

N° Série :/2023

Université Kasdi Merbah Ouargla



Faculté des Hydrocarbures, Energies Renouvelables et Science de la Terre et de l'Univers

Département de Production des Hydrocarbures

MEMOIRE

Pour obtenir le Diplôme de Master

Option : Production

Présenté Par :

Korichi Rania, Maou Manar, Charaoui Marwa

-THEME-

**UTILISATION DE L'INTELLIGENCE ARTIFICIELLE POUR OPTIMISER LES
DECISIONS DE DEVELOPEMENT DU CHAMPS DE HASSI MESSAOUD**

Soutenue publiquement le : 13/ 06 / 2023 devant la commission d'examen

Président	Boufades Djamila	MCB	Univ. Ouargla
Examineur	Lebtahi Hamid	MCB	Univ. Ouargla
Rapporteur	Chetti Djamel Eddine	MAA	Univ. Ouargla
Co-rapporteur	Adjou Zakaria	Doctorant	Univ. Ouargla

Année Universitaire 2022/2023

Remerciements

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

Nous voudrions dans un premier temps remercier notre directeur de mémoire **Djamel Eddine .CHETTI** Vice Doyen de la faculté d'hydrocarbures, pour la confiance qu'il nous a témoignée en acceptant de suivre ce thème, sa patience, sa disponibilité et surtout ses judicieux conseils, qui ont contribué à alimenter notre réflexion.

Nous remercions également monsieur **Adjou Zakaria** Co encadreur pour son soutien pendant notre parcours universitaire et Son aide précieuse dans laréalisation de ce modeste travail.

Nos remerciements vont aussi à monsieur **Zaoui Mohamed** ingénieur à SH- DP qui a consenti d'énormes efforts pour la réalisation de ce travail. Il a mêmepartagé avec nous ses connaissances et expériences.

Nous remercions les membres du jury D'examen, Mme Boufades Djamila et Mr Lebtahi Hamid d'avoir accepté d'examiner ce travail, pour leurs observations constructives.

Nous remercions toutes les personnes qui ont contribué au succès de notre stage et qui nous ont aidées à la rédaction de ce mémoire.

Enfin, nous remercions vivement nos parents pour leurs soutiens constants et leurs encouragements incessants.

Dédicaces

A mon père HOCINE, à ma mère KAMLA DJEGHDJEGHEt

Mes frères Sofiane et Nourdinne

A mes sœurs Nora Samia Dallah Rabia Linda Hadjer Sabrina et Nour djihane

A ma sœur MANAR MAOU

Rania Korichi

A mon père ABDELHAI, à ma mère HAFSA AMANI

A mes sœurs Maram, Mayar et Mon frère Mohammed et mon oncle Laamri

A ma chère sœur Rania Korichi

Manar Maou

A mon père AHMED, à ma mère HOURIA MEHAMADI

Mes sœurs Safa, Aycha et Mon frère Laarbi

Marwa charaoui

Résumé

L'objectif de ce mémoire est focalisé sur l'estimation de débit d'huile dans deux types de puits : éruptif et non éruptifs, en utilisant plusieurs techniques de l'intelligence artificielle basées sur des DATA jaugeage des puits nord du champ de Hassi Messaoud. L'intégration de la régression linéaire simple RLS, la régression linéaire multiple RLM, le réseau de neurone artificiel simple RNAS et le réseau de neurone artificiel multiple RNAM a été faite pour déterminer le débit d'huile. Les calculs prouvent que la méthode RLM donne le meilleur coefficient de corrélation entre le débit d'huile réel et le débit d'huile estimé (Erreur de 0,2). Par contre, la méthode RLS montre un écart important entre le débit estimé le débit mesuré (Erreur de 2,7). Les méthodes RNAS et RNAM ont donné des résultats non satisfaisants (Erreur de 1,15 et 0,86 respectivement). Dans cette étude les codes Visual Studio Code et python ont été utilisés pour l'implantation d'un système codiciel permettant l'estimation des futurs débits des puits candidats. Les résultats obtenus confirment l'efficacité des techniques de l'intelligence artificielle appliquées pour la prédiction de gain de la production en fonction du temps et de l'investissement.

Mots Clé : intelligence artificielle, débit, Jaugeage, RLS, RLM, RNAS, RNAM, Python, Visual Studio code.

Abstract

The objective of this thesis is focused on the estimation of oil flow rate in two types of wells: eruptive and non-eruptive, using several artificial intelligence techniques based on data Well Test from the northern wells of Hassi Messaoud field, The integration of simple Linear regression SRL, multiple linear regression MLR, simple artificial neural network SANN, and multiple artificial neural network MANN was done to determine the oil flow rate. The calculations prove that the RLM method gives the best correlation coefficient between the actual oil flow rate and the estimated oil flow rate (Error of 0.2). However, the RLS method shows a significant difference between the estimated flow rate and the measured flow rate (Error of 2.7). For the RNAS and RNAM methods, the results were unsatisfactory (Error of 1.15 and 0.86, respectively). In this study, Visual Studio Code and Python were used to implement a software system for estimating future flow rates of candidate wells. The results confirm the effectiveness of artificial intelligence techniques applied for predicting production gain based on time and investment.

Keywords: artificial intelligence, flow rate, Well Test, SLR, MLR, SANN, MANN, Visual Studio Code , Python

المخلص

يركز الهدف من هذه الأطروحة على تقدير تدفق النفط في نوعين من الآبار: الثائرة وغير الثائرة ، باستخدام العديد من تقنيات الذكاء الاصطناعي (IA) القائمة على قياس البيانات من الآبار الشمالية لحقل حاسي مسعود. تم استعمال عدة طرق معتمدة منها التوقع الخطي البسيط (RLS)، التوقع الخطي المتعدد (RLM)، الشبكة العصبية الاصطناعية بسيطة (RNAS) والشبكة العصبية الاصطناعية المتعددة (RNAM) لتحديد تدفق النفط (Qh). تثبت الحسابات أن الطريقة التي تعطي أفضل معامل ارتباط بين تدفق النفط الفعلي وتدفق النفط المقدر هي التوقع الخطي المتعدد (RLM) بمعامل خطأ يقدر بقيمة 0.2. من ناحية أخرى، تظهر طريقة التوقع الخطي البسيط فرقا كبيرا بين معدل التدفق المقدر ومعدل التدفق المقاس بمعامل خطأ 2.7. اما عن RNAM و RNAS فقد تحصلنا من خلالهما عن نتائج غير مرضية بمعامل خطأ يقدر ب 1.15 و 0.86 على التوالي . في هذه الدراسة، تم استخدام Visual Studio Code ورموز Python لتنفيذ نظام رمزي يسمح بتقدير معدلات التدفق المستقبلية للآبار المرشحة. تؤكد النتائج التي تم الحصول عليها فعالية تقنيات الذكاء الاصطناعي المطبقة للتنبؤ بمكاسب الإنتاج كدالة للوقت والاستثمار.

الكلمات المفتاحية: الذكاء الاصطناعي, تدفق النفط, RNAM, RNAS, RLM ,RLS, Python, Visual Studio Code

Table des matières

Remerciements	I
Dédicaces.....	II
Résumé	3
Table des matières	V
Liste des figures.....	VII
Liste des tableaux	IX
Introduction Générale	1
Chapitre I : Présentation du champ duHassi Messaoud	
I.1 Genèse et origine de l'huile	2
I.2 Historique de recherche.....	3
I.5 Description de la série stratigraphique	6
I.6 Le Jaugeage Well Testing	6
I.7 Opérations assistées	7
Chapitre II : Synthèse bibliographique sur les méthodes de l'intelligenceartificielle	
II.1 Intelligence artificielle IA :	11
II.2 La relation entre IA et le machine Learning :	12
II.3 Les réseaux de neurones artificiels RNA.....	12
II.4 Conception d'un réseau de neurones	14
II.5 Principe du neurone artificiel.....	15
II.6.1 Les phases	15
II.6.2 Critères de validation	18
II.6.3 Les critères numériques	18

II.7 Machine Learning	19
II.7.1 L'apprentissage supervisé	20
II.7.2 L'apprentissage non supervisé	20
II.7.3 Les algorithmes d'apprentissage supervisé	21
II.7.4 Les algorithmes d'apprentissage non supervisé	22
II.8 Les différentes Logiciels Utilisés.....	22
II.8.2 Logiciel PYTHON	22
II.8 L'application de l'intelligence artificielle dans le domaine pétrolier :	23

Chapitre III : Application de l'intelligence artificielle au niveau du puits

III.1 Prédiction de Débit d'huile	24
III.2 Les différents Algorithmes de L'IA	25
III.2.2 Régression linéaire multiple RLM	26
III.2.3 Réseaux de neurones artificiels avec seule input RNAS	26
III.2.4 Réseaux de neurones artificiels avec plusieurs inputs RNAM	26
III.3. Les résultats de l'application d'IA dans des différents puits	28
III.4. Partie économique	47

REFERENCES

ANNEXE

Liste des figures

Chapitre I : Présentation du champ du Hassi Messaoud

Figure I. 1: Situation géographique du HMD. _____	4
Figure I. 2: Colonne stratigraphique du champ de Hassi Messaoud _____	6
Figure I. 3: Unité de jaugeage avec séparateur et bac de stockage _____	8
Figure I. 4: Unité de jaugeage nucléaire _____	8
Figure I. 5 Source nucléaire Ba133 _____	8
Figure I. 6 Densimètre électronique _____	9
Figure I. 7 Ramarex (densimètre) pour gaz _____	10
Figure I. 8 Cellule Barton enregistrant La différence de pression en bleu et la séparation en rouge. _____	10
Figure I. 9 Turbine comptant le débit d'huile. _____	10

Chapitre II : Synthèse bibliographique sur les méthodes de l'intelligence artificielle

Figure II. 1 l'intelligence artificielle _____	11
Figure II. 2 Les types de L'intelligence Artificielle _____	12
Figure II. 3 Neurone artificiel _____	15
Figure II. 4 Les types et les algorithmes de Machine Learning. _____	19
Figure II. 5 Organigramme de conception d'un réseau de neurones _____	21

Chapitre III : Application de l'intelligence artificielle au niveau du puits

Figure III. 1 Organigramme explicatif des Méthodes pour la prédiction le débit d'huile. _____	25
Figure III. 2 Architecture de réseau de neurone approprié pour la prédiction de débit d'huile. _____	27
Figure III. 3 Courbe comparative entre Qh mesuré et Qh estimé par RLS puits ERAA1 _____	28
Figure III. 4 Résultat de test par RLS puits ERAA1 _____	29
Figure III. 5 Courbe comparative entre Qh mesuré et Qh estimé par RLM puits ERAA1 _____	29
Figure III. 6 Courbe comparative entre Qh mesuré et Qh estimé par RNAS puits ERAA1 _____	30
Figure III. 7 Résultats de test par RNAS. _____	30
Figure III. 8 Courbe comparative entre Qh mesuré et Qh estimé par RNAM puits ERAA1. _____	31
Figure III. 9 courbe comparative entre Qh mesuré et Qh estimé par RLS puits _____	32
Figure III. 10 résultats de test par RLS _____	32
Figure III. 11 Courbe comparative entre Qh mesuré et Qh estimé par RLM puits RDC20 _____	33
Figure III. 12 Courbe comparative entre Qh mesuré et Qh estimé par RLM puits RDC20. _____	33
Figure III. 13 Résultat de test par RNAS puits RDC20. _____	34

