvements tectoniques des plaques qui ont fait que la structure est devenue anticlinale. Les réservoirs ont subi une fracturation hydraulique naturelle.

Les accidents affectant le réservoir sont de deux types :

- ❖ Les failles de direction subméridienne et ainsi que les autres failles, perpendiculaires de direction Nord-Ouest / sud-est, font ressortir le caractère tectonique de la région.
- ❖ Les cassures sans rejets qui ont un grand effet sur la fracturation du réservoir

I.1.2. Représentation du reservoir

Le champ de Hassi Messaoud fait partie de la province orientale de la plate-forme saharienne. Cette province contient les principales accumulations d'hydrocarbures du Sahara ; les réservoirs sont principalement constitués par différents niveaux gréseux du Cambro-ordovicien et du Trias. Sa profondeur varie entre 3100 et 3380 m. Son épaisseur va jusqu'à 200 m. L'huile est légère avec un degré API de 45.4. Sa pression initiale évaluée dans le puits est de 482 kg/cm² pour un point de Bulle compris entre 140 kg/cm² et 200 kg/cm².

I.1.3. Caractéristiques Du Réservoir

Ses caractéristiques sont légèrement variables d'une zone à une autre en générale

[6]

- ❖ L'huile est légère de densité moyenne 0.8 (45° API).
- ❖ La pression de gisement : variable de 120 à 400 (kg/cm²).
- ❖ La température est de l'ordre de 120 °c.
- ❖ Le GOR de dissolution est de l'ordre de 219 (v/v), sauf pour les puits en percée de gaz où le GOR peut dépasser 1000 (v/v).
- ❖ La porosité est faible, elle est de l'ordre de 5 à 10%.
- ❖ La perméabilité varie de 0.1 md à 1000 md.
- ❖ Contact huile/eau : ≈ - 3380 m.
- ❖ Point de Bulle : 140 à 200 kg/cm².
- ❖ Côte de référence : ≈ - 3200 m.
- ❖ L'épaisseur de la zone productive peut atteindre 120m au maximum mais peut également être nulle.
- ❖ La saturation en huile est de 80 % à 90 % maximum.

I.1.4. Description de la série stratigraphie

Dans la figure dessous (fig I.2)

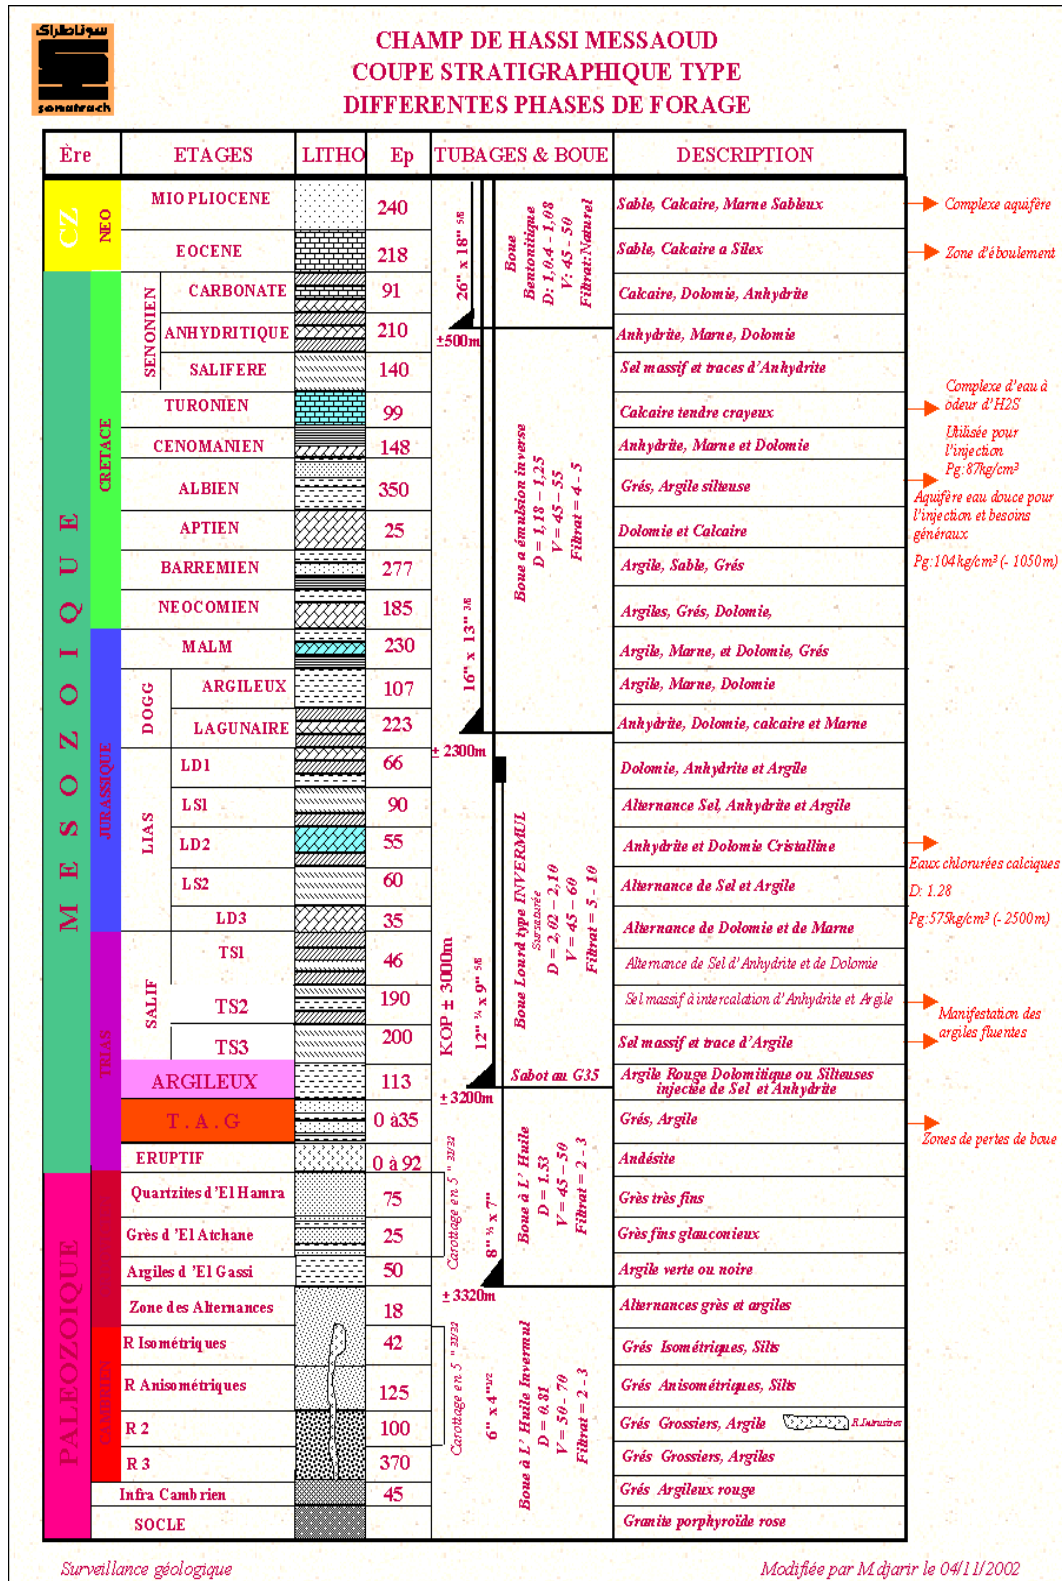


Figure I.2. Colonne Stratigraphie du champ HMD [4]

I.2.Réservoir fissurée

Les réservoirs fissurés englobent tous les réservoirs conventionnels qui contiennent des discontinuités suffisamment nombreuses et connectées pour modifier substantiellement les écoulements. Ces réservoirs représentent plus de 50% des réservoirs pétroliers et contribuent efficacement à une grande proportion dans la production de pétrole et de gaz à travers le monde. Les fractures sont définies comme des discontinuités dans les roches, et elles apparaissent sous la forme de cassures locales dans la séquence naturelle des propriétés de la roche. Les fractures représentent des défaillances mécaniques de la résistance de la roche due aux contraintes géologiques naturelles, telles que mouvements tectoniques, changements litho statiques de la pression, contraintes thermiques à haute pression de fluide, activité de forage, et même retrait du fluide .L'étude des réservoirs fracturés est différente de l'étude des réservoirs matriciels. Elle nécessite l'intégration des fractures dans toutes les étapes de l'étude du réservoir pour l'évaluer correctement. La tendance générale d'ignorer l'effet et la présence de fractures naturelles n'est pas bonne, elle conduit parfois à des pertes irréparables du facteur de récupération, Au cours de ces dernières années, beaucoup d'efforts ont été faits pour étudier ce type de réservoirs. À estimer la densité de fractures dans des puits en se basant sur les réseaux de neurones artificiels ; et ont estimé les fractures en combinant les réseaux de neurones et les algorithmes génétiques. Le rôle des fractures et leur importance dans l'accumulation d'huile sont étudiés en se basant sur les données sismique 3D. Dans cette partie des notions théoriques sur les réservoirs fracturés ainsi que des généralités sur la zone d'étude.

I.2.1. Les fractures

Le mouvement continu des plaques tectoniques provoque des accidents géologiques dans les différentes couches sédimentaires. La conséquence de ces accidents peut se manifester sous forme de discontinuités au niveau des différentes couches géologiques. On parle ici de fractures et failles. On donne dans la Figure 3 un exemple de réservoir fracturé.




Figure.I.3.Exemple de réservoir fracturé avec un réseau généré statistiquement [7]

I.2.2. Différents types de réservoir fracturé

Les réservoirs fracturés sont classés en fonction de la contribution des fractures dans la porosité et la perméabilité du réservoir en quatre types suivants (Fig.I.4):

Type I: Les fractures fournissent l'essentiel de la porosité et de la perméabilité du réservoir. Dans ce type de réservoir, le calcul de la porosité de fractures où le volume de fractures par puits a une importance primordiale. La connaissance précise de ce volume doit être acquise dès que possible pour évaluer les réserves totales obtenues par puits et de prédire si les débits initiaux élevés seront maintenus ou diminueront rapidement avec le temps.. Parmi les réservoirs fracturés on trouve le champ d'Amal en Libye, Iapaz et Mara au Venezuela et les réservoirs précambrien dans l'est de la Chine. [1]

Type II: Les fractures fournissent l'essentiel de la perméabilité du réservoir à l'exemple des champs de Kirkuk en Iraq et Asmari en Iran

Type III: Les fractures aident à la perméabilité dans les réservoirs productifs : ce type de réservoir est rencontré dans le champ de Monterey en Californie et le réservoir Spraberry dans l'ouest du Texas.

