

Université Kasdi Merbah – Ouargla

**Faculté Des Hydrocarbures, Des Energies Renouvelables Et Des Sciences de la
Terre et de l'Univers**

Département Des Sciences De La Terre Et De l'Univers



Mémoire de Master Académique

Domaine : Sciences de la Terre et de l'Univers

Filière : Géologie

Spécialité : Géologie Pétrolière

THEME

**Prédiction des paramètres géo-mécaniques à l'aide des
techniques de l'intelligence artificielle cas du Quartzite El
Hamra**

Présenté par :

Lamamra Sami / Hacini Mohamed Amine

Soutenu publiquement : 03/06/2025

Devant le jury :

Président	BELKSIER Med Salah	Professeur	Univ. Ouargla
Promoteur	AMEUR-ZAIMECHE Ouafi	M.C.A	Univ. Ouargla
Co-Promoteur	KERMIA Hanane	Doctorante	Univ. Ouargla
Examineur	KECHICHED Rabah	Professeur	Univ. Ouargla

Année universitaire : 2024 / 2025

Remerciement

Avant tout, nous adressons nos sincères remerciements à Allah, le grand créateur, qui nous a donné la force et la capacité nécessaires.

Nous tenons à exprimer notre profonde gratitude à notre encadrant, **Dr. AMEUR-ZAIMECHE Ouafi**, qui a accepté de diriger ce travail et nous a accordé toute son attention et sa patience pour mener à bien ce projet.

Nos sincères remerciements vont également aux membres du jury de mémoire qui ont consacré une part importante de leur temps à la lecture et à l'évaluation de ce travail.

Nous souhaitons aussi remercier tous les enseignants de l'Institut des Sciences de la Terre, sans oublier nos enseignants de spécialité :

Dr. KERMIA Hanane Dr. BOUTAGHANE Ayoub, pour leur soutien moral et leurs orientations précieuses tout au long de notre formation.

Dédicace

Je dédie ce mémoire :

À ma très chère mère et à mon cher père, pour leur amour inconditionnel, leur soutien indéfectible et leurs prières silencieuses qui m'ont accompagné tout au long de ce parcours.

À la famille Lamamra, en signe de profonde gratitude pour leur bienveillance et leur appui constant.

À mes camarades du département des sciences de la Terre à Ouargla et Constantine, pour leur esprit de collaboration, leur aide précieuse et leur amitié sincère.

À tous ceux qui me sont chers, de près ou de loin — vous avez tous, à votre manière, contribué à l'aboutissement de ce travail.

Et enfin, à l'ensemble de mes enseignants et enseignantes, pour la qualité de leur enseignement, leur disponibilité et leur engagement, qui ont nourri ma curiosité et enrichi mon parcours académique.

Lamamra Sami

Dédicace

Je dédie ce mémoire à mes parents, dont le soutien inébranlable et l'amour inconditionnel m'ont toujours guidé et inspiré. Merci de m'avoir donné les moyens de croire en moi et de poursuivre mes rêves.

À mes amis et proches, pour leur encouragement et leur compréhension tout au long de ce parcours exigeant.

Je tiens également à exprimer ma gratitude à mes professeurs et encadrants, dont les conseils avisés et les encouragements ont été essentiels à l'aboutissement de ce travail.

Enfin, je dédie ce mémoire à tous ceux qui, de près ou de loin, ont contribué à ma réussite.

HACINI Mohamed Amine

Résumé

L'objectif de cette mémoire est la prédiction du module de Young dynamique en utilisant des techniques d'intelligence artificielle basées sur les données de diagraphies de puits dans le réservoir fracturé et compacté Combro-ordovicien de Quartzite El Hamra situé dans le champ de Rhourde Nouss Wilaya d'Illizi au sud-est de l'Algérie. L'intégration des algorithmes Random Forest (RF) et Extrême Gradient Boosting (XGB) a été réalisée afin d'estimer le module élastique à partir des données de diagraphies. Les résultats montrent que l'algorithme XGB offre de meilleures performances par rapport à RF, avec la meilleure précision obtenue pour des diamètres de puits supérieurs à 7" ($R^2 \approx 0,8520$; $RMSE \approx 1,1701$; $MAE \approx 0,9077$). Les résultats confirment la fiabilité des diagraphies comme alternative aux méthodes de laboratoire traditionnelles. De plus, l'influence du diamètre du puits sur la qualité des prédictions a été mise en évidence, ce qui ouvre la voie à une amélioration de la caractérisation des réservoirs et des opérations de forage.

Mots clé : *Module de Young dynamique, Quartzite El Hamra, diagraphies, XGBoost, Random Forest, Rhourde Nouss., Algérie.*

ملخص

الهدف من هذه المذكرة هو التنبؤ بمعامل يونغ الديناميكي باستخدام تقنيات الذكاء الاصطناعي استناداً إلى بيانات سجل الآبار في مكنن متصدع ومضغوط كومبرو_اوردوفيشي، كوارتزيت الحمراء حقل رورد النص ولاية إيليزي في جنوب شرق الجزائر. تم دمج خوارزمية الغابة العشوائية (RF) وخوارزمية تعزيز التدرج القصوى (XGB) لتقدير معامل المرونة من بيانات السجل. أظهرت النتائج أن أداء خوارزمية XGB أفضل من أداء خوارزمية الغابة العشوائية، مع الحصول على أفضل دقة لأقطار الآبار الأكبر من 7 بوصة ($R^2 \approx 0.8520$)؛ $RMSE \approx 1.1701$ ؛ $MAE \approx 0.9077$). تؤكد النتائج موثوقية التسجيل كبديل للطرق المختبرية التقليدية. بالإضافة إلى ذلك، تم إثبات تأثير قطر البئر على جودة التنبؤات، مما يمهد الطريق لتحسين توصيف المكامن وعمليات الحفر.

الكلمات المفتاحية: معامل يونغ الديناميكي، كوارتزيت الحمراء، بيانات سجل الآبار، XGBoost، الغابة العشوائية، الجزائر، رورد نوس.

Abstract

The objective of this memoir is the prediction of the dynamic Young's modulus using artificial intelligence techniques based on well log data in the fractured and compacted Cambro-Ordovician Quartzite El Hamra reservoir, located in the Rhourde Nouss field, Illizi Province, in the southeast of Algeria. The integration of Random Forest (RF) and Extreme Gradient Boosting (XGB) algorithms was carried out to estimate the elastic modulus from well log data. The results show that the XGB algorithm offers better performance compared to RF, with the best accuracy obtained for well diameters greater than 7" ($R^2 \approx 0.8520$; $RMSE \approx 1.1701$; $MAE \approx 0.9077$). The results confirm the reliability of well logs as an alternative to traditional laboratory methods. Moreover, the influence of well diameter on the prediction quality was highlighted, paving the way for improved reservoir characterization and drilling operations.

Keywords: *Dynamic Young's modulus, Quartzite El Hamra, well logs, XGBoost, Random Forest, Rhourde Nouss, Algeria.*

Sommaire

Résumé.....	IV
ملخص.....	V
Abstract.....	VI
Liste de figures.....	IX
Liste de Tableaux.....	X
Introduction Générale	1
Chapitre I :Géologie Régionale Et Local.....	3
introduction	3
.1 Situation géographique :	3
.2 Contexte géologique :	4
.2.1 Aspect stratigraphique :	5
2.2. Aspect structural :	12
.2.3 Aspect pétrolier :	15
.2.4 Les Réservoirs Compacts	18
3. La Fracturation Naturelle :	20
3.1. Typologie des fractures naturelles :	20
3.2. Microstructures associées :	21
3.3. Effets des fractures naturelles :	21
Chapitre II :Généralités sur la Mécanique des Roches	23
Introduction	23
1. Les contraintes	23
1.1. Définition.....	23
2. Déformation	25
2.1. Différents Stades de Déformation	26
3. Les propriétés mécanique des roches.....	28
3.1. Définition et importance.....	28
3.2. Les propriétés élastiques des roches.....	28
Chapitre III : Généralités sur les Méthodes d'Intelligence Artificielle.....	33
Introduction	33
1. Intelligence artificielle	33
2. Apprentissage automatique.....	33

2.1.	Apprentissage Supervisé :	34
2.2.	Apprentissage Semi-Supervisé	39
2.3.	Apprentissage Non-Supervisé	40
3.	L'apprentissage profond	40
4.	Notion des neurones	41
4.1.	Neurone Biologique	41
4.2.	Les différents types de neurones	41
4.3.	Réseaux de neurones artificiels	42
5.	Forêt aléatoire vs Extrême Gradient Boosting	45
6.	Application de IA en science de la terre	45
Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young		47
1.	Methodologie :	49
1.1.	Collecte des données :	49
1.2.	Description des données :	50
1.3.	Analyse statistique :	51
2.	Application des techniques d'apprentissage automatique :	55
2.1.	Algorithmes d'apprentissage automatique utilisés :	55
2.2.	Optimisation des hyperparamètres :	55
2.3.	Méthodologie d'évaluation :	56
3.	Resultats et discussion :	60
3.1.	Analyse de sélection des caractéristiques (scénarios de diagraphie) :	60
3.2.	Lecture des résultats :	61
3.3.	Discussion des résultats	68
Conclusion		72
Conclusion Générale		73
Références		74

Liste de figures

Liste de figures

Figure 1: Situation géographique du Champs de Rhourde Nous 4	4
Figure 2: Colonne stratigraphique de Rhourde Nous 7	7
Figure 3: Décomposition Vectorielle d'une Contrainte en une Normale et une Tangentielle 24	24
Figure 4: Principaux Plans Correspondant aux Trois Principales Contraintes $\sigma : \sigma_1, \sigma_2, \sigma_3$ 24	24
Figure 5: Orientation des trois contraintes (σ_v, σ_h et σ_H)..... 25	25
Figure 6: Les Différentes Contraintes Subi par une Roche. 25	25
Figure 7: Relation Contrainte Déformation selon la Rhéologie des Roches 27	27
Figure 8: Les Différents Régimes de Stress Selon le Contexte Tectonique 28	28
Figure 9: Déformation Latérale et Axiale Suite à une Compression 30	30
Figure 10: Déformation Selon un Axe de Contrainte d'un Cylindre 31	31
Figure 11: Les types de l'Intelligence Artificielle 33	33
Figure 12: Types d'apprentissage automatique 34	34
Figure 13: Explication de forêt aléatoire 36	36
Figure 14: XGBoost (extreme gradient-boosting) algorithmstructure 38	38
Figure 15: Decision tree 38	38
Figure 16: Réseaux de neurones 41	41
Figure 17: Illustration montrant les 4 types de neurones. (https://www.alamyimages.fr/photo-image-illustration-montrant-les-4-types-de-neurones-de-gauche-a-droite-unipolaire-bipolaire-multi) 42	42
Figure 18: Schéma représente L'architecture du modèle optimale MLP 44	44
Figure 19: Modélisation du neurone biologique par un neurone artificiel 44	44
Figure 20: Matrice de corrélation entre le module de Young dynamique E et les paramètres de diagraphies pour les trois réservoirs. 54	54
Figure 21: Organigramme illustrant l'architecture du modèle d'apprentissage automatique (ML) développé pour prédire le module de Young dynamique à partir des données de diagraphie..... 59	59
Figure 22: Module de Young dynamique mesuré Vs module de Young dynamique prédit de réservoir CLASSE 1. 63	63
Figure 23: Module de Young dynamique mesuré Vs module de Young dynamique prédit de 65	65
Figure 24: Module de Young dynamique mesuré Vs module de Young dynamique prédit de réservoir MERGED. 67	67
Figure 25: Courbes de performance (R^2 , RMSE, MAE) des meilleurs scénarios. 69	69
Figure 26: Analyse de l'importance des variables SHAP pour la prédiction du module de Young dynamique. 71	71

Liste de Tableaux

Liste de Tableaux

Tableau 1: Structural interprétatif montrant l'effet des plus importantes phases tectoniques qui ont affecté le Sahara algérien.....	13
Tableau 2: Résumé statistique des données de diagraphie collectées et du module d'Young dynamique estimé.....	51
Tableau 3: Hyperparamètres optimisés pour les modèles ML.....	56
Tableau 4: Scénarios des variables d'entrée des paramètres de diagraphies pour la prédiction du module de Young dynamique.....	60
Tableau 5: Performances de prédiction du module d'Young dynamique (E) pour le réservoir CLASSE 1 à l'aide des modèles RF et XGBoost.....	61
Tableau 6: Performances de prédiction du module d'Young dynamique (E) pour le réservoir CLASSE 2 à l'aide des modèles RF et XGBoost.....	64
Tableau 7: Performances de prédiction du module d'Young dynamique (E) pour le réservoir MERGED à l'aide des modèles RF et XGBoost.....	66

Introduction Générale

Introduction Générale

Durant les dernières décennies, le Sahara algérien a connu une progression notable en termes de découvertes nouvelles de gisements d'hydrocarbures, consolidant ainsi son importance stratégique dans le cadre économique national et mondial. L'un des secteurs les plus prometteurs est la région de Rhourde Nouss, qui se trouve dans le sud-est de l'Algérie. Cette région se distingue par ses formations géologiques complexes, notamment le Quartzite de l'Hamra (GZH), un réservoir compact à forte fracturation naturelle, dont l'exploitation reste difficile en raison de sa faible perméabilité et des conditions géomécaniques contraignantes.

Au vu des défis techniques et géologiques que l'on rencontre lors de l'évaluation et de l'exploitation de ces réservoirs, de nouvelles méthodes basées sur l'intelligence artificielle (IA) ont été mises en place. Ces approches avant-gardistes aident à surmonter les contraintes des procédés traditionnels, généralement onéreux et gourmands en temps, tout en délivrant des estimations plus promptes et précises des paramètres géodynamiques cruciaux, tel que le module de Young dynamique.

La finalité première de cette recherche est d'étudier l'usage des techniques de machine Learning, comme Random Forest (RF) et XGBoost (XGB), pour anticiper le module de Young dynamique à partir des informations provenant des diagraphies de puits. Cette action fait partie d'une démarche visant à parfaire la modélisation géomécanique et à perfectionner le processus décisionnel dans les activités de forage et d'exploitation des ressources non conventionnelles.

Dans ce cadre, la recherche actuelle se concentre sur plusieurs volets : un examen géologique de la zone visée, une compilation des principes de base en mécanique des roches, une exposition des techniques d'IA mises en œuvre, et enfin l'application pratique des algorithmes d'apprentissage supervisé pour prédire précisément les propriétés du réservoir de Quartzite El Hamra à Rhourde Nouss.

Introduction Générale

Chapitre I

Ce premier chapitre présente le contexte géologique de la région de Rhourde Nous, les structures tectoniques, les formations lithologiques, et l'importance pétrolière.

Chapitre II :

Dans ce deuxième chapitre les principes fondamentaux de la mécanique des roches, en se concentrant sur les propriétés mécaniques et le module de Young, le module de compressibilité et le coefficient de Poisson.

Chapitre III :

Ce chapitre se penche sur les fondements de l'intelligence artificielle, en se focalisant sur des algorithmes d'apprentissage automatique tels que Random Forest et XGBoost, et leur mise en œuvre dans l'industrie pétrolière.

Chapitre IV :

Dans ce chapitre, nous détaillons la procédure de collecte, de traitement et d'analyse des données, ainsi que l'application des algorithmes pour déterminer avec précision le module de Young dynamique.

Chapitre I : Géologie

Régionale Et Locale

Chapitre I : Géologie Régionale Et Locale

Introduction

L'analyse du cadre géologique représente une étape fondamentale pour une bonne perception des propriétés géomécaniques et pétrophysiques d'un réservoir, particulièrement dans les environnements complexes tels que les réservoirs fracturés ou compactés. Ce chapitre est entièrement dédié à l'étude géologique de la zone d'étude du sud-est algérien, par voie d'une approche intégrée mobilisant des données géographiques, stratigraphiques, tectoniques et pétrolières en vue d'enrichir la connaissance du sous-sol.

Nous commencerons par la situation géographique de la zone d'étude, puis nous définirons épistémologiquement le cadre géologique régional. La colonne stratigraphique sera traitée avec soin, focalisant l'attention sur les unités paléozoïques, notamment sur l'Ordovicien en raison de son rôle dans la géologie locale. Les grandes structures tectoniques de la région seront ensuite décrites, en tenant compte de leur implication dans la fracturation naturelle et la migration des hydrocarbures.

Enfin, les principales composantes du système pétrolier seront exposées, en insistant sur les réservoirs dits « tight », caractérisés par une porosité et une perméabilité étroitement liées à la présence de fractures naturelles. Une typologie des fractures observées dans la zone viendra conclure cette synthèse, servant de base à l'analyse géomécanique développée dans les chapitres suivants.

1. Situation géographique :

La région de Rhourde Nouss fait partie de la wilaya d'Illizi et se situe à environ 850 km au sud d'Alger, à 230 km au sud-est du champ de Hassi Messaoud, et à 350 km au nord-ouest d'Aïn Aménas. Au nord, elle limite avec la région de Gassi-Touil ; au sud, sa région voisine est celle de Tin-Fouyé Tabenkourt (TFT). Cette zone couvre l'espace compris entre les longitudes 06°24' E et 07° E, et les latitudes 29°16' N et 30° N, englobant presque l'intégralité du bloc 246. De la Rhourde El Hamra au nord au champ de Hamra au sud, cette zone s'étend sur environ 10 000 km² (WEC., 2007).

Chapitre I : Géologie Régionale Et Locale




Figure 1: Situation géographique du Champs de Rhourde Nous

2. Contexte géologique :

La compréhension approfondie du contexte géologique constitue une étape essentielle pour l'analyse des caractéristiques pétrophysiques et géomécaniques du réservoir. Cela passe notamment par l'étude détaillée de l'aspect stratigraphique, des structures tectoniques, ainsi que des particularités lithologiques qui influencent directement le comportement du milieu réservoir.

Chapitre I : Géologie Régionale Et Locale

2.1. Aspect stratigraphique :

Selon (Beicip/SONATRACH., 2002), la série stratigraphique de la région de Rhourde Nouss se divise en trois grands ensembles correspondant aux principales ères géologiques : le Paléozoïque, dominé par des dépôts silicoclastiques affectés par l'érosion hercynienne ; le Mésozoïque, marqué par une alternance de formations argilo-gréseuses, évaporitiques et carbonatées ; et enfin le Cénozoïque, représenté par des dépôts mio-pliocènes reposant en discordance sur les terrains plus anciens.

2.1.1. Le socle :

Il se présente sous la forme d'un complexe granitique et/ou métamorphique, plissé et faillé. Sa connaissance dans la région de Rhourde Nouss reste limitée en raison du faible nombre de forages l'ayant recoupé.

2.1.2. Le Paléozoïque :

Les plus anciens dépôts paléozoïques, datés du Silurien, sont un ensemble argilo-gréseux au sein du cadre hercynien discordant : les formations de l'Ordovicien et du Silurien ont été mieux préservées que les formations de l'âge dévonien et carbonifère qui ont subi une importante érosion.

2.1.2.1. Le Cambrien :

Il est principalement constitué des grès de Hassi Leïla, avec une partie inférieure composée de grès quartzitiques fins à grossiers mal triés, et une partie supérieure formée de quartzites fins, pour une épaisseur moyenne de 104 m.

2.1.2.2. L'Ordovicien :

Il s'agit d'un terme particulièrement complexe, formé d'alternances de grès quartzitiques et d'argiles. Son épaisseur moyenne varie entre 750 et 1250 m et il est composé de plusieurs unités superposées, du bas vers le haut :

- ❖ **les grès de Miribel** : ces grès, datés du Trémadoc inférieur, ont une épaisseur de 180 mètres. Ils sont principalement constitués de grès quartzitiques fins à très fins, alternant avec des argiles grises à noires et des grès argilo-silteux.

Chapitre I : Géologie Régionale Et Locale

- ❖ **Les argiles d'El-Gassi** : datées du Trémadoc moyen, ces argiles ont une épaisseur de 268 mètres. Elles sont caractérisées par l'alternance de grès quartzitiques et d'argiles silteuses gris foncé, parfois plastiques.
- ❖ **Les grès d'El-Attchane** : il s'agit d'une alternance de grès fins, silteux et quartzites bien classés, séparés par des niveaux argileux.
- ❖ **Les quartzites de Hamra** : ces quartzites, datés de l'Arenig moyen, ont une épaisseur variant de 80 à 232 mètres. Ils sont constitués de quartzites gris-brun, fins à moyens, avec des intercalations d'argiles noires.
- ❖ **Les grès d'Ouargla** : datés de l'Arenig supérieur, ces grès ont une épaisseur variant de 91 à 100 mètres. Ils sont essentiellement composés de grès quartzitiques à grains fins à moyens, de teinte gris-brun, avec des intercalations d'argiles noires.
- ❖ **Les argiles d'Azzel** : datées du Llanvirn, ces argiles présentent une épaisseur estimée entre 64 et 117 mètres. Elles sont constituées d'argiles gris-noires, silteuses, plus ou moins indurées.
- ❖ **Les grès d'Oued Saret** : datés du Llandeilien, ces grès ont une épaisseur variant de 103 à 137 mètres. Ils sont fins, parfois quartzitiques.
- ❖ **Les argiles microconglomératiques** : datées du Caradoc, ces argiles présentent une épaisseur variant de 66 à 119 mètres. Cette unité est exclusivement constituée d'argiles microconglomératiques à grains de quartz.
- ❖ **La dalle de M'kratta** : datée de l'Asghil, cette dalle présente une épaisseur variant de 6 à 10 mètres, constituée de grès quartzitiques allant du très fin au moyen, puis au grossier.