Figure III. 14	Courbe comparative entre Qh mesuré et Qh estimé par RNAM puits RDC20.	__ 34
Figure III. 15	Courbe comparative entre Qh mesuré et Qh estimé par RLS puits OMKZ15.	___ 35
Figure III. 16	Résultat de test par RLS puits OMKZ15.	_____ 36
Figure III. 17	courbe comparative entre Qh mesuré et Qh estimé par RLM puits OMKZ15	___ 36
Figure III. 18	Courbe comparative entre Qh mesuré et Qh estimé par RNAS puits OMKZ15.	_ 37
Figure III. 19	Résultat de test par RNAS puits OMJZ65.	_____ 37
Figure III. 20	Courbe comparative entre Qh mesuré et Qh estimé par RNAM puits OMKZ15.	_ 38
Figure III. 21	Courbe comparative entre Qh mesuré et Qh estimé par RLS puits OMJZ65.	____ 39
Figure III. 22	Résultat de test par RLS puits OMJZ65.	_____ 39
Figure III. 23	Courbe comparative entre Qh mesuré et Qh estimé par RLM puits OMJZ65	___ 40
Figure III. 24	Courbe comparative entre Qh mesuré et Qh estimé par RNAS puits OMJZ65.	__ 40
Figure III. 25	Résultat de test par RNAS puits OMJZ65.	_____ 41
Figure III. 26	Courbe comparative entre Qh mesuré et Qh estimé par RNAM puits OMJZ65.	_ 41
Figure III. 27	Courbe comparative entre Qh mesuré et Qh estimé par RLS puits OMJZ633.	__ 42
Figure III. 28	Résultat de test par RLS puits OMJZ633.	_____ 43
Figure III. 29	Courbe comparative entre Qh mesuré et Qh estimé par RLM puits OMJZ633.	___ 43
Figure III. 30	Courbe comparative entre Qh mesuré et Qh estimé par RNAS puits OMJZ633.	_ 44
Figure III. 31	Résultat de test par RNAS puits OMJZ633.	_____ 44
Figure III. 32	Histogramme reprenste les erreurs de quatre méthodes de calcul.	_____ 46
Figure III. 33	Histogramme Histogramme represente la régression des coûts après l'IA	_____ 49

Liste des tableaux

Chapitre II : Synthèse bibliographique sur les méthodes de l'intelligence artificielle

Tableau II.1: les domaines de l'utilisation de l'intelligence artificielle. _____	16
-----------------------------------------------------------------------------------	----

Chapitre III : Application de l'intelligence artificielle au niveau du puits

Tableau III.1: Description du puits ERAA1 _____	28
Tableau III.2: Description du puits RDC20 _____	31
tableau III.3: Description du puits OMKZ15 _____	35
Tableau III.4: Description de puits OMJZ65 _____	38
Tableau III.5: Description du puits OMJZ363 . _____	42
Tableau III.6: les erreurs de quatre méthodes de calcul. _____	46
Tableau III.7: coût des opérations de jaugeage par puits. _____	47
Tableau III.8: coût des opérations de jaugeage par puits après l'application d'IA. _____	48

Liste des abréviations

HMD	Hassi Messaoud
IA	Intelligence Artificiel
RLS	Régression linéaire simple
RLM	Régression linéaire multiple
RNAS	Réseaux des Neurones Artificiels Simple
RNAM	Réseaux des Neurones Artificiels Multiple
MAE	Mean Absolute Error
DL	Deep Learning
ML	Machine Learning
RNA	Réseaux des Neurones Artificiels
SVM	Support vector machine
Q_h	Le débit d'huile (m ³ /h)
Q_{GL}	Le débit de gaz lift (m ³ /h)
P_t	La pression de tête (Bar)
P_p	La pression de pipe (Bar)
T_h	Température d'huile (C°)
∅	Diamètre de duse (cm)

Introduction Générale

Introduction Générale

La situation actuelle sur le marché pétrolier se caractérise par une chute des cours du brut et une instabilité due à l'influence de divers facteurs tels que la politique, la géopolitique et la pandémie du coronavirus. Parallèlement, la production mondiale de pétrole continue d'augmenter, notamment grâce au boom de réserves non conventionnelles, en particulier le gaz de schiste.

Cette conjoncture a fortement impacté l'économie de l'Algérie, dont plus de 90 % des revenus proviennent des hydrocarbures. De ce fait, les pays producteurs au sein de l'OPEP, dont l'Algérie fait partie, doivent agir efficacement pour réduire les coûts de production et garantir une marge bénéficiaire satisfaisante. Cela passe notamment par un bon contrôle des coûts de production, en particulier lors des phases d'exploration et de développement, qui comprennent des opérations coûteuses. Il est donc nécessaire de travailler pour limiter les dépenses (Ziamech, 2021). À cet égard, l'utilisation de nouvelles technologies innovantes pourrait permettre de réduire la facture tout en résolvant efficacement les problèmes liés à cette activité, tels que les paramètres pétro physique, le gisement, production de surface et le jaugeage. L'intelligence artificielle est introduite dans notre étude afin de réduire le nombre des opérations.

En 1976, l'équation de la Duse a été mise au point afin d'évaluer le débit d'huile dans des conditions de pression élevée. Cependant, dans le contexte actuel, l'utilisation de cette équation est restreinte en raison des modifications des conditions thermodynamiques dans le réservoir HMD, ainsi que de l'augmentation du GOR dans les puits sélectionnés. Rations dans Les puits producteurs et obtenir des data jaugeages. L'exploitation de la programmation dans l'industrie offre une multitude d'avantages et de stratégies opérationnelles qui ne demandent qu'à être mises en pratique. Le problème mis en évidence dans cette étude est de déduire la meilleure méthode pour obtenir un débit d'huile estimé plus proche que le débit d'huile mesure par le jaugeage en introduisant des inputs et des outputs et de vérifier les erreurs de chaque méthode, la méthode du régression linéaire simple et multiple ainsi que le réseau de neurone artificielle simple et multiple s'impose.

Ce mémoire a pour objectif principal de se concentrer sur l'estimation du débit d'huile dans deux types de puits, éruptifs et non éruptifs, en mettant en œuvre différentes techniques d'intelligence artificielle basées sur les données de jaugeage des puits situés dans la champs

nord du Hassi Messaoud.

Afin de réaliser cette étude, le travail est composé en trois axes:

La présentation de la région d'étude ; le cadre géologique régional, la géologie locale du champ de Hassi Messaoud ainsi que l'opération de jaugeage sont exposés au premier chapitre. Dans le deuxième chapitre sont présentées les différentes techniques de l'intelligence Artificielle qui sont utilisés pour résoudre les problèmes posés à savoir le débit d'huile.

L'estimation de débit d'huile par les différentes techniques de l'intelligence artificielle à l'aide des Data jaugeages dans les puits éruptif et non éruptif sont exposés dans le troisième et dernier chapitre avec une étude technico-économique.

Ce travail s'achève par une conclusion générale présentant les principaux résultats obtenus et une discussion portant sur les perspectives d'étude.

Chapitre I :
Présentation du champ du Hassi Messaoud

Introduction

Le champ de Hassi Messaoud représente l'un des champs les plus complexes au monde. Durant l'histoire géologique, ce champ a subi d'une part une évolution tectonique intense caractérisée par des phases compressives et distinctives. D'autre part, par la transformation diagénétique dans le réservoir lors de son enfouissement au cours du temps géologique, jusqu'à ce que le gisement a pris forme tel que représentée par la configuration actuelle. Ces événements peuvent quelques fois améliorer les paramètres pétro-physiques comme ils peuvent les détériorer. (Sahoune, 2019)

I.1 Genèse et origine de l'huile

Le réservoir de Hassi – Messaoud est à 3300 m de profondeur en moyenne dans les terrains quartziques du cambrien.

NB : L'âge géologique du Cambrien de HASSI-MESSAOUUD a été daté par **Mobil Field Research Laboratory** à 560 millions d'années plus ou moins 25 M.A. par la méthode Rubidium/Strontium (chronologie absolue).

Il y a deux sources possibles à propos de l'origine de l'huile de Hassi Messaoud :

Les bancs argileux des argiles d'El-Gassi du fait de leur présence proche du champ et surtout de l'état de leur carbonisation avancée qui témoigne de leur contribution au processus de formation des hydrocarbures.

Les argiles du silurien, puissante série, riches en matières organiques, situées de part et d'autre du gisement à de grandes profondeurs (sillon de Dorbane notamment).

L'extension géographique des niveaux, leur importante radioactivité et les tests géochimiques réalisés leur confèrent le rôle de roche mère potentielle ayant généré une grande partie de l'huile.

Les huiles formées ont migré vers le début du Jurassique jusqu'au Crétacé inférieur où le piégeage a eu lieu (vers 110 millions d'années).

Le gisement de Hassi Messaoud fut découvert par deux compagnies françaises CFPA (Compagnie Française de Pétrole d' Algérie) et SN.REPAL (Société Nationale de Recherche Pétrolière en Algérie)

(M.T.HAMMOUDI.,

2004)

I.2 Historique de recherche

En 1946, la SN.REPAL avait commencé sa recherche à travers le Sahara, trois années plus tard, elle débutait la prospection géophysique par reconnaissance gravimétrique

Le champ Hassi Messaoud se situe à 850 Km au Sud-Sud Est d'Alger et à 350 Km de la frontière tunisienne. Les dimensions du champ atteignent 2500 Km² avec une surface imprégnée d'huile d'environ 1600 Km².

Le 15 janvier, la SN.REPAL a amorcé le premier forage MD1 implanté à la suite d'une campagne sismique réfraction, non loin du puits chamelier de Hassi Messaoud.

Le 15 juin de cette même année, ce forage découvrit à 3338m de profondeur des grés de cambrien.

Juin 1957 à 7.5 Km du MD1 vers le Nord, la CFPA confirmait l'existence d'un gisement par le forage OM1. (Sahoune, 2019)

Dès l'or, les forages se développaient et se multipliaient sans cesse. Après 35 ans de production la pression de gisement a énormément chuté ce qui a incité à utiliser les méthodes de récupération assistées (injection de gaz, eau, ...).

La partie Sud de la concession sur laquelle se trouve le champ, a été octroyé à la SNREPAL et celle du Nord à la CFPA.

Le champ de Hassi Messaoud demeure traditionnellement divisé en Hassi Messaoud Nord et Hassi Messaoud Sud.