Type IV: La fracture ne fournit pas une porosité additionnelle ou une perméabilité supplémentaire, mais elle crée une importante anisotropie du réservoir (barrière de perméabilité). Ces champs sont parfois non rentables du point de vue économique

pour pouvoir les développer. Les calculs précis de la porosité de fractures dans les réservoirs fracturés de type II et III sont moins importants parce que le système de fracture ne fournit que la perméabilité

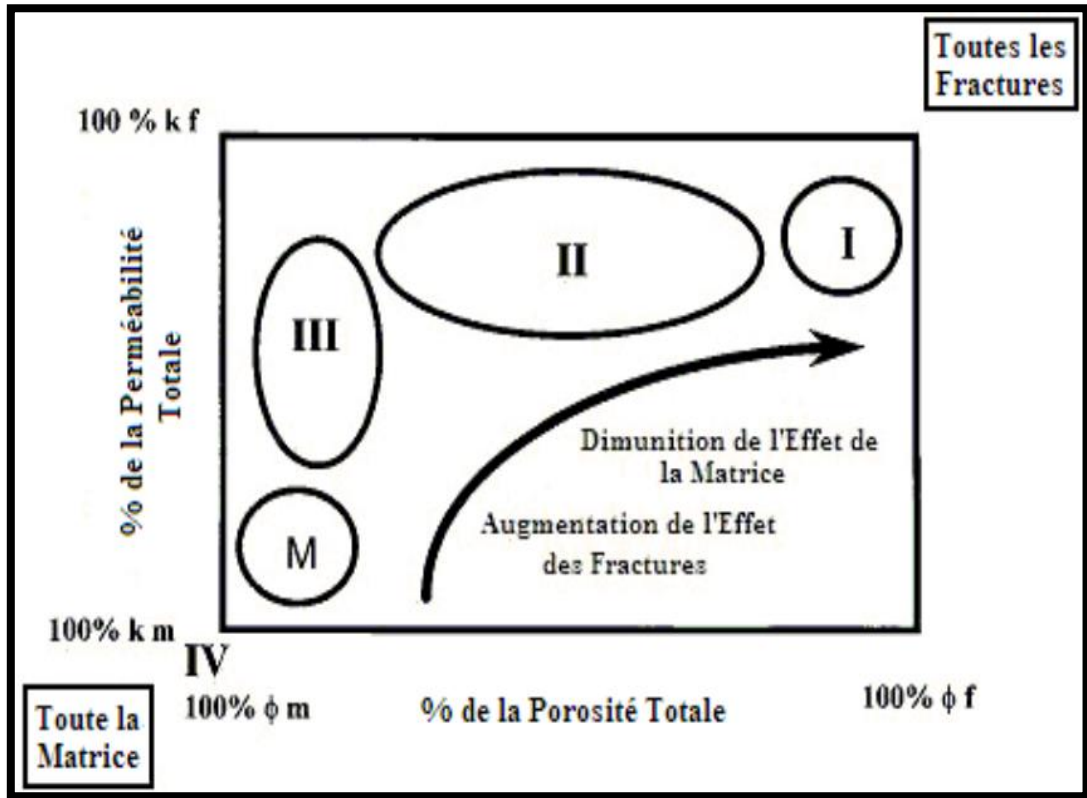


Figure.I.4.:Types de réservoirs fracturés [1]

I.3. Méthodes d'estimation de la porosité de fractures naturelles

I.3.1. Les analyses des carottes

L'analyse des carottes consiste à faire une analyse détaillée des fractures apparues sur les carottes de puits de forage. Elle nous permet de mesurer l'ouverture, le degré de remplissage, la longueur, l'orientation par rapport à la verticale et l'azimut du plan de fissuration, .La connaissance de la largeur et le nombre de fractures dans les carottes permettent d'estimer la porosité de fractures à l'aide des équations empiriques. Dans la plupart des champs pétroliers en Algérie, les carottes de puits ne sont pas orientées, ce qui rend la mesure de l'orientation et l'azimut de fractures difficile.

I.3.2. Les logs des diagraphie

Les logs de diagraphies enregistrés par les outils d'imagerie telle qu'UBI (Ultra sonique Borehole Imager) permettent de détecter les fractures dans les puits étudiés (Fig.I.5). On peut connaître leurs localisations, leurs types (fermé, ouvert ou partiellement ouverte) et leurs orientations. , Le calcul de cette porosité n'est possible qu'à partir de la détermination de la porosité totale et secondaire,




Figure I.5. Exemple Fractures enregistrées par l'outil UBI [1]

I.3.3. Les tests de puits

Les tests de puits fournissent les paramètres essentiels d'un réservoir fracturé, telle que la porosité et la perméabilité de fractures, la capacité des fissures et la direction générale de l'anisotropie de la perméabilité. D'autres paramètres sont obtenus par l'analyse de la pression transitoire, l'essai d'impulsion de pression, et les essais d'interférence, qui définissent les propriétés de la fracture dans une réponse de court terme, et les propriétés de la matrice dans un écoulement de fluide à long terme. En plus de ces méthodes, il existe d'autres méthodes que nous étudierons, telles que classement flou de réseaux de neurons

I.4. Situation de la zone d'étude

La région de Hassi Messaoud est située dans la partie centrale de la Sahara algérien, et est connu pour ses puits producteurs de pétrole, principalement des réservoirs cambriens. Le super-géant Hassi Messaoud champ est un dôme couvrant une superficie de près de 1600 km². L'étude la zone est composée de trois zones, 1A, 1B et 1C; les puits étudiés sont situés dans la zone 1A est située dans la partie sud-ouest du champ de Hassi Messaoud (FigIII.1.). Le réservoir principal dans cette zone est le drain D4 qui se caractérise par une variation des faciès mal connus et très hétérogènes par rapport aux autres drains (Fig. 3). Et Les gisements cambriens, qui sont représentés par les grès et les quartzites, sont les plus connus et forment les principaux réservoirs (Cambrien Ra et Ri). . Le réservoir anisométrique offre de meilleures caractéristiques pétro physiques, il est célèbre pour la production de pétrole dans les réservoirs cambriens ; leur porosité et perméabilité varient de 5% à 10% et de 1 à 50 mD respectivement. L'analyse de base montre que de nombreux puits dans le réservoir est fracturé.

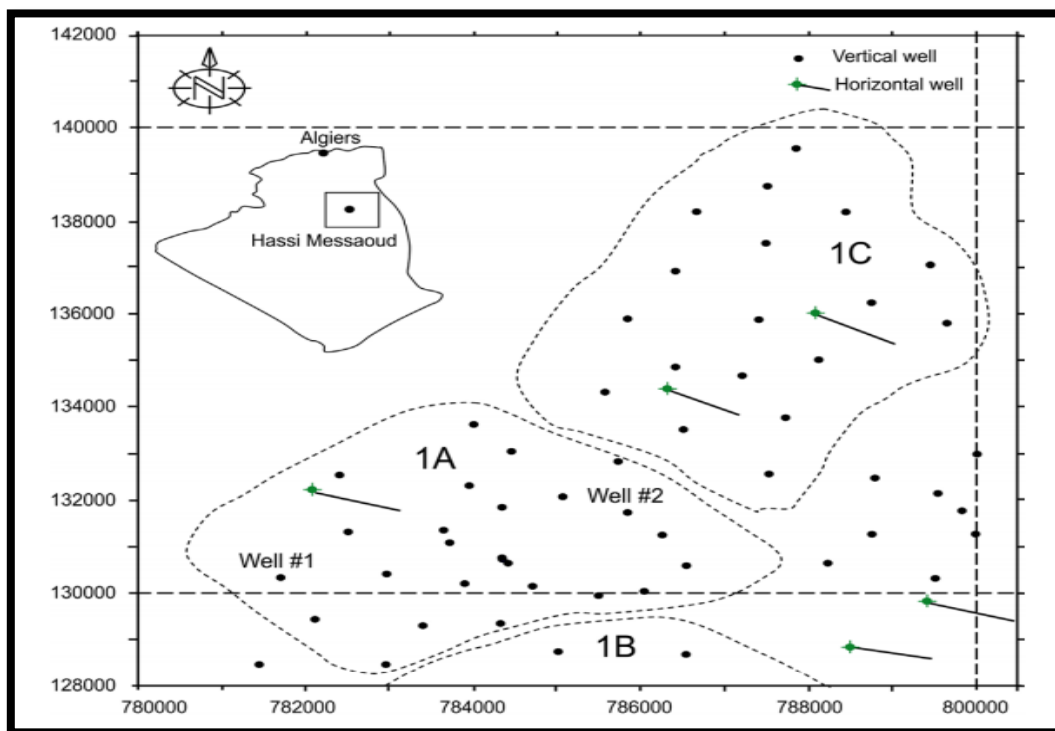


Figure I.6 . Localisation de la zone d'étude dans le champ pétrolifère de Hassi Messaoud. [1]

C H A P I T R E

II

*Méthodes d'estimation de la
porosité des fractures
naturelles*

(logique floue & R.N.A)

II.1. Méthode du la logique floue

II.1.1.Introduction

Au départ théorie, la logique floue s'affirme comme une technique opérationnelle. Utilisée à côté d'autres techniques de contrôle avancé, elle fait une entrée discrète mais appréciée dans les automatismes de contrôle industriel.

La logique floue (fuzzy logic, en anglais) est une logique polyvalente où les valeurs de vérité des variables - au lieu d'être vrai ou faux - sont des réels entre 0 et 1. En ce sens, elle étend la logique booléenne classique avec des valeurs de vérités partielles¹. Elle consiste à tenir compte de divers facteurs numériques pour aboutir à une décision qu'on souhaite acceptable.

Les bases théoriques de la logique floue (fuzzy logic) ont été établies au début des années 1965 par le professeur Zadeh de l'université de Californie de Berkeley.