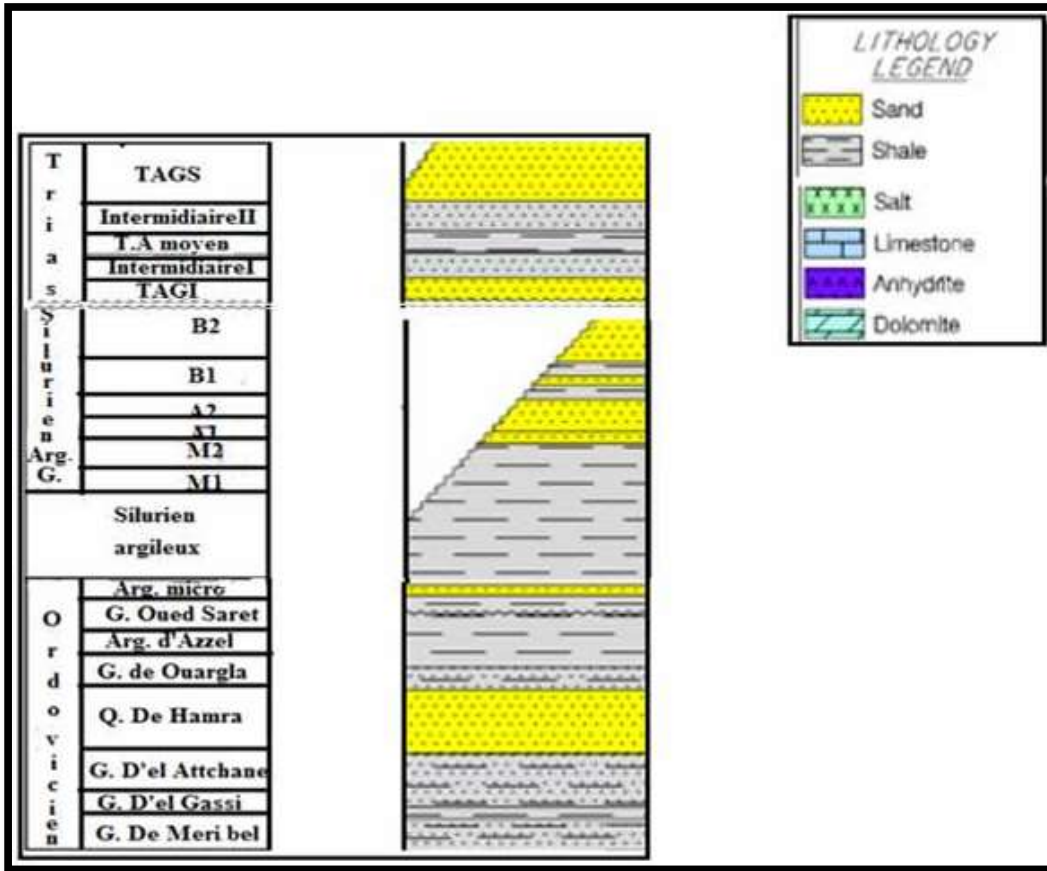


Figure 2: Colonne stratigraphique de Rhourde Nouss (Mokrani L., Saidj N., 2015)

2.1.2.3. Silurien :

Le Silurien de la région de Rhourde Nouss est divisé en deux grandes séries lithologiques :

- une série argileuse épaisse à la base,
- surmontée par une série argilo-gréseuse plus hétérogène.

Le Silurien argileux

Daté du Llandovery au Wenlock (Llandoveryen – Taranon – Wenlock), il présente une épaisseur comprise entre 232 et 341 mètres. Il est constitué principalement d'argiles noires micacées, riches en faune fossile, notamment des brachiopodes, des gastéropodes et des graptolites. Ces dépôts correspondent aux fameuses "argiles à graptolites", témoignant de conditions marines relativement profondes et calmes.

Chapitre I : Géologie Régionale Et Locale

Le Silurien argilo-gréseux

Attribué au Ludlow, cette série représente le réservoir F6 et se compose de six unités superposées, numérotées de M1 à B2 :

- ❖ **Unité M1** : Argiles silteuses indurées, avec quelques intercalations carbonatées à la base. Son épaisseur varie entre 32 et 37 mètres.
- ❖ **Unité M2** : Argiles silteuses indurées, parfois intercalées de grès de Mederba ; épaisseur variant de 61 à 153 mètres.
- ❖ **Unité A1** : Grès fins à moyens, bien consolidés à ciment siliceux, interstratifiés de minces couches d'argiles grises à noires ; épaisseur entre 13 et 18 mètres.
- ❖ **Unité A2** : Niveau de grès fins, silteux, à passées argileuses dans sa partie basale ; épaisseur de 98 à 126 mètres.
- ❖ **Unité B1** : Succession de grès quartzitiques compacts et d'argiles grises noires micacées et indurées. Cette unité, affectée par l'érosion hercynienne, notamment sur le flanc Sud-Est de la structure de Rhourde Nouss, présente une épaisseur variable de 0 à 149 mètres.
- ❖ **Unité B2** : Alternance de grès quartzitiques et d'argiles micacées. Elle est également tronquée par l'érosion hercynienne, principalement au Sud-Est et au Sud-Ouest de la région étudiée. Son épaisseur varie de 0 à 111 mètres.

2.1.2.4. Le Dévonien, le Carbonifère et le Permien

Les formations du Dévonien, du Carbonifère et du Permien sont totalement absentes dans la région de Rhourde Nouss, en raison de l'intense érosion hercynienne qui a affecté ces niveaux. Par conséquent, le Trias repose directement sur le Silurien, lui-même localement entamé par cette érosion.

2.1.3. Le Mésozoïque :

Est représenté dans la région de Rhourde Nouss par trois grandes périodes : le Trias, le Jurassique et le Crétacé. Cette ère marque une reprise de la sédimentation après l'érosion hercynienne qui a fortement affecté les terrains paléozoïques.

Chapitre I : Géologie Régionale Et Locale

2.1.3.1. Le Trias

Se dépose en discordance hercynienne sur le Silurien argilo-gréseux. Il est composé de cinq unités stratigraphiques très différenciées, disposées de la base vers le sommet :

- ❖ **Le Trias Argilo-Gréseux Inférieur (TAGI)** : d'âge Carnien, avec une épaisseur variant de 15 à 57 m ; il se compose de bancs de grès fins à ciment silico-argileux, intercalés par des passées d'argiles silteuses, avec présence de microconglomérats à la base ;
- ❖ **Le Trias Intermédiaire I** : d'âge Norien inférieur, son épaisseur varie de 29 à 70 m ; il est formé de grès fins, argileux à la base et tendant vers une texture quartzitique au sommet ;
- ❖ **Le Trias Argileux Moyen** : attribué au Norien moyen, présente une épaisseur de 33 à 53 m ; cette unité est constituée d'argiles brunes à rouges, silteuses et dolomitiques, parfois indurées ;
- ❖ **Le Trias Intermédiaire II** : daté du Norien supérieur, d'une épaisseur comprise entre 53 et 77 m ; il se caractérise par une alternance de grès fins et d'argiles rouges à vertes, silteuses ;
- ❖ **Le Trias Argilo-Gréseux Supérieur (TAGS)** : d'âge Rhétien, avec une épaisseur variante entre 100 et 198 m ; cette unité débute par des grès fins gris-blanc, parfois microconglomératiques, et est surmontée par des argiles brunes à rouges, silteuses et légèrement dolomitiques. C'est le principal réservoir de la région de Rhourde Nous.

2.1.3.2. Jurassique :

Le Jurassique est bien représenté dans la région de Rhourde Nous par une série sédimentaire épaisse et variée. Elle témoigne de conditions de dépôt évolutives, allant des environnements lagunaires évaporitiques aux milieux marins restreints. Cette série est subdivisée en trois grandes unités stratigraphiques : le Lias, le Dogger et le Malm.

Le Lias

Chapitre I : Géologie Régionale Et Locale

Le Lias est subdivisé en cinq unités stratigraphiques qui se succèdent de la base vers le sommet :

- ❖ **Le Lias Argileux (S1)** : d'une épaisseur variante entre 39 et 62 m, il est constitué d'argiles versicolores accompagnées de silts.
- ❖ **Le Lias Salifère (S2)** : d'épaisseur importante variant de 202 à 443 m, il est caractérisé par des sels massifs blancs à rosâtres, intercalés par des bancs d'argiles brunes et des niveaux d'anhydrite, marqueurs à la base.
- ❖ **L'Horizon B** : épais de 14 à 42 m, cet horizon est formé de dolomies graveleuses, vacuolaires ou silteuses, légèrement anhydritiques.
- ❖ **L'Horizon H** : dont l'épaisseur varie entre 13 et 41 m, composé d'anhydrite blanche compacte à aspect crayeux, avec quelques passées de gypse rose maclé. Il constitue un excellent marqueur sismique à l'échelle régionale.
- ❖ **Le Lias Argilo-Dolomitique** : formé d'argiles silteuses dolomitiques avec quelques passées anhydritiques, son épaisseur est comprise entre 140 et 220 m.

Le Dogger

Le Dogger est représenté par deux unités principales :

- ❖ **Le Dogger Lagunaire** : d'épaisseur variable entre 0 et 322 m, constitué d'une alternance d'argiles silteuses et de grès fins à moyens.
- ❖ **Le Dogger Argileux** : dont l'épaisseur varie de 55 à 228 m, formé d'argiles versicolores intercalées de bancs de grès fins.

Le Malm

Le Malm, dont l'épaisseur varie de 0 à 232 m, est constitué principalement d'argiles silteuses, tendres, parfois dolomitiques. Il marque la fin du Jurassique dans la région étudiée.

2.1.3.3. Le Crétacé :

Dans la région de Rhourde Nouss, le Crétacé est représenté par une importante série sédimentaire, divisée en deux grandes unités : le Crétacé inférieur et le Crétacé supérieur. Cette succession traduit une évolution des environnements de dépôt, allant

Chapitre I : Géologie Régionale Et Locale

de conditions deltaïques et côtières vers des milieux marins profonds, voire évaporitiques.

Le Crétacé inférieur :

- ❖ **Néocomien** : D'une épaisseur comprise entre 46 et 345 m, cette formation est constituée d'argiles silteuses dolomitiques avec des alternances de sables fins
- ❖ à grossiers et de grès fins à très fins, parfois enrichis en lignite ou en pyrite.
- ❖ **Barrémien** : Épaisse en moyenne de 529 m, elle se caractérise par une alternance de sables, de grès fins et d'argiles rouges sableuses, légèrement dolomitiques. La partie supérieure marque une discordance d'âge autrichien.
- ❖ **Aptien** : Cette unité, peu développée (0 à 22 m), est composée de marnes calcaro-dolomitiques.
- ❖ **Albien** : Avec une épaisseur variant de 30 à 216 m, elle se compose de sables fins à grossiers et de grès argilo-dolomitiques.

Le Crétacé supérieur :

- ❖ **Cénomaniens** : Son épaisseur varie de 62 à 111 m. Il est constitué d'argiles carbonatées contenant des passées d'anhydrite.
- ❖ **Turonien** : D'une épaisseur de 69 à 113 m, cette formation est composée d'une alternance d'argiles versicolores plastiques, de calcaires blancs à beiges parfois argileux, et de marnes calcaires.
- ❖ **Sénonien** : Subdivisé en trois sous-unités :
 - Sénonien salifère : D'une épaisseur de 13 à 80 m, constitué de sel massif blanc avec parfois des intercalations argileuses.
 - Sénonien anhydritique : Variant de 111 à 233 m, formé d'anhydrite massive beige alternant avec des argiles carbonatées.
 - Sénonien carbonaté : Épaisseur comprise entre 0 et 194 m, constitué de calcaires dolomitiques micro-cristallins.

2.1.4. Le Cénozoïque :

Chapitre I : Géologie Régionale Et Locale

Le Cénozoïque n'est représenté que par le Mio-Pliocène. Les formations plus anciennes — Paléocène, Éocène, Oligocène — sont absentes, probablement en raison de l'érosion ou d'une non-sédimentation liée à la tectonique pyrénéenne.





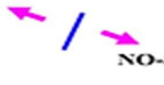

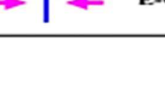
❖ Le Mio-Pliocène :

D'une épaisseur variant de 154 à 677 m, il repose en discordance sur les formations carbonatées du Sénonien. Il est constitué de sables fins à très grossiers, parfois gréseux, avec des intercalations d'argiles sableuses à tendance dolomitique, ainsi que de passées de calcaire sableux.

2.2. Aspect structural :

L'évolution tectonique de la région s'inscrit dans la dynamique générale de la plateforme saharienne, marquée par un héritage structural anté-paléozoïque, notamment l'Orogenèse Panafricaine, ainsi que par les événements hercyniens et alpins. Cette dynamique intègre également la province triasique, correspondant à un bassin intraplaque de type plateforme épicontinentale (Perrodon., 1985). Sur le plan géodynamique, la région est située au sein de cette province et présente une architecture étroitement liée au môle d'Amguid El-Biod, ayant enregistré de multiples phases tectoniques au cours de l'histoire géologique (Boudjemaa., 1987).

Tableau 1: Structural interprétatif montrant l'effet des importantes phases tectoniques affectant le Sahara algérien (BOUDJEMAA 1994 et BEICIP).

ERE	EPOQUE	PHASES	DIRECTION DES PHASES	EFFETS SUR LES JEUX DE FAILLES
CENOZOIQUE	NEOGENE MIOCENE	ALPINE TARDIVE TERTIAIRE TARDIVE N. 60	 N060°	Jeu en compression
		ALPINE MOYENNE EOCENE N. 160	 N160°	Jeu en compression sur les accidents N-S et création de nouvelles structures
MESOZOIQUE	CRETACE	PHASE AUTRICHIENNE (ALPINE PRECOCE)	 N090°	Jeu en inverse sur les accidents N-S
	JURASSIQUE			
	TRIAS			
PALEOZOIQUE	PERMIEN	PHASE HERCYNIENNE TARDIVE	 N120°	Jeu inverse sur les failles NE-SO
	CARBONIFERE VISIEN	PHASE HERCYNIENNE PRECOCE		
		DEVONIEN Supérieur Moyen Inférieur	PHASE FRASNIEENNE	 NO-SE
	SILURIEN ORDOVICIEN	PHASE CALEDONIENNE	 E-O ??	
	750 – 550 Ma	PHASE PANAFRICAINE		 E-O

2.2.1. Les phases tectoniques :

Les principales phases tectoniques et les orientations des contraintes associées ayant marqué la région sont synthétisées par (Boudjema., 1987) selon la séquence suivante :

2.2.1.1. Cycle Hercynien :

Le cycle hercynien, qui s'est déroulé entre 416 et 250 millions d'années, comprend deux grandes phases tectoniques. La première, appelée phase hercynienne précoce, se manifeste par un régime compressif orienté NE/SO, déduit de l'observation des stries dans les grès de Khenig du Dévonien supérieur. La seconde, dite phase hercynienne majeure, est marquée par des contraintes compressives orientées NO/SE, à l'origine du jeu de failles parallèles, ayant structuré le relief en horsts et grabens, reflet d'une déformation différentielle de la croûte terrestre.

2.2.1.2. Phase Autrichienne :

Chapitre I : Géologie Régionale Et Locale

La phase autrichienne (100 Ma) résulte de l'ouverture de l'Atlantique Sud entre l'Amérique du Sud et l'Afrique. Une compression E-W a réactivé les failles existantes sous forme de failles en échelons orientées NE-SW, permettant ainsi l'installation et le piégeage des hydrocarbures.

2.2.1.3. Phase Atlasique (Eocène) :

Cette phase compressive de direction NNE-SSW est tardive, s'étendant de l'Éocène (à partir du Lutétien) au Miocène (entre l'Oligocène et le Miocène). Elle se manifeste localement par l'érosion des formations éocènes et par une lacune miocène. Survenue après l'hydrocarbonogénèse, cette phase a probablement entraîné la formation de barrières de perméabilité liées au déplacement des niveaux de réservoir, favorisant le colmatage des fractures et la dégradation des propriétés pétrophysiques du réservoir.

2.2.2. Caractéristiques structurales et tectoniques de la région de Rhourde

Nouss :

À partir des données géologiques et géophysiques disponibles, la région de Rhourde Nouss se caractérise par une forte mobilité tectonique, ayant engendré d'intenses déformations au cours de l'histoire géologique. Ces dernières ont favorisé, en partie, la migration et l'accumulation des hydrocarbures dans des pièges structuraux.

L'architecture de la zone révèle une organisation complexe selon deux grandes directions structurales principales :

- ❖ **La direction subméridienne (Nord-Sud)** : Elle suit le prolongement nord du môle d'Amguid El-Biod. Elle correspond notamment à la faille de Ramade, dont le rejet atteint 2050 m à Eaktaia, ainsi qu'à la structure de Hamra, toutes deux orientées Nord-Sud (BEICIP., 1991).
- ❖ **La direction NE-SO** : Trois grands trends structuraux peuvent y être distingués :
 - Le trend structural A, reliant la bordure nord-ouest de Rhourde Nouss à Rhourde Hamra.

Chapitre I : Géologie Régionale Et Locale

- Le trend structural **B**, traversant les structures d'El Mouileh, Draa Allal, Rhourde Nouss Sud-Ouest, puis se ramifiant vers le sud.
- Le trend structural **C**, à extension régionale, reliant les structures de Ektaia, Hamra, M'ksen et Rhourde Adra.

Ces directions témoignent d'une structuration tectonique ancienne, régulièrement réactivée, à l'origine de la complexité géologique actuelle de la région.

2.2.3. Influence de la structuration tectonique sur le potentiel pétrolier :

La complexité tectonique de la région de Rhourde Nouss, résultant de la superposition de plusieurs phases de déformation, conditionne fortement la genèse et la distribution des accumulations d'hydrocarbures. Il ne s'agit pas uniquement de pièges structuraux classiques formés par des compressions et des réactivations de failles, mais également de mécanismes favorisant la migration verticale et latérale des hydrocarbures vers les zones de piégeage. Les horsts, grabens et failles associés à ces déformations peuvent ainsi jouer un double rôle : soit en tant que conduits facilitant la migration des fluides, soit en tant que barrières retenant ces derniers, influençant directement la géométrie et la qualité des réservoirs (Perrodon., 1985 ; Boudjema., 1987).

La combinaison entre cette dynamique tectonique active, la présence de roches mères riches en matière organique et de couvertures imperméables efficaces confère à la région de Rhourde Nouss un potentiel pétrolier élevé. Elle constitue ainsi un cadre géodynamique majeur à prendre en compte dans toute évaluation des systèmes pétroliers locaux. Ces éléments seront approfondis dans la section suivante dédiée à l'analyse du système pétrolier local.

2.3. Aspect pétrolier :

La zone de Rhourde Nouss s'inscrit dans le domaine saharien algérien dont l'immense potentialité en hydrocarbures a été mise en évidence lors des découvertes du XXe siècle : la structure pétrolière locale est caractérisée par des schistes siluriens à forte matière organique et des réservoirs gréseux-quartzitiques paléozoïques. Les niveaux compacts sont également en voie d'exploration, tels que les Quartzites de l'Hamra, dont la perméabilité, bien que faible, est compensée par une porosité fracturée exploitable. La structure de Rhourde Nouss Central présente une morphologie

Chapitre I : Géologie Régionale Et Locale

particulière en fleur, à la suite de l'intersection d'une faille inverse profonde orientée N-S avec un accident décrochant orienter NE-SW et à l'origine d'un mouvement transgressif du Crétacé/post-Crétacé ayant provoqué une inversion complexe qui a donné lieu à des failles inverses en réseau ([Sonatrach., Document interne](#)), l'ensemble étant un cadre structural pesant sur la migration, le piégeage et la productivité des hydrocarbures. Cette section restitue les caractéristiques géologiques, structurales et pétrolières de la zone avec une attention particulière portée aux spécificités des réservoirs fracturés et leur potentiel d'exploitation.

2.3.1. Contexte pétrolier régional :

Le bassin d'étude se situe dans le domaine saharien, reconnu pour son potentiel pétrolier depuis les grandes découvertes des années 1950 dans les bassins d'Illizi et de Berkine ([Benayad, Park., et Kharfi., 2011](#)). Les réservoirs en production sont majoritairement gréseux et quartzitiques, datés de l'Ordovicien au Dévonien, associés à des roches mères siluriennes riches en matière organique. En plus des réservoirs conventionnels, l'intérêt se porte désormais sur les réservoirs compacts, tel que le Quartzite de l'Hamra, caractérisé par une faible perméabilité mais une porosité fracturée exploitable. Ce contexte géologique complexe justifie le recours à des techniques avancées d'exploration et de stimulation.

2.3.2. Le système pétrolier :

2.3.2.1. Roche mère :

Le principal système pétrolier de la région de Rhourde Nouss est associé aux schistes siluriens riches en matière organique, en particulier à la base du Silurien où l'on observe un pic radioactif corrélé à une matière organique bien conservée, bien que de faible épaisseur. Les niveaux moyens et supérieurs sont plus épais mais généralement pauvres à médiocres en contenu organique ([Beicip., 1995](#)). Un système secondaire pourrait être lié aux quartzites de l'Hamra, pour lesquels une alimentation potentielle à partir des argiles ordoviciennes (Argiles d'El Gassi) n'est pas à exclure ([WEC., 2007](#)).

2.3.2.2. Roche réservoir

Les réservoirs actifs dans la région comprennent :

Chapitre I : Géologie Régionale Et Locale

- ❖ **Le TAGS (Trias Argilo-Gréseux Supérieur)**, principal réservoir, formé de dépôts fluviatiles à porosité variant entre 15 et 20 %, avec des perméabilités atteignant 1 Darcy (Beicip., 2002).
- ❖ **Les réservoirs infra-TAGS**, moins homogènes, aux porosités de 5 à 15 % et perméabilités <10 mD, souvent influencés par la discordance hercynienne.
- ❖ **Le niveau A du Silurien**, composé de barres gréseuses marines, représente le meilleur réservoir silurien avec jusqu'à 50 m d'épaisseur utile (porosité 10–15%).
- ❖ **Les réservoirs profonds** du Cambro-Ordovicien, notamment les quartzites de l'Hamra, constituent une cible stratégique en raison de leur grande épaisseur (200 à 250 m) et de leur fracturation intense (Beicip., 2002). Bien qu'ils présentent une faible perméabilité interstitielle, leur porosité fracturée offre un potentiel exploitable.

2.3.2.3. Roche couverture :

La couverture régionale est assurée par les évaporites du Lias, étendues et efficaces à l'échelle des structures de Rhourde Nouss. Pour les niveaux plus profonds, notamment les quartzites de l'Hamra, ce rôle est repris par les argiles d'Azzel, jouant un rôle de couverture locale (WEC., 2007).