I.3 Situation géographique

Le champ de Hassi Messaoud se situe à 850 km Sud-Sud Est d'Alger et à 350 km de la frontière tunisienne Sa localisation en coordonnées Lambert Sud Algérie est la suivante (Figure I.1) :

De [790.000 à 840.000] Est.

De [110.000 à 150.000] Nord.

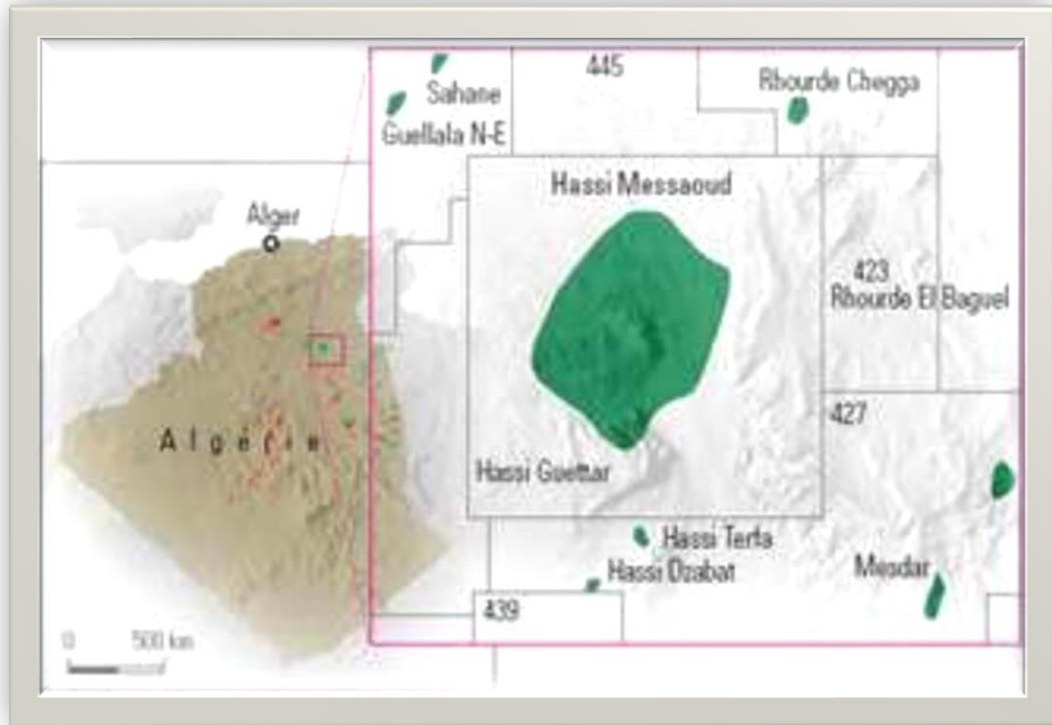


Figure I. 1 Situation géographique du HMD.

Il est limité :

Au Nord-Ouest par les gisements d'Ouargla [Gellala, Ben Kahla et HaoudBerkaoui]. Au Sud- Ouest par les gisements d'El Gassi, Zotti et El Agreb.

Au Sud-Est par les gisements; Rhourde El Baguel et Mesdar . Géologiquement, il est limité : A l'Ouest par la dépression d'Oued M'ya . Au Sud par le môle d'Amguid El Biod .

Au Nord par la structure Djammâa-Touggourt .

A l'Est par les hauts fonds de Dahar ,Rhourde El Baguel et la dépression de Ghadames.

I.4 Zones et numérotation des puits

Actuellement le champ est divisé en 25 zones de production (Figure I.2). Ces zones sont relativement indépendantes et correspondant à un ensemble de puits communiquant entre eux mais pas avec ceux des zones voisines, et se comportent de la même manière de point de vue pression de gisement.

Il est important de noter que la subdivision actuelle n'est pas satisfaisante car une Même zone peut être divisée en sous zones. (Ex : 1a, 1b, 1c).

Le champ de Hassi Messaoud est divisé d'Est en ouest en deux parties distinctes : Le champ sud et le champ Nord, chacun a sa propre numérotation.

Champ Nord : comporte une numérotation géographique complétée par une numérotation chronologique, exemple : Omn 43

O : Majuscule, permis d'Ouargla.

m : Minuscule, carreau de 1600 km

n : Minuscule, carré de 100 km

4 : Abscisse et **3** : ordonnée

Champ Sud : Elle est principalement chronologique complétée par une Numérotation géographique basée sur des abscisses et des ordonnées d'intervalle égale à 1, 250 km et harmonisée avec les coordonnées Lambert, Exemple : Md10 (33)-(15). (GAsmi, 2013)

I.5 Description de la série stratigraphique

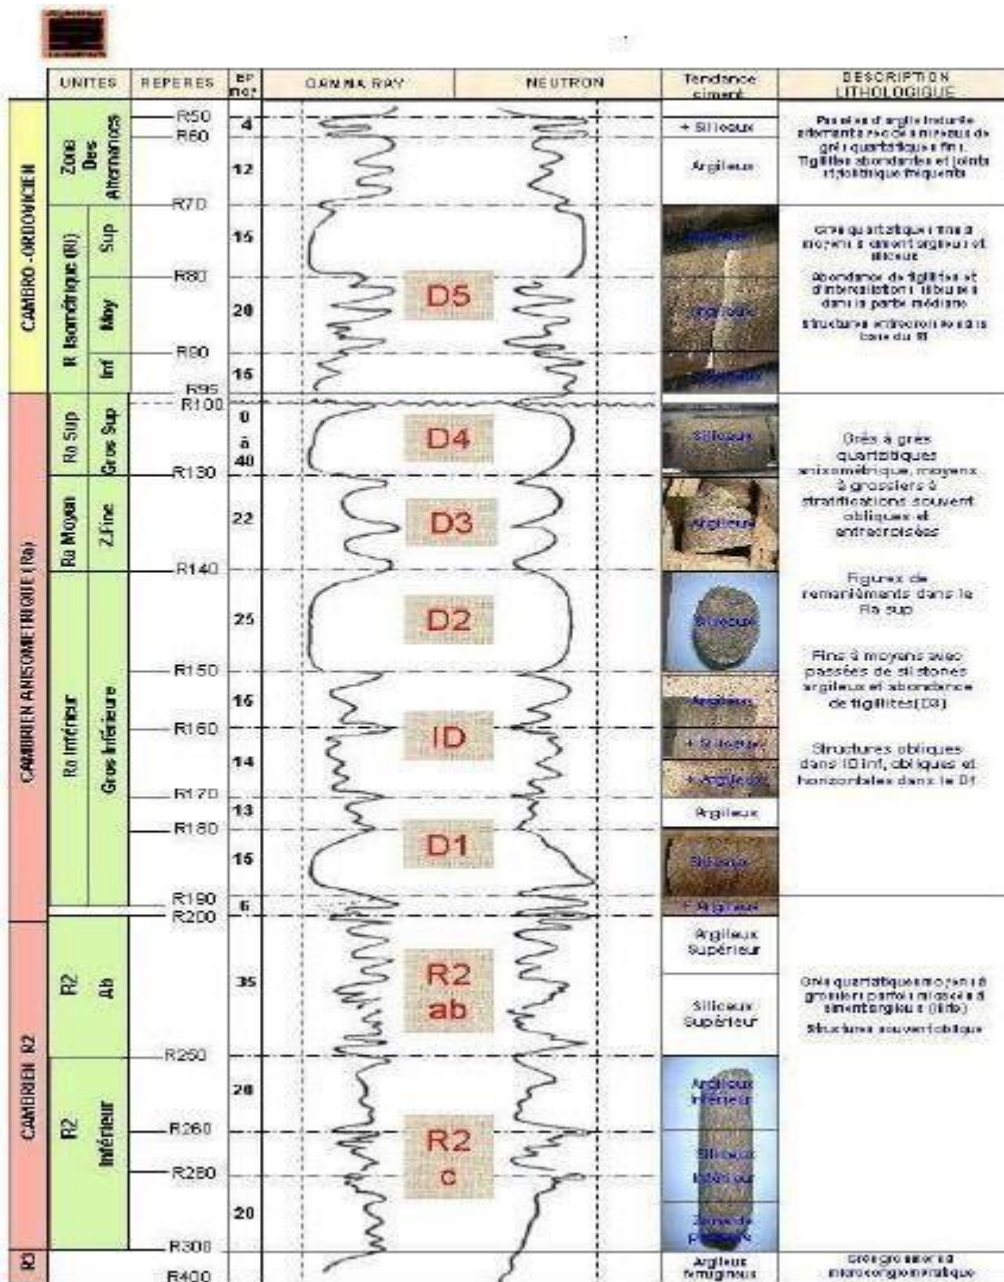


Figure I.2: Colonne stratigraphique du champ de Hassi Messaoud

I.6 Le Jaugeage Well Testing

Le jaugeage est un Well Test qui a pour but de calculer le débit d'huile de gaz et d'eau produit par un puits. Cette opération dure en général quatre heures et peut être effectuée de deux façons différentes au niveau du procédé (calcul des volumes produit en un temps précis) (GAsmi, 2013).

- **Jaugeage conventionnel** : la production est interrompue et mise sur séparateur + bac de stockage + torche.
- **Jaugeage non conventionnel** : 'In Line test' la production n'est pas perturbée seulement déviée par un séparateur (ou un compteur nucléaire) puis remise sur collecte vers le centre de traitement. (Hamza. & Mr. MEDDI, 2017).

I.7 Opérations assistées

I.7.1. Jaugeage conventionnel sur le puits OMJZ65

Le puits OMJZ65 est un puits producteur d'huile avec injection de gaz lift continu, avec une pression en tête de 15 Bar et une température de 27°C, (Figure I.3)(Figure I.4)(Figure I.5).

L'opération de jaugeage a commencé à 6h 15min en ouvrant la vanne de piquage et en fermant la vanne de centre, le brut sort du puits avec une pression de ligne de 11.3 bar et passe par le séparateur triphasique, de capacité 600 Psi. Ce dernier sépare le brut en :

- **Gaz** : passe par un porte orifice Daniel qui crée une différence de pression entre l'amont et l'aval de l'orifice. Cette différence de pression plus la pression de séparation sont portés sur une cellule Barton. Tous ces paramètres sont utilisés pour calculer le volume de gaz produit avec des formules mathématiques. Ce gaz est ensuite brûlé sur torche.
- **Huile** : est stocké dans un bac de capacité de 50 m³ qui contient deux compartiments A+B et chaque 30 min on lit le volume d'huile produit.
- **Eau** : le puits ne produit pas d'eau.

A la fin de l'opération, l'huile stockée dans le bac est pompée sur collecte pour finir au centre de traitement ; et le puits est remis à produire normalement. (Hamza. & Mr. MEDDI, 2017)



Figure I.3: Unité de jaugeage avec séparateur et bac de stockage



Figure I.4: Unité de jaugeage nucléaire



Figure I.5: Source nucléaire Ba133

I.7.2. Jaugeage non conventionnel (nucléaire) VX

La compagnie SLB a procédé à un jaugeage en utilisant un multi phase flowmeter (MPFM).