Il s'agit d'une approche calquée sur le raisonnement humain plutôt que sur des calculs rigides ; pour des problèmes mal définis, l'être humain est irremplaçable.

II.1.2.Les avantages de la logique floue

Un avantage certain à travailler en logique floue [29] :

- Cette méthode est très utile lorsque l'on se trouve confronté à des systèmes qui ne sont pas, ou difficilement modélisable.
- Cette méthode est très avantageuse si l'on possède un bon niveau d'expertise humaine. Plus l'expertise humaine d'un système est importante et plus on est capable d'ajouter des règles d'inférences au système.

II.1.3. L'Inconvénients de la logique floue

Cette méthode présente divers inconvénients [29] :

- Le fait d'exprimer ses connaissances sous la forme de règles en langage naturel (et donc qualitative) ne permet pas de prouver que le système aura un comportement optimal.
- Tous les réglages que le programmeur doit entrer au système se fait de façon totalement ad-hoc. Cette méthode ne peut donc pas garantir que le système soit stable, précis ou optimal.

II.1.4. Les domaines d'applications de la logique floue

Les domaines d'applications de la logique floue sont très nombreux. On la retrouve [29] :

- En automatique, pour faire de la commande et de la régulation floue, etc.
- En traitement du signal, pour faire de la fusion de données, de la classification, de la reconnaissance de forme ou de la recherche d'information, etc.
- En robotique, pour faire de la planification de trajectoire, etc.
- En traitement d'image, pour atténuer le bruit d'une image, pour faire de l'interpolation, etc...

En effet, le mode de raisonnement en logique floue est plus intuitif que la logique classique. Il permet aux concepteurs de mieux appréhender les phénomènes naturels, imprécis et difficilement modélisables en s'appuyant sur la définition de règles et de fonctions d'appartenance à des ensembles dits « ensembles flous ».

II.2.Sous-ensemble floue

Les sous-ensembles flous sont des méthodes mathématiques pour représenter l'imprécision de la langue naturelle, ils peuvent être considérés comme une généralisation de la théorie des ensembles classiques.

Un sous-ensemble floue A de X est défini par une fonction d'appartenance qui associe à chaque élément x de X le degré $\mu_A(x)$, compris entre 0 et 1, avec lequel x appartient à A . Dans le cas particulier où $\mu_A(x)$ ne prend que des valeurs égales à 0 ou à 1, le sous-ensemble flou A est un sous-ensemble classique de X . Un sous-ensemble classique est donc un cas particulier des sous-ensembles flous [5]

Un exemple : Soit S un ensemble des entiers positifs et F un sous-ensemble flou de petits entiers. Des entiers peuvent avoir une distribution de probabilité qui indiquent leur appartenance au sous-ensemble flou F : $\mu_F(1) = 1.0$, $\mu_F(2) = 1.0$, $\mu_F(3) = 0.9$, ... $\mu_F(30) = 0.01$.




Figure II.1 : Représentation du sous-ensemble flou U_F des petits entiers [16]

La figure (II.1) Montre cette fonction d'appartenance. Dans la théorie des ensembles flous, l'ensemble flou ' A de X (ou' X est l'univers d'étude)

Où' $\mu_A(x) = 1$ si x est totalement dans A, $\mu_A(x) = 0$ si x n'est pas dans A et

$0 < \mu_A(x) < 1$ si x est partiellement dans A.

II.2.1. Opérations sur les sous-ensembles flous

Les opérations flous décrivent comment des ensembles flous interagissent ensembles. On regardera certaines opérations communes, comme le complément, l'intersection et l'union :

- Intersection de sous-ensembles flous : l'intersection de deux sous-ensembles flous A et B de X est définie par :

$$\forall x \in \mu_{A \cap B}(x) = \min(\mu_A(x), \mu_B(x)) \dots\dots\dots(\text{II.1})$$

- Union des sous-ensembles flous : l'union de deux sous-ensembles flous A et B de X est donnée par :

$$\forall x \in \mu_{A \cup B} = \max(\mu_A(x), \mu_B(x)) \dots\dots\dots(\text{II.2})$$

- Complément de sous-ensemble flou A : le complément de sous-ensemble flou A de X est noté $\neg A$ est défini par :

$$\forall x \in \mu_{\neg A} = 1 - (\mu_A(x)) \dots\dots\dots(\text{II.3})$$

La figure (II.2) résume ces opérations, de façon graphique.




Figure II.2 : Exemple d'Opérations sur des ensembles flous [27]

II.3.Système de logique floue

Les systèmes de contrôle d'aujourd'hui sont généralement décrits par des modèles mathématiques qui suivent les lois de la physique des modèles ou des modèles stochastiques qui ont émergé de la logique mathématique. Une difficulté générale de ce modèle construit est de savoir comment passer d'un problème donné à un modèle mathématique approprié. Sans aucun doute d'après la technologie informatique de pointe d'aujourd'hui mais la gestion de ces systèmes est encore trop complexe. [16]

Les analyses et les méthodes de contrôle de la logique floue (Fig. II.3) peuvent être décrites.

Comme suit :

1. La réception d'un grand nombre de mesures ou d'autres évaluations des conditions existantes dans un système qui sera analysé ou contrôlé.
2. Les traitements ont tous reçu des contributions basées, règles floues "If-then", qui peut être exprimées par des mots de la langue simples et combinés avec un traitement non floue traditionnelle.
3. La compensation et la pondération des résultats de toutes les règles individuelles en une seule décision de sortie unique ou un signal qui

décide ce qu'il faut faire ou dit un système contrôlé. Le signal de sortie du résultat est une valeur précise "défuzzifiée".

4. Le graphe est le schéma de la Logique floue de la méthode d'analyses de contrôle.

Afin de la faire fonctionner, la logique floue a besoin d'être représentée par des nombres ou des descriptions. Habituellement le système flou de contrôle logique est créé à partir de trois éléments

majeurs présentés (II.3): fuzzification, règles d'inférence et défuzzification

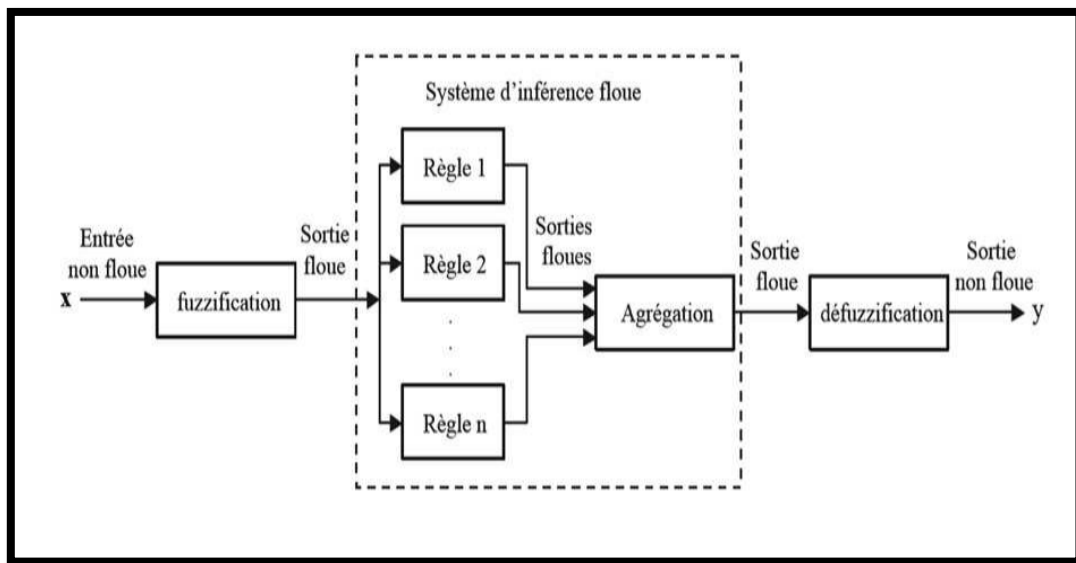


Figure II.3 : Fonctionnement d'un système flou.[29]

II.3.1.Fuzzification

La fuzzification est la première opération dans un processus utilisant la logique floue. L'opération de fuzzification permet de passer du domaine réel au domaine flou. Elle consiste à déterminer le degré d'appartenance d'une valeur numérique à un ensemble flou. A chaque variable d'entrée et de sortie est associé un sous-ensemble caractérisé par des termes linguistiques (appelés aussi variables linguistiques), en utilisant des règles sémantiques définies par un expert. La fonction d'appartenance est utilisée pour associer un degré d'appartenance à chaque terme linguistique [1] :

- a) Variables linguistiques (variables floues)

La description d'une certaine situation, d'un phénomène ou d'un procédé contient en général des qualificatifs flous tels que :

- * peu, beaucoup, énormément
- * rarement, fréquemment, souvent
- * froid, tiède, chaud
- * petit, moyen, grand
- * etc.....

b) *Fonction d'appartenance*

Au lieu d'appartenir à l'ensemble « vrai » ou à l'ensemble « faux » de la logique binaire traditionnelle, la logique floue admet des degrés d'appartenance à un ensemble donné. Le degré d'appartenance à un ensemble flou est matérialisé par un nombre compris entre 0 et 1. [28]

Une valeur précise de la fonction d'appartenance liée à une valeur de la variable est notée μ et appelée « facteur d'appartenance ».

II.3.2. Les règles d'inférence floues

Les règles d'inférence floues ou l'inférence floue est le processus de formulation de la relation entre les entrées et les sorties par la logique floue. Cette relation offre une base avec laquelle la décision est prise par le système flou. L'inférence floue fait appel alors aux concepts de fonctions d'appartenance, d'implication floue et des règles floues. Plusieurs valeurs de variables linguistiques sont liées entre elles par des règles et permettent de tirer des conclusions. Les règles peuvent alors être exprimées sous la forme générale. [1]

Les systèmes à logique floue utilisent une expertise exprimée sous forme d'une base de règles du type: Si....Alors...

Si (X est A) Alors (Y est B)

Si condition 1 alors action 1

Si condition 2 alors action 2

Si Si condition n alors action n

Exp : Si Temps est beau et Moment est Début Matinée ALORS Morales est haut

Si la température élevée et la pression élevée alors ouvrir la vanne.

II.3.3. Défuzzification

La tâche " Défuzzification " consiste à trouver une valeur unique non floue qui résume l'ensemble floue.