2.3.3. Types de pièges et structuration :

Les pièges présents dans la région de Rhourde Nouss sont principalement dus aux mouvements tectoniques d'origine autrichienne, ayant généré des fermetures structurales significatives, particulièrement associées aux réservoirs du Trias et du Silurien Argilo-Gréseux. Ces pièges de grande amplitude ont joué un rôle déterminant dans l'accumulation d'hydrocarbures. Il est supposé que les hydrocarbures stockés dans ces réservoirs ont été mis en charge après des migrations latérales sur de longues distances en provenance de l'Ouest et du Nord, et éventuellement des migrations verticales à travers les failles, permettant aux fluides de remonter vers les niveaux de réservoir (Beicip., 1995).

2.3.4. Géologie et structure des Quartzites de l'Hamra à Rhourde Nouss Central :

Chapitre I : Géologie Régionale Et Locale

La formation des Quartzites de l'Hamra est globalement homogène à l'échelle régionale. Cependant, au niveau du champ de Rhourde Nouss Central, la variabilité locale reste très marquée, en raison de la complexité structurale de la région qui a subi plusieurs phases tectoniques majeures.

Ce champ est situé dans une zone charnière entre deux grandes unités structurales : à l'ouest, le môle d'Amguid El Biod, connu pour ses fortes déformations et ses anomalies d'épaisseur stratigraphique ; et à l'est, le haut de Maouar, une formation d'âge anté-mésozoïque, érodée jusqu'à l'Ordovicien (Beicip., 2002 ; WEC., 2007).

La région présente des structures plissées complexes, où alternent des anticlinaux prononcés et des synclinaux profonds. Ces reliefs résultent de plusieurs phases tectoniques superposées, avec une phase principale de compression — la phase autrichienne — qui a aussi contribué à la formation de structures en fleur à jeu dextre, typiques de tectoniques transgressives (voir sous-section 1.2.2). Les failles associées sont souvent très inclinées, parfois presque verticales, comme l'ont confirmé les interprétations sismiques réalisées (Sonatrach/PED., 2005).

Du point de vue réservoir, quatre électrofaciès principaux ont été identifiés grâce à une analyse intégrée des carottes et des diagraphies issues de plusieurs puits dans la zone (Beicip., 2002 ; Sonatrach., 2005) :

- **QH-1** : marqueur basal clair, correspondant à la plus faible valeur du gamma ray à la base du Grès d'Ouargla, qui marque le sommet réel des Quartzites de l'Hamra.
- **QH-2** : un repère majeur du complexe de Rhourde Nouss, reconnu dans tous les puits forés.
- **QH-3 et QH-4** : bien identifiés localement, bien que certaines incertitudes persistent dans certains puits où le réservoir n'a pas été entièrement foré.

Ces caractéristiques géologiques et structurales donnent au réservoir une complexité interne importante, ce qui nécessite une approche spécifique en ingénierie de réservoir et en complétion, afin de gérer au mieux la porosité fracturée et les pièges structuraux complexes.

2.4. Les Réservoirs Compacts

Chapitre I : Géologie Régionale Et Locale

2.4.1. Définition et Importance

Tight Réservoirs sont des réservoirs gaziers ou pétroliers dont les roches sont fortement densifiées et peu poreuses, généralement de nature gréseuse ou carbonatée. Ils possèdent une porosité effective inférieure à 10 % et une perméabilité extrêmement faible (inférieure à 1 millidarcy, parfois proche des valeurs du microdarcy) (Holditch., 2006). Cette faible connectivité entre les pores freine considérablement l'écoulement des hydrocarbures au sein de la matrice rocheuse, limitant ainsi la mobilité naturelle des fluides.

Ces réservoirs se sont majoritairement formés dans des environnements géologiques profonds, où l'effet d'une pression lithostatique importante – due au poids des successions sédimentaires – entraîne généralement une compaction mécanique, une cimentation intergranulaire, voire une recristallisation. Ces processus confèrent aux roches des propriétés géomécaniques particulières : une forte cohésion, une faible déformabilité, et une tendance accrue à la fracturation sous l'effet des contraintes tectoniques ou thermomécaniques.

Alors que les réservoirs conventionnels montrent des signes d'épuisement progressif, les Tight Réservoirs apparaissent aujourd'hui comme des atouts stratégiques majeurs pour répondre à la demande énergétique mondiale. Des formations emblématiques telles que le Bakken ou le Barnett Shale (États-Unis) ont révélé leur fort potentiel économique, bien que leur exploitation reste techniquement complexe (Jarvie et al., 2007).

D'après (Ahmed., 2018), plus de 50 % des réservoirs pétroliers dans le monde présentent des caractéristiques de roches compactées ou fracturées, ce qui souligne leur importance croissante dans les stratégies de développement énergétique. Leur valorisation nécessite toutefois une caractérisation géologique et géomécanique fine, en particulier par une compréhension approfondie des réseaux de fractures naturelles.

Ainsi, les Tight Réservoirs se situent à l'interface entre géologie et ingénierie, où la compréhension du comportement des roches sous contrainte, de leur architecture poreuse et de leur histoire tectonique est essentielle pour évaluer leur potentiel productif et mettre en œuvre des solutions d'exploitation adaptées.

2.4.2. Cas d'Étude : Quartzites de l'Hamra (Rhourde Nous)

Chapitre I : Géologie Régionale Et Locale

Au sein du bassin de Rhourde Nous, les Quartzites de l'Hamra constituent un exemple de réservoir compact fracturé : malgré une porosité primaire faible, la connexion de réseaux de fractures interconnectés est essentielle à la connectivité hydraulique pour la production (Beicip., 1995 ; WEC., 2007).

Le contexte géologique complexe de ce réservoir est le fruit d'un passif tectonique consistant en plusieurs événements majeurs. On y observe trois types de fractures ouvertes selon les contraintes : des fractures multidirectionnelles, radiales ou longitudinales (Nelson., 2001 ; Tiab et Donaldson., 2015).

Le succès des forages horizontaux dans ce type de réservoir repose sur leur capacité à capter les réseaux de fractures et donc, sur la productivité (Jarvie et al., 2007). Ne pas tenir compte de ce paramètre pourrait conduire à une inscription des réserves surévaluées, et des stratégies d'exploitation peu efficaces.

L'est donc impératif d'assurer une fine caractérisation des réseaux de fractures s'appuyant sur des données sismiques de haute résolution, des diagaphies avancées, des modélisations géomécaniques valables afin de mieux optimiser la récupération dans ces réservoirs

3. La Fracturation Naturelle :

La fracturation naturelle constitue un phénomène géologique fondamental dans le comportement des réservoirs compacts. Elle désigne toute cassure présente dans la roche, qu'elle soit accompagnée ou non d'un déplacement relatif entre les deux lèvres. Ces structures jouent un rôle clé dans la circulation des fluides, la connectivité intergranulaire et la réponse mécanique des réservoirs aux sollicitations de forage et de production (Nelson., 2001 ; Tiab et Donaldson., 2015).

3.1. Typologie des fractures naturelles :

On distingue principalement trois types de fractures naturelles selon leur degré d'ouverture :

3.1.1. Les fractures ouvertes : Ce sont des fractures présentant plus de 50 % de vide entre les deux lèvres. Elles sont considérées comme bénéfiques, car elles permettent un drainage efficace des fluides au sein du réservoir.

Chapitre I : Géologie Régionale Et Locale

Elles sont souvent responsables de l'amélioration de la perméabilité dans les milieux peu poreux.

3.1.2. Les fractures colmatées : Ces fractures sont remplies par des minéraux secondaires, ce qui empêche la circulation des fluides. Elles peuvent agir comme des barrières de perméabilité et compliquer l'exploitation du réservoir.

3.1.3. Les fractures partiellement colmatées : Elles conservent un vide résiduel malgré un remplissage partiel. Leur influence sur la productivité dépend du degré de colmatage et de leur interconnexion avec d'autres structures ouvertes.

3.2. Microstructures associées :

Les fractures naturelles sont souvent accompagnées de structures microtectoniques qui renseignent sur l'histoire déformationnelle du réservoir :

3.2.1. Les diaclases : Fractures sans déplacement relatif des lèvres, souvent perpendiculaires aux couches sédimentaires. Elles sont fréquentes dans les réservoirs sédimentaires et peuvent avoir une répartition régulière (Rives., 1992).

3.2.2. Les paraclases : Elles sont caractérisées par un déplacement parallèle au plan de fracture, et sont souvent associées à des phénomènes de cisaillement.

3.2.3. Les stylolites : Structures en dents de scie formées par dissolution sous pression. Celles à plans horizontaux traduisent une compaction, tandis que celles à plans verticaux témoignent d'une activité tectonique.

3.2.4. Les brèches tectoniques : Résultant du broyage de la roche lors de mouvements tectoniques, elles remplissent les vides entre fragments et signalent souvent la présence de grandes failles.

3.3. Effets des fractures naturelles :

Durant le forage

Les fractures naturelles peuvent avoir un double impact pendant les opérations de forage :

Chapitre I : Géologie Régionale Et Locale

- **Avantages** : Elles permettent une meilleure circulation du fluide de forage et réduisent parfois la pression nécessaire pour atteindre la zone cible. Elles facilitent également le drainage précoce des hydrocarbures lors des tests de production.
- **Inconvénients** : Certaines fractures très ouvertes peuvent provoquer des pertes importantes de fluide de forage, entraînant des instabilités dans le puits et augmentant les coûts opérationnels.

Durant la production

Les effets des fractures naturelles persistent lors de la phase de production :

- **Avantages** : Elles augmentent la perméabilité effective, particulièrement dans les réservoirs à faible porosité matricielle. Elles permettent également une meilleure connectivité entre les pores et facilitent le déplacement des fluides vers le puits producteur.
- **Inconvénients** : Lorsque les fractures sont connectées à des aquifères sous-jacents ou latéraux, elles peuvent entraîner une remontée prématurée d'eau. De plus, si la matrice rocheuse est peu contributive, la production peut chuter rapidement malgré un débit initial élevé

Chapitre II : Généralités
sur la Mécanique des
Roches

Chapitre II : Généralités sur la Mécanique des Roches

Introduction

L'extraction des hydrocarbures représente l'un des objectifs majeurs de l'industrie pétrolière. Pour y parvenir, il est indispensable de comprendre la nature du sous-sol, qui se compose d'un empilement complexe de couches géologiques aux caractéristiques très diverses. Ces couches se sont formées au fil du temps par des processus de sédimentation, avant d'être modifiées par l'action continue de différentes forces externes, qu'elles soient d'origine naturelle ou humaine.

Pour garantir le bon déroulement des opérations d'exploitation, il est crucial d'identifier et de maîtriser les phénomènes physiques qui influencent le comportement des roches, tout en surmontant les diverses contraintes techniques. C'est ici qu'intervient la mécanique des roches : une discipline essentielle qui permet d'analyser, modéliser et quantifier les effets mécaniques qui touchent les formations géologiques.

Étroitement liée à la géomécanique, cette science joue un rôle central dans la mise en œuvre de nombreuses techniques utilisées aujourd'hui, notamment la fracturation hydraulique. Cette dernière repose largement sur les principes fondamentaux de la mécanique des roches pour être appliquée de manière efficace et sécurisée.

1. Les contraintes

1.1. Définition

Contrainte ou tension (stress), c'est l'ensemble des forces affectant un matériau et tendant à le déformer. En tout point de ce corps, on peut définir la contrainte (σ) comme le rapport entre la force appliquée (F) à la surface (S), elle est donnée par la relation suivante :

$$\sigma = \frac{F}{S}$$

La contrainte est une quantité mathématique appelée tenseur, et l'état des contraintes est souvent appelé tenseur des contraintes. Une contrainte a les propriétés d'un vecteur qui n'est pas souvent perpendiculaire à la surface d'application. Notamment, on peut la décomposer en une contrainte normale (σ_n) à la surface d'application, et une contrainte tangentielle, ou de cisaillement (τ) dans le plan de cette surface. Les trois contraintes correspondantes sont la contrainte maximale (σ_1), la

Chapitre II : Généralités sur la Mécanique des Roches

contrainte intermédiaire (σ_2) et la contrainte minimale (σ_3). à travers ces trois principales contraintes on définit ce qu'on appelle régime de contrainte ou régime de stress.




Figure 3: Décomposition Vectorielle d'une Contrainte en une Normale et une Tangentielle (Sonatrach/Schlumberger., 2010)




Figure 4: Principaux Plans Correspondant aux Trois Principales Contraintes σ : σ_1 , σ_2 , σ_3 (Sonatrach/Schlumberger., 2010)

En géomécanique des réservoirs, on distingue trois contraintes principales : la contrainte verticale (σ_v), la contrainte horizontale maximale (σ^H) et la contrainte horizontale minimale (σ^h).

3.4. Contrainte verticale (σ_v)

Elle est orientée perpendiculairement à la surface du sol et résulte principalement de la charge gravitationnelle exercée par les formations rocheuses sus-jacentes. Elle est donc directement liée au poids des couches supérieures.

Chapitre II : Généralités sur la Mécanique des Roches

3.5. Contraintes horizontales (σ^H et σ^h)

Ces contraintes agissent dans le plan horizontal. Elles dépendent en grande partie de la tectonique régionale. D'autres facteurs peuvent également les influencer ou les accentuer, tels que les variations thermiques, les phénomènes tectoniques actifs, ou encore la présence de structures géologiques particulières.




Figure 5: Orientation des trois contraintes (σ_v , σ_h et σ_H).

2. Déformation

C'est le changement de la forme d'un matériau. La déformation permanente observée ou déformation finie acquise par une roche dépend de ses propriétés et des contraintes subies, compression, traction ou cisaillement. (Alain F., ; Raoult J.-F., 2010)




Figure 6: Les Différentes Contraintes Subi par une Roche.

Chapitre II : Généralités sur la Mécanique des Roches

La déformation du corps est mesurée par son élongation " ϵ " telle que :

Ou :

l_0 =Longueur initiale

l_1 =Longueur finale

$$\epsilon = \frac{l_1 - l_0}{l_0}$$

2.1. Différents Stades de Déformation

Les roches peuvent se déformer de diverses manières lorsqu'elles subissent des contraintes. Elles passent souvent par les deux stades suivants, avant d'arriver à la fracture.

2.1.1. Elasticité

Le lien le plus simple entre contrainte et déformation pour un matériau est son comportement élastique, où toute déformation est annulée lors de la suppression de la contrainte appliquée. La forme la plus simple d'élasticité est l'élasticité linéaire isotrope.

- La linéarité signifie que l'application d'une contrainte double engendre une déformation double
- L'isotropie signifie qu'une contrainte donnée engendre les mêmes niveaux de déformations quelle que soit l'orientation de l'état de contrainte c'est-à-dire que le matériau a le même aspect dans toutes les directions.

2.1.2. Plasticité

Lorsqu'une roche est chargée au-delà de sa limite élastique elle peut céder, c'est-à-dire subir une déformation permanente et lorsque la contrainte est annulée, elle ne revient pas à sa forme originelle.

Chapitre II : Généralités sur la Mécanique des Roches




Figure 7: Relation Contrainte Déformation selon la Rhéologie des Roches(<http://coursgeologie.com/la-deformation-des-roches-65/>)

Régime de stress

Le régime de stress est principalement déterminé par la relation entre les trois contraintes principales.

Régime extensif

Lorsqu'une contrainte verticale (σ_v) est supérieure aux contraintes horizontales, le milieu subit une extension, ce qui engendre la formation de failles normales.

Régime compressif

Lorsque la contrainte horizontale maximale (σ^H) dépasse la contrainte verticale, le milieu est en compression, ce qui conduit à la formation de failles inverses.

Régime décrochant

Ce régime apparaît lorsque les deux contraintes maximales (σ_v et σ^H) dominent la contrainte horizontale minimale (σ^h). Il est caractérisé par des mouvements en cisaillement et donne lieu à des failles décrochantes. (Sonatrach/Schlumberger, 2007)

Chapitre II : Généralités sur la Mécanique des Roches




Figure 8: Les Différents Régimes de Stress Selon le Contexte Tectonique (Schlumberger., 2010)

3. Les propriétés mécanique des roches

3.1. Définition et importance

La mécanique des roches est une discipline fondamentale de la mécanique appliquée, consacrée à l'analyse du comportement mécanique des formations rocheuses naturelles exposées à des contraintes d'origine naturelle ou humaine. Elle étudie la réaction des roches face aux contraintes, que ce soit par déformation, fracture ou résistance, en se basant sur l'examen des caractéristiques physiques, de l'élasticité et de la résistance pour simuler leur comportement dans différents environnements géologiques ou industriels (Hoek and Brown., 1997). elle permet d'estimer comment les réservoirs souterrains réagiront aux interventions de forage, d'injection ou d'extraction. Elle est essentielle pour assurer la stabilité des puits, optimiser l'efficacité des méthodes de fracturation hydraulique et minimiser les dangers géomécaniques comme l'éroulement des parois, le glissement des failles ou la compression des réservoirs. En comprenant parfaitement des caractéristiques mécaniques telles que le coefficient de Poisson, le module de Young et la résistance à la compression, les ingénieurs sont en mesure d'élaborer des stratégies d'exploitation plus sûres et plus efficaces (Fjaer et al., 2008).

3.2. Les propriétés élastiques des roches

Les propriétés élastiques des roches représentent leur réaction mécanique lorsqu'elles subissent des pressions, plus précisément leur aptitude à se modifier de façon réversible. Ces caractéristiques sont cruciales pour saisir comment les formations

Chapitre II : Généralités sur la Mécanique des Roches

géologiques réagissent aux forces tectoniques, aux contraintes de surface ou lors de l'extraction et de l'exploitation des ressources souterraines comme le pétrole et le gaz. Ces caractéristiques sont habituellement établies grâce à des tests en laboratoire effectués sur des échantillons rocheux ou via des techniques indirectes comme les enregistrements acoustiques réalisés dans des puits. Ces informations sont cruciales pour la géomécanique, l'évaluation de la stabilité des puits et des réservoirs ainsi que la projection du comportement des roches. (zoback., 2007).

3.2.1. Module de compressibilité (K)

Le module de compressibilité (k) évalue la résistance d'une substance, comme la roche ou le sol, à une modification de volume lorsqu'elle est exposée à une pression constante dans tous les sens. Autrement dit, ce terme fait référence à la faculté d'une roche à supporter la compression sous l'effet de contraintes géologiques naturelles telles que la pression lithostatique et celle des fluides interstitiels peut être exprimée par la relation suivante :

$$K = -V \frac{dP}{dV}$$

Où :

V : Volume initial de la roche,

dP : Variation infinitésimale de la pression,

dV : Variation infinitésimale du volume.

Pour de petites variations, on utilise la forme simplifiée.

$$K = \frac{\Delta P}{\Delta V/V}$$

Dans le domaine de la mécanique des roches et de l'ingénierie géologique, le module de compressibilité est caractérisé comme étant le quotient de la modification de la contrainte moyenne par la modification de la déformation volumique, selon l'expression suivante :

$$K = \frac{\Delta \sigma_m}{\Delta \varepsilon_n}$$

σ_m : Contrainte moyenne

ε_n : Déformation volumique.

Le comportement des roches lors du forage ou de l'extraction de ressources naturelles est largement déterminé par le paramètre crucial qu'est le module de

Chapitre II : Généralités sur la Mécanique des Roches

compressibilité. Cela a un effet direct sur la stabilité des puits et des installations souterraines

3.2.2. Coefficient de Poisson (ν)

Le coefficient de Poisson (ν) est une propriété élastique des roches, qui se définit comme le quotient de la déformation latérale par la déformation longitudinale lorsque le matériau est exposé à une pression extérieure. Ce paramètre sert à examiner le comportement des roches lorsqu'elles sont soumises à une contrainte, particulièrement dans l'étude de la stabilité des puits et la planification de la fracturation hydraulique.

$$\nu = \frac{\Delta d}{\Delta l}$$

ν ; Coefficient de poisson.

Δd : Déformation latérale.

Δl : Déformation axiale.




Figure 9: Déformation Latérale et Axiale Suite à une Compression (hills c. d. et al., 2000)

Plus le coefficient de Poisson est élevé, plus l'ouverture de la fracture est limitée. En effet, une roche présentant un coefficient de Poisson élevé tend à **se contracter** davantage latéralement lorsqu'elle est comprimée axialement, ce qui **renforce sa cohésion**. Il devient ainsi plus difficile de la fracturer, car elle résiste mieux à la propagation des fissures sous contrainte

3.2.3. Module de Young (E)

Chapitre II : Généralités sur la Mécanique des Roches

Le module de Young, qui quantifie la rigidité d'un matériau, est défini comme le ratio entre la contrainte axiale et la déformation axiale dans la zone où le matériau se comporte de manière élastique. En d'autres termes, il symbolise le degré de résistance qu'un matériau offre à la déformation longitudinale lorsqu'il est soumis à une force spécifique, exprimant ainsi la dureté ou la flexibilité de la roche.

Autrement dit, plus le module Young est grand, plus la rigidité du matériau est importante et moins il a tendance à se comprimer ou à s'étendre. Il est noté E et s'exprime généralement en pascal (Pa) ou en giga pascal (GPa) dans le cas des roches.

$$E = \frac{\sigma}{\epsilon}$$

E : Le module de Young.

σ : La contrainte (Stress).

ϵ : La déformation (Strain).

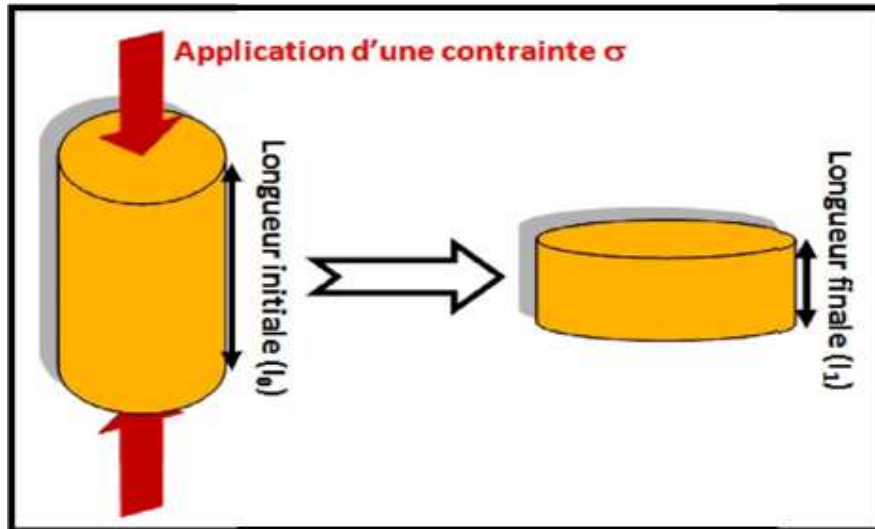


Figure 10: Déformation Selon un Axe de Contrainte d'un Cylindre
(abizar Jugurta et aoudjehout ahmed, 2016)

3.2.3.1. Différence entre module de Young dynamique et statique

Les propriétés élastiques des roches sont caractérisées par leurs modules d'élasticité, qui peuvent être mesurés de manière dynamique ou statique, selon la méthode et les conditions d'acquisition.