- **Le Principe:** on utilise dans cette opération une source émettrice de rayon γ (Baryum 133) ces rayons bombardent le brut, chaque phase atténue une quantité de rayons, cette atténuation dépend de la densité de chaque phase (Par ex : l'eau atténue plus que l'huile qui atténue plus que le gaz). Un ordinateur enregistre le taux de rayons gamma non absorbé par l'effluent et nous donne le débit de chaque phase avec une précision non égalée.

Il est impératif de procéder à des échantillonnages de chaque phase et calculer leurs densité (pour le gaz on utilise un appareil appelé Ramarex, pour l'huile on effectue une centrifugation.)

Pour la séparer des sédiments ensuite on utilise un densimètre). Ces densités sont entrées dans l'ordinateur pour que le logiciel puisse reconnaître la nature de l'effluent.

Avant toute opération de VX on doit procéder à un Empty Pipe (opération de jaugeage maissous vide) pour stabiliser la source (Figure I.6) (Figure I.7).

- **Avantage :**
 - précision de calcul.
 - Non interruption de la production.
 - Personnel et matériel réduit
 - avantage économique et environnementale vu que le gaz n'est pas brulé sur torche. (GAsmi, 2013)



Figure I.6: Densimètre électronique




Figure I.7: Ramarex (densimètre) pour gaz

I.7.3. Jaugeage non conventionnel avec turbine IN LINE

La compagnie EXPRO a effectué une opération de jaugeage sur le puits OMKZ15. Le principe de l'opération est similaire au jaugeage conventionnel, la seule différence est que l'huile n'est pas stocké dans un bac mais continue à être envoyé vers le centre de traitement c'est-à-dire que la production se fait en continue en passant par un séparateur. Le brut est donc séparé en trois phases, l'huile passe par une turbine qui mesure son débit et envoie ces mesures à un ordinateur. La mesure faite par la turbine contient une certaine erreur du fait du gaz qui peut entrer dedans et pour corriger cette erreur, on remplit un bac pendant 5 minutes, on calcule le débit de l'huile dedans et on le compare au débit enregistré par la turbine. On obtient par la suite une erreur à prendre en considération lors du calcul final (Hamza. & Mr. MEDDI, 2017).

Le débit de gaz est calculé par le même procédé mais finit sur collecte et non sur torche (Figure I.8)




Figure I.8: Cellule Barton enregistrant La différence de pression en bleu et la pression de séparation en rouge.

Chapitre II :
Synthèse bibliographique sur
Les méthodes de l'intelligence artificielle.

Introduction

L'intelligence artificielle (IA) se consacre à l'étude des activités intellectuelles humaines pour lesquelles aucune méthode a priori connue n'est disponible. L'IA s'intéresse à tous les cas où le traitement de l'information ne peut être réduit à une méthode simple, précise et algorithmique. Un algorithme est une suite d'opérations ordonnées, bien définies et exécutables sur un ordinateur, permettant d'obtenir une solution en un temps raisonnable, allant de quelques minutes à quelques heures. L'IA a vu le jour en 1956 et son objectif est de permettre à une machine d'accomplir des tâches que l'homme réalise en utilisant son intelligence. (Ahmadi, 2018.)

II.1 Intelligence artificielle IA :

C'est un domaine scientifique lié au traitement des connaissances et du raisonnement pour permettre aux machines d'accomplir des fonctions normalement associées aux humains. L'intelligence artificielle tente de reproduire les processus cognitifs humains d'effectuer des actions "intelligentes". Il s'agit de la création de programmes (Figure II.1).

Le domaine principal de recherche de l'intelligence artificielle s'appelle l'apprentissage automatique (Machine Learning).

Il consiste à entraîner un ordinateur à effectuer trois types d'actions : prédire, classer et regrouper (Adibifard, Tabatabaei-Nejad,, & S. A. R. , 2014).

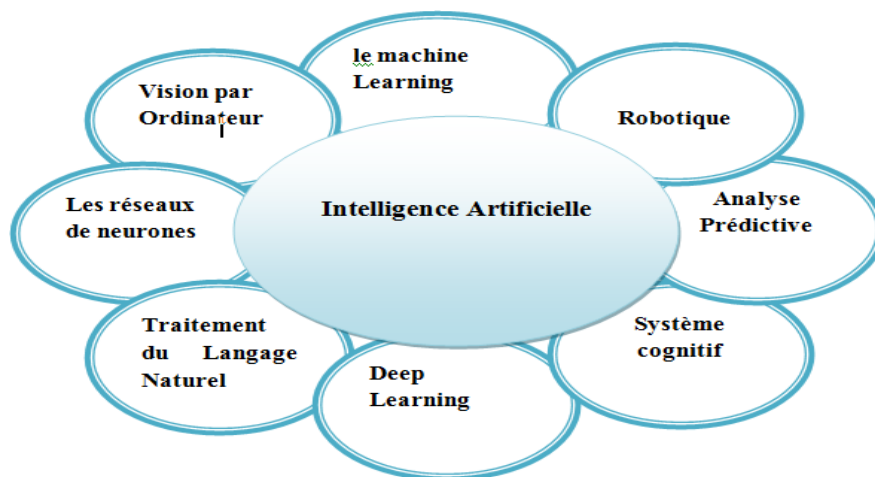


Figure II.1: l'intelligence artificielle

II.2 La relation entre IA et le machine Learning :

Le Machine Learning, ainsi que l'apprentissage profond et les réseaux de neurones artificiels qui le composent, constituent des sous-ensembles concentriques de l'IA. L'IA traite les données pour prendre des décisions et émettre des prévisions. Les algorithmes de Machine Learning permettent non seulement à l'IA de traiter ces données, mais aussi de les exploiter pour apprendre et devenir plus intelligente, sans avoir à recourir à une programmation additionnelle. Le Machine Learning est issu de l'intelligence artificielle (Figure II.2). Dans le premier sous-ensemble se trouve le Machine Learning. Dans le Machine Learning se trouve l'apprentissage profond. Et dans l'apprentissage profond se trouvent les réseaux de neurones artificiels (Adibifard, Tabatabaei-Nejad, & S. A. R. , 2014)

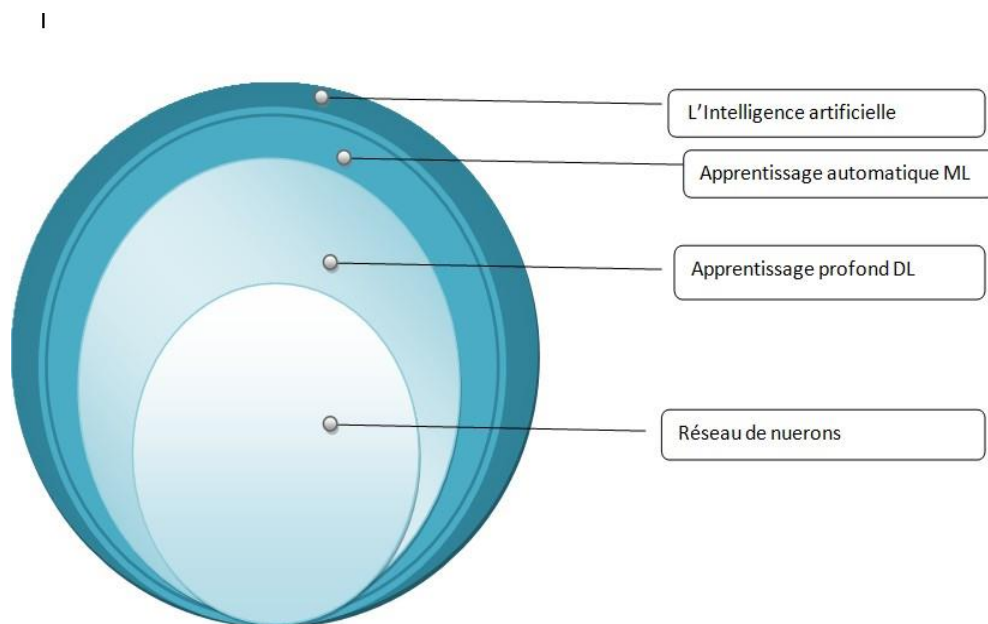


Figure II.2: Les types de L'intelligence Artificielle

II.3 Les réseaux de neurones artificiels RNA

Les réseaux de neurones artificiels sont des méthodes intelligentes artificielles, Depuis cinquante ans, les informaticiens se sont inspirés de la biologie pour produire des structures capables de résoudre divers problèmes complexes (Ziamech, 2021)

Un neurone est une fonction algébrique non linéaire, paramétrée, à valeurs bornées. Les réseaux de neurones sont fabriqués de structures cellulaires artificielles et constituent une approche permettant d'aborder sous des angles nouveaux les problèmes de perception,

De mémoire, d'apprentissage et de raisonnement. Ils s'avèrent aussi des alternatives très prometteuses pour contourner certaines des limitations des ordinateurs classiques. Grâce à leur traitement parallèle de l'information et à leurs mécanismes inspirés des cellules nerveuses (neurones), ils infèrent des propriétés émergentes permettant de solutionner des problèmes jadis qualifiés de complexes.

Dans ce chapitre nous nous intéresserons à l'application des réseaux de neurones à la production du pétrole.

Au début, les définitions et notations de base relatives aux réseaux de neurones seront rappelées, suivies de l'exposition des types et de la méthodologie d'apprentissage. Ensuite, les étapes de conception d'un réseau de neurones seront présentées de manière générale, notamment le choix de l'input et output, l'élaboration de la base de données et de la structure du réseau. En somme, cet article traite des fondements des réseaux de neurones, de leur apprentissage et de leur conception, en fournissant des explications claires et détaillées pour chaque étape.

Un réseau de neurone peut être considéré comme un modèle mathématique de traitement réparti, composé de plusieurs éléments de calcul non-linéaire (neurones), opérant en parallèle et connectés entre eux par des poids.

Les réseaux de neurones artificiels sont des réseaux fortement connectés de processeurs élémentaires fonctionnant en parallèle. Chaque processeur élémentaire calcule une sortie unique sur la base des informations qu'il reçoit.

Les neurones artificiels sont souvent utilisés sous forme de réseaux qui diffèrent selon le type de connections entre les neurones, une cinquantaine de types peut être dénombrée.

Ces derniers sont les plus utilisés dans le domaine de la modélisation et de la commande des procédés.

Ils sont constitués d'un nombre fini de neurones qui sont arrangés sous forme de couches.

Nous distinguons trois types des couches:

- **Couche d'entrée** : les neurones de cette couche reçoivent les valeurs d'entrée du réseau et les transmettent aux neurones cachés. Chaque neurone reçoit une valeur, il ne fait pas donc de sommation.
- **Couches cachées** : chaque neurone de cette couche reçoit l'information de plusieurs couches précédentes, effectue la sommation pondérée par les poids, puis la transforme selon sa fonction d'activation qui est en général une fonction sigmoïde. Par la suite, il envoie cette réponse aux neurones de la couche suivante.