Les méthodes d'inférence fournissent une fonction d'appartenance résultante μ_R de la variable de sortie X_r . Il s'agit donc d'une information floue. Il faut transformer cette information floue en une valeur déterminée qui sera appliquée à l'interface de commande du processus. C'est cette transformation qui est appelée défuzzification. La méthode de défuzzification la plus utilisée est celle de la détermination du centre de gravité [16] :

La méthode du centre de gravité (COG)

La défuzzification par centre de gravité consiste à calculer l'abscisse du centre de gravité de la fonction d'appartenance. Par comparaison avec la méthode du centre de maximum, les résultats sont très stables vis-à-vis des variations minimales des sous-ensembles flous, mais d'un autre côté, elle exige une plus grande puissance de calcul. La valeur x obtenue par la défuzzification est calculée par la formule [10] :

$$Z_0 = \frac{\int U_i(x) x ds}{\int U_i(x) dx} \dots \dots \dots (II.4)$$

où Z_0 est la sortie défuzzifiée, U_i est une fonction d'appartenance et X est la variable de sortie.

II.4. Théorie du Classement floue

L'idée originale de Zadeh (1965) pour la logique floue peut être conceptualisée comme une généralisation de la logique classique pour modéliser des complexes systèmes avec un modèle de paramètres qui peuvent être exprimés par un ensemble de règles floues.[8] .

Une caractéristique importante de la logique floue est la possibilité d'utiliser des outils (utilisant des fonctions d'appartenance floue) pour quantifier l'incertitude. [12], ont développé une nouvelle approche bien adaptée classement des systèmes non linéaires à partir des données d'entrée-sortie. L'objectif de cette méthode consiste à prédire y (porosité naturelle de la fracture), lorsque X_i (les variables de journal de puits d'entrée (GR, ILD, Rhob, phin)) changent légèrement dans un quartier proche de X_i, k . La méthode fonctionne tout d'abord en construisant une

fonction d'appartenance floue, cette fuzzification des données est réalisée à travers une fonction Gaussienne :

$$\mu_{i,k}(x_i) = \exp(-(x_{i,k} - x_i)/b)^2 \dots\dots\dots(II.5)$$

Telle que $k = 1, 2, \dots, M$ et b est généralement constant pris comme 10% de la Longueur de l'intervalle d'entrée X_i [14].

La courbe floue (C_i) est obtenue après la déffuzzification de la fonction d'appartenance floue :

$$C_i(x_{i,k}) = \frac{\sum_{k=1}^M Y_k \times \mu_{i,k}(x_i)}{\sum_{i=1}^N \mu_{i,k}(x_i)} \dots\dots\dots(II.6)$$

L'erreur quadratique moyenne entre les courbes floues et les sorties originales est:

$$MSE_{ci} = \frac{1}{M} \sum_{k=1}^M (C_i(x_i, k) - y)^2 \dots\dots\dots(II.7)$$

Il indique la valeur attendue du carré de la différence entre la valeur estimée du paramètre et la valeur réelle du paramètre

L'erreur quadratique moyenne peut évaluer le degré de changement des données, plus la valeur MSE est petite, meilleure est la précision du modèle de prédiction pour décrire les données expérimentales.[16]

Nous utilisons l'erreur quadratique moyenne entre chaque courbe floue (C_i) et les données de sortie pour classer les variables d'entrée selon leurs degrés d'importance sur la sortie.

La méthode de la courbe floue fonctionne très bien dans identifier l'importance des entrées [19], et sélectionner la meilleure entrée associée (données de puits) avec la sortie (coré porosité et perméabilité). Le classement flou est utilisé pour classer les différents moteurs géologiques et géo mécaniques avec l'indice de fracture correspondant [11].

II.4.1. Les applications de classement floue

Cette technique a été utilisée pour :

- Classer les données pétrographiques pour estimer la perméabilité [8]
- Classer 30 paramètres qui affectent l'estimation des crues d'eau [13]

- Evaluer la hiérarchie effect cial des facteurs géologique (structure , épaisseur du lit et lithologie) sur les fractures [14]

II.4.2. Normalisation des données

Normalisation de l'entrée et de la sortie des ensembles de données (entre les intervalles 0 et 1) pour dimensionner les données et supprimer l'effet de mise à l'échelle.

Lors du traitement des données réelles, en raison des différentes dimensions du paramètre d'évaluation des roches réservoirs, le niveau de données réelles de volume varie considérablement. Si l'on calcule en utilisant directement les données brutes, les données ayant un volume plus important seraient de plus en plus remarquables, alors que l'indicateur avec un volume plus faible et une plus grande sensibilité, sera sous-estimée. Ainsi, nous devrions prétraiter et normaliser les données brutes. Dans ce travail, la normalisation des données a lieu en utilisant les valeurs maximales et minimales des données. [16]

$$X' = (x - \min(x)) / (\max(x) - \min(x)) \dots \dots \dots (II.8)$$

II.4.3. Algorithme

Toutes les autres simulations et applications aux données réelles ont été réalisées sous environnement Matlab. Les étapes spécifiques pour le L'algorithme de classement flou peut être donné comme suit:

➤ *Etape 1 :*

Nous lisons premièrement le fichier de données qui contient les valeurs de diagraphies (densité, gamma ray, résistivité dans la zone vierge, porosité neutron) comme entrées (X_i , $i=1, 2, N$), et la porosité de fractures naturelles comme sortie Y :

X_1 =densité

X_2 =gamma ray

X_3 =résistivité

X_4 =porosité neutron

➤ *Etape 2 :*

Nous créons ensuite les courbes floues par les deux étapes suivantes:

- a) Pour chaque point de données $(x_{i, k}; y_k)$, $k=1,2,\dots M$, dans chaque X_i - Y espace, la fonction d'appartenance floue est créée
- b) On défuzzifie ces fonctions d'appartenance afin de produire une courbe floue C_i , $i=1, 2,\dots N$ pour chaque variable d'entrée X_i , $i=1, 2,\dots N$.

➤ *Etape 3 :*

Les fonctions d'appartenance équation (2) peuvent être considérées comme des règles floues pour la sortie y à l'égard de chaque entrée X_i . Si la variable d'entrée X_i , est la fonction d'appartenance floue des X_i , alors Y est Y_k .

➤ *Etape 4 :*

Nous calculons l'erreur quadratique moyenne entre chaque courbe floue C_i , et les données originales Y .

➤ *Etape 5 :*

On trie les variables d'entrée en ordre croissant de valeurs d'erreurs quadratiques moyennes et on choisit les variables d'entrées les plus importantes. L'entrée correspondante à la plus petite erreur quadratique moyenne est la plus importante, et l'entrée avec la plus grande erreur quadratique moyenne est la moins importante.

II.5.Méthode du réseau de neurones artificiel

Un neurone est une fonction algébrique non linéaire, paramétrée, à valeurs bornées. Les réseaux de neurones sont fabriqués de structures cellulaires artificielles et constituent une approche permettant d'aborder sous des angles nouveaux les problèmes de perception, de mémoire, d'apprentissage et de raisonnement. Ils s'avèrent aussi des alternatives très prometteuses pour contourner certaines des limitations des ordinateurs classiques. Grâce à leur traitement parallèle de l'information et à leurs mécanismes inspirés des cellules nerveuses (neurones), ils infèrent des propriétés émergentes permettant de solutionner des problèmes jadis qualifiés de complexes. Dans ce chapitre, nous nous intéresserons à l'application des réseaux de neurones aux géosciences. Dans un premier temps, nous rappellerons les définitions et notations de base relatives aux réseaux de neurones. Nous poursuivrons en exposant les types et la méthodologie d'apprentissage. Nous présenterons aussi, d'une manière générale, les étapes de conception d'un réseau de neurones : le choix des entrées et sorties, l'élaboration de la base de données, de la structure du réseau, etc. Dans ce travail, l'application est destinée à montrer que dans le domaine des géosciences, les réseaux de neurones sont susceptibles

d'apporter des solutions efficaces et élégantes notamment dans la modélisation et la prédiction des paramètres pétrophysiques des roches réservoirs.

Un réseau de neurones peut être considéré comme un modèle mathématique de traitement réparti, composé de plusieurs éléments de calcul non-linéaire (neurones), opérant en parallèle et connectés entre eux par des poids. Les réseaux de neurones artificiels sont des réseaux fortement connectés de processeurs élémentaires fonctionnant en parallèle. Chaque processeur élémentaire calcule une sortie unique sur la base des informations qu'il reçoit.

Les neurones artificiels sont souvent utilisés sous forme de réseaux qui diffèrent selon le type de connections entre les neurones, une cinquantaine de types peut être dénombrée. En guise d'exemples nous citons : le perceptron de Rosembat, les réseaux de Hopfield, etc.

Ces derniers sont les plus utilisés dans le domaine de la modélisation et de la commande des procédés. Ils sont constitués d'un nombre fini de neurones qui sont arrangés sous forme de couches. Les neurones de deux couches adjacentes sont interconnectés par des poids. L'information dans le réseau se propage d'une couche à l'autre, on dit qu'ils sont de type " feed-forward ".

II.5.1. Les avantages des réseaux de neurones artificiels

- Capacité d'apprentissage
- Capacité de généralisation
- Robustesse par rapport aux perturbations

II.5.2. L' inconvénients des réseaux de neurones artificiel

- Interprétation impossible de la fonctionnalité
- Difficulté à déterminer le nombre de couches et le nombre de neurones

II.5.3. Conception d'un réseau de neurones

Les réseaux de neurones réalisent des fonctions non-linéaires paramétrées. Leurs mises en œuvre nécessitent :


- La détermination des entrées et des sorties pertinentes, c'est-à-dire les grandeurs qui ont une influence significative sur le phénomène que l'on cherche à modéliser.

- La collecte des données nécessaires à l'apprentissage et à l'évaluation des performances du réseau de neurones.
- La détermination du nombre de neurones cachés nécessaires pour obtenir une approximation satisfaisante.
- La réalisation de l'apprentissage
- L'évaluation des performances du réseau de neurones à l'issue de l'apprentissage.

II.5.4. Principe du 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 ses 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. Il est commode de représenter graphiquement un neurone comme indiqué sur la figure II.4. Cette représentation est à l'origine de la première vague d'intérêt pour les neurones formels



FigureII.4Neuroneartificiel [16].