Le module de Young dynamique

Chapitre II : Généralités sur la Mécanique des Roches

Est calculé à partir des vitesses des ondes acoustiques de compression et de cisaillement mesurées in situ à l'aide des outils de diagraphie acoustique, notamment le Sonic log. Ces mesures sont effectuées à haute fréquence, avec des déformations très faibles, ce qui signifie que les roches sont sollicitées brièvement, dans des conditions dites non drainées. Dans ces conditions, les roches apparaissent plus rigides, et E dynamique donne donc une estimation élevée de la rigidité du matériau.

Le module de Young statique

Est obtenu à partir d'essais mécaniques en laboratoire, ou estimé à partir de E dynamique par des corrélations empiriques. Ces essais reproduisent des sollicitations lentes et durables, avec des déformations plus importantes, proches des conditions réelles autour du puits. Les mesures sont alors réalisées à basse fréquence, dans des conditions quasi-drainées, ce qui révèle un comportement plus déformable de la roche. De ce fait, E statique est généralement inférieur à E dynamique, parfois de 30 à 70 %, selon la nature de la roche. ([Anis Benyoucef Ladjadi Nassim Mekhmoukhem., 2019](#))

Chapitre III : Généralités
sur les Méthodes
d'Intelligence Artificielle

Chapitre III : Généralités sur les Méthodes d'Intelligence Artificielle

Introduction

L'intelligence artificielle et l'apprentissage automatique se sont imposés comme des instruments essentiels dans divers secteurs scientifiques et industriels. En raison de leur aptitude à traiter et examiner d'immenses volumes de données (Schmidhuber, 2015), ces technologies ont conduit à des progrès notables dans la solution de problèmes complexes (Iecum et al., 2015). L'utilisation de l'intelligence artificielle, en particulier l'apprentissage automatique, dans divers secteurs tels que la géoscience (Lary et al., 2016), a dévoilé de nouvelles avenues pour appréhender et modéliser des phénomènes complexes.

Dans ce cadre, cette étude examine l'importance cruciale de l'intelligence artificielle, en se concentrant particulièrement sur deux méthodes : la Forêt Aléatoire Random Forest (RF) et le Boosting par Extrême Gradient boosting (XGBoost). Ces deux algorithmes sont couramment employés pour l'examen et la prévision dans des contextes compliqués.

1. Intelligence artificielle

L'intelligence artificielle est un domaine de recherche qui se concentre sur le développement de systèmes informatiques capables d'effectuer des tâches qui requièrent l'intelligence humaine, comme l'apprentissage, le raisonnement et la perception.

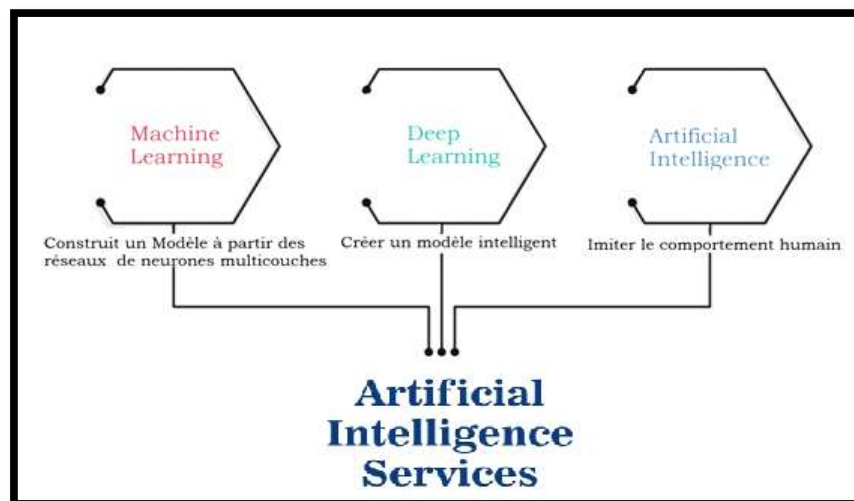


Figure 11: Les types de l'Intelligence Artificielle

2. Apprentissage automatique

Chapitre III : Généralités sur les Méthodes d'Intelligence Artificielle

L'apprentissage automatique représente une sous-discipline de l'intelligence artificielle, axée sur la conception de systèmes aptes à apprendre à partir des données et à améliorer leurs performances de façon autonome, sans requérir d'implication humaine. Cette méthode s'appuie sur des algorithmes capables de faire analyser les données par les ordinateurs, d'en extraire des modèles et de procéder à des décisions ou prédictions en fonction des informations existantes.

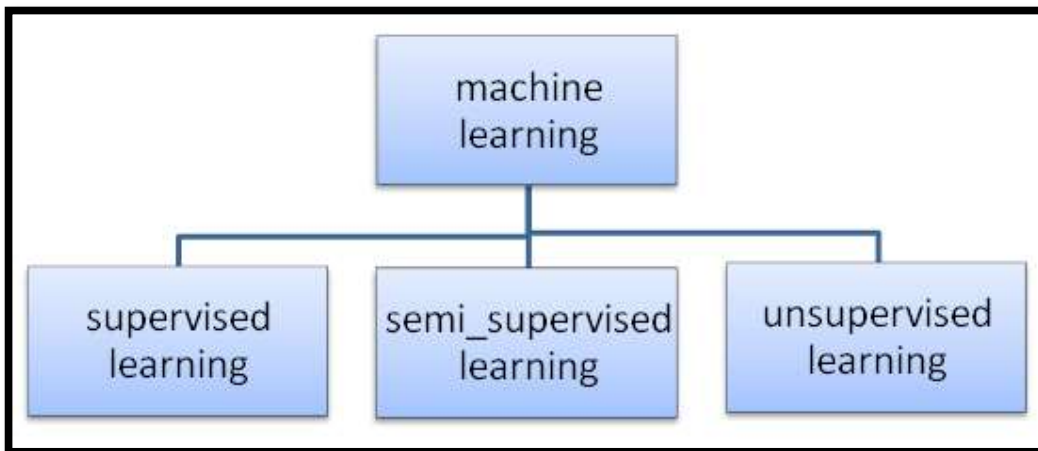


Figure 12: Types d'apprentissage automatique

On peut classer l'apprentissage automatique en trois catégories majeures, chacune possédant sa propre méthode et ses propres applications.

2.1. Apprentissage Supervisé :

L'apprentissage supervisé est une subdivision de l'apprentissage automatique dans laquelle un ensemble de données comprenant des entrées et leurs valeurs de sortie associées est présenté. Le but est de développer un modèle capable de comprendre le lien entre les données d'entrée et de sortie, afin qu'il soit en mesure d'évaluer les résultats pour des entrées inédites qui n'ont pas été présentées lors du processus d'apprentissage. Cela implique de rectifier les écarts entre les prédictions du modèle et les données réelles au cours de la phase d'apprentissage. (Van Engelen and Hoos., 2020).

2.1.1. Les algorithmes d'apprentissage supervisé

2.1.1.1. Forêt aléatoire (Random Forest),

Forêt aléatoire, ou connu sous le nom de Random Forest (RF) qui introduits par (Breiman., 2001) est un algorithme d'apprentissage automatique se base sur l'élaboration d'un groupe d'arbres décisionnels pour augmenter la précision des prédictions tout en diminuant la variance. Chaque arbre de la forêt est élaboré grâce à

Chapitre III : Généralités sur les Méthodes d'Intelligence Artificielle

un algorithme d'arbre décisionnel, où les informations sont segmentées à chaque nœud selon un critère spécifique, comme l'impureté de Gini ou l'entropie. On calcule l'impureté de Gini de la manière suivante :

$$\text{Gini}(t) = 1 - \sum_{i=1}^c (p(i|t))^2$$

où (t) représente le nœud, (c) symbolise le nombre de classes, et (p(i|t)) dénote la fraction d'échantillons de la classe (i) dans le nœud (t).

Le calcul de l'entropie se fait de la manière suivante :

$$\text{Entropie}(t) = - \sum_{i=1}^c p(i|t) \cdot \log_2(p(i|t))$$

Chaque arbre est élaboré en utilisant l'agrégation Bootstrap (Bagging) (Breima., 1996), un processus qui sélectionne des échantillons aléatoires avec remplacement à partir du jeu de données initial, et construit un arbre décisionnel pour chaque échantillon. Au moment de la prédiction, chaque nouvel échantillon est traité par tous les arbres et les résultats sont consolidés. Pour la tâche de classification, le choix se porte sur la classe la plus courante grâce à l'utilisation du vote majoritaire, comme l'indique cette formule :

$$\hat{y} = \operatorname{argmax}_i \frac{1}{T} \sum_{t=1}^T I(h_t(x) = i)$$

Où:

(\hat{y}) Est la classe prédite, (T) est le nombre d'arbres, $h_t(x)$ est la prédiction de l'arbre (t) pour l'échantillon(x), et (I) est la fonction indicatrice.

Pour la régression, la prédiction est simplement la moyenne des résultats obtenus par tous les arbres.

$$\hat{y} = \frac{1}{T} \sum_{t=1}^T h_t(x)$$

La forêt aléatoire diminue la variance en élaborant des arbres indépendants qui exploitent divers échantillons et sous-groupes de caractéristiques, tout en employant le Bagging (Breiman., 1996). Lors de chaque division, un sous-ensemble aléatoire de caractéristiques est choisi afin d'identifier la meilleure séparation, minimisant par conséquent la corrélation entre les arbres. Des éléments clés incluent le nombre d'arbres

Chapitre III : Généralités sur les Méthodes d'Intelligence Artificielle

($n_estimateurs$), la profondeur maximale de l'arbre (max_depth), le nombre minimum d'échantillons requis pour une division ($min_samples_split$) et le nombre minimal d'échantillons dans une feuille ($min_samples_leaf$).

On peut évaluer l'importance des caractéristiques (feature importance) en se basant sur leur apport à la diminution du critère de séparation dans tous les arbres, comme illustré ci-dessous.

$$Importance(f) = \frac{1}{T} \sum_{t=1}^T \sum_{s \in S_t(f)} \Delta Gini(s)$$

Dans ce contexte, (f) représente la caractéristique, (T) dénote le nombre d'arbres, ($S_t(f)$) correspond à l'ensemble des divisions utilisant la caractéristique (f) dans l'arbre (t), et ($\Delta Gini(s)$) indique la diminution de l'impureté de Gini causée par la division (s). (Brieman., 2001)




Figure 13: Explication de forêt aléatoire
(<https://medium.com/@roiyebo/random-forests-98892261dc49>)

2.1.1.2. Extrême Gradient Boosting (XGBoost)

XGBoost, ou extrême Gradient Boosting, est une méthode sophistiquée d'apprentissage automatique qui repose sur un cadre de boosting basé sur le gradient. Il excelle dans les missions de classification et de régression, alliant vitesse, exactitude et solidité grâce à des procédés d'optimisation avancés et des méthodes de régularisation.

Chapitre III : Généralités sur les Méthodes d'Intelligence Artificielle

L'efficacité de XGBoost est basée sur une fonction objective qui combine à la fois un indicateur d'erreur et un élément de complexité du modèle. Cette fonction se définit comme l'addition d'une fonction de perte standard et d'un terme de régularisation qui sanctionne la complexité des arbres décisionnels. Officiellement, la définition de la fonction objective est la suivante :

$$\text{Obj}(\theta) = \sum_{i=1}^n L(y_i, \hat{y}_i) + \sum_{k=1}^K (f_k)$$

Où $L(y_i, \hat{y}_i)$ représente la fonction de perte, mesurant l'écart entre la prédiction (\hat{y}_i) et la valeur réelle (y_i), et (f_k) est le terme de régularisation qui contrôle la complexité de chaque arbre (f_k).

Le terme de régularisation (f) pour un arbre individuel est donné par :

$$(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2$$

Dans cette équation, (T) désigne le nombre de feuilles de l'arbre, (w_j) sont les poids associés à chaque feuille, et (γ) et (λ) sont des hyperparamètres qui ajustent l'impact de la régularisation.

L'optimisation de la fonction objective est réalisée au moyen d'une technique de descente de gradient, où les gradients et hessiens de la fonction de perte orientent l'élaboration successive des arbres. Pour une itération t , l'approximation de la fonction objective se base sur les dérivées première et seconde de la fonction de perte :

$$\text{Obj}^{(t)} = \sum_{i=1}^n \left[g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + (f_t)$$

Avec $g_i = \delta_{\hat{y}_i^{(t-1)}} L(y_i, \hat{y}_i^{(t-1)})$ (gradient) et $h_i = \delta_{\hat{y}_i^{(t-1)}}^2 L(y_i, \hat{y}_i^{(t-1)})$ (hessien).

Un élément essentiel de XGBoost est sa technique pour déterminer les meilleures scissions dans les arbres. On calcule le gain lié à une division candidate de la manière suivante :

$$\text{Gain} = \frac{1}{2} \left[\frac{(\sum_{i \in I_L} g_i)^2}{\sum_{i \in I_L} h_i + \lambda} + \frac{(\sum_{i \in I_R} g_i)^2}{\sum_{i \in I_R} h_i + \lambda} - \frac{(\sum_{i \in I} g_i)^2}{\sum_{i \in I} h_i + \lambda} \right]$$

Chapitre III : Généralités sur les Méthodes d'Intelligence Artificielle

Cette formule évalue la qualité d'une division en comparant la réduction de la fonction objective obtenue en séparant les données en sous-ensembles gauche (I_L) et droit (I_R). Le paramètre (γ) agit comme un seuil minimal pour accepter une division.

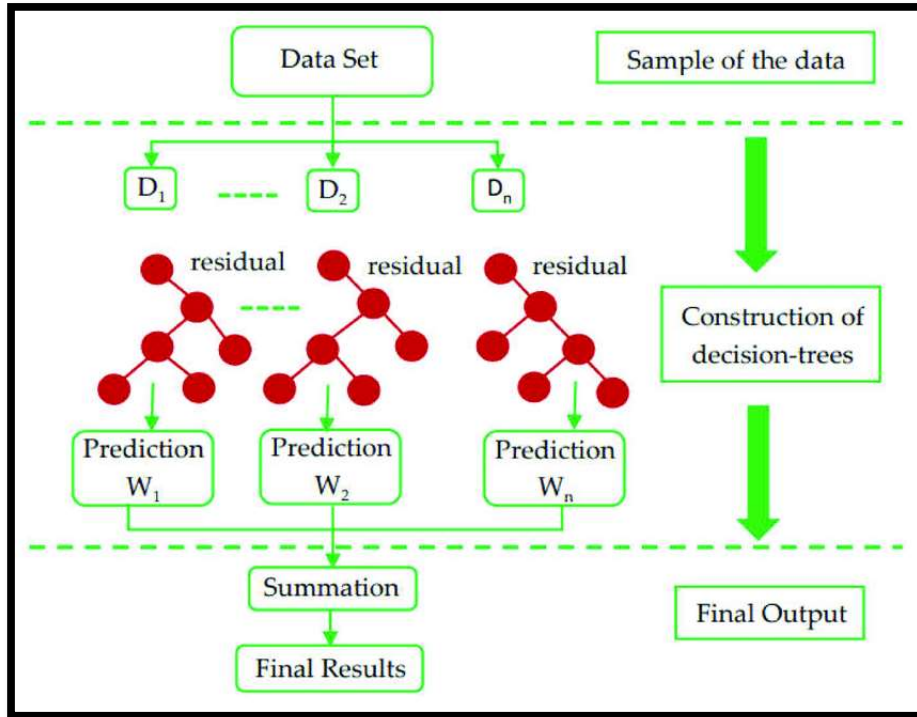


Figure 14: XGBoost (extreme gradient-boosting) algorithm structure (https://www.researchgate.net/figure/GBoost-extreme-gradient-boosting-algorithm-structure-31_fig2_362325316)

2.1.1.3. Arbre de décision

Un modèle d'apprentissage automatique comme l'arbre de décision, est employé dans les missions de classification et régression. Il s'appuie sur la segmentation des




Figure 15: Decision tree (<https://algodaily.com/lessons/decision-trees-basics>)

Chapitre III : Généralités sur les Méthodes d'Intelligence Artificielle

informations en catégories plus petites, à l'aide de règles « si-alors » qui se basent sur les valeurs des attributs. Chaque nœud de l'arbre symbolise une interrogation ou un critère, chaque branche illustre l'issue de cette condition et les feuilles manifestent le choix ou la prédiction définitive.

2.2. Apprentissage Semi-Supervisé

L'approche semi-supervisée consiste à fusionner un petit volume de données étiquetées avec une vaste quantité de données qui ne le sont pas. L'idée est d'améliorer les performances du modèle en utilisant les données non étiquetées en plus des données déjà étiquetées.

2.2.1. Les algorithmes d'apprentissage semi supervise

Auto-formation (Self-Training)

L'auto-formation est l'un des algorithmes les plus élémentaires dans le cadre de l'apprentissage semi-supervisé. Le processus commence par entraîner le modèle sur des données étiquetées, après quoi il est utilisé pour déterminer les étiquettes des données qui ne le sont pas. Par la suite, les données pour lesquelles les prédictions sont les plus précises sont intégrées à l'ensemble de données annotées, puis le modèle est réentraîné sur ce lot élargi.

Méthodes basées sur les graphes (Graph-Based Methods)

Cet algorithme modélise les données sous la forme d'un graphe, avec des nœuds symbolisant les points de données et des arêtes illustrant leurs interrelations. Les étiquettes sont transférées des données labellisées vers les données non labellisées en se basant sur leur proximité dans le graphe. Cette technique se base sur l'assumption que les points à proximité dans l'espace des données font partie de la même catégorie.

Apprentissage par régularisation de la cohérence (Consistency Regularization)

L'idée derrière l'apprentissage par régularisation de la cohérence est que le modèle doit demeurer cohérent lorsqu'on applique de légères modifications aux données dépourvues d'étiquettes. Le modèle est affiné pour maintenir sa cohérence lors de l'introduction de bruit ou de distorsions minimales dans les données non labellisées. Ceci permet au modèle d'apprendre des schémas plus solides. ([Van Engelen and Hoos., 2020](#)).

Chapitre III : Généralités sur les Méthodes d'Intelligence Artificielle

2.3. Apprentissage Non-Supervisé

L'apprentissage non supervisé est décrit comme le processus qui consiste à rassembler les objets en groupes de manière à ce que les objets au sein de chaque groupe présentent des similitudes. Ces éléments peuvent être des informations ou des graphes (Ali, H. T., 2018).

2.3.1. Les algorithmes d'apprentissage non-supervisé

Les algorithmes apriori

L'algorithme Apriori est un outil d'exploration de données utilisé pour découvrir des relations entre des éléments dans de grandes bases de données. Il s'appuie sur la notion que les composants qui se présentent souvent de concert peuvent constituer des règles bénéfiques.

La répartition en K-moyennes (K-means)

Une méthode de partitionnement de données qui regroupe un ensemble de données en k clusters en fonction de leur similarité. Son objectif principal est de minimiser la variance intra-cluster en attribuant chaque point de données au cluster dont le centre est le plus proche, en utilisant la distance euclidienne comme mesure. L'algorithme procède de manière itérative, mettant à jour les centroïdes et réaffectant les points jusqu'à ce que les clusters se stabilisent et que les centroïdes ne changent plus. (Jain., 2010)

3. L'apprentissage profond

Est une branche de l'apprentissage automatique qui fait appel à des réseaux de neurones artificiels à plusieurs couches afin de représenter des schémas complexes dans les données. Ces réseaux neuronaux profonds ont la capacité d'acquérir des représentations hiérarchisées, où les strates inférieures saisissent des caractéristiques élémentaires et les strates supérieures les rassemblent pour illustrer des notions plus abstraites. L'apprentissage profond a démontré une efficacité notable dans de nombreuses applications, comme la détection d'images, le traitement du langage naturel ou encore la reconnaissance de parole. (Lecum et al., 2015)

4. Notion des neurones

4.1. Neurone Biologique

Est caractérisé comme l'élément essentiel du système nerveux, chargé de capter, de traiter et de diffuser les signaux électrochimiques au sein du réseau neuronal. Il se compose de trois éléments majeurs : le soma qui abrite le noyau et les organites vitaux, les dendrites qui captent les signaux d'autres neurones, et l'axone qui achemine les impulsions nerveuses vers d'autres neurones ou cellules cibles. Le neurone remplit sa fonction en produisant et diffusant un potentiel électrique à travers sa membrane plasmique, ce qui facilite la communication entre les cellules nerveuses.




Figure 16: Réseaux de neurones (<https://blent.ai/blog/a/reseaux-de-neurones-tout-comprendre>)

4.2. Les différents types de neurones

Neurones multipolaires : Ces neurones représentent la forme la plus répandue dans le système nerveux. Ils possèdent de multiples prolongements connus sous le nom de dendrites, qui captent les signaux issus d'autres neurones, ainsi qu'un unique axone qui achemine les signaux vers d'autres cellules. Les neurones multipolaires jouent un rôle dans le traitement et la synthèse de l'information.

Neurones bipolaires : Ces neurones possèdent deux prolongements - une dendrite et un axone - qui surgissent de l'extrémité opposée du corps cellulaire. Les neurones

Chapitre III : Généralités sur les Méthodes d'Intelligence Artificielle

bipolaires sont fréquemment associés à des fonctions sensorielles spécifiques telles que la vision et l'audition.