- **Couche de sortie** : elle joue le même rôle que les couches cachées, la seule différence entre ces deux types de couches est que la sortie des neurones de la couche de sortie n'est liée à aucun autre neurone (Bouchon-Meunier, 1995).

En revanche, Zhang et al. (1998) ont mentionné que l'utilisation d'une seule couche peut exiger un nombre élevé de neurones dans la couche cachée, ce qui nécessite un temps d'apprentissage élevé et cause une diminution de la capacité de généralisation du RNA. En général, un RNA avec peu de neurones cachés est préférable, car il a généralement une meilleure capacité de généralisation et moins de problème de surapprentissage (overfitting). Dans la topologie du réseau de neurones, on distingue les réseaux de neurones non bouclés (feed-forward), cas où l'information circule sans retour de neurones de la première couche vers les neurones de la couche suivante sans aucun lien entre les neurones de la même couche (FigII.3.a). Dans le cas de retour de l'information de la couche suivante vers la couche précédente, on appelle ce type réseau de neurones à connexion récurrente (feedback) (Fig.II.3.b). (Widrow & Hoff, M.E, 1960)

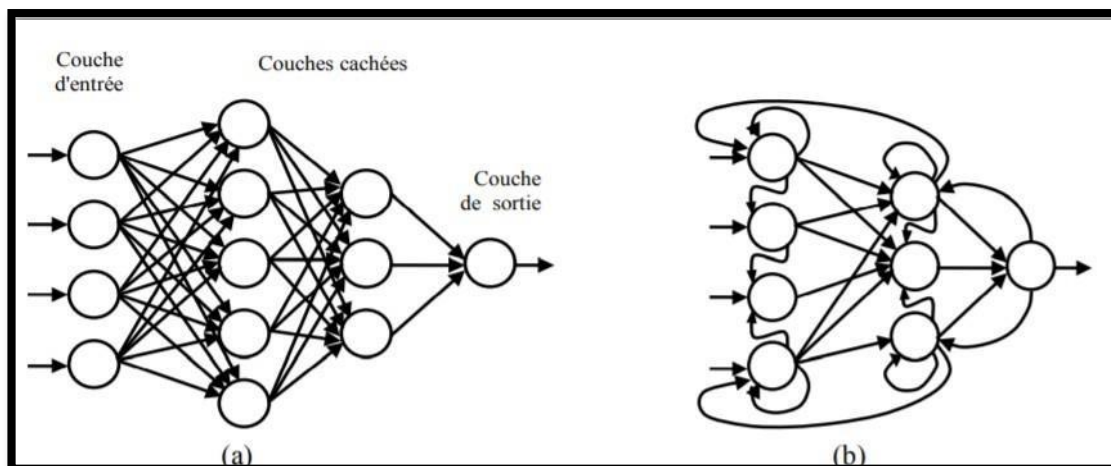


Figure II. 3: Topologie des réseaux de neurones : (a) réseau de neurones non bouclé et (b) réseau de neurones.

II.4 Conception d'un réseau de neurones

Les réseaux de neurones réalisent des fonctions non-linéaires paramétrées. Leur mise en œuvre nécessite :

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

- La collecte des données nécessaires à l'apprentissage et à l'évaluation des performances du réseau de neurones.
- La détermination du nombre de neurones cachés nécessaires pour obtenir une approximation satisfaisante.
- La réalisation de l'apprentissage
- L'évaluation des performances du réseau de neurones à l'issue de l'apprentissage. (Bouchon-Meunier, 1995)

II.5 Principe du neurone artificiel

Chaque neurone artificiel est un processeur élémentaire qui reçoit un nombre variable d'entrées provenant de neurones en amont ou de capteurs composant la machine dont il fait partie. À chacune de ses entrées est associé un poids représentatif de la force de la connexion. En somme, chaque neurone artificiel est un élément clé dans le fonctionnement des réseaux de neurones, car il traite les informations entrantes en fonction de leur poids et les transmet aux neurones suivants pour le traitement ultérieur.

Chaque processeur élémentaire est doté d'une sortie unique qui se ramifie ensuite pour alimenter un nombre variable de neurones en aval. À chaque connexion est associé un poids. Il est commode de représenter graphiquement un neurone comme indiqué sur la figure II.4 Cette représentation est à l'origine de la première vague d'intérêt pour les neurones formels (Ameur-Zaimeche O. Z., 2014).

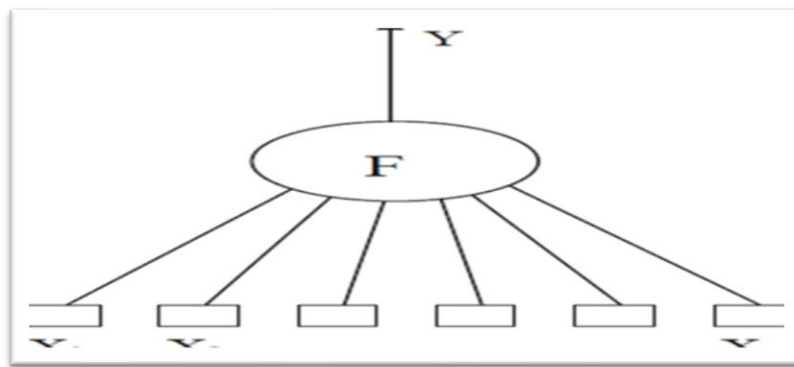


Figure II.4: Neurone artificiel

II.6. Elaboration des modèles par les réseaux de neurones

II.6.1 Les phases :

Elles se subdivisent en sept étapes

A- Collecte des données :

L'objectif de cette étape est de recueillir des données (Tableau II.1.), à la fois pour développer et valider le modèle. Le but est de rassembler un nombre de données suffisant pour constituer une base représentative nécessaire à la modélisation.

Tableau II. 1 les domaines de l'utilisation de l'intelligence artificielle.

Domaines	Donnes
Production de surface	Jaugeage Réseaux de collecte
Production de fond	Pression de fond La liaison couche-trou
Gisement	Perméabilité Porosité Résistivité

B- Analyse des données :

Celle-ci consiste à détecter d'éventuelles valeurs douteuses de la base de données recueillies qui peuvent avoir une répercussion sur les résultats de la modélisation.

C- Séparation de la base de données :

La base de données est scindée en trois parties, la première servant comme base d'apprentissage), et la seconde utilisée comme base de validation (performances du modèle) et la troisième pour (test). Il n'y a pas de règle pour déterminer ce partage de manière quantitative. Il résulte souvent d'un compromis tenant compte du nombre de données dont on dispose et du temps imparti pour effectuer l'apprentissage. Chaque base doit cependant satisfaire aux contraintes de représentativité de chaque classe de données, et doit généralement refléter la distribution réelle, c'est à dire la probabilité d'occurrence des diverses classes. (Ahmadi, 2018.)

D- Choix de l'architecture du réseau :

Il existe un grand nombre de types de réseaux de neurones, avec pour chacun des avantages et des inconvénients. Le choix d'architecture des réseaux peut dépendre:

- De la tâche à effectuer (classification, association, contrôle de processus, ...)
- De la nature des données (données présentant des variations au cours du temps).

Ce choix est aussi fonction de la maîtrise, ou de la connaissance que l'on a de certains Réseaux, ou encore du temps dont on dispose pour tester une architecture prétendue plus performante.

E- Apprentissage du réseau de neurones :

La plupart des modèles de réseaux de neurones requièrent un apprentissage. Plusieurs types d'apprentissages peuvent être adaptés à un même type de réseau de neurones. Les critères de choix sont souvent la rapidité de convergence, ou les performances de généralisation.

F- Validation :

Une fois le réseau de neurones entraîné, il est nécessaire de le tester sur une base de données différente de celle utilisée pour l'apprentissage. Ce test permet d'apprécier les performances du modèle élaboré. Si ces performances ne sont pas satisfaisantes, il faudra soit modifier l'architecture du réseau, soit modifier la base d'apprentissage. La démarche expérimentale exige cependant une étape de validation avant toute utilisation. Elle est en effet nécessaire, pour vérifier la fiabilité de la représentation interne du réseau. Elle consiste à simuler l'utilisation du réseau.

Cette validation est effectuée à l'aide de couples entrées-sorties, autres que ceux utilisés lors de l'apprentissage. Évidemment, le réseau étant par définition un outil d'interpolation, les valeurs des entrées et des sorties de ces couples, tout comme celles des entrées fournies lors de l'utilisation, appartiennent aux mêmes intervalles que celles des expériences qui ont servi à l'apprentissage.

La validation consiste alors à fournir au réseau de neurones les entrées de ces couples, à partir desquelles il calcule (grâce aux poids définis à l'apprentissage) les sorties correspondantes.

Ce qui permet de constater l'erreur commise par le réseau de neurones. Cette étape de validation est particulièrement utilisée lors de l'ajustement d'un réseau de neurones à la situation à modéliser, puisqu'il quantifie l'erreur commise.

Elle est donc systématiquement réalisée à chaque test effectué lors de la détermination de l'architecture optimale et des autres paramètres (fonction d'activation par exemple) ; Il s'agit

d'une évaluation de l'erreur de généralisation. La différence entre l'erreur d'apprentissage et l'erreur de généralisation représente une mesure de la qualité de l'apprentissage effectué.

L'erreur de généralisation dépend avant tout de trois paramètres :

- Le nombre d'exemples utilisé pour l'apprentissage
- La complexité du problème sous-jacent
- L'architecture du réseau

Les approches statistiques de la généralisation sont l'un des domaines d'investigation majeur pour optimiser les performances de l'apprentissage des réseaux de neurones.

G- Test :

En réalité il n'est y a pas grand différence entre la validation et le test puisque il réalise la même opération, Seulement la phase de validation est utilisée aussi pour éviter le problème de sur apprentissage (Overfitting) et augmenter la capacité de généralisation du modèle. Pendant l'arrêt de l'apprentissage du modèle, on constate que l'erreur totale sur la partie validation cesse de se dégrader, donc à ce point-là l'apprentissage est stoppé ce qui s'appelle l'Early- Stopping (Ameur-Zaimeche O. Z., 2014).

II.6.2 Critères de validation

Une fois le modèle construit se pose alors la question s'il rend fidèlement compte de l'échantillon. Pour cela, la modélisation nécessite des critères de validation sur la base desquels, le concepteur juge les performances finales du modèle qui sera retenu. Certains sont numériques et d'autres graphiques.

II.6.3 Les critères numériques

A- Erreur Absolue Moyenne, Mean Absolute Error MAE

C'est une mesure de la différence entre deux variables continue, elle est utilisé pour mesurer la précision des prévisions dans les modèles de prédiction le MAE est plus facilement interprétable car il est basé sur des mesures de valeurs absolue plutôt que sur le carrés

$$MAE = \frac{1}{N} \sum_{i=1}^N |Y_{i\text{obs}} - Y_{i\text{sim}}|$$

Eq.II.1

i et N nombre totaux d'observation

$Y_{i\text{obs}}$: Valeur observée.