Le neurone réalise alors trois opérations sur ses entrées :

- **Pondération** : multiplication de chaque entrée par un paramètre appelé poids de connexion,
- **Sommation** : une sommation des entrées pondérées est effectuée

• **Activation** : passage de cette somme dans une fonction, appelée fonction d'activation. La valeur calculée est la sortie du neurone qui est transmise aux neurones suivants.

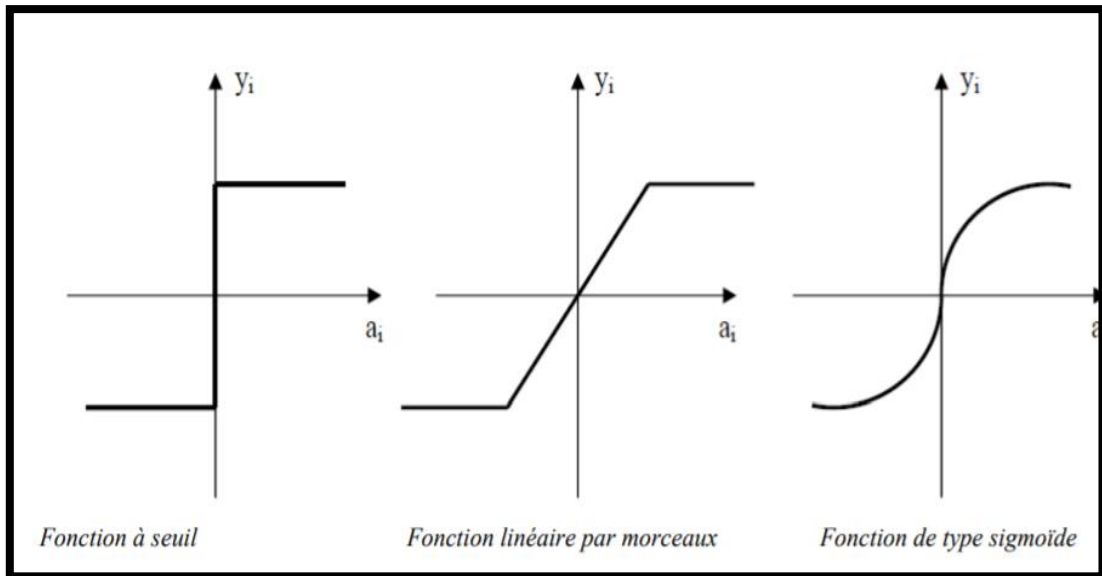


Figure II.5. Différents types de fonction de transfert pour le neurone artificiel (1).

La fonction f est appelée fonction d'activation (Fig.II.5). Elle peut être une fonction à seuil, une fonction linéaire ou non-linéaire. La fonction sigmoïde se présente comme une approximation continûment dérivable de la fonction d'activation linéaire par morceaux ou de la fonction seuil. Elle présente l'avantage d'être régulière, monotone, continûment dérivable, et bornée entre 0 et 1 :

$$F(x) = 1 / (1 + \exp(-x)) \dots\dots\dots (II.9)$$

La fonction f peut être paramétrée de manière quelconque. Deux types de paramétrages sont fréquemment utilisés : Les paramètres sont attachés aux entrées du neurone : la sortie du neurone est une fonction non linéaire d'une combinaison des entrées $\{x_i\}$ pondérées par les paramètres $\{w_i\}$, qui sont alors souvent désignés sous le nom de poids.

$$Y = \text{th}[W_0 + \sum_{i=1}^{n-1} W_i X_i] \dots\dots\dots (II.10)$$

Les paramètres sont attachés à la non-linéarité du neurone : ils interviennent directement dans la fonction f . Les modèles linéaires et sigmoïdaux sont bien adaptés aux algorithmes d'apprentissage impliquant une rétro propagation du

gradient car leur fonction d'activation est différentiable ; ce sont les plus utilisés. Le modèle à seuil est sans doute plus conforme à la "réalité" biologique mais pose des problèmes d'apprentissage. Enfin le modèle stochastique est utilisé pour des problèmes d'optimisation globale de fonctions perturbées ou encore pour les analogies avec les systèmes de particules.

II.5.5. Architecture des réseaux de neurones

Le réseau de neurones est composé de plusieurs couches dans son architecture, la première couche est appelée couche d'entrée, son rôle est limité uniquement de rentrer les données dans le réseau. La dernière couche est appelée couche de sortie, elle constitue l'interface entre le réseau et le monde extérieur, elle fournit les résultats du traitement effectués par les autres couches. Entre ces deux couches sont déposées les couches cachées, elles sont responsables de la transformation du signal. La connexion entre ces couches se fait entre les neurones. Les couches cachées peuvent être présentées par un nombre variable mais le plus souvent par une seule couche [2]. En revanche, Zhang et al. (1998) ont mentionné que l'utilisation d'une seule couche peut exiger un nombre élevé de neurones dans la couche cachée, ce qui nécessite un temps d'apprentissage élevé et cause une diminution de la capacité de généralisation du RNA. En général, un RNA avec peu de neurones cachés est préférable, car il a généralement une meilleure capacité de généralisation et moins de problème de sur apprentissage (overfitting). Dans la topologie du réseau de neurones, on distingue les réseaux de neurones non bouclés (feed-forward), cas où l'information circule sans retour de neurones de la première couche vers les neurones de la couche suivante sans aucun lien entre les neurones de la même couche (FigII.6.a). Dans le cas de retour de l'information de la couche suivante vers la couche précédente, on appelle ce type réseau de neurones à connexion récurrente (feedback) (Fig. II.6.b).




Figure II.6. Topologie des réseaux de neurones : (a) réseau de neurones non bouclé et (b) réseau de neurones.[1]

II.5.6. Les types d'apprentissage de réseaux de neurones

L'une des caractéristiques importantes des réseaux neuronaux est leur capacité d'apprentissage qui leur permet d'améliorer ses performances. L'apprentissage est considéré comme un processus d'ajustement des poids et des biais, en se basant sur un algorithme et suivant une méthode précise pour obtenir un résultat satisfaisant. Les méthodes d'apprentissage sont divisées en deux catégories principales

II.5.6.a. L'apprentissage supervisé

Dans ce type d'apprentissage, on cherche à imposer au réseau un fonctionnement donné, en le forçant à partir des entrées qui lui sont présentées de trouver la sortie désirée, tout en modifiant les poids synaptiques 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 [23]. Le réseau se comporte alors comme un filtre dont les paramètres de transfert sont ajustés à partir des couples entrées/sorties présentés. L'adaptation des paramètres du réseau s'effectue à partir d'un algorithme d'optimisation, l'initialisation des poids synaptiques étant le plus souvent aléatoires [22] Parmi ces réseaux on peut citer le perceptron, le réseau de neurone multicouche et les réseaux à base de fonctions radiales.

II.5.6.b. L'apprentissage non supervisé

L'apprentissage non supervisé ou l'apprentissage auto-organisé ne nécessite pas une réponse correcte associée avec chaque modèle d'entrée dans l'apprentissage des données. 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, par contre dans l'apprentissage supervisé le vecteur de sortie désirée est connu pour chaque forme d'entrée et il est emmagasiné dans la base d'apprentissage. Les deux types d'apprentissage sont caractérisés par une phase d'apprentissage, dans la quelle on présente au réseau des formes d'entrées extraites d'une base d'apprentissage. Parmi les réseaux de neurones non supervisés on cite le réseau de Hopfield, Kohonen et les modèles ART [24].

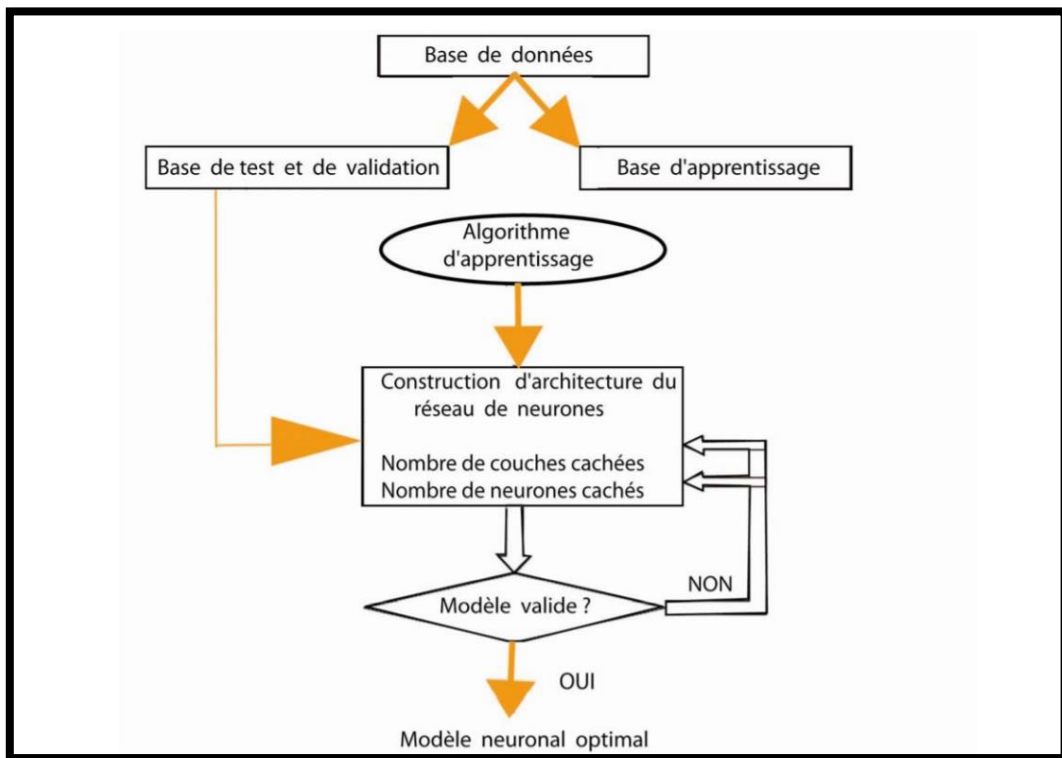


Figure II.7. Organigramme de conception d'un réseau de neurones [5].