Neurones pseudo-unipolaires : ces neurones possèdent un axone qui se fractionne en deux ramifications distinctes. Une de ces branches capte les signaux sensoriels, alors que l'autre direction achemine les signaux vers le système nerveux central.

Neurones unipolaires : Il s'agit des neurones les plus simples en termes de structure. Ils possèdent une unique extension qui se subdivise en deux ramifications - l'une qui capte les signaux et l'autre qui les diffuse. On trouve essentiellement des neurones unipolaires chez les organismes invertébrés, où ils participent à des fonctions sensorielles et motrices fondamentales.

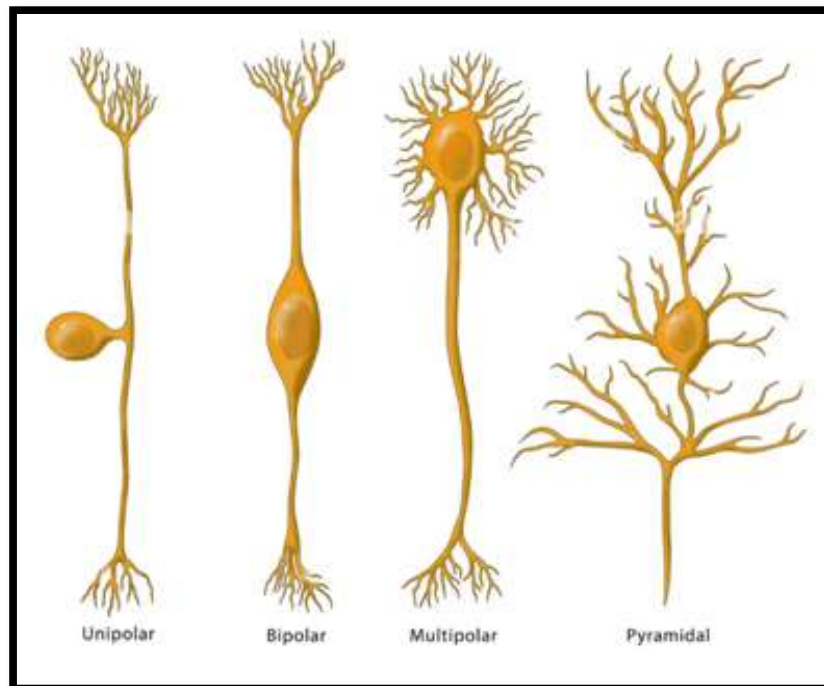


Figure 17: Illustration montrant les 4 types de neurones.

(<https://www.alamyimages.fr/photo-image-illustration-montrant-les-4-types-de-neurones-de-gauche-a-droite-unipolaire-bipolaire-multi>)

4.3. Réseaux de neurones artificiels

L'intelligence artificielle s'est progressivement développée en s'inspirant du fonctionnement du cerveau humain, notamment à travers les réseaux de neurones artificiels (RNA). Ces systèmes informatiques visent à reproduire, de manière schématisée, l'organisation et le comportement des neurones biologiques. Cette

Chapitre III : Généralités sur les Méthodes d'Intelligence Artificielle

approche biomimétique repose sur l'idée que les structures naturelles, comme le cerveau, offrent des solutions efficaces et robustes à des problèmes de traitement de l'information. Depuis plusieurs décennies, les chercheurs en informatique exploitent les principes de la neurobiologie pour concevoir des modèles computationnels capables d'apprendre, de généraliser et de s'adapter à des situations complexes. La nature, en effet, constitue une source d'inspiration inépuisable, qu'il s'agisse de l'architecture de l'ADN ou des circuits neuronaux, tous deux remarquables par leur efficacité, leur capacité d'auto-organisation et leur traitement parallèle massif. Le cerveau humain, composé de centaines de milliards de neurones reliés entre eux selon une topologie tridimensionnelle, a fortement influencé la conception des RNA. Ces derniers tentent de reproduire les mécanismes de transmission synaptique et de plasticité qui caractérisent les systèmes biologiques, avec pour objectif de simuler une forme d'intelligence artificielle autonome et évolutive ([AMEUR-ZAIMECHE., 2020](#)).

4.3.1. Architecture des réseaux de neurones artificiels

Les réseaux de neurones artificiels sont des modèles mathématiques inspirés du fonctionnement du cerveau humain. Ils sont utilisés pour résoudre des problèmes complexes tels que la reconnaissance de formes, la prédiction, ou encore la classification. Un réseau de neurones est composé de plusieurs unités de traitement, appelées **neurones**, organisées en couches successives.

Chaque neurone reçoit un ensemble d'entrées, les combine selon des poids associés à chaque connexion, puis applique une fonction d'activation pour produire une sortie. Cette sortie devient ensuite une entrée pour les neurones de la couche suivante.

Le réseau comprend généralement trois types de couches :

La couche d'entrée, qui reçoit les données brutes issues de l'environnement (par exemple, les pixels d'une image ou les mesures d'un capteur).

Une ou plusieurs couches cachées, où s'effectuent la majorité des traitements internes. Les neurones de ces couches apprennent à détecter des motifs ou des relations complexes entre les données.

Chapitre III : Généralités sur les Méthodes d'Intelligence Artificielle

La couche de sortie, qui génère le résultat final du réseau, comme une catégorie prédite ou une valeur numérique.




Figure 18: Schéma représente L'architecture du modèle optimale MLP (Touzet., 1992)

L'apprentissage du réseau se fait généralement par un algorithme appelé rétropropagation de l'erreur, qui ajuste les poids des connexions pour minimiser l'écart entre la sortie produite et la sortie attendue. Ce processus est itératif et nécessite un ensemble de données d'entraînement.

Grâce à leur capacité à apprendre à partir de données, les réseaux de neurones artificiels sont aujourd'hui au cœur de nombreuses applications en intelligence artificielle, notamment dans les domaines de la vision par ordinateur, du traitement automatique du langage et de la robotique. (Touzet., 1992).




Figure 19: Modélisation du neurone biologique par un neurone artificiel (https://www.researchgate.net/figure/Compara-ison-entre-neurone-biologique-et-neurone-artificiel_fig6_281015872)

Chapitre III : Généralités sur les Méthodes d'Intelligence Artificielle

5. Forêt aléatoire vs Extrême Gradient Boosting

Random Forest et XGBoost Ce sont deux algorithmes d'apprentissage automatique basés sur les arbres parmi les plus courants, mais ils se distinguent par leur traitement des données et leurs performances globales. Random Forest s'appuie sur la création aléatoire d'une collection d'arbres décisionnels, chaque arbre étant construit à partir d'un échantillon distinct de données en utilisant Bootstrap. Cela diminue les risques de biais, mais peut provoquer une augmentation de la variance. Par contre, XGBoost utilise la technique du Boosting, où les arbres sont élaborés de façon séquentielle, chaque nouvel arbre visant à rectifier les fautes de l'arbre précédent. Par conséquent, XGBoost est plus efficace pour gérer des données complexes, mais il peut être plus vulnérable aux biais si les paramètres ne sont pas correctement configurés (Chen and Guestrin., 2016).

Concernant la gestion des données, Random Forest se distingue par sa souplesse dans le traitement des données absentes et des valeurs aberrantes, car il utilise les résultats moyens des arbres pour réduire l'effet de ces soucis. XGBoost requiert une préparation préalable des données, comme l'imputation des valeurs absentes ou la transformation des données catégorielles en format numérique, ce qui augmente sa complexité d'implémentation (Biau and Scornet., 2016). De plus, grâce à l'emploi de méthodes comme le gradient et l'optimisation en parallèle (Friedman., 2001), XGBoost se montre plus performant dans la gestion de données massives et complexes.

6. Application de IA en science de la terre

Dans le secteur de la géologie, l'emploi de l'intelligence artificielle se développe considérablement en raison de sa faculté à examiner des données complexes, améliorer l'exploration et anticiper les événements naturels. On peut citer, entre autres, la détection et l'anticipation des tremblements de terre grâce à l'étude des données sismiques (Kong et al., 2019), ou encore l'analyse des données environnementales et géographiques (Pradhan et Lee., 2010) comme applications remarquables. L'IA offre aussi la possibilité de saisir l'effet du changement climatique sur les formations géologiques et les ressources naturelles (Reichstein et al., 2019), tout en optimisant les processus d'extraction pour augmenter l'efficacité et réduire l'impact sur l'environnement (Zhou, Li, Mitri., 2016). Par ailleurs, la modélisation et l'anticipation du comportement des nappes phréatiques sont cruciales pour la gestion de l'eau. (Sun et Scanlon., 2019).

Chapitre III : Généralités sur les Méthodes d'Intelligence Artificielle

Dans le domaine pétrolier, La recherche intitulée « Advancing Reservoir Evaluation : Machine Learning Approaches for Predicting Porosity Curves » (Ali et al., 2024) cherche à diminuer la dépendance aux procédés conventionnels, tels que les diagraphies de puits, en suggérant des méthodes d'intelligence artificielle pour une évaluation précise de la porosité.

« Multilayer perception neural network-based approach for permeability modelling in TAGI reservoir » (Ameur Zaimeche et al., 2019) offre des solutions de remplacement aux techniques onéreuses et compliquées d'estimation de la perméabilité, en se basant sur des équations empiriques et des procédés de régression.

« Prediction of Poisson's ratio for a petroleum engineering application : Machine learning methods » (Alakbari et al., 2025) a conçu un modèle efficace pour estimer le coefficient de Poisson statique (vs) à l'aide de 19 techniques d'apprentissage automatique, diminuant ainsi les dépenses et la durée par rapport aux techniques de laboratoire classiques.

« Innovations in Real-Time Pore Pressure Prediction Using Drilling Data : A Conceptual Framework » (Ogbo et al., 2024) se focalise sur l'exploitation des données de forage en temps réel pour perfectionner la précision de la prédiction de la pression interstitielle, en utilisant des algorithmes d'apprentissage automatique et des analyses de données sophistiquées. Ce modèle conceptuel englobe des technologies telles que l'informatique de haute performance et l'informatique en nuage afin d'assurer une analyse à la fois rapide et précise.

« Predicting shear stress distribution on structural surfaces under internal solitary wave loading : A deep learning perspective » (Zhang et al., 2024) suggère un modèle hydrodynamique prédictif basé sur un réseau de capteurs et des algorithmes d'apprentissage profond pour offrir des prédictions précises concernant la distribution des contraintes de cisaillement.

**Chapitre IV : Application
des Techniques
d'Apprentissage
Automatique pour
Prédire le Module de
Young**

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

Introduction

La géomécanique occupe une place centrale en ingénierie des réservoirs pétroliers, car elle fournit des éléments de compréhension sur le comportement mécanique des formations du sous-sol. L'une des grandeurs géomécaniques essentielles est le module d'Young (E), représentant la rigidité des roches par leur capacité à être déformées de façon élastique sous contrainte (Sone et Zoback., 2013). Ce paramètre est à la fois déterminant pour le bon fonctionnement mécanique des roches, la stabilité des puits, mais aussi pour une opération de fracturation hydraulique efficace (Zoback., 2007). Classiquement, il est mesuré en laboratoire sur carottes au travers d'essais de compression uniaxiale ou triaxiale. Mais ces méthodes nécessitent des échantillons de carottes de haute qualité, souvent indisponibles en raison de contraintes opérationnelles et géologiques (Kermia et al., 2025). Une alternative envisagée est l'estimation du module d'Young à partir de diagraphies, notamment soniques et de densité, qui fournissent des mesures continues des propriétés mécaniques en tous points du réservoir (Sanei et al., 2023). Cependant, cette estimation peut s'avérer difficile dans les réservoirs fracturés et peu perméables, en raison des conditions de forage et de l'influence de paramètres opérationnels tels que la densité de la boue. Cette dernière peut perturber la qualité des mesures, notamment celles des logs soniques, et affecter la fiabilité des données (Zerrouki et al., 2014). La conjugaison des diagraphies et des techniques reposant sur l'apprentissage automatique permettrait d'envisager des solutions intéressantes pour progresser dans l'évaluation des valeurs du module d'Young et diminuer ainsi certaines incertitudes du modèle.

L'intelligence artificielle s'impose aujourd'hui comme un outil incontournable dans le domaine pétrolier (Sanei et al., 2023). Elle permet notamment d'estimer certains paramètres manquants des réservoirs hétérogènes et complexes, tels que les réservoirs compactés et à forte fracturation naturelle (Bermingham et al., 2015), en apportant des solutions aux limites des approches conventionnelles, notamment le manque d'échantillons de carottes de qualité et les incertitudes liées aux mesures dans ces environnements géologiques difficiles (Ameur-Zaimeche et al., 2022). Dans cette étude, l'intégration d'algorithmes d'apprentissage automatique tels que la Forêt Aléatoire (RF) et le Gradient Boosting Extrême (XGB) a permis d'améliorer considérablement la précision et la robustesse des prédictions, tout en contribuant à une gestion plus efficace du réservoir et à l'optimisation des stratégies de développement.

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

1. Méthodologie :

1.1. Collecte des données :

La base de données est constituée de mesures issues d'un puits horizontal foré dans un réservoir compact naturellement fracturé. Chaque enregistrement correspond à une valeur estimée du module d'Young dynamique (E), accompagnée de différents paramètres de diaggraphie, à savoir : la profondeur, le diamètre du puits (CALI), les résistivités profondes (RT10, RT20, RT30, RT60, RT90), la porosité neutronique (NPFI), le facteur photoélectrique (PE), le rayonnement gamma naturel (GR), le potassium (POTA), le thorium (THOR) et l'uranium (URAN).

L'épaisseur du réservoir est estimée à environ 225 mètres. En fonction du diamètre du puits (Caliper), le réservoir a été subdivisé en deux classes :

- **Classe 1** : diamètre supérieur à 7" (130 mesures)
- **Classe 2** : diamètre inférieur à 7" (1351 mesures)
- **Merged** : l'ensemble du réservoirs (1481 mesures).

Le nombre total d'observations est de 1481 mesures.

Enfin, l'ensemble du réservoir a également été considéré comme un troisième cas d'étude, désigné par réservoir fusionné (Merged Réservoir).

Les données utilisées proviennent de mesures continues prises à intervalles réguliers (6 à 7 données par mètre). Ces données ont été soigneusement nettoyées et traitées pour éliminer toute anomalie ou erreur de mesure avant d'être utilisées pour l'entraînement des modèles.

Les données des trois réservoirs ont été aléatoirement séparées en deux groupes : 80% ont servi à l'entraînement des modèles et 20% à leur test. Cette séparation garantit que jamais les modèles n'avaient « vu » les données de test durant leur apprentissage, pour éviter toute fuite d'information et évaluer objectivement et avec fiabilité les performances des modèles (Ameur-Zaimeche et al., 2021).

Le module d'Young dynamique (E) n'a pas été mesuré directement, mais calculé à partir des vitesses des ondes acoustiques de cisaillement (V_s) et de compression (V_p), obtenues par diaggraphies acoustiques. Ces vitesses renseignent sur le comportement

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

élastique des roches traversées, tandis que la densité (ρ) a été extraite directement à partir de la diagraphie de densité.

La relation utilisée pour son calcul est la suivante (Gassmann., 1951) :

$$E = \frac{\rho \cdot V_s^2 (3v_p^2 - 4v_s^2)}{v_p^2 - v_s^2}$$

Ou :

E : Module d'Young dynamique (en GPa)

ρ : Densité de la roche (en g/cm³ ou kg/m³ selon les unités utilisées)

V_p : Vitesse des ondes de compression (P-wave) (en m/s)

V_s : Vitesse des ondes de cisaillement (S-wave) (en m/s)

1.2. Description des données :

Les paramètres de diagraphie utilisés dans cette étude sont décrits comme suit :

CALI (Caliper Log) : Mesure le diamètre du puits de forage, permettant d'identifier les zones de lavage ou de rétrécissement qui peuvent affecter la qualité des autres mesures.

RT10, RT20, RT30, RT60, RT90 (Résistivité) : Mesures de la résistivité électrique de la formation à différentes profondeurs d'investigation, utilisées pour évaluer la saturation en fluides et la porosité.

NPHI (Porosité Neutronique) : Estime la porosité de la formation en mesurant la réponse aux neutrons, sensible à la présence d'hydrogène dans les pores, donc aux fluides.

PE (Facteur Photoélectrique) : Indique la capacité d'absorption photoélectrique des roches, utile pour distinguer différents types de lithologies.

GR (Rayonnement Gamma Naturel) : Mesure la radioactivité naturelle des formations, principalement due au potassium, à l'uranium et au thorium, permettant de différencier les argiles des autres lithologies.

Plusieurs études ont montré que les techniques d'intelligence artificielle, comme les réseaux de neurones, peuvent être utilisées pour estimer le volume d'argile à partir de ces paramètres, notamment dans le contexte du bassin de Berkine (Ameur-Zaimeche et al., 2022a).

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

POTA (Potassium), THOR (Thorium), URAN (Uranium) : Composants du spectre gamma naturel, fournissant des informations détaillées sur la composition minéralogique des formations.

Ces paramètres sont essentiels pour caractériser les propriétés pétrophysiques et géomécaniques du réservoir, et leur intégration dans des modèles prédictifs permet une meilleure compréhension du comportement des formations souterraines. (Asquith et Krygowski, 2004 ; Rider et Kennedy, 2011 ; Ameer-Zaimeche et al., 2014 ; Mellal et al., 2023)

1.3. Analyse statistique :

Afin de mieux appréhender la structure et la répartition des données collectées, une analyse statistique descriptive a été menée. Celle-ci repose à la fois sur une approche **mono variée (Tableau 2)**, visant à examiner individuellement chaque variable afin d'en extraire les principales caractéristiques statistiques (moyenne, écart-type, minimum, maximum, etc.), et sur une approche **bi variée (Figure 20)**, permettant d'explorer les relations potentielles entre les variables.

Ces analyses permettent non seulement d'identifier les variables les plus influentes à l'aide de différents critères, mais également de détecter d'éventuelles corrélations pouvant orienter la construction et l'optimisation des modèles de prédiction (Ameer-Zaimeche et al., 2020), notamment en ce qui concerne la classification lithologique dans les puits non carottés.

Tableau 2: Résumé statistique des données de diagraphie collectées et du module d'Young dynamique estimé.

Variabl e	unit	mean	std	skew	min	25%	50%	75%	max
MERGEDRESERVOIRE									
DEPT	M	3736.84	65.17	1.6e-15	3624.07	3680.45	3736.84	3793.23	3849.62
CALI	in	6.29	1.01	4.24	5.61	5.87	6.00	6.21	13.48
GR	api	17.67	5.57	0.51	5.93	13.47	16.93	21.64	42.69
NPHI	pu	0.31	0.94	0.67	-1.74	-0.39	0.22	1.01	5.42
PE	cm ² /g	4.36	2.15	2.15	2.15	3.09	3.54	4.65	14.03

**Chapitre IV : Application des Techniques d'Apprentissage Automatique pour
Prédire le Module de Young**

RT10	ohm m	822.04	500.5	0.18	55.47	344.89	798.64	1286.92	1939.03
RT20	ohm m	832.2	503.0 2	0.23	87.81	359.62	827.84	1329.46	1948.32
RT30	ohm m	845.85	498.9 6	0.25	122.4	377.75	854.73	1339.54	1952.57
RT60	ohm m	860.44	491.5 8	0.24	135.27	395.19	849.34	1352.55	1952.96
RT90	ohm m	879.53	479.1 2	0.24	147.9	436.12	855.86	1355.87	1953.01
POTA	%	0.3	0.11	0.45	0.07	0.20	0.28	0.38	0.69
URAN	ppm	0.86	0.36	0.60	0.14	0.58	0.80	1.12	2.42
THOR	ppm	1.56	0.66	0.81	0.36	1.08	1.49	1.94	3.83
E	Gpa	64.91	6.25	-0.71	33.14	62.36	65.09	67.83	85.87

CLASSE 1 RESERVOIRE

DEPT	M	3751.2 9	21.37	3.45	3725.41	3741.00	3749.57	3754.48	3842.46
CALI	in	8.96	1.82	0.90	7.02	7.55	8.19	9.88	13.48
GR	api	14.29	4.28	0.88	8.16	10.71	13.26	17.38	28.73
NPHI	pu	-0.18	1.52	1.73	-1.74	-1.00	-0.84	-0.42	4.56
PE	cm2/ g	8.84	2.86	-0.07	3.37	6.90	8.67	11.32	14.03
RT10	ohm m	1348.5 9	413.4 4	-1.45	199.98	1251.59	1506.94	1578.19	1939.03
RT20	ohm m	1392.2 8	399.7 6	-1.54	191.36	1314.60	1511.87	1616.51	1948.32
RT30	ohm m	1416.7 2	381.3 8	-1.60	217.20	1353.32	1514.78	1633.69	1952.57
RT60	ohm m	1430.1 0	367.2 2	-1.64	242.20	1385.44	1515.46	1639.73	1952.96
RT90	ohm m	1436.4 7	357.4 3	-1.62	270.56	1399.28	1515.49	1643.33	1953.01

**Chapitre IV : Application des Techniques d'Apprentissage Automatique pour
Prédire le Module de Young**

POTA	%	0.29	0.12	0.70	0.10	0.20	0.26	0.40	0.58
URAN	ppm	0.62	0.20	0.96	0.32	0.46	0.61	0.72	1.29
THOR	ppm	1.75	0.87	0.98	0.53	1.13	1.41	2.25	3.83
E	Gpa	66.16	2.50	0.87	60.29	64.99	65.84	67.32	75.67
CLASSE 2RESERVOIRE									
DEPT	M	3735.4 5	67.76	0.04	3624.07	3675.50	3727.55	3797.27	3849.62
CALI	in	6.03	0.24	1.14	5.61	5.86	5.98	6.14	6.94
GR	api	18	5.57	0.47	5.93	13.86	17.20	21.91	42.65
NPHI	pu	0.36	0.84	0.44	-1.24	-0.23	0.30	1.02	5.42
PE	cm2/ g	3.93	1.47	2.30	2.15	3.04	3.46	4.20	12.88
RT10	ohm m	771.37	478.5 6	0.27	55.47	327.57	704.49	1114.94	1700.13
RT20	ohm m	778.31	478.5 5	0.32	87.81	343.48	703.84	1122.64	1747.74
RT30	ohm m	790.92	473.9 6	0.35	122.40	359.34	732.10	1147.61	1765.25
RT60	ohm m	805.62	466.6 6	0.35	135.27	383.40	755.21	1157.24	1757.35
RT90	ohm m	825.94	454.6 5	0.34	147.90	420.64	7776.98	1175.06	1757.42
POTA	%	0.30	0.11	0.43	0.07	0.20	0.28	0.38	0.69
URAN	ppm	0.88	0.36	0.52	0.14	0.59	0.83	1.16	2.42
THOR	ppm	1.55	0.63	0.68	0.36	1.07	1.49	1.94	3.79
E	Gpa	64.79	6.48	-0.65	33.14	62.04	64.86	67.89	85.87

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

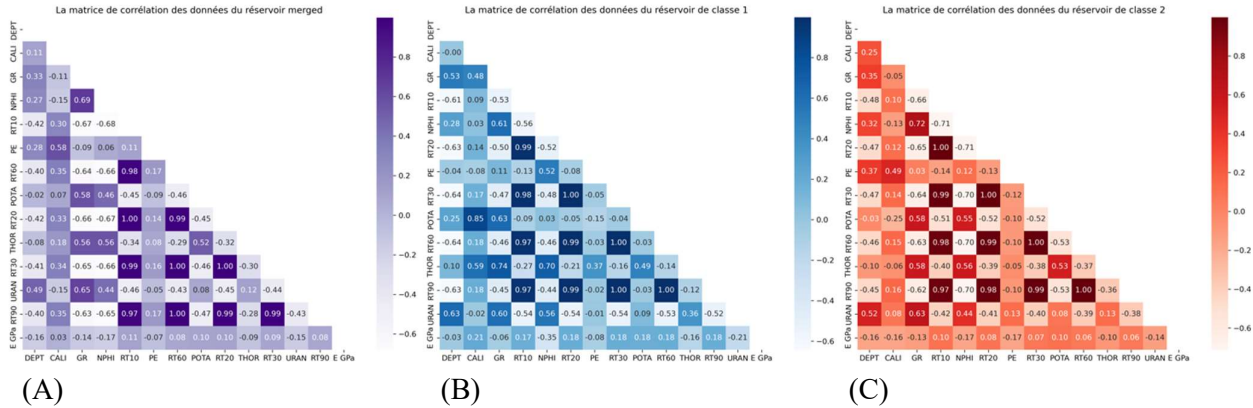


Figure 20: Matrice de corrélation entre le module de Young dynamique E et les paramètres de diagraphies pour les trois réservoirs.