$Y_{i\text{sim}}$: Moyenne de la variable observé (Ziamech, 2021).

II.7 Machine Learning

Le Machine Learning est un sous-ensemble de l'intelligence artificielle (IA). Cette technologie vise à apprendre aux machines à tirer des enseignements des données et à s'améliorer avec l'expérience, au lieu d'être explicitement programmées pour le faire. Dans le Machine Learning, les algorithmes sont entraînés à trouver des patterns et des corrélations dans de grands ensembles de données, ainsi qu'à prendre les meilleures décisions et à émettre les meilleures prévisions en s'appuyant sur leur analyse. Avec la pratique, les applications du Machine Learning s'améliorent. Et plus le volume de données auxquelles elles ont accès est important, plus elles deviennent précises.

Il existe deux principaux types d'algorithmes d'apprentissage, selon que l'apprentissage est supervisé ou non supervisé. Les deux types ont un processus d'apprentissage dans lequel le réseau est présenté avec un formulaire d'entrée dérivé de la base d'apprentissage (Figure II.5) (Ahmadi, 2018.).

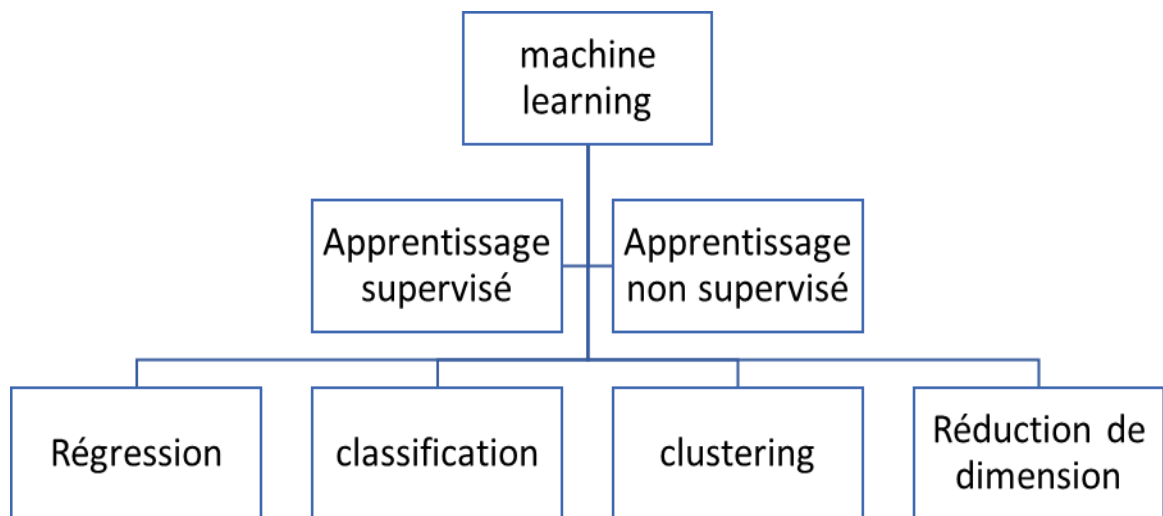


Figure II.5: Les types et les algorithmes de Machine Learning.

II.07.01 L'apprentissage supervisé

L'apprentissage d'un réseau de neurones consiste à lui imposer un fonctionnement donné en le forçant à trouver la sortie désirée à partir des entrées présentées, tout en modifiant les poids synaptiques pour minimiser l'erreur entre la sortie désirée et l'actuelle sortie du réseau. Ce processus est répété plusieurs fois jusqu'à ce que le réseau atteigne un état d'équilibre où il n'y a plus d'avantage à changer les poids. En somme, l'apprentissage d'un réseau de neurones est un processus itératif qui permet de le rendre capable de résoudre des problèmes complexes en modifiant ses connexions synaptiques (RAFIK).

Le réseau se comporte alors comme un filtre dont les paramètres de transfert sont ajustés à partir des couples input/output présentés. L'adaptation des paramètres du réseau s'effectue à partir d'un algorithme d'optimisation, l'initialisation des poids synaptiques étant le plus souvent aléatoires (Haykin, 1999).

II.07.02 L'apprentissage non supervisé

L'apprentissage non supervisé ou l'apprentissage auto-organisé ne nécessite pas une réponse correcte associée avec chaque modèle d'entrée dans l'apprentissage des données. Le RNA explore la structure sous-jacente dans les données, ou des corrélations entre les tendances dans les données, et organise des modèles en des catégories à partir de ces corrélations. Dans ce type d'apprentissage la sortie désirée du réseau n'est pas fixée, par contre dans l'apprentissage supervisé le vecteur de sortie désirée est connu pour chaque forme d'entrée et il est emmagasiné dans la base d'apprentissage (Widrow & Hoff, M.E, 1960). Les deux types d'apprentissage sont caractérisés par une phase d'apprentissage, dans laquelle on présente au réseau des formes d'entrées extraites d'une base d'apprentissage. Parmi les réseaux de neurones non supervisés on cite le réseau de Hopfield, Kohonen et les modèles ART (Figure II.10).

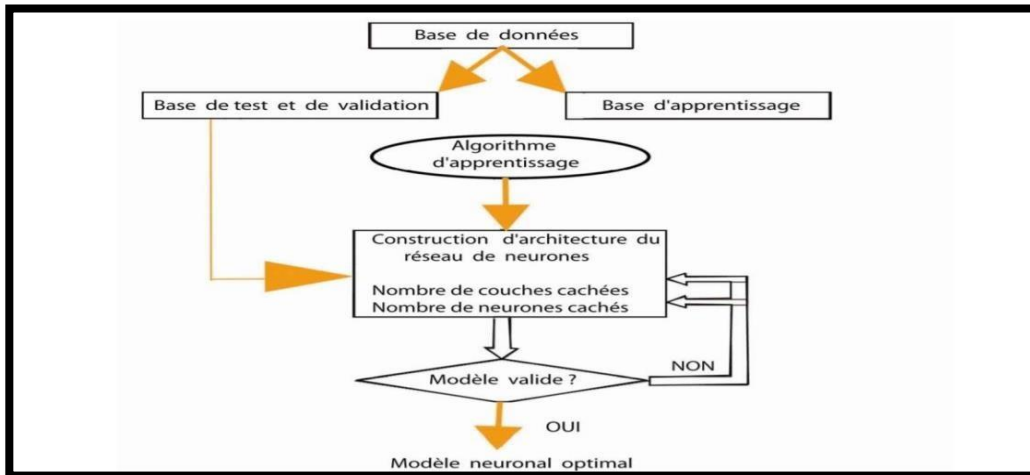


Figure II.6: Organigramme de conception d'un réseau de neurones (Haykin, 1999).

II.7.3 Les algorithmes d'apprentissage supervisé

- Régression linéaire : Les algorithmes de régression linéaire sont sans doute les plus couramment utilisés par les équipes de science des données. Cela implique d'effectuer une simple corrélation entre deux variables de votre ensemble de données. Un ensemble d'entrées et leurs sorties correspondantes sont examinées, quantifiées et liées. Par exemple Comment les changements d'une variable affectent une autre. Une régression linéaire est tracée sous la forme d'une ligne sur un graphique.
- Machine à vecteur de support (SVM) : sont une technique d'apprentissage automatique supervisé utilisée pour la classification et la régression. Le but d'une SVM est de trouver un hyperplan qui sépare le mieux les données d'entraînement dans un espace de haute dimension, où chaque dimension représente une caractéristique des données d'entrée. Les SVM sont couramment utilisées pour la classification binaire, mais peuvent également être appliquées à des problèmes de classification multi-classes. Les SVM ont montré leur efficacité dans de nombreux domaines tels que la bioinformatique, la vision par ordinateur et la finance.
- L'arbre de décision : L'arbre de décision est une méthode d'analyse de données qui permet de représenter graphiquement toutes les alternatives possibles à une décision donnée. Cela peut aider à résoudre des problèmes complexes en identifiant les différentes options disponibles, les conséquences potentielles de chaque choix et les conditions qui doivent être remplies pour chaque option. (Bouchon-Meunier, 1995).

II.7.4 Les algorithmes d'apprentissage non supervisé

Voici quelques exemples d'algorithmes d'apprentissage non supervisé :

- K-moyennes (K-means) : Cet algorithme regroupe les données en clusters à partir de leurs similarités.
- Analyse en composantes principales (ACP) : Cette méthode réduit la dimensionnalité des données en trouvant les axes qui contiennent le plus d'information.
- Réduction de dimensionnalité par projection (t-SNE) : Cette technique réduit la dimensionnalité des données tout en maintenant les similarités entre les points.

Ces algorithmes sont très utiles pour explorer et découvrir des structures cachées dans les données non étiquetées sans avoir besoin d'une supervision humaine (RAFIK).

II.8 Les différents Logiciels Utilisés

II.8.1 Logiciel VISUAL STUDIO CODE

Est un éditeur de code source développé par Microsoft, Il prend en charge plusieurs langages de programmation tels que Python, Java script.

Visual studio code est open source et dispose d'une grande communauté de développeurs qui contribuent à son développement et à sa maintenance, il est connu par sa légèreté, sa rapidité et sa facilité d'utilisation.

Visual studio code dispose également d'une grande variété d'extension qui permettent aux développeurs de personnaliser leur environnement de développement en fonction de leurs besoins (MORANDAT).

II.8.2 Logiciel PYTHON

Est langage de programmation interprété de haut niveau qui largement utilisé dans des divers domaines tels que Data science, l'apprentissage automatique (machine Learning).

Python est connu pour sa simplicité et sa facilité d'utilisation. Il possède une grande bibliothèque standard est une vaste collection de bibliothèques tierces qui en font un langage polyvalent pour diverse applications (MORANDAT).