II.5.9.L'Algorithme de rétro propagation du gradient d'erreur

L'algorithme de rétro propagation d'erreur est l'un des algorithmes les plus connus pour l'apprentissage des réseaux de neurones multicouches. L'idée de base de cet algorithme est due à Bryson et Ho (1969), publiée dans leur livre intitulé "application du contrôle optimal", la méthode de dérivation de la rétro propagation par la formule de Lagrange. C'est d'ailleurs à sa découverte par Rumelhart et McClelland (1986) que l'intérêt de cet algorithme pour les réseaux de neurones est mis en évidence. En réalité l'algorithme de rétropropagation est trouvé indépendamment par d'autres chercheurs presque dans le même temps [15]. L'objectif de cet algorithme est de modifier les poids du réseau dans le sens contraire du gradient du critère de performance. C'est une technique de calcul des dérivées qui peut être appliquée à n'importe quelle structure de fonctions dérivables. Mathématiquement, cette méthode est basée sur l'algorithme de descente du gradient et elle utilise les règles de dérivation des fonctions dérivables. Dans cette méthode, l'erreur commise en sortie du réseau sera rétropropagée vers les couches cachées d'où le nom de rétropropagation. Cet algorithme est basé sur l'extension de la règle delta généralisée. L'algorithme du gradient stochastique est utilisé pour tenter de minimiser l'erreur quadratique moyenne sur la sortie, on a :

$$P_i^k = \sum_{j=1} W_{ji} \cdot S_j^k + \theta_i \dots \dots \dots (II.11)$$

Et

$$S_i^k = \varphi(P_i^k) \dots \dots \dots (II.12)$$

Avec

P_i^k : potentiel du neurone i pour l'exemple k,

W_{ji} : poids de la connexion du neurone j vers le neurone i,

θ_i : seuil du neurone i,

S_i^k : signal de sortie du neurone i pour l'exemple k,

φ : fonction de transfert.

L'erreur sur l'exemple k est définie comme :

$$E^k = 0.5 \sum_{o=1}^O (d_o^k - S_o^k)^2 \dots \dots \dots (II.13)$$

Avec d_k^o le signal désiré pour l'exemple k sur le neurone de sortie o, et O le nombre de neurones dans la couche de sortie.

L'erreur totale est

$$E = \sum_{k=1}^K E^k \dots \dots \dots (II.14)$$

L'application de la règle delta généralisée donne:

$$\Delta^k w_{ji} = -\eta \cdot \frac{\delta E^k}{\delta w_{ji}} \dots \dots \dots (II.15)$$

La fonction d'apprentissage est donnée par:

$$\Delta^k w_{ji} = \eta \cdot \delta_i^k \cdot s_i^k \dots \dots \dots (II.16)$$

telle que δ_i^k est le signal d'erreur La règle d'apprentissage pour les neurones de sortie est donnée par

$$\Delta^k w_{j0} = \eta \cdot (d_0^k - S_0^k) \cdot \varphi(p_0^k) \cdot S_j^k \dots \dots \dots (II.17)$$

C H A P I T R E

III

*Application de la logique floue
et des réseaux de neurones pour
prédire la porosité de fractures
naturelles*

Partie I : Analyse des données de diagraphies

Les données de diagraphies utilisées dans cette étude sont obtenues à partir de l'interprétation diagraphiques des puits#1 et puits#2 situés dans le Zone 1A. Les données diagraphiques sont enregistrées dans le drain D4 du réservoir anisométrique (Ra). L'enregistrement des rayons gamma naturels dans le puits détecte et évalue les minéraux radioactifs dans les formations sédimentaires (Fig.III.1.), ils sont un excellent indicateur pour évaluer le volume d'argile dans le réservoir. En revanche, l'augmentation des argiles dans les fractures à cause du dépôt des minéraux radioactifs dans les fractures ouvertes au cours de la circulation des fluides, Les valeurs du gamma ray dans le puits#1 varient de 31 à 71.79 API (moyenne : 43.13 API), ce qui donne des indications sur la propriété du réservoir étudié. La diagraphie de porosité neutron mesure la porosité totale, les valeurs mesurées varient de 6.58% à 11.56% (moyenne: 7.9%). La diagraphie neutron dépend essentiellement de la quantité d'hydrogène présent dans la formation (à la suite de la perte d'énergie qui se produit lorsque le neutron entre en interaction avec les atomes d'hydrogène). En présence d'une fracture ouverte, une anomalie indiquant une porosité plus élevée peut être prévue. La diagraphie de densité peut également servir à localiser les fractures, puisqu'une fracture ouverte traversée par un sondage apparaîtra souvent comme une zone de faible densité dans les diagraphies de densité [20]. Les valeurs de densité sont comprises entre 2.49 et 2.59 g/cm³ (moyenne : 2.53 g/cm³). Les diagraphies de résistivité enregistrent la résistance des liquides interstitiels à l'écoulement d'un courant électrique. Elles sont principalement utilisées pour l'évaluation des fluides à l'intérieur de la formation et pour la corrélation entre puits. Les valeurs de résistivité profonde dans le puits étudié varient de 29.90 à 154.47 Ohm.m (moyenne : 61.47 Ohm.m) .

Les valeurs de la porosité de fractures naturelles calculées dans le puits#1 par carottage citées ci-dessus sont très faibles (Fig.III.1.), elles varient de 0.11% à 5.13% dans l'intervalle fracturé. Les valeurs maximales ne dépassent pas 5.13%. La valeur moyenne de la porosité de fractures naturelles est 1.41 %.




Figure III.1. Les données de diagraphies du puits#1.[5]

Partie II : Présentation du logiciel de simulation (Mathlab)

Un algorithme est un ensemble (séquence) d'opération (ou d'ordres) simples, que l'ordinateur peut exécuter (sous un langage de programmation) et conçu afin de résoudre un problème plus complexe. Notons qu'il y a une "infinité" de façons de concevoir un algorithme mais seule une (ou quelques) façon est optimale. L'algorithme dépend des actions que l'ordinateur (ou plutôt le langage) peut exécuter. Plus l'ordinateur peut exécuter des opérations complexes plus l'algorithme est simple et inversement. [26]

Figures présentant fuzzy_logic & neuro_fuzzy :

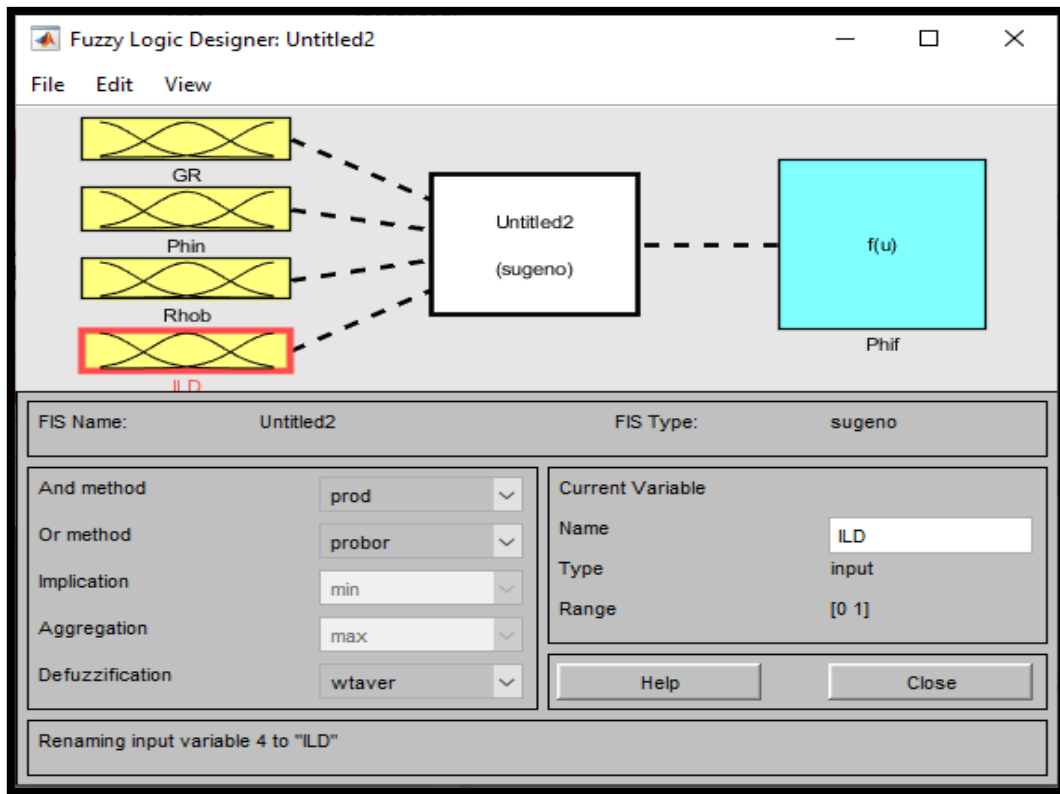


Figure III.2. fuzzy logic designer [16]

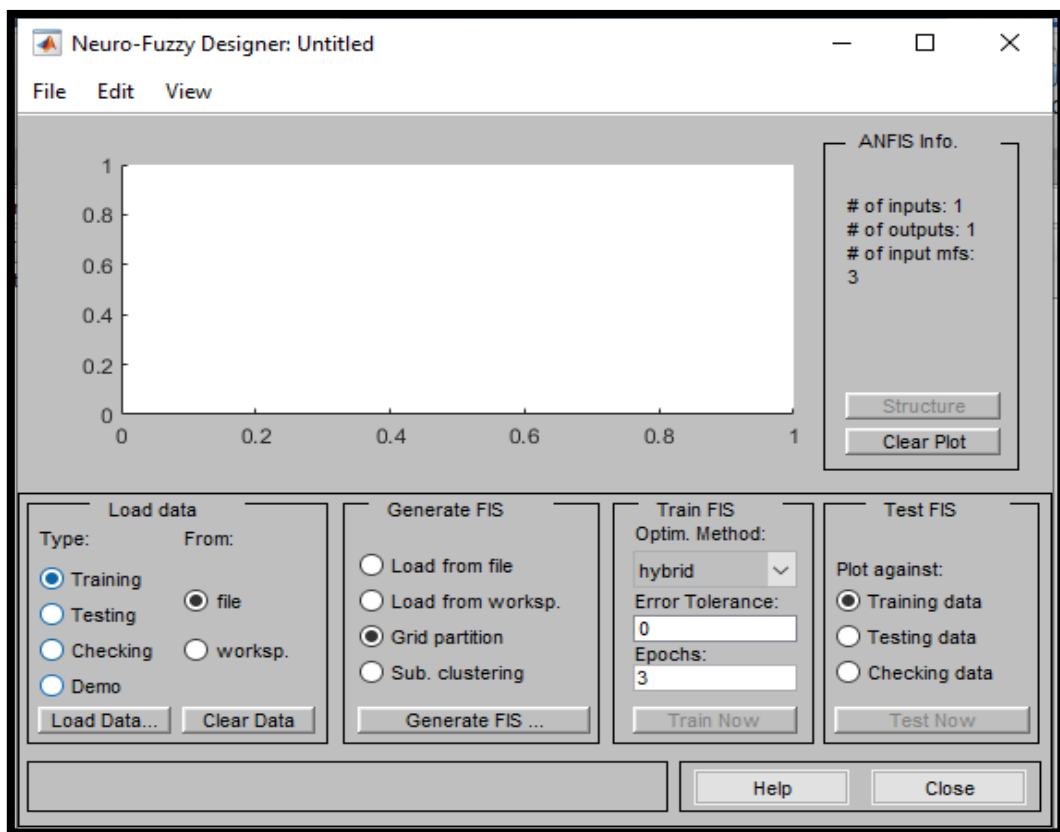


Figure III.3. neuro-fuzzy designer [16]