(A) réservoir MERGED, (B) réservoir de Classe 1, (C) le réservoir de Classe 2

Les relations entre les variables de diagraphie (variables d'entrée du modèle) et le module d'Young (variable de sortie) dans le réservoir MERGED révèlent des corrélations à la fois positives et négatives. Des corrélations positives sont observées entre le module d'Young (E) et des variables telles que le diamètre du puits (CALI), le potassium (POTA), ainsi que les résistivités profondes (RT10, RT20, RT30, RT60, RT90), avec des coefficients de corrélation et des valeurs p comme suit : CALI ($R \approx 0,027$; $p \approx 0,305$), POTA ($R \approx 0,099$; $p < 0,001$), RT10 ($R \approx 0,111$; $p < 0,001$), RT20 ($R \approx 0,102$; $p < 0,001$), RT30 ($R \approx 0,092$; $p < 0,001$), RT60 ($R \approx 0,084$; $p \approx 0,001$), et RT90 ($R \approx 0,083$; $p \approx 0,001$). En revanche, des corrélations négatives sont constatées avec la profondeur (DEPT), le rayonnement gamma (GR), la porosité neutronique (NPHI), le facteur photoélectrique (PE), le thorium (THOR) et l'uranium (URAN), avec les coefficients suivants : DEPT ($R \approx -0,158$; $p < 0,001$), GR ($R \approx -0,140$; $p < 0,001$), NPHI ($R \approx -0,173$; $p < 0,001$), PE ($R \approx -0,071$; $p \approx 0,006$), THOR ($R \approx -0,094$; $p < 0,001$), et URAN ($R \approx -0,153$; $p < 0,001$), comme illustré dans la **Figure 20 (A)**.

Dans le réservoir de Classe 1, le module d'Young présente une corrélation positive avec le diamètre du puits (CALI), le potassium (POTA) et les résistivités profondes (RT10, RT20, RT30, RT60, RT90), avec des coefficients de corrélation et des valeurs p comme suit : CALI ($R \approx 0,207$; $p \approx 0,018$), POTA ($R \approx 0,177$; $p \approx 0,044$), RT10 ($R \approx 0,173$; $p \approx 0,049$), RT20 ($R \approx 0,184$; $p \approx 0,037$), RT30 ($R \approx 0,184$; $p \approx 0,036$), RT60 ($R \approx 0,182$; $p \approx 0,038$), et RT90 ($R \approx 0,180$; $p \approx 0,041$). En revanche, les variables DEPT, GR, NPHI, PE, THOR et URAN présentent une corrélation négative avec le module d'Young, avec les coefficients suivants : DEPT ($R \approx -0,033$;

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

$p \approx 0,713$), GR ($R \approx -0,060$; $p \approx 0,496$), NPHI ($R \approx -0,353$; $p < 0,001$), PE ($R \approx -0,080$; $p \approx 0,368$), THOR ($R \approx -0,157$; $p \approx 0,075$), et URAN ($R \approx -0,213$; $p \approx 0,015$), comme illustré dans la **Figure 20 (B)**.

Pour le réservoir de Classe 2, une corrélation positive est également observée entre le module d'Young (E) et le potassium (POTA) ainsi que les résistivités profondes (RT10, RT20, RT30, RT60, RT90), avec des coefficients de corrélation et des valeurs p comme suit : POTA ($R \approx 0,098$; $p < 0,001$), RT10 ($R \approx 0,095$; $p < 0,001$), RT20 ($R \approx 0,084$; $p \approx 0,002$), RT30 ($R \approx 0,072$; $p \approx 0,008$), RT60 ($R \approx 0,063$; $p \approx 0,020$), et RT90 ($R \approx 0,062$; $p \approx 0,023$). En revanche, les variables DEPT, CALI, GR, NPHI, PE, THOR et URAN présentent une corrélation négative avec le module d'Young, avec les coefficients suivants : DEPT ($R \approx -0,165$; $p < 0,001$), CALI ($R \approx -0,164$; $p < 0,001$), GR ($R \approx -0,134$; $p < 0,001$), NPHI ($R \approx -0,167$; $p < 0,001$), PE ($R \approx -0,165$; $p < 0,001$), THOR ($R \approx -0,101$; $p < 0,001$), et URAN ($R \approx -0,143$; $p < 0,001$), comme illustré dans la **Figure 20 (C)**.

2. Application des techniques d'apprentissage automatique :

Afin d'obtenir une prédiction du module d'Young dynamique (E) à partir des paramètres de diagraphie, nous avons mis en œuvre différentes techniques d'apprentissage automatique, permettant de modéliser et d'identifier des relations complexes entre les variables tout en recherchant la précision des prédictions par rapport aux méthodes classiques. L'efficacité de cette approche nécessite une sélection appropriée des modèles, une optimisation rigoureuse des hyperparamètres, ainsi qu'une évaluation des performances appropriée.

2.1. Algorithmes d'apprentissage automatique utilisés :

Dans cette étude, deux algorithmes d'apprentissage automatique ont été utilisés pour prédire le module d'Young dynamique :

- La Forêt Aléatoire (Random Forest, RF)
- Le Gradient Boosting Extrême (XGBoost, XGB).

2.2. Optimisation des hyperparamètres :

Les hyperparamètres sont des éléments fondamentaux pour la performance des modèles en apprentissage automatique. Ce sont des paramètres qui ont été définis avant

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

d'entraîner le modèle et qui impactent de manière directe la capacité du modèle à généraliser et à éviter le sur-apprentissage (Hutter, Hoos et Leyton-Brown., 2014). Ici, pour optimiser les hyperparamètres des deux modèles utilisés, il a été décidé d'utiliser un processus de recherche par grille (GridSearch), effectué avec GridSearchCV, la fonction de la librairie scikit-learn. Seule la base de données d'entraînement a été utilisée afin d'éviter toute fuite d'information, permettant donc d'assurer une bonne généralisation sur des données non vues (Bergstra et Bengio., 2012). Les combinaisons de paramètres ont été testées à travers des divisions de validation croisée, ce qui a permis d'assurer une évaluation fiable des modèles. Le tableau ci-après présente les valeurs optimales, choisies en maximisant les performances et en évitant le sur-apprentissage. Cette étape a permis de renforcer la robustesse des modèles et de garantir leur fiabilité en phase de test.

Tableau 3: Hyperparamètres optimisés pour les modèles ML

Algorithms	Hyperparameter	Valeur optimale sélectionnée
RF	n_estimators	100
	max_depth	20
XGB	n_estimators	100
	max_depth	5
	learning_rate	0.1
	Subsample	1.0

Afin de sélectionner les meilleures configurations des hyperparamètres pour les deux modèles utilisés (RF et XGB), une validation croisée combinée à une recherche par grille (GridSearch) a été appliquée. Ce processus a permis de tester systématiquement plusieurs combinaisons de paramètres à l'aide de la fonction GridSearchCV de la bibliothèque scikit-learn. La validation croisée a assuré une évaluation fiable sur le jeu d'entraînement uniquement, évitant ainsi toute fuite d'information. Les valeurs retenues dans le **Tableau 3** représentent les hyperparamètres ayant offert les meilleures performances durant cette étape d'optimisation.

2.3. Méthodologie d'évaluation :

Après l'optimisation des hyperparamètres des modèles à l'aide du GridSearch avec validation croisée, une phase d'évaluation rigoureuse a été mise en œuvre afin de

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

mesurer leur capacité prédictive sur des données non vues. Cette évaluation repose sur l'utilisation de métriques adaptées aux tâches de régression, permettant une comparaison objective entre les valeurs prédites et les valeurs observées du module d'Young dynamique. Les métriques retenues dans cette étude sont : l'erreur absolue moyenne (MAE), la racine carrée de l'erreur quadratique moyenne (RMSE) et le coefficient de détermination (R^2), telles que définies par [Hyndman et Koehler \(2006\)](#).

2.3.1. Métriques de performance :

Afin d'évaluer la qualité prédictive des modèles développés pour estimer le module d'Young dynamique, plusieurs métriques de régression ont été considérées. Ci-après, une brève description des principales métriques utilisées :

2.3.1.1. Erreur absolue moyenne (MAE) :

L'erreur absolue moyenne (MAE) mesure la moyenne des erreurs absolues entre les valeurs prédites et les valeurs réelles. Elle donne une indication directe de la magnitude des erreurs, en pénalisant chaque erreur de manière égale, quelle que soit sa direction (positive ou négative).

$$MAE = \frac{1}{N} \sum_{i=1}^n |y_i - \hat{y}_i|$$

Où :

- y_i est la valeur réelle,
- \hat{y}_i est la valeur prédite,
- (n) est le nombre d'échantillons.

Une valeur plus faible de MAE indique une meilleure performance du modèle.

2.3.1.2. Racine de l'erreur quadratique moyenne (RMSE) :

Le RMSE est une autre métrique populaire qui mesure l'écart-type des erreurs de prédiction. Contrairement au MAE, le RMSE pénalise les erreurs plus importantes de manière plus significative en élevant les différences au carré. Il est particulièrement utile lorsque l'on veut donner plus d'importance aux grandes erreurs de prédiction.

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

Une valeur plus faible du RMSE signifie une meilleure précision des prédictions.

2.3.1.3. Coefficient de détermination (R²) :

Le coefficient de détermination (R²) évalue la proportion de la variance des données qui est expliquée par le modèle. Il varie entre 0 et 1, où 1 indique une correspondance parfaite entre les prédictions et les valeurs réelles. Un (R²) élevé signifie que le modèle explique bien la variabilité des données, tandis qu'un (R²) faible indique une mauvaise capacité de prédiction.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

Ou :

- \bar{y} est la moyenne des valeurs réelles
- y_i est la valeur réelle,
- \hat{y}_i est la valeur prédite,
- (n) est le nombre d'échantillons.

Le processus complet de prédiction du module d'Young dynamique, depuis la collecte des données jusqu'à l'évaluation des modèles, est résumé dans la **figure 21** ci-dessous

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

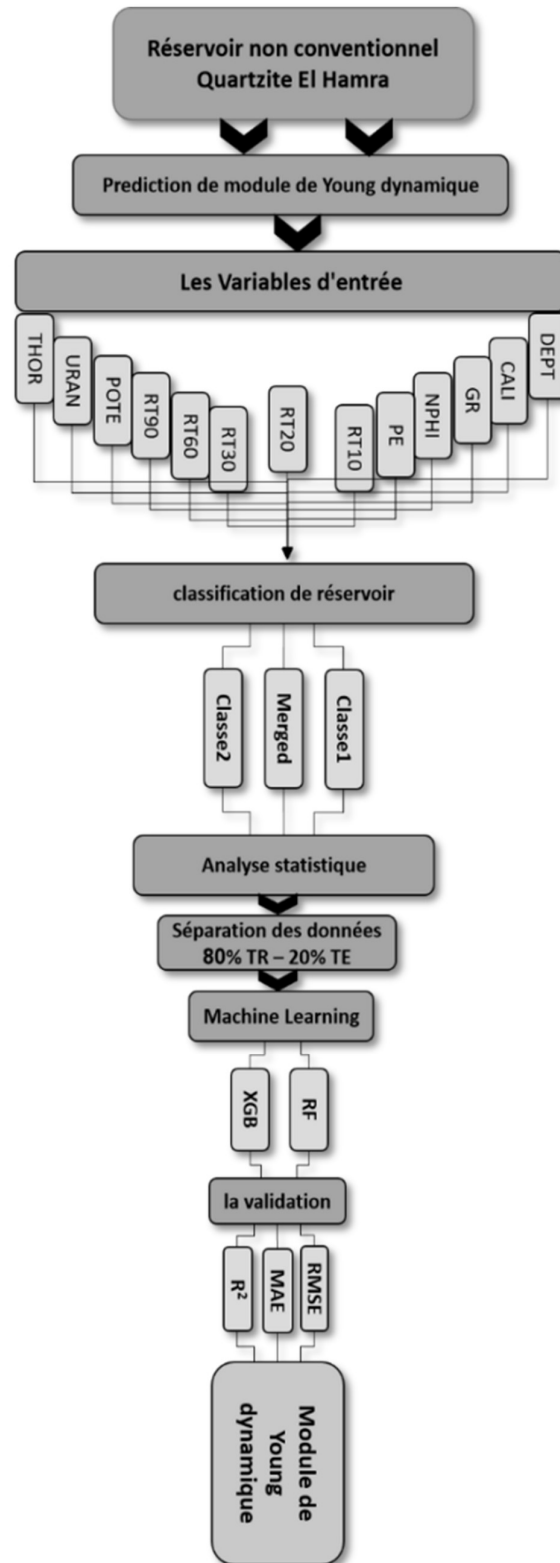


Figure 21: Organigramme illustrant l'architecture du modèle d'apprentissage automatique (ML) développé pour prédire le module de Young dynamique à partir des données de diagraphie

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

3. Résultats et discussion :

3.1. Analyse de sélection des caractéristiques (scénarios de diaggraphie) :

Dans cette étude, nous avons adopté la méthode de sélection de scénarios composés de données des diaggraphies, ce qui nous permet de déterminer l'influence des variables d'entrée sur la performance des modèles pour la prédiction de module d'Young dynamique (E). **Tableau 4** présentes les Scénarios des variables d'entrée des paramètres de diaggraphies pour la prédiction du module de Young dynamique.

Chaque modèle de machine learning a été appliqué à ces scénarios afin d'évaluer la qualité de la prédiction du module d'Young dynamique en fonction des variables de diaggraphie retenues. Cette approche s'inspire de celle de [Bermingham et al., 2015](#), qui ont utilisé l'analyse de sélection des caractéristiques ainsi que des modèles de régression sur des données géophysiques pour prédire les propriétés mécaniques des réservoirs.

Tableau 4: Scénarios des variables d'entrée des paramètres de diaggraphies pour la prédiction du module de Young dynamique.

Référence de combinaison	Variables d'entrée	Sortie
1	DEPT, NPHI, POTA, GR, PE, Cali, URAN, RT10, THOR, RT20, RT30, RT60, RT90	E
2	DEPT, NPHI, POTA, GR, PE, Cali, URAN, RT10, THOR, RT20, RT30	E
3	DEPT, NPHI, POTA, GR, PE, Cali, URAN, RT10, THOR	E
4	DEPT, NPHI, POTA, GR, PE, Cali, URAN	E
5	DEPT, NPHI, POTA, GR, PE	E
6	DEPT, NPHI, POTA	E

Pour construire les différents scénarios à partir des données de diaggraphie, une approche itérative a été adoptée en se basant sur l'importance moyenne des variables, extraite des modèles RF et XGBoost. À chaque étape, les deux variables les moins influentes ont été supprimées, ce qui a permis de générer un nouveau scénario avec un ensemble réduit de variables. Ce processus d'élimination progressive s'est poursuivi jusqu'à l'obtention

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

de six combinaisons de variables d'entrée, chacune correspondant à un scénario testé (Tableau 4).

3.2. Lecture des résultats :

3.2.1. Résultats pour le réservoir CLASSE 1 :

Les performances des modèles d'apprentissage supervisé ont été évaluées à partir des différents scénarios testés. Pour le modèle XGBoost, le scénario 5 s'est distingué comme étant le plus performant, avec un coefficient de détermination R^2 de 0,8520, une RMSE de 1,1701, et une MAE de 0,9077 sur le jeu de test. Les autres scénarios présentent également des résultats comparables. Notamment le scénario 1 (R^2 de 0,8432, et RMSE et MAE de 1,2044 et 0,9232 respectivement), suivi du scénario 6 (R^2 de 0,8429, et RMSE et MAE de 1,2056 et 1,0110 respectivement). Le scénario 3 arrive ensuite (R^2 de 0,8401, et RMSE et MAE de 1,2164 et 0,9170 respectivement), suivi du scénario 2 (R^2 de 0,8249, et RMSE et MAE de 1,2727 et 0,9648 respectivement). Enfin, le scénario 4 affiche les performances les plus faibles parmi les variantes de XGBoost, avec un R^2 de 0,7972, et un RMSE et MAE de 1,3696 et 1,0087 respectivement. Le scénario 5 se révèle également le plus performant pour l'algorithme Random Forest, avec un (R^2 de 0,8041 et RMSE et MAE (1,3462, 0,9996) respectivement. Il est suivi par le scénario 1 (R^2 de 0,7769 et RMSE et MAE (1,4366, 1,0426) respectivement, les scénarios 2 et 4 (R^2 de 0,7729 et RMSE et MAE respectivement de (1,4495, 1,0436) et (1,4495, 1,0680)), le scénario 3 (R^2 de 0,7703 et RMSE et MAE (1,4579, 1,0323) respectivement, et enfin le scénario 6, qui enregistre les moins bonnes performances du modèle RF avec un (R^2 de 0,7458 et RMSE et MAE (1,5336, 1,1777) respectivement (Tableau 4, Figure 22).

Tableau 5: Performances de prédiction du module d'Young dynamique (E) pour le réservoir CLASSE 1 à l'aide des modèles RF et XGBoost.

RESERVOIRS	ML MODELS	TR			TE		
		R^2	RMSE	MAE	R^2	RMSE	MAE
	XGB1	1.000	0.0009	0.0006	0.843	1.2044	0.9232
		0			2		

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

	XGB2	1.000 0	0.0007	0.0005	0.824 9	1.2727	0.9648
	XGB3	1.000 0	0.0009	0.0007	0.840 1	1.2164	0.9170
	XGB4	1.000 0	0.0009	0.0006	0.797 2	1.3696	1.0087
	XGB5	1.000 0	0.0012	0.0009	0.852 0	1.1701	0.9077
CLASSE 1	XGB6	0.999 9	0.0022	0.0015	0.842 9	1.2056	1.0110
	RF1	0.934 9	0.5931	0.4432	0.776 9	1.4366	1.0426
	RF2	0.936 5	0.5857	0.4349	0.772 9	1.4495	1.0436
	RF3	0.931 9	0.6064	0.4478	0.770 3	1.4579	1.0323
	RF4	0.928 8	0.6201	0.4563	0.772 9	1.4495	1.0680
	RF5	0.932 2	0.6052	0.4466	0.804 1	1.3462	0.9996
	RF6	0.941 8	0.5607	0.4289	0.745 8	1.5336	1.1777

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

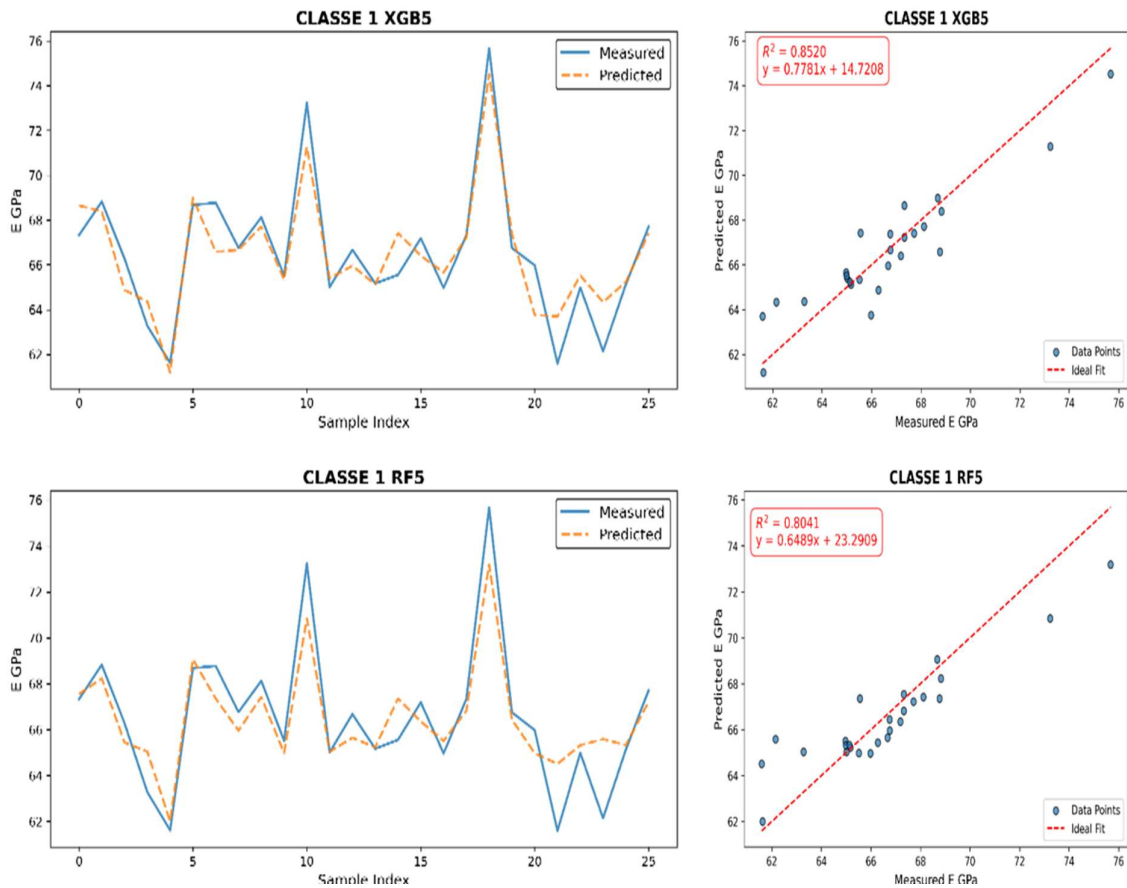


Figure 22: Module de Young dynamique mesuré Vs module de Young dynamique prédit de réservoir CLASSE 1.