II.8 L'application de l'intelligence artificielle dans le domaine pétrolier :

Estimation du débit individuel des phases (eau, huile, gaz) en sortie des puits de pétrole de production polyphasique, et estimation de paramètres pétro-physiques comme :

- Permeability and porosity prediction using logging data in a heterogeneous dolomite reservoir : An integrated approach."(**Zhang, Zhao, et al, 2021**) Cette étude présente Cinq corrélations typiques de la perméabilité-porosité et six méthodes d'apprentissage automatique ont été appliquées sur la base des données (diagraphies et carottes) pour évaluer l'applicabilité et la performance de prédiction de différentes méthodes.
- Permeability prediction in argillaceous and stone reservoir using fuzzy logic analysis a case study of Trias **Nabawy,2021**) Cette étude présente une méthode statistique pour analyser des ensembles des données pétro-physiques, y compris des données diagraphies et des données des carottes, afin de discriminer les principaux réservoirs de grès argileux produisant du gaz triasique à Hassi R'Mel.
- Permeability prediction of porous media using a combination of computational fluid dynamics and hybrid machine learning methods."(**Tian, Jianwei, et al, 2020**) Dans cette étude, un procédé ML hybride a été proposé pour établir une relation non linéaire implicite entre les paramètres de la structure des pores et de la perméabilité. Pour la modélisation ML, une combinaison de réseau neuronal artificiel (RNA) et d'algorithme génétique (AG) a été proposée. Sic sequences, Southern Hassi R'Mel Gas Field, Algeria (**Baouche,**

Chapitre III :
**Application de l'intelligence artificielle
au niveau du puits.**

Introduction

Dans le présent chapitre on va effectuer des traitements statistiques sur la base des données. L'étape consiste à rassembler, combiner, structurer, organiser et voir l'homogénéité, la similarité des données afin de pouvoir les analyser dans le cadre de programmes d'informatique. Dans la deuxième partie de ce chapitre on va appliquer et comparer les performances de quatre algorithmes de l'intelligence artificielle qui sont (régression linéaire simple, régression linéaire multiple, régression avec les réseaux de neurones artificiels, régression linéaire multiple avec les réseaux de neurones artificiels) sur les données de jaugeage pour prédire le débit d'huile dans les puits nord de Champ de Hassi Messaoud.

III.1 Prédiction de Débit d'huile

Pour une exploitation économique des champs, il est important de connaître avec précision les débits de production de chaque puits.

Ce paramètre est crucial pour :

- L'optimisation de la production et le management des réserves
- La prévision des futures performances des puits.

L'équation de la Duse a été développée en 1976 pour quantifier le débit de l'huile lorsque la pression est élevée. Dans le cas actuel l'application de cette équation est limitée par le changement des conditions thermodynamiques de réservoir HMD ainsi l'augmentation de GOR au niveau des puits candidats. (Hamza. & Mr. MEDDI, 2017).

Le débit d'huile est obtenu par les données de jaugeages (12 opérations/jour, avec un coût dépassant les 7315.25 \$/op).

La prédiction de débit d'huile à partir des données de jaugeages utilise différentes approches de l'intelligence artificielle (IA) pour déterminer une valeur précise de débit d'huile dans tous les puits voire même les puits non éruptifs.

L'objectif de ce travail est de trouver des algorithmes d'IA tels que la régression linéaire simple (RLS), la régression linéaire multiple (RLM), le réseau de neurones artificiels (RNA) pour prédire le débit d'huile (Figure III.1).

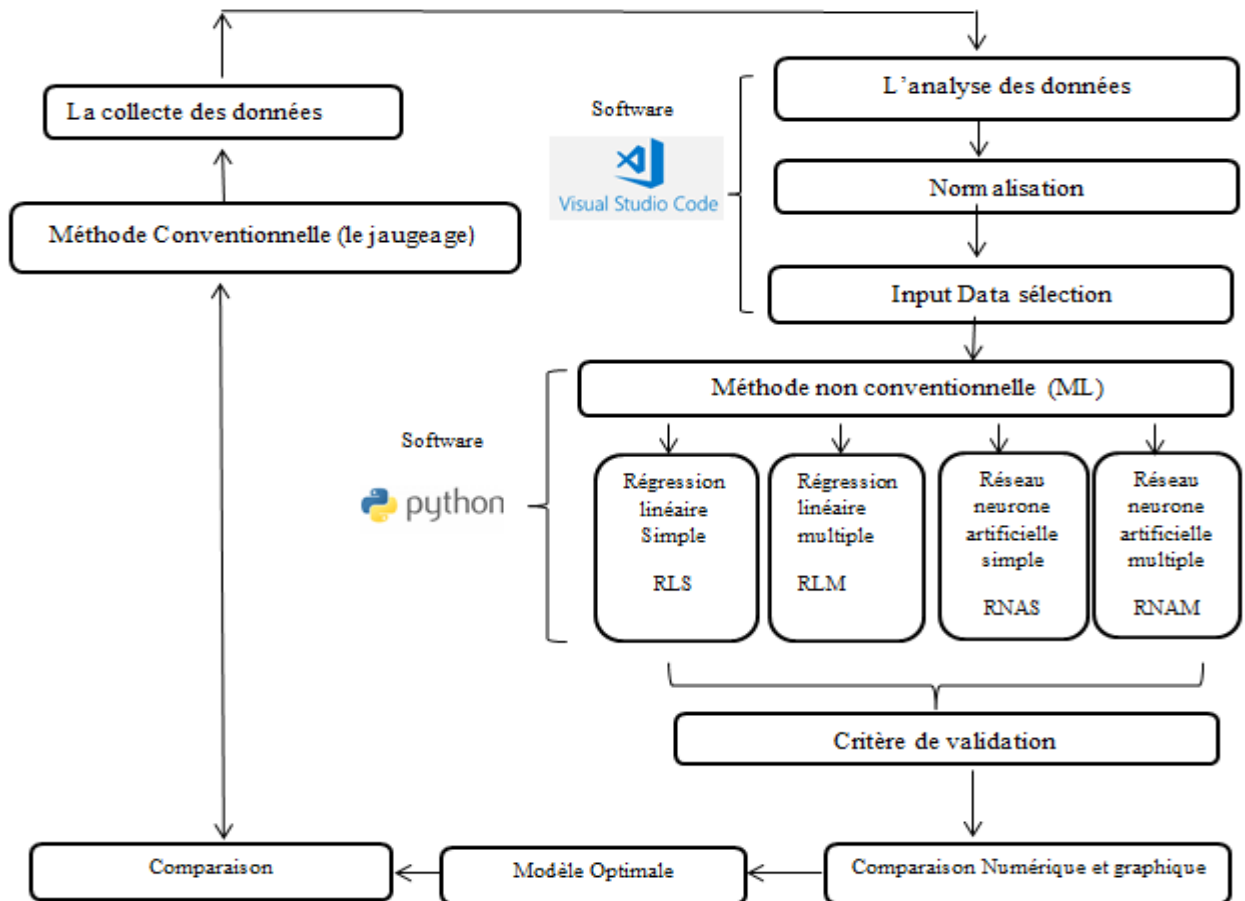


Figure III.1: Organigramme explicatif des Méthodes pour la prédiction le débit d'huile.

III.2 Les différents Algorithmes de L'IA

III.2.1 Régression linéaire simple RLS

La méthode de régression simple est une méthode statistique permettant de trouver une relation linéaire entre une variable explicative X et une variable à expliquer Y, ce modèle consiste à considérer Y comme une fonction affine de X (Ahmadi, 2018.).

- Input : Pression tête (Bar)
- Output : débit d'huile (m^3/h)

III.2.2 Régression linéaire multiple RLM

La méthode de régression linéaire multiple RLM utilisée sur une série de 4 paramètres (Pression de tête/Pression de pipe / température /Duse/ Débit de gaz lift) de la base de données afin de prévenir et de choisir les facteurs explicatifs les plus influents, sur la prévision de débit d'huile (Ahmadi, 2018.).

Input :

- Pression de tête (Bar)
- Pression de pipe (Bar)
- Duse (Cm)
- La température (C°)
- Débit de gaz lift QGL(m³/h) cas de puits non éruptif

Output : Débit d'huile (m³/h)

III.2.3 Réseaux de neurones artificiels avec seule input RNAS

Le modèle des réseaux de neurones proposé pour la prédiction de débit d'huile est basé sur la sélection des variables par la méthode (RLS) qui est (Pression de tête) comme input Pour la base de données est subdivisée aléatoirement en trois parties, 70% des données sont utilisées pour la phase d'apprentissage et 15% pour la validation et 15% pour test (Bouchon-Meunier, 1995).

L'architecture du réseau de neurone proposé est composée d'une couche d'entrée constituée d'une seule variable explicative qui est (Pt) et une seule couche cachée, constituée de 8 neurones. La couche de sortie est constituée d'un seul neurone qui est le variable a expliqué (le débit d'huile)

- Input : Pression tête (Bar)
- Output : débit d'huile (m³/h)

III.2.4 Réseaux de neurones artificiels avec plusieurs inputs RNAM

Le modèle des réseaux de neurones proposé pour la prédiction de débit d'huile est basé sur la sélection des variables par la méthode (RLM) qui sont (Pression de tête /Pression de pipe/ température/Duse/Débit de gaz lift) comme input Pour la base de données est subdivisée

Chapitre III : Application de l'intelligence artificielle au niveau du puits

aléatoirement en trois parties, 70% des données sont utilisées pour la phase d'apprentissage et 15% pour la validation et 15% pour test (Bouchon-Meunier, 1995).

L'architecture du réseau de neurone proposé est composée d'une couche d'entrée constituée de 4 variables explicatives qui sont (Pt/Pp/Duse/Température) et une seule couche cachée, constituée de 8 neurones. La couche de sortie est constituée d'un seul neurone qui est le variable a expliqué (le débit d'huile) (Figure III.2).

Input :

- Pression de tête (Bar)
- Pression de pipe (Bar)
- Duse (Cm)
- La température (C°)
- Débit de gaz lift QGL(m³/h) cas de puits non éruptif

Output : Débit d'huile (m³/h)

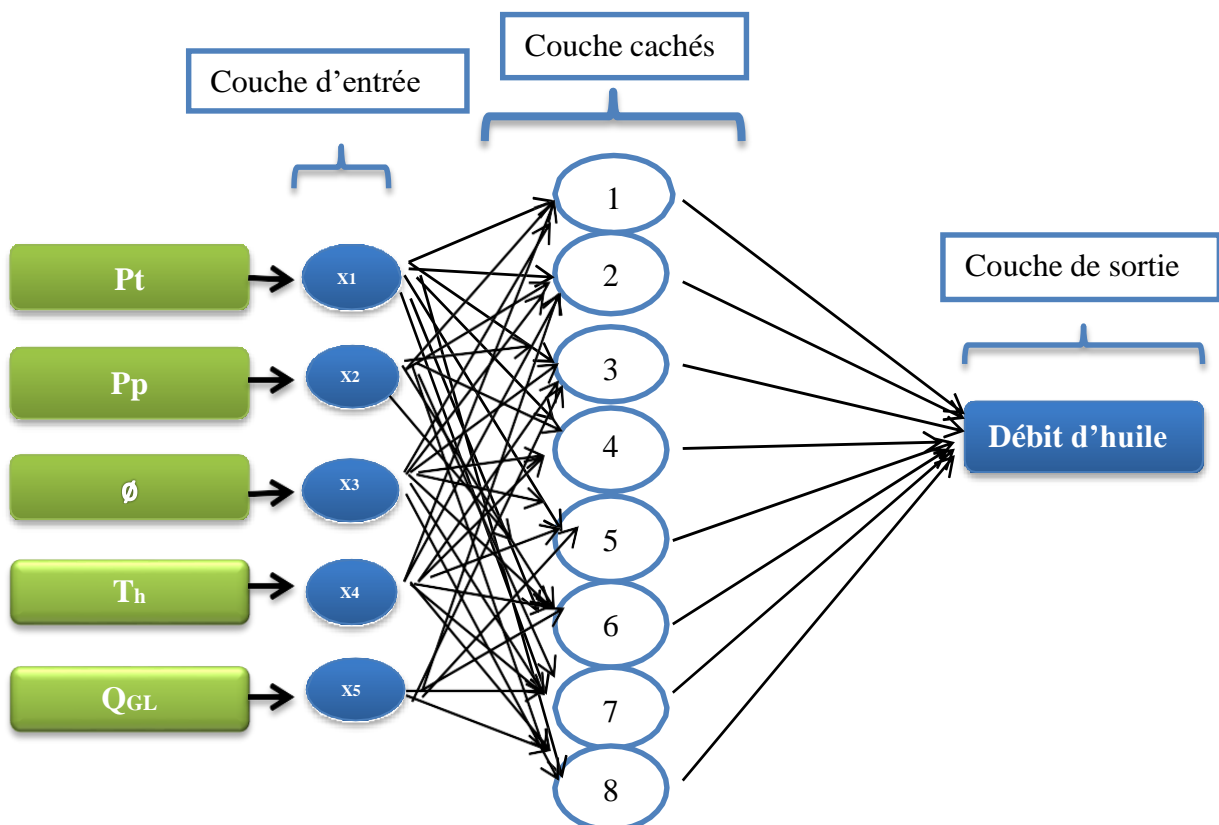


Figure III.2: Architecture de réseau de neurone approprié pour la prédiction de débit d'huile.

III.3. Les résultats de l'application d'IA dans des différents puits

A. Puits ERAA1

➤ Description de puits..

Tableau III.1: Description du puits ERAA1

Puits	Type de puits	Champ	Date de forage	Zone	Statu	Etat	MFD
ERAA1	Eruptif	Nord	02/10/2015	HZP	Producteur Huile	Ouvert	EPF-RAMA2

➤ **Méthode 01:** Régression linéaire simple

Erreur : 2.78




Figure III.3 : Courbe comparative entre Qh mesuré et Qh estimé par RLS puits ERAA1




Figure III.4 : Résultat de test par RLS puits ERAA1

➤ Méthode 02 : Régression linéaire multiple

Erreur : 0.76




Figure III.5: Courbe comparative entre Qh mesuré et Qh estimé par RLM puits ERAA1

➤ Méthode 03 : Réseau de neurone artificielle avec un seul Input

Erreur : 1.5




Figure III.6 : Courbe comparative entre Qh mesuré et Qh estimé par RNAS puits ERAA1




Figure III.7: Résultats de test par RNAS.

- **Méthode 04:** Réseau de neurone artificielle avec plusieurs inputs .




Figure III.8 : Courbe comparative entre Qh mesuré et Qh estimé par RNAM puits ERAA1.

B. Puits RDC20

- Description du puits.

Tableau III. 2: Description du puits RDC20

Puits	Type de puits	Champ	Date de forage	Zone	Statu	Etat	MFD
RDC20	Eruptif	Nord	20/10/2016	HZP	Producteurhuile	Ouvert	OML75

➤ Méthode 01 : Régression linéaire simple

Erreur : 0.96




Figure III. 9 : Courbe comparative entre Qh mesuré et Qh estimé par RLS puits




Figure III. 10 : Résultats de test par RLS

➤ Méthode 02 : Régression linéaire multiple

Erreur : 0.33




Figure III. 11: Courbe comparative entre Qh mesuré et Qh estimé par RLM puits RDC20

➤ Méthode 03 : Réseau de neurone artificielle avec un seul input

Erreur : 0.49




Figure III.12: Courbe comparative entre Qh mesuré et Qh estimé par RLM puits RDC20.




Figure III.13: Résultat de test par RNAS puits RDC20.

➤ **Méthode 04 :** Réseau de neurone artificielle avec plusieurs inputs

Erreur 0.76




Figure III.14: Courbe comparative entre Qh mesuré et Qh estimé par RNAM puits RDC20.

C. Puits OMKZ15

➤ Description de puits .

Tableau III.3 : Description du puits OMKZ15

Puits	Type de puits	Champ	Date de forage	Zone	Statu	Etat	MFD
OMKZ15	NON Eruptif	Nord	04/02/2006	HZN	Producteur huile	Ouvert	OMJ82

➤ **Méthode 01** : Régression linéaire simple

Erreur : 1.15




Figure III. 15 Courbe comparative entre Qh mesuré et Qh estimé par RLS puits OMKZ15.




Figure III. 16 Résultat de test par RLS puits OMKZ15.

➤ **Méthode 2** : Régression linéaire multiple

Erreur : 0.2




Figure III. 17 Courbe comparative entre Qh mesuré et Qh estimé par RLM puits OMKZ15

➤ Méthode 3 : Réseau de neurone artificielle avec un seul input

Erreur : 1.01




Figure III. 18 Courbe comparative entre Qh mesuré et Qh estimé par RNAS puits OMKZ15.




Figure III. 19 Résultat de test par RNAS puits OMJZ65.

➤ **Méthode 04** : Réseau de neurone artificielle avec plusieurs inputs

Erreur : 0.9




Figure III. 20 : Courbe comparative entre Qh mesuré et Qh estimé par RNAM puits OMKZ15.

D. Puits OMJZ65

➤ Description de puits .

Tableau III. 4 description de puits OMJZ65

Puits	Type de puits	Champ	Date de forage	Zone	Statu	Etat	MFD
OMJZ65	NON Eruptif	Nord	08/04/2017	HZN	Producteur huile	Ouvert	OMJ82N

➤ Méthode 01 : Régression linéaire simple

Erreur : 0.63




Figure III. 21 Courbe comparative entre Qh mesuré et Qh estimé par RLS puits OMJZ65.

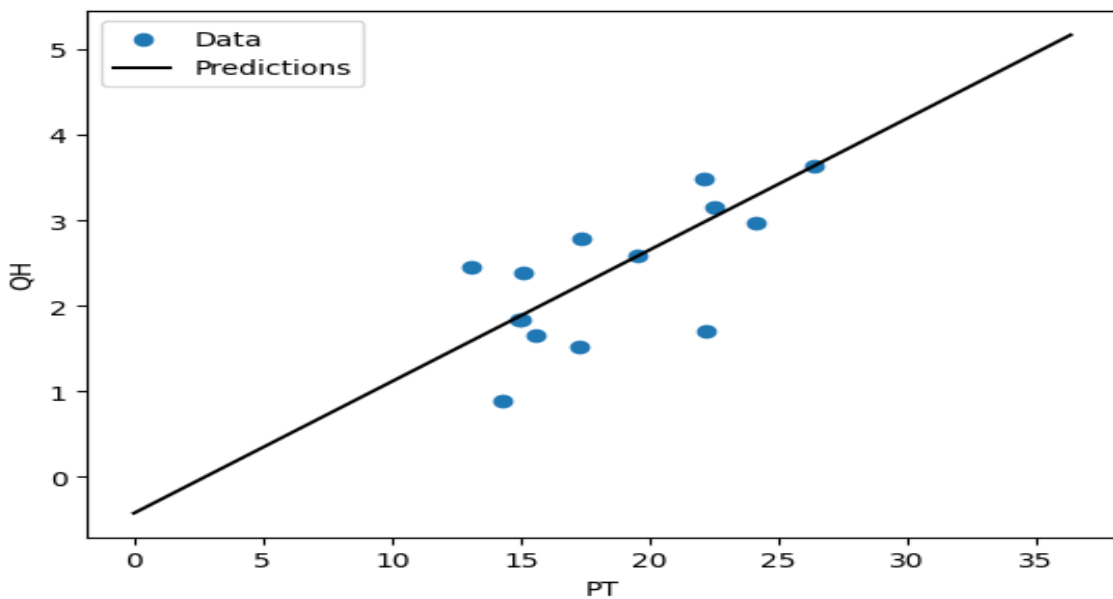


Figure III. 22 Résultat de test par RLS puits OMJZ65.

➤ Méthode 02: Regression linear multiple

Erreur: 0.23




Figure III. 23 : Courbe comparative entre Qh mesuré et Qh estimé par RLM puits OMJZ65

➤ Méthode 03: Réseaux de neurones artificiels avec seule input

Erreur :0.54




Figure III. 24 : Courbe comparative entre Qh mesuré et Qh estimé par RNAS puits OMJZ65.




Figure III. 25 :Résultat de test par RNAS puits OMJZ65.

➤ **Méthode 04** : Réseaux de neurones artificiels avec plusieurs inputs

Erreur : 0.49




Figure III. 26 Courbe comparative entre Qh mesuré et Qh estimé par RNAM puits OMJZ65.

E. Puits OMJZ633

➤ Description du puits .

Tableau III. 5 Description du puits OMJZ633 .

Puits	Type de puits	Champ	Date de forage	Zone	Statu	Etat	MFD
OMJZ633	NON Eruptif	Nord	08/06/2004	4	Producteur huile	Ouvert	OMJ82N

➤ **Méthode 01** Régression linéaire simple

Erreur : 0.63




Figure III. 27 Courbe comparative entre Qh mesuré et Qh estimé par RLS puits OMJZ633.




Figure III. 28 Résultat de test par RLS puits OMJZ633.

➤ Méthode 02 Régression linéaire Multiple

Erreur : 0.39




Figure III. 29 Courbe comparative entre Qh mesuré et Qh estimé par RLM puits OMJZ633.

➤ Méthode 03 Réseaux de neurones artificiels avec seule input

Erreur : 0.56




Figure III. 30 : Courbe comparative entre Qh mesuré et Qh estimé par RNAS puits OMJZ633.




Figure III. 31 Résultat de test par RNAS puits OMJZ633.

➤ **Méthode 04** : Réseau de neurone artificielle avec multiple inputs

Erreur : 0.46




Figure III. 32 : Courbe comparative entre Qh mesuré et Qh estimé par RNAM puits OMJZ633.

➤ Commentaires

D'après les résultats obtenus par les quatre méthodes (RLS, RLM, RNAS et RNAM) appliquées sur les différents puits (ERAA1, RDC20, OMKZ15, OMJZ65, OMJZ633), on obtient le tableau comparatif suivant

Tableau III.6: Les erreurs de quatre méthodes de calcul.

PUITS / ERREURS	RLS	RLM	RNAS	RNAM
ERAA1	2.78	0.76	1.5	0.86
RDC20	0.96	0.33	0.49	0.76
OMKZ15	1.15	0.2	1.01	0.9
OMJZ65	0.63	0.23	0.54	0.49
OMJZ633	0.63	0.39	0.56	0.46




Figure III. 33 Histogramme représente Les erreurs de quatre méthodes de calcul.

On peut voir sur l'histogramme que la méthode qui donne des résultats avec un minimum d'erreur est la régression linéaire multiple.

III.4. Partie économique

L'étude économique est la phase finale de l'étude technique. L'objectif essentiel est d'estimer l'investissement dans un projet. Les critères financiers de