Partie III : Application de la logique floue et des réseaux de neurones pour prédire la porosité de fractures naturelles

III.3.1. Classement flou

La méthode du classement flou est utilisée dans ce travail pour classer les données diagraphiques des entrées de RNA selon leurs degrés d'importance sur la sortie désirée. Nous devons savoir parmi les données de diagraphies utilisées (gamma ray (GR), résistivité dans la zone vierge (ILD), densité (Rho_b) et porosité neutron (Nphi)) comme des entrées dans le RNA, quelles sont les données les plus influentes sur la porosité de fractures naturelles.

a. Premièrement :

Nous avons construit les graphes de corrélation entre la porosité de fractures naturelles et les données d'entrées du RNA (données de diagraphies de puits 1), Nous obtenons les résultats suivants :

- La valeur élevée du coefficient de corrélation est enregistrée avec une densité de 0.874 (Fig. III.4.c)
- la valeur la plus faible avec une résistivité de 0.082 (Fig III.4.b)
- Coefficient de corrélation trouvé entre porosité de fractures naturelles et gamma ray est 0.334 mais faible corrélation basée sur des coefficients de corrélation
- Et entre la porosité de fractures naturelles et porosité neutron est 0.182

Donc le rayon gamma a plus influence sur la sortie que la résistivité. La courbe floue de la densité est plus inclinée, donc la densité a plus influence sur la sortie que les autres paramètres. Le neutron la porosité est classée troisième et illustre que le changement de neutron porosité n'est pas le principal facteur de la porosité naturelle de la fracture

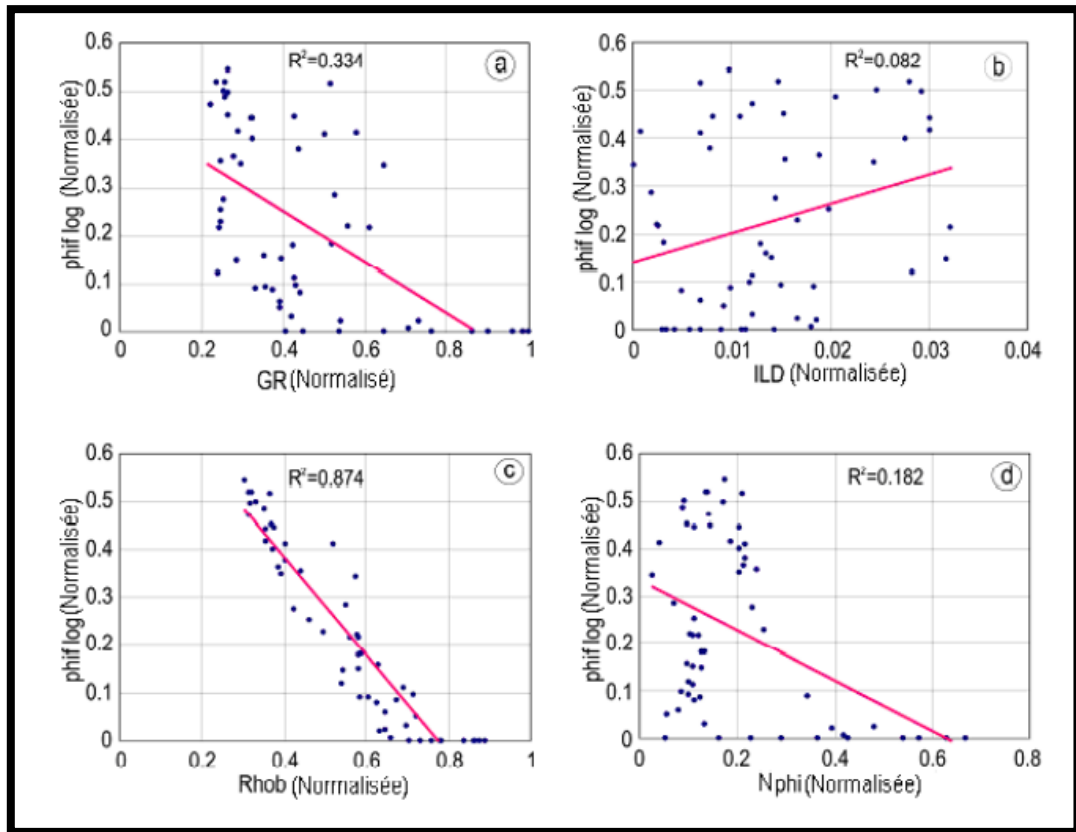


Figure III.4. Corrélations entre porosité de fractures naturelles et données de diagraphies.[1]

b. Deuxièmement

Les courbes floues sont obtenues après normalisation des données [21] en utilisant la méthode du classement flou. L'analyse qualitative des courbes floues permet de classer les données d'entrées selon leur ordre d'importance sur la sortie désirée. On constate que la courbe floue de la résistivité est plate, ce qui justifie la faible influence de ce paramètre sur les données de sortie du réseau. La forme de la courbe floue du gamma ray est inclinée par rapport à la résistivité profonde ce qui signifie que le gamma ray a plus d'influence sur la sortie que la résistivité. La courbe floue de la densité est plus inclinée par rapport aux autres courbes enregistrées (Fig. III.5.c), indiquant que la densité a la plus grande influence sur la sortie que les autres paramètres d'entrée. La porosité neutron est classée en troisième position et illustre un faible effet (Fig. III.5.d).




Figure III.5. Les courbes floues des données de diagraphies d’entrées.[1]

On peut connaître l’influence des paramètres d’entrée sur la sortie avec précision, en analysant quantitativement l’erreur quadratique moyenne obtenue entre la courbe floue de chaque paramètre d’entrée et la sortie du réseau de neurones. Cette analyse quantitative consiste à classer les paramètres d’entrée selon leurs erreurs quadratiques moyennes obtenues en sens décroissant.

La densité est classée en première position avec une erreur quadratique moyenne (MSE) plus faible par rapport aux autres paramètres (7.61×10^{-3}), et la résistivité en quatrième position avec une MSE égale (3.07×10^{-2}).

Tableau III.1. Classement des entrées diagraphiques par logique floue.

<i>Paramétré d’entré</i>	<i>MSE</i>	<i>Classement</i>
Résistivité	$3.07 \cdot 10^{-2}$	4
Porosité de neutron	$2.62 \cdot 10^{-2}$	3
Densité	$7.61 \cdot 10^{-3}$	1
Gamma ray	$2.58 \cdot 10^{-2}$	2

Nous constatons d'après les résultats obtenus que l'interprétation qualitative et quantitative coïncident. Nous remarquons aussi que la densité est caractérisée par une très faible MSE par rapport aux autres paramètres (gamma ray, porosité neutron et résistivité), mais ces derniers ont des MSE presque proches, ce qui signifie que les trois paramètres ont presque la même influence. D'après ces résultats, tous les quatre paramètres sont indispensables pour faire l'apprentissage du réseau de neurones.

III.3.2. Réseau de neurones artificiel

III.3.2.a. Phase d'apprentissage

La détermination de l'architecture du RNA est la tâche la plus importante dans la modélisation d'un réseau de neurones. Elle consiste à trouver la topologie adéquate pour que le réseau de neurones converge en un temps minimal et avec une capacité de généralisation optimale. La base de données d'apprentissage est choisie à partir des données diagraphiques du puits#1 qui contient le maximum de données diagraphiques et surtout l'enregistrement du temps de transit (Δt) qui manque dans plusieurs puits de la zone d'étude. Cette base est composée de données de sonique, résistivité, porosité neutron, densité et gamma ray. Ces données sont utilisées dans le RNA comme des entrées, et la porosité de fractures naturelles log calculée à partir des équations diagraphiques citées ci-dessus comme une sortie désirée. Le nombre d'itération est fixé à 1000 dans la phase d'apprentissage, et l'erreur quadratique moyenne (MSE) utilisée pour calculer la performance du RNA est fixée à 0.001. La fonction d'activation dans la première et la deuxième couche est de type log sigmoïde, elle est donnée par :

$$F(x)=1/(1+\exp(-x)) \dots\dots\dots(III.1)$$

Après l'essai de différentes structures de réseaux de neurones avec une et deux couches cachées, la meilleure structure obtenue est composée de 25 neurones dans la première couche cachée et 12 neurones dans la deuxième couche cachée. La convergence du RNA est obtenue à une MSE égale à 0.002. La variation de la MSE en fonction du nombre d'itérations est représentée en (Fig. III.6.) :




Figure III.6. Performance du RNA après l'apprentissage.[1]

Une fois l'apprentissage terminé, les poids du réseau sont sauvegardés. La porosité de fractures naturelles obtenue par RNA est corrélée avec la porosité de fractures naturelles calculée par diagraphie, le coefficient de corrélation (R^2) obtenu est égale 0.965 (Fig.III.7.). Le graphe de la variation des porosités en fonction de la profondeur montre que les deux porosités coïncidentes (Figure III.8.a) .bien que dans le puits étudié, il y ait des intervalles fracturés et d'autres non fracturés. Le réseau de neurones a donné de bons résultats et il a prédit toutes ces parties.