3.2.2. Résultats pour le réservoir CLASSE 2 :

Dans le réservoir de Classe 2, les performances des modèles confirment une fois de plus l'avantage de XGBoost sur Random Forest. Le scénario 6 s'est avéré être le plus performant, avec un coefficient de détermination R^2 de 0,8422 et RMSE et MAE (2,2966, 1,6318) respectivement, sur le jeu de test. Les autres scénarios XGBoost affichent également des résultats proches. À commencer par le scénario 1 (R^2 de 0,7847, et RMSE et MAE de 2,6829 et 1,9243 respectivement), suivi du scénario 2 (R^2 de 0,7762, et RMSE et MAE de 2,7355 et 1,9396 respectivement), du scénario 5 (R^2 de 0,7315, et RMSE et MAE de 2,9963 et 1,9662 respectivement), du scénario 3 (R^2 de 0,7248, et RMSE et MAE de 3,0330 et 2,0610 respectivement), et enfin du scénario 4, qui enregistre les performances les plus faibles de la série XGBoost (R^2 de 0,7084, et RMSE et MAE de 3,1222 et 2,1494 respectivement).

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

En ce qui concerne le modèle Random Forest, le scénario le plus performant est le scénario 6, avec un R^2 de 0,8255, une RMSE de 2,4154, et une MAE de 1,6032. Il est suivi par le scénario 5 avec un R^2 de 0,7745, une RMSE de 2,7455, et une MAE de 1,8306, puis le scénario 1 ($R^2 \approx 0,7710$; $RMSE \approx 2,7670$; $MAE \approx 1,8960$), le scénario 2 ($R^2 \approx 0,7704$; $RMSE$ et MAE de 2,7704 et 1,9023 respectivement), et enfin le scénario 3, qui présente un R^2 de 0,7636, une RMSE de 2,8114, et une MAE de 1,9320. et enfin le scénario 4, qui présente les moins bonnes performances du modèle RF avec un R^2 de 0,7571, une RMSE de 2,8494, et une MAE de 1,9081 respectivement. (Tableau 6, Figure 23).

Tableau 6: Performances de prédiction du module d'Young dynamique (E) pour le réservoir CLASSE 2 à l'aide des modèles RF et XGBoost.

RESERVOIRS	ML MODELS	TR			TE		
		R^2	RMSE	MAE	R^2	RMSE	MAE
CLASSE 2	XGB1	0.999	0.1719	0.1215	0.784	2.6829	1.9243
		3			7		
	XGB2	0.999	0.1317	0.0923	0.776	2.7355	1.9396
		6			2		
	XGB3	0.999	0.1568	0.1093	0.724	3.0330	2.0610
		4			8		
	XGB4	0.998	0.2175	0.1513	0.708	3.1222	2.1494
		9			4		
	XGB5	0.998	0.2632	0.1854	0.731	2.9963	1.9662
		4			5		
	XGB6	0.995	0.4680	0.3414	0.842	2.2966	1.6318
		0			2		
	RF1	0.969	1.1673	0.7812	0.771	2.7670	1.8960
		1			0		
	RF2	0.970	1.1488	0.7600	0.770	2.7704	1.9023
		1			4		
	RF3	0.970	1.1369	0.7623	0.763	2.8114	1.9320
		7			6		

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

RF4	0.970	1.1334	0.7716	0.757	2.8494	1.9081
	9			1		
RF5	0.976	1.0149	0.6947	0.774	2.7455	1.8306
	6			5		
RF6	0.981	0.8943	0.5948	0.825	2.4154	1.6032
	9			5		

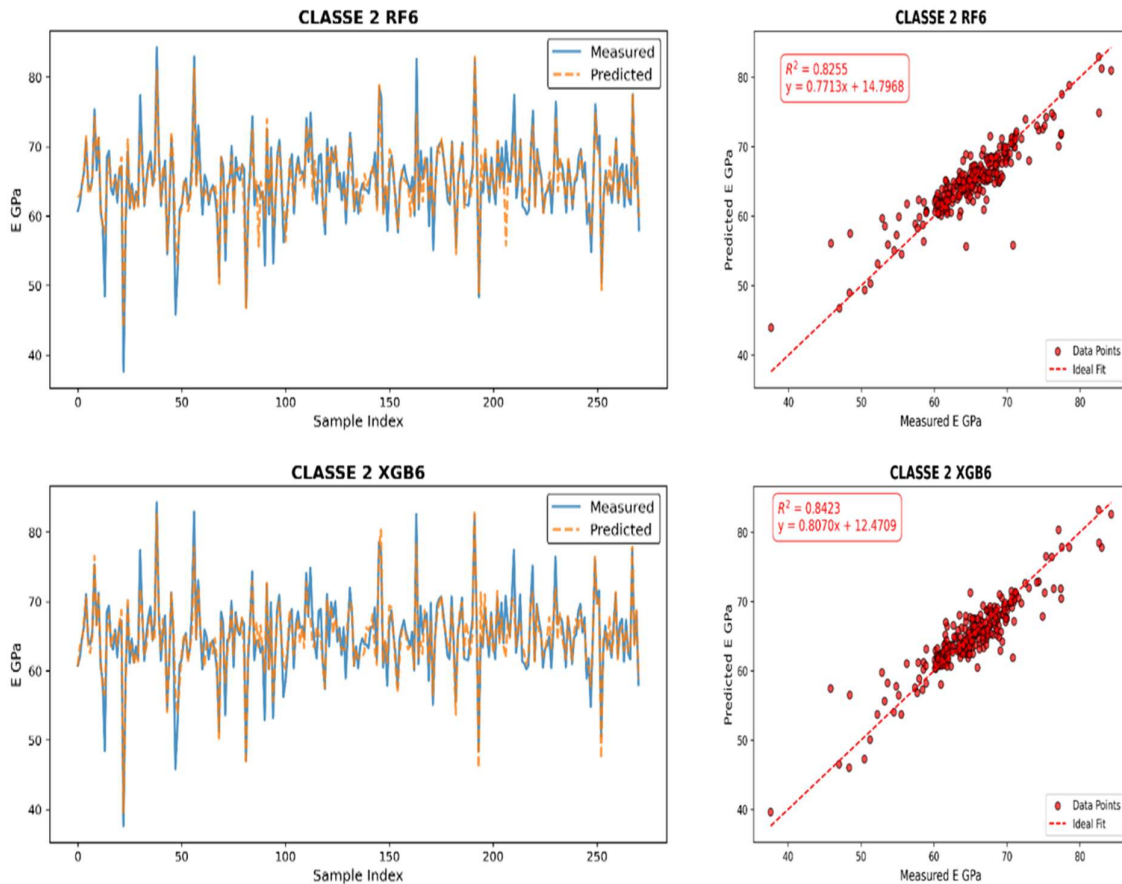


Figure 23: Module de Young dynamique mesuré Vs module de Young dynamique prédit
Résultats pour le réservoir fusionné (MERGED) :

Dans le réservoir MERGED, les performances des modèles d'apprentissage supervisé traduisent la complexité liée à l'hétérogénéité des données combinées. Pour le modèle XGBoost, le scénario 1 offre les meilleurs résultats avec un R^2 de 0,8090, une RMSE de 2,4854, et une MAE de 1,7509 sur le jeu de test. Il est suivi de très près par les scénarios 2 (R^2 de 0,8073 et RMSE et MAE respectivement de 2,4962 et 1,8247) et 6 (R^2 de 0,8010 et RMSE et MAE (2,5367 ; 1,6716)). Les autres configurations

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

présentent une baisse progressive de performance, notamment le scénario 3 (R^2 de 0,7924 et RMSE et MAE respectivement de 2,5912 et 1,8937), suivi du scénario 4 (R^2 de 0,7658 avec une RMSE de 2,7519 et une MAE de 1,8597), et enfin le scénario 5, qui enregistre les performances les plus faibles de la série XGBoost avec un R^2 de 0,7416, une RMSE et une MAE de 2,8905 et 1,9639 respectivement. En ce qui concerne le modèle Random Forest, le scénario 6 se distingue nettement avec un R^2 de 0,8100, une RMSE et une MAE de 2,4787 et 1,5660 respectivement, surpassant ainsi toutes les autres configurations, y compris celles de XGBoost. Il est suivi par les scénarios 5 (R^2 de 0,7596 et RMSE et MAE (2,7884, 1,8011) respectivement), 4 (R^2 de 0,7358 et RMSE et MAE (2,9231, 1,8848)), et 3 (R^2 de 0,7195 et RMSE et MAE (3,0116, 1,9854) respectivement), tandis que les scénarios 1 (R^2 de 0,7106 et RMSE et MAE (3,0595, 2,0024)) et 2 (R^2 de 0,6581 et RMSE et MAE (3,3251, 2,1036)), ferment la marche avec les performances les plus faibles du modèle RF. (**Tableau 7, Figure 24**).

Tableau 7: Performances de prédiction du module d'Young dynamique (E) pour le réservoir MERGED à l'aide des modèles RF et XGBoost.

RESERVOIRS	ML MODELS	TR			TE		
		R^2	RMSE	MAE	R^2	RMSE	MAE
	XGB1	0.999	0.1725	0.1210	0.809	2.4854	1.7509
	2				0		
	XGB2	0.999	0.1891	0.1315	0.807	2.4962	1.8247
	1				3		
	XGB3	0.999	0.1905	0.1334	0.792	2.5912	1.8937
	1				4		
	XGB4	0.998	0.2483	0.1745	0.765	2.7519	1.8597
	4				8		
	XGB5	0.997	0.3237	0.2326	0.741	2.8905	1.9639
	4				6		
MERGED	XGB6	0.992	0.5404	0.3783	0.801	2.5367	1.6716
	8				0		
	RF1	0.961	1.2482	0.8105	0.710	3.0595	2.0024
	6				6		

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

RF2	0.961	1.2447	0.8086	0.658	3.3251	2.1036
	9			1		
RF3	0.963	1.2255	0.7913	0.719	3.0116	1.9854
	0			5		
RF4	0.967	1.1486	0.7575	0.735	2.9231	1.8848
	5			8		
RF5	0.972	1.0506	0.7030	0.759	2.7884	1.8011
	8			6		
RF6	0.977	0.9554	0.6304	0.810	2.4787	1.5660
	5			0		

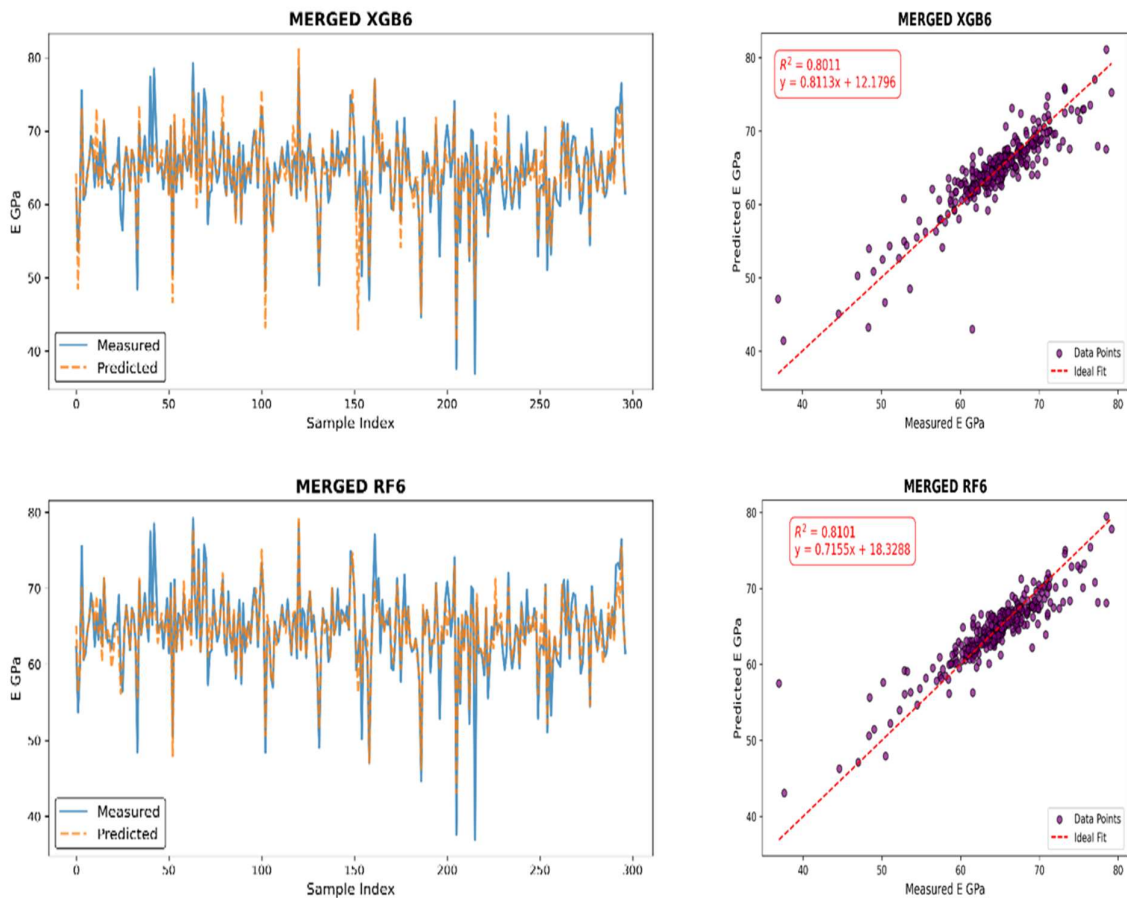


Figure 24: Module de Young dynamique mesuré Vs module de Young dynamique prédit de réservoir MERGED.

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

3.3. Discussion des résultats

L'analyse comparative des modèles d'apprentissage supervisé, à savoir XGBoost et Random Forest, appliqués aux trois classes de réservoirs, met en lumière des performances variables selon le degré d'homogénéité ou de complexité des données.

Pour la Classe 1, le modèle XGBoost dans sa configuration 5 se distingue nettement avec les meilleures performances (R^2 de 0,8520 et RMSE et MAE (1,1701, 0,9077) respectivement, suivi de près par le scénario 1. La faible différence entre ces deux configurations indique une bonne stabilité du modèle dans un environnement de données relativement cohérent. En comparaison, le modèle Random Forest atteint des performances moindres, avec son meilleur résultat également au scénario 5 (R^2 de 0,8041 et RMSE et MAE (1,3462, 0,9996) respectivement. Dans la Classe 2, une nette supériorité du scénario XGB6 est observée, affichant les meilleures métriques en phase de test (R^2 de 0,8422 et RMSE et MAE (2,2966, 1,6318) respectivement. Ce scénario surpasse les autres versions du modèle XGBoost, notamment XGB5 et XGB1. Du côté de Random Forest, le scénario 6 fournit également les résultats les plus convaincants (R^2 de 0,8255 et RMSE et MAE (2,4154, 1,6032) respectivement, bien que légèrement inférieurs à ceux de XGB6 en termes de coefficient de détermination, avec des erreurs comparables. Cela confirme l'efficacité de XGBoost dans sa configuration 6 pour capturer la complexité des variations lithologiques dans cette classe.

S'agissant du réservoir fusionné (MERGED), caractérisé par une hétérogénéité plus marquée, la tendance s'inverse. Le modèle Random Forest, scénario 6, s'impose comme le plus performant (R^2 de 0,8100 et RMSE et MAE (2,4787, 1,5660) respectivement, dépassant tous les scénarios XGBoost. Le meilleur résultat XGBoost (XGB1) atteint un R^2 de 0,8090, mais avec des erreurs plus élevées. Cela met en évidence la robustesse accrue de Random Forest face à des données complexes et bruitées.

Sur un plan transversal, la Classe 1 apparaît comme la plus favorable à la prédiction du module d'Young dynamique, grâce à des résultats globaux plus élevés. Cette performance semble liée à une meilleure cohérence géologique ainsi qu'à une forte corrélation entre les variables explicatives et la variable cible. La Classe 2 reste performante, bien que plus affectée par les variations lithologiques. Quant au réservoir

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

fusionné, il met en valeur la capacité de certains algorithmes, en particulier Random Forest, à s'adapter aux contextes hétérogènes.

En conclusion, le choix du modèle optimal dépend étroitement du type de réservoir étudié, ce qui souligne l'importance de segmenter les données avant toute modélisation prédictive.

Ces constats sont synthétisés dans la **Figure 25**, qui illustre visuellement les meilleures performances par réservoir à travers les indicateurs R^2 , RMSE et MAE.

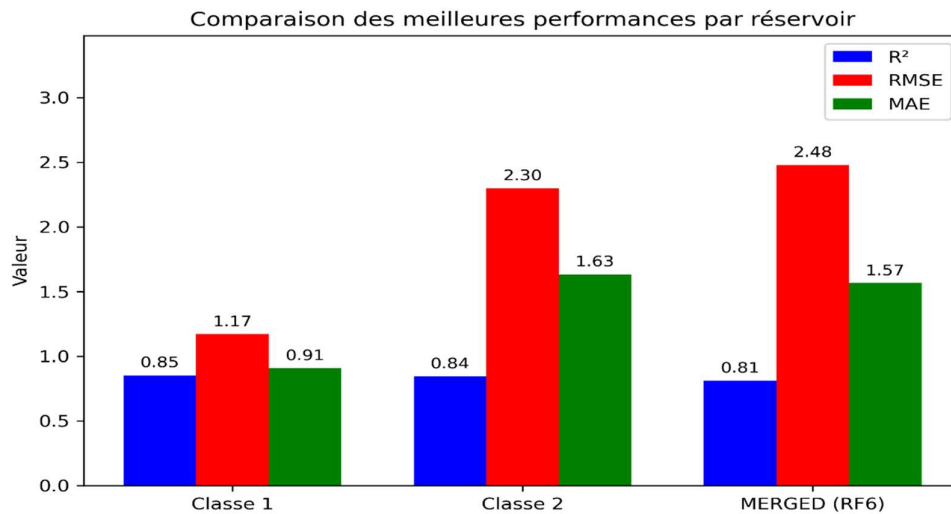


Figure 25: Courbes de performance (R^2 , RMSE, MAE) des meilleurs scénarios.

L'utilisation des données de diagraphie dans la prédiction des propriétés géomécaniques, telles que le module d'Young dynamique, présente de nombreux avantages opérationnels et stratégiques. D'une part, ces données sont acquises de manière continue et quasi instantanée tout au long du forage, ce qui permet une réduction significative du temps et des coûts par rapport aux essais mécaniques en laboratoire, souvent dépendants de carottes de haute qualité, coûteuses et parfois difficiles à obtenir, notamment dans les environnements fracturés ou profonds (Kermia et al, 2025 ; Sanei et al, 2023).

En outre, les diagraphies apportent une couverture longitudinale du puits, en opposition aux échantillons ponctuels que sont les carottages, permettant ainsi d'appréhender des modèles prédictifs plus représentatifs sur le plan spatial, à l'aide de profils continus du module d'Young dynamique le long du puits, contribuant à renforcer la caractérisation mécanique des réservoirs.

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

Cependant, certaines limitations demeurent, avec par exemple des pertes locales ou totales du signal acoustique en certains points, dues à l'existence de fractures ouvertes, à une hétérogénéité lithologique forte, ou à un mauvais couplage entre l'outil et la paroi du puits (Zoback., 2007), à l'origine de lacunes locales, ce qui ne facilite pas la stratégie prédictive. Ce passage met en lumière l'efficacité de l'intelligence artificielle à surmonter les problèmes de perte d'enregistrements et sa grande aptitude à reconstituer les données manquantes avec précision et fluidité.

L'évaluation des SHAP (SHapley Additive exPlanations) appliquée à l'ensemble des variables du jeu de données a permis d'analyser la contribution réelle de chaque paramètre à la prédiction du module d'Young. La figure 7, élaborée à l'aide des outils SHAP, montre que certaines variables dominent nettement l'explication globale du modèle, notamment la profondeur (DEPT), la porosité neutronique (NPHI) et la potasse (POTA), qui se distinguent clairement comme les principaux contributeurs. Cela confirme le rôle central de ces paramètres pétrophysiques dans l'analyse prédictive. Cette approche paramétrique démontre qu'il est possible d'obtenir une prédiction fiable du module d'Young à partir d'un nombre restreint de variables pertinentes.

L'importance de ces variables ne réside pas uniquement dans leur poids statistique : leur signification physique est directement liée aux mécanismes contrôlant la rigidité des roches. Ainsi, l'analyse SHAP ne valide pas seulement la performance du modèle, mais fournit également une interprétation physique pertinente, facilitant les décisions en ingénierie des réservoirs.

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

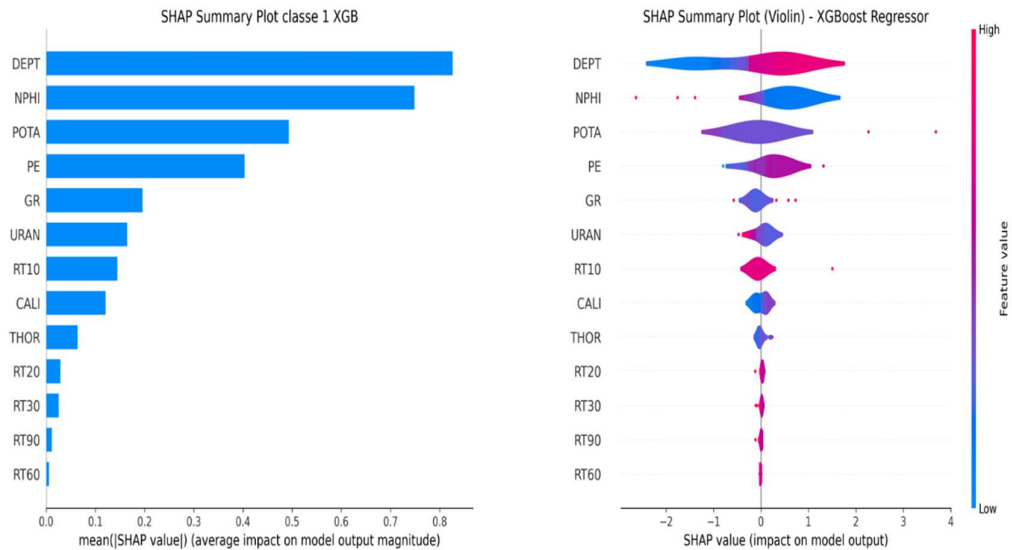


Figure 26: Analyse de l'importance des variables SHAP pour la prédiction du module de Young dynamique.

L'approche adoptée dans cette étude, fondée sur l'exploitation des données de diagraphie couplée à des techniques d'apprentissage automatique interprétables comme SHAP, présente plusieurs avantages notables. Elle permet notamment une estimation continue et fiable du module d'Young dynamique, tout en réduisant la dépendance à des données coûteuses et difficiles à acquérir, telles que les carottes. L'interprétabilité offerte par SHAP constitue également un atout majeur, en identifiant de manière transparente les paramètres les plus influents, ce qui facilite l'intégration des modèles dans un cadre opérationnel.

Cependant, les méthodes mises en œuvre sont, le plus souvent, limitées à l'exploitation des seuls logs géophysiques — en cas de perte de signal ou en conditions de mesure dégradées — or plusieurs voies méthodologiques méritent d'être étudiées. Il serait intéressant, dans de prochains travaux, d'intégrer d'autres données, encore peu utilisées, comme les données de forage (drilling data), les gaz mesurés lors du forage (gas while drilling) ou les essais mécaniques in situ (Ameur-Zaimeche et al., 2022b ; Ouladmansour et al., 2023). La fusion de plusieurs types de données (par exemple logs et données de forage) pourrait également renforcer la robustesse et la précision des modèles prédictifs, en permettant de capter des éléments d'information complémentaires sur le comportement géomécanique des formations rocheuses.

Chapitre IV : Application des Techniques d'Apprentissage Automatique pour Prédire le Module de Young

Enfin, la recherche de techniques performantes d'apprentissage profond (deep learning) ou de modèles hybrides mêlant approches physiques et statistiques constitue une autre voie prometteuse pour raffiner toujours plus la prédiction des propriétés mécaniques en contexte réservoir (Kermia et al., 2025 ; Khassaf et al., 2025 ; Boutaghane et al., 2025 ; Djebbas et al., 2023).

Conclusion

En conclusion, la présente étude a particulièrement mis en exergue la performance d'exception du modèle XGBoost pour prédire le module dynamique d'Young en fonction de données diagraphiques. En effet, le meilleur scénario proposé à partir de la Classe 1 a ainsi obtenu un coefficient de détermination R^2 de 0,8520, et des erreurs RMSE et MAE de 1,1701 et 0,9077 respectivement, confirmant la capacité et la précision de ce modèle dans la caractérisation géomécanique des réservoirs pétroliers. Ces résultats confirment ainsi le potentiel de XGBoost en tant qu'outil robuste et efficace, dans un contexte géologique complexe. L'analyse des valeurs SHAP a permis de déterminer un faible nombre de variables clés (DEPT, NPHI, POTA), indispensables à des prédictions fiables ; ce qui augure d'une intégration plus performante des données continues de diagraphie et de techniques d'intelligence artificielle. Cependant, des pertes de signal et des contextes géologiques complexes trouvent légitimation dans l'exploration de données complémentaires (forages, mesures de gaz), et dans l'emploi de méthodes progressistes (deep learning, modèles hybrides). Ainsi, cette recherche confirme l'importance de l'apprentissage automatique pour la caractérisation géomécanique des réservoirs pétroliers afin de contribuer à l'optimisation de la gestion des ressources dans un environnement géologique difficile.

Conclusion Générale

Conclusion Générale

Cette étude constitue une avancée significative dans l'exploration des potentialités de l'intelligence artificielle pour améliorer la caractérisation des réservoirs pétroliers complexes, avec un focus particulier sur la prédiction du module de Young dynamique dans le réservoir fracturé et compacté Cambro-Ordovicien Quartzite El Hamra, situé dans le champ de Rhourde Nouss, wilaya d'Illizi, Algérie. En appliquant des algorithmes d'apprentissage automatique, notamment la Forêt Aléatoire (Random Forest) et le Gradient Boosting Extrême (XGBoost), sur les données de diagraphies de puits, l'étude a démontré la capacité de ces techniques à fournir des prédictions précises du module de Young, avec une performance optimale obtenue par l'algorithme XGBoost pour des diamètres de puits supérieurs à 7 pouces. Ces résultats confirment la fiabilité des diagraphies comme alternative efficace aux tests de laboratoire traditionnels, tout en mettant en évidence l'influence du diamètre du puits sur la qualité des prédictions.

Cette recherche souligne le rôle crucial de l'intelligence artificielle dans la résolution des défis liés aux réservoirs non conventionnels, contribuant ainsi à l'optimisation des opérations de forage et à la gestion des réservoirs de manière efficace et durable. Elle met également en lumière l'importance d'une analyse précise des données géologiques pour comprendre les propriétés géomécaniques des roches, facilitant ainsi la prise de décisions éclairées dans l'industrie pétrolière et gazière. À l'avenir, il est recommandé d'élargir le champ de l'étude en intégrant des données supplémentaires, telles que les données de forage ou les mesures en temps réel, et d'explorer les techniques d'apprentissage profond pour accroître la précision des modèles prédictifs. Ces efforts représentent une étape vers le renforcement de l'innovation dans le secteur énergétique algérien et soutiennent les initiatives mondiales visant à développer des solutions technologiques avancées pour une exploitation plus efficace des ressources naturelle.

Références

Références

- Ahmed, T. (2018). *Reservoir engineering handbook*. Gulf professional publishing.
- Alain F., Raoult J.-F., 2010 : Dictionnaire de Géologie, 7e Edition.
- Alakbari, F. S., Mahmood, S. M., Ayoub, M. A., Khan, M. J., Afolabi, F., Mohyaldinn, M. E., & Muhsan, A. S. (2025). Prediction of Poisson's ratio for a petroleum engineering application: Machine-learning methods. *PloS one*, 20(2), e0317754.
- Ali, H. T. (2018). Nouvelles méthodes pour l'apprentissage non-supervisé en grandes dimensions (Doctoral dissertation, Université Paris Saclay (COMUE)). P01
- Ali, N., Fu, X., Chen, J., Hussain, J., Hussain, W., Rahman, N., ... & Altalbe, A. (2024). Advancing reservoir evaluation: machine learning approaches for predicting porosity curves. *Energies*, 17(15), 3768.
- Ameer Zaimeche, O., Zeddouri, A., Kouadria, T., Kechiched, R., & Belaksier, M. S. (2014, March). Use of Cluster Analysis method in log's data processing: prediction and rebuilding of lithologic facies. In International Conference on Environmental Science and Geoscience (ESG'14) Venice, Italy (pp. 98-101).
- AMEUR-ZAIMECHE, O. (2020). MODÉLISATION GÉOLOGIQUE DES RÉSERVOIRS PÉTROLIERS A L'AIDE DES MÉTHODES DE L'INTELLIGENCE ARTIFICIELLE, CAS DU BASSIN DE BERKINE, SUD-EST DE L'ALGÉRIE.
- Ameer-Zaimeche, O., Kechiched, R., Bouhafs, R., Mammeri, A., Hamdat, A., Zeddouri, A. (2022a). Volume of Clay Estimation Using Artificial Neural Network Case Study: Berkine Basin Southern Algeria. In: Meghraoui, M., et al. Advances in Geophysics, Tectonics and Petroleum Geosciences. CAJG 2019. Advances in Science, Technology & Innovation. Springer, Cham. https://doi.org/10.1007/978-3-030-73026-0_81
- Ameer-Zaimeche, Ouafi., Kechiched, Rabah., Aouame Charafeddine. 2021. "Rate of penetration prediction in drilling wells from the Hassi Messaoud oil field (SE Algeria): Use of artificial intelligence techniques and environmental implications". In book: Computers in Earth and Environmental Sciences Artificial Intelligence and Advanced Technologies in Hazards and Risk Management Publisher: Elsevier: <https://doi.org/10.1016/B978-0-323-89861-4.00032-4>
- Ameer-Zaimeche, Ouafi., Kechiched, Rabah., Heddam, Salim., David A. Wood. 2022b. Real-time porosity prediction using gas-while-drilling data and machine learning with reservoir associated gas: Case study for Hassi Messaoud field, Algeria.

Références

Marine and Petroleum Geology. Publisher: Elsevier.
<https://doi.org/10.1016/j.marpetgeo.2022.105631>

- Ameer-Zaimeche, Ouafi., Zeddouri, Aziez., Heddami, Salim., Kechiched, Rabah., 2020. Lithofacies prediction in non-cored wells from the Sif Fatima oil field (Berkine basin, southern Algeria): A comparative study of multilayer perceptron neural network and cluster analysis-based approaches, *Journal of African Earth Sciences*, Volume 166, 2020, 103826, ISSN 1464-343X, <https://doi.org/10.1016/j.jafrearsci.2020.103826>
- AOUDJEGHOUT A., ABIZAR J., (2016) La Géo-Mécanique au Service de la Fracturation Hydraulique : Exemple des Réservoirs Compacts de l'Ordovicien (Bassin d'Illizi, Algérie). Université Mouloud Mammeri de Tizi-Ouzou, p.35
- Asquith, G. B., Krygowski, D., & Gibson, C. R. (2004). *Basic well log analysis* (Vol. 16, pp. 305-371). Tulsa: American Association of Petroleum Geologists.
- BEICIP, 1991- interprétation sismique et structurale au toit du Trias Argileux.
- Beicip.Franlab, 1995 : révision du model géologique du champ de Rhourde Nous
- Beicip Franab ,2002 : étude sédimentologique du bassin de Berkin, rapport interne sonatrach.
- Benayad, S., Park, Y. S., &Kharfi, N. (2011, May). The Hamra quartzite tight reservoir properties in the Oued Mya Basin, Algeria. In *73rd EAGE Conference and Exhibition incorporating SPE EUROPEC 2011* (pp. cp-238). European Association of Geoscientists & Engineers.
- Bergstra, J., &Bengio, Y. (2012). Random search for hyper-parameter optimization. *The journal of machine learning research*, 13(1), 281-305.
- Birmingham, P. J., Alzayer, Y., Granger, B., &Skelt, C. (2015). Predicting Mechanical Properties from Geophysical Logs Using Data Analytics Techniques. In 49th US Rock Mechanics/Geomechanics Symposium. American Rock Mechanics Association.
- Biau, G., &Scornet, E. (2016). A random forest guided tour. *Test*, 25(2), 197-227.
- Boudjema, A. (1987). *Évolution structurale du bassin pétrolier " triasique " du Sahara Nord oriental (Algérie)* (Doctoral dissertation, Paris 11).
- Boutaghane, A., Ameer-Zaimeche, O., Heddami, S., Kechiched, R., Tahar-Belkacem, N., Ouladmansour, A., ... & Wood, D. A. (2025). Enhancing formation bulk density prediction while drilling using mud logging data and interpretable boosting machine

Références

learning. *Earth Science Informatics*, 18(1), 172. <https://doi.org/10.1007/s12145-024-01642-7>

- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
- Breiman, L., 1996. Bagging predictors. *Machine learning*, 24(2), 123-140
- Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable treeboosting system. In *Proceedings of the 22nd acmsigkdd international conference on knowledge discovery and data mining* (pp. 785-794).
- Djebbas, F., Ameer-Zaimeche, O., Kechiched, R., Heddami, S., Wood, D. A., & Movahed, Z. (2023). Integrating hydraulic flow unit concept and adaptive neuro-fuzzy inference system to accurately estimate permeability in heterogeneous reservoirs: Case study Sif Fatima oilfield, southern Algeria. *Journal of African Earth Sciences*, 206, 105027. <https://doi.org/10.1016/j.jafrearsci.2023.105027>
- Fjaer et al. (2008) *Petroleum Rock Mechanics: Drilling Operations and Well Design*
- Friedman, J. H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of statistics*, 1189-1232.
- Gassmann, F. (1951). Elastic waves through a packing of spheres. *Geophysics*, 16(4), 673-685.
- Hills C.-D et Al., 2000: *International Journal of Rock Mechanics and Mining Science & Geomechanics Abstracts*, A Calometric and Microstructural Study of Solidified Toxic Wastes-Part 2: A Model for Poisoning of OPC Hydration.
- Hoek, E., & Brown, E. T. (1997). Practical estimates of rock mass strength. *International Journal of Rock Mechanics and Mining Sciences*, 34(8), 1165–1186. [https://doi.org/10.1016/S1365-1609\(97\)00330-1](https://doi.org/10.1016/S1365-1609(97)00330-1)
- Holditch, S. A. (2006). Tight gas sands. *Journal of petroleum Technology*, 58(06), 86-93.
- Hutter, F., Hoos, H., & Leyton-Brown, K. (2014, January). An efficient approach for assessing hyperparameter importance. In *International conference on machine learning* (pp. 754-762). PMLR.
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International journal of forecasting*, 22(4), 679-688.
- Jain, A. K. (2010). Data clustering: 50 years beyond K-means. *Pattern recognition letters*, 31(8), 651-666..

Références

- Jarvie, D. M., Hill, R. J., Ruble, T. E., & Pollastro, R. M. (2007). Unconventional shale-gas systems: The Mississippian Barnett Shale of north-central Texas as one model for thermogenic shale-gas assessment. *AAPG bulletin*, 91(4), 475-499.
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.
- Kermia, H., Ameer-Zaimeche, O., Belksier, M. S., Boutaghane, A., Tahar-Belkacem, N., Ouladmansour, A., & Kechiched, R. (2025). Advanced machine learning and mud logging data for dynamic Poisson's ratio prediction while drilling in tight fractured reservoir of Quartzite El Hamra, Rhourde Nouss field, Algeria. *Petroleum Science and Technology*, 1-19.
- Kermia, H., Ameer-Zaimeche, O., Belksier, M. S., Boutaghane, A., Tahar-Belkacem, N., Ouladmansour, A., & Kechiched, R. (2025). Advanced machine learning and mud logging data for dynamic Poisson's ratio prediction while drilling in tight fractured reservoir of Quartzite El Hamra, Rhourde Nouss field, Algeria. *Petroleum Science and Technology*, 1–19. <https://doi.org/10.1080/10916466.2025.2477648>
- Khassaf, Ahmed K., Al-hameed, Zainab M., Al-Mohammedawi, Noor R., Al-Mudhafar, Watheq J., Wood, David A., Abbas, Mohammed A., Ameer-Zaimeche, Ouafi, and Ahmed A. Alsubaih. "Physics-Informed Machine Learning for Enhanced Permeability Prediction in Heterogeneous Carbonate Reservoirs." Paper presented at the Offshore Technology Conference, Houston, Texas, USA, May 2025. doi: <https://doi.org/10.4043/35892-MS>
- Kong, Q., Trugman, D. T., Ross, Z. E., Bianco, M. J., Meade, B. J., & Gerstoft, P. (2019). Machine learning in seismology: Turning data into insights. *Seismological Research Letters*, 90(1), 3-14.
- LADJADJ A., MEKHMOKHEN N., (2019) Modélisation géomécanique à une dimension et élaboration d'un design de fracturation hydraulique pour une stimulation réussie des réservoirs à grès compacts d'Algérie (Ecole Nationale Polytechnique), p.65
- Lary, D. J., Alavi, A. H., Gandomi, A. H., & Walker, A. L. (2016). Machine learning in geosciences and remote sensing. *Geoscience Frontiers*, 7(1), 3-10.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.

Références

- Liaw, A., & Wiener, M. (2002). Classification and regression by Random Forest. *R News*, 2(3), 18-22.
- Mellal, I., Malki, M. L., Latrach, A., Ameer-Zaimeche, O., & Bakelli, O. (2023, June). Multiscale Formation Evaluation and Rock Types Identification in the Middle Bakken Formation. In SPWLA Annual Logging Symposium (p. D031S002R006). SPWLA. <https://doi.org/10.30632/SPWLA-2023-0012>
- Mokrani L., Saidj N. (2015) Etude sédimentologique et diagraphique des Quartzites de Hamra de la région de Rhourde Nouss Université Mouloud Mammeri de Tizi-Ouzou, p.12
- Nelson, R.A., 2001: Geologic Analysis of Naturally Fractured Reservoirs, second edition. Gulf professional publishing. p323.
- Ogbu, A. D., Iwe, K. A., Ozowe, W., & Ikevuje, A. H. (2024). Innovations in real-time pore pressure prediction using drilling data: a conceptual framework. *Innovations*, 20(8), 158-168.
- Ouladmansour, A., Ameer-Zaimeche, O., Kechiched, R., Heddami, S., & Wood, D. A. (2023). Integrating drilling parameters and machine learning tools to improve real-time porosity prediction of multi-zone reservoirs. Case study: Rhourd Chegga oilfield, Algeria. *Geoenergy Science and Engineering*, 223, 211511. <https://doi.org/10.1016/j.geoen.2023.211511>
- Perrodon, A. (1980). Géodynamique pétrolière. Genèse et répartition des gisements d'hydrocarbures.
- Pradhan, B., & Lee, S. (2010). Landslide susceptibility assessment and factor effect analysis: back propagation artificial neural networks and their comparison with frequency ratio and bivariate logistic regression modelling. *Environmental Modelling & Software*, 25(6), 747-759.
- Reichstein, M., Camps-Valls, G., Stevens, B., Jung, M., Denzler, J., Carvalhais, N., & Prabhat, F. (2019). Deep learning and process understanding for data-driven Earth system science. *Nature*, 566(7743), 195-204.
- Rider, M., & Kennedy, M. (2011). The geological interpretation of well logs (3rd ed.). Rider-French Consulting Ltd.

Références

- Rives, T. (1992). *Mécanismes de formation des diaclases dans les roches sédimentaires : approche expérimentale et comparaison avec quelques exemples naturels* (Doctoral dissertation, Montpellier 2).
- Sanei, M., Ramezanzadeh, A., & Delavar, M. R. (2023). Applied machine learning-based models for predicting the geomechanical parameters using logging data. *Journal of Petroleum Science and Engineering*, 226, 108841. <https://doi.org/10.1016/j.petrol.2023.108841>
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.
- SEKHER Kh, BOUTAGHANE A. (2021) Prédiction des paramètres pétrophysiques à l'aide des méthodes de l'intelligence artificielle, cas du réservoir TAGI champs de Chebet El-Nakhlabbassin d'Oued M'Ya, sud-est de l'Algérie. UNIVERSITE KASDI MERBAH – OUARGLA
- Sonatrach 2010 : Laboratoire Mécanique des Roches, Etude Géo-mécanique du Réservoir Quartzites de Hamra, Puits ELAS-01.
- Sonatrach. (s.d.). Étude géologique et structurale de la zone de Rhourde Nous. Document interne
- Sonatrach/PED. (2005). *Rapport interne*. Sonatrach
- Sone, H., & Zoback, M. D. (2013). Mechanical properties of shale-gas reservoir rocks— Part 1: Static and dynamic elastic properties and anisotropy. *Geophysics*, 78(5), D381–D392. <https://doi.org/10.1190/geo2013-0050.1>
- Sonatrach/Schlumberger, 2007 : Algérie WEC 2007, French version.
- Sun, A. Y., & Scanlon, B. R. (2019). How can Big Data and machine learning benefit environment and water management: a survey of methods, applications, and future directions. *Environmental Research Letters*, 14(7), 073001.
- Tiab, D., & Donaldson, E. C. (2015). *Petrophysics: Theory and Practice of Measuring Reservoir Rock and Fluid Transport Properties*. Gulf Professional Publishing.
- Touzet, C. (1992). *les réseaux de neurones artificiels, introduction au connexionnisme*. Ec2.
- Van Engelen, J. E., & Hoos, H. H. (2020). A survey on semi-supervised learning. *Machine learning*, 109(2), 373-440.

Références

- WEC (2007). *Well Evaluation Conference: a compilation of studies carried out by Sonatrach staff and published in association with Schlumberger-France*. Schlumberger, 489 p.
- Zhang, C., Bengio, S., Hardt, M., Recht, B., & Vinyals, O. (2021). Understanding deep learning (still) requires rethinking generalization. *Communications of the ACM*, 64(3), 107-115.
- Zhang, M., Hu, H., Guo, B., Liang, Q., Zhang, F., Chen, X., ... & Du, P. (2024). Predicting shear stress distribution on structural surfaces under internal solitary wave loading: A deep learning perspective. *Physics of Fluids*, 36(3).
- Zhou, J., Li, X., & Mitri, H. S. (2016). Classification of rock burst in underground projects: comparison of ten supervised learning methods. *Journal of Computing in Civil Engineering*, 30(5), 04016003.
- Zoback, M. D. 2007. *Reservoir Geomechanics*. 1st ed. Cambridge, United Kingdom: Cambridge University Press.