Figure III.7. Corrélation entre la porosité des fractures obtenue par réseau de neurones et celle calculée par diagraphie (phase d'apprentissage (puits#1)).[5]

III.3.2.b. Phase de test

Une fois le processus d'apprentissage terminé, l'ensemble des données de test doit être présenté au réseau. Si le test donne une bonne concordance entre la porosité de fractures naturelles obtenue par diagraphie et la porosité de fractures naturelles prédite par RNA, la matrice des poids doit être sauvegardée. Sinon, l'apprentissage est répété plusieurs fois jusqu'à ce qu'un bon résultat de test soit réalisé. Pour tester la capacité d'apprentissage du RNA, nous présentons au réseau les données d'entrée qui ont déjà été pris dans la phase d'apprentissage et on génère la porosité de fractures naturelles. Cette dernière est comparée avec la porosité de fractures naturelles obtenue par diagraphie. Le résultat obtenu montre que les deux porosités se coïncident (Figure III.8.b). L'erreur quadratique moyenne (MSE) entre les valeurs prédites et les valeurs calculées est égale à 13.52×10^{-4} et l'erreur relative moyenne (ARE) est égale à 0.01.

III.3.2.c. Phase de généralisation

La phase de généralisation est l'étape décisive pour tester l'efficacité d'un RNA et juger son aptitude de prédire la sortie à partir des données qui n'ont pas dans la phase d'apprentissage. Dans cette étape, on a introduit au réseau de neurones de nouvelles données, celles du puits #2 qui n'ont pas été prises dans la phase d'apprentissage, pour tester sa capacité à la généralisation. La porosité de fractures naturelles de ce puits est calculée en se basant sur les données des diagraphies et en appliquant les équations citées précédemment, de la même manière que pour le puits#1. Ensuite, nous avons utilisé les données de résistivité profonde (ILD), porosité neutron (Nphi), densité (Rho_b) et gamma ray (GR) comme des entrées du RNA après leurs normalisations pour générer la porosité de fractures naturelles dans le puits #2. La porosité de fractures naturelles log (log phif) calculées dans le puits#2 après normalisation est corrélée avec la porosité de fractures naturelles. Les résultats trouvés montrent que le RNA possède une grande capacité de généralisation avec les nouvelles données d'entrée du puits #2. Sans retour aux données de diagraphie sonique, on a pu prédire la porosité des fractures naturelles uniquement à partir des quatre données des diagraphies conventionnelles, sans passage par les équations diagraphiques citées auparavant et sans avoir besoin de paramètres d'interprétation. Le graphe de variation de la porosité de fractures

naturelles log et la porosité obtenue par RNA en fonction de la profondeur (Fig. III.8.c) montre un faible écart entre ces deux porosités entre la profondeur 3430 m et 3434.5 m. Cet écart peut être justifié par l'hétérogénéité et la fracturation du réservoir du champ de Hassi Messaoud. Ces derniers éléments influent sur la variation de la densité de fracturation d'un puits à un autre et sur la porosité de fractures naturelles. Le RNA joue ici le rôle d'une fonction de transfert. Il a prouvé son succès marqué par la valeur élevée du coefficient de corrélation calculé entre phi RNA et phif log qui est de 0.878 (Figure III.9). Le MSE entre les valeurs prédites et celles calculées est de 0.032 et la ARE est égale à 0.142.




Figure III.8. Corrélation entre la porosité de fractures naturelles obtenue par réseau de neurones et celle calculée par diagraphie : (a) phase d'apprentissage, (b) phase de test et (c) phase de généralisation.[5]




Figure III.9. Corrélation entre la porosité des fractures obtenue par réseau de neurones et celle calculée par diagraphie (phase de généralisation (puits#2)). [5]

Conclusion générale

Le développement d'un réservoir fracturé nécessite la résolution de n'importe quel problème rencontré dans l'étape de la caractérisation ou de la modélisation du réservoir, tel que le manque de porosité de fractures pour une exploitation optimale de ses réserves. Le manque d'enregistrement de diagrapie sonique dans les puits pétroliers ou autres diagrapies nécessaires telles que la porosité neutron, densité, ou les paramètres de boue de forage, peut remettre en cause la détermination de la porosité de fractures naturelles qui est un paramètre essentiel pour l'évaluation et la simulation d'un réservoir fracturé. Pour résoudre ce problème nous avons appliqué avec succès le classement flou pour connaître l'importance des données d'entrées de diagrapie, ainsi que leur influence sur la porosité de fractures naturelles. Nous notons que l'analyse qualitative et quantitative des courbes floues montrent que les quatre données d'entrée de diagrapies utilisées pour la prédiction de la porosité de fractures naturelles sont indispensables parce qu'ils ont presque la même influence sur la porosité de fractures naturelles obtenue par réseau de neurones. L'intérêt des réseaux de neurones réside dans leur capacité intrinsèque à la généralisation. Le RNA multicouche appliqué dans cette étude montre sa capacité de prédire la porosité de fractures naturelles en se basant sur les données de diagrapies conventionnelles. La méthodologie proposée permet d'estimer un paramètre essentiel pour évaluer ou simuler un réservoir fissuré, en exploitant les données de diagrapies conventionnelles enregistrées presque dans la majorité des puits pétroliers bien qu'elles ne soient pas complètes.

Bibliographie

- [1]. Ahmed Ali Zerrouki. Contribution à la caractérisation des réservoirs fissures du champ de Hassi Messaoud par classement flou, réseaux de neurones artificiels et magnétisme des roches. Sciences de la Terre. Université M'Hamed Bougara-Boumerdes, 2015. Français.
- [2]. Amat, J.L., Yahiaoui, G., 1996. Techniques avancées pour le traitement de l'information, Réseaux de neurones, logique floue et algorithmes génétiques. Edition Cépaduès,
- [3]. Asadisaghandi, J., Tahmasebi, P., 2011. Comparative evaluation of back-propagation neural network learning algorithms and empirical correlations for prediction of oil PVT properties in Iran oilfields.
- [4]. Behrens, R.A., Macleod, M.K., Tran, T.T., Alimi, A.O., 1998. Incorporating seismic attribut maps in 3D reservoir models. SPE Reservoir Evaluation & Engineering,
- [5]. Bouchon-Meunier, B., 2007. La logique floue, Que sais-je . 4^{ième} Edition. Edition Universitaire de France
- [6]. BOUZID Abderrahmen - NOURI Dhiya Eddine, APPLICATION DE L'ANALYSE DES COURBES DE DECLIN POUR L'EVALUATION DES PERFORMANCES ET L'ESTIMATION DES RESERVES DE LA ZONE FISSUREE HZN DANS LE CHAMP DE HASSI MESSAOUD, UNIVERSITE M'HAMED BOUGARA DE BOUMERDES.
- [7]. Chahir Jerbi. Simulation des transferts diphasiques en réservoir fracturé par une approche hiérarchique. Hydrologie. Université Pierre et Marie Curie - Paris VI, 2016. Français.
- [8]. Dubois, D., Prade, H., 1980. Fuzzy Sets and Systems: Theory and Applications. Academic Press, New York
- [9]. Hoffman, B.T., Narr, W., 2012. Using production logs (PLT) to estimate the size of fracture networks. Journal of Petroleum Science and Engineering,
- [10]. Ibrahim, A.M., 2004. Fuzzy logic for embedded system applications. Elsevier science (USA),
- [11]. Kouider El Ouahed, A., Djebbar, T., Mazouzi, A., 2005. Application of artificial intelligence to characterize naturally fractured zones in Hassi Messaoud Oil Field, Algeria. Journal of Petroleum Science and Engineering,
- [12]. Lin, Y., Cunningham, G.A., Coggeshall, S.V., 1996. Input variable identification-fuzzy curves and fuzzy surfaces. Fuzzy sets and systems,
- [13]. Orientation des groupes d'aimantation définissant les domaines de Weiss (d'après Larroque et Virieux, 2001
- [14]. Ouenes, A., 2000. Practical application of fuzzy logic and neural networks to fractured reservoir characterization. Computers & Geosciences,
- [15]. Parker, D., 1985. Learning Logic. Technical Report TR-87, Cambridge, MA: Center for Computational Research in Economics and Management Science, MIT, Cambridge.

- [16]. Rafik Baouche. Prédiction des Paramètres Physiques des Couches Pétrolifères par Analyse des Réseaux de Neurones et Analyse Faciologique.. Sciences de la Terre. université M'hamed Bougara. Boumerdes, 2015. Français
- [17]. Sahimi, M., Hashemi, M., 2001. Wavelet identification of the spatial distribution of fractures. Geophysical Research Letters.
- [18]. Sausse, J., Dezayes, C., Dorbath, L., Genter, A., Place, J., 2010. Modele 3D des zones de fractures dans le réservoir profond de Soultz-sous-Forêts (Bas-Rhin, France) : données géologiques, imageries de puits, microsismicité induite et résultats VSP. Comptes Rendus Geoscience,
- [19]. Sung, A.H., 1998. Ranking importance of input parameters of neural networks. Expert Syst. Appl
- [20]. Van Golf-Racht, T.D., 1982. Fundamentals of Fractured Reservoir Engineering. Elsevier Scientific Publishing Company, Amsterdam-Oxford-New York,
- [21]. Weiss, W., Shaochang, Wo., Weiss, J.W., 2001. Data mining at a regulatory agency to forecast waterflood recovery. In: Proceedings of the SPE Rocky Mountain Petroleum Technology Conference, Keystone, Colorado, 21-23 May. Society of Petroleum Engineers, paper SPE
- [22]/. Bouchon-Meunier, B., 1995. La logique floue et applications. Edition Addison-Wesley, France, 254 p
- [23]/. Haykin, S., 1999. Neural Network: A Comprehensive Foundation, second edition. PrenticeHall, 837 pp.
- [24]. Widrow, B., Hoff, M.E., 1960. Adaptive switching circuits. IRE WESCON Convention Record, 4, 96-104.
- [25].Pdf, Introduction à la logique floue. « Fuzzy logic »
- [26]. Pdf introduction à matlab
- [27].Pdf Gabriel Cormier ,GELE5313
- [28]. Pdf ,598-presentation-logique-floue
- [29].sit : <http://www.ferdinandpiette.com/blog/2011/08/la-logique-floue-interets-et-limites/> 26/05/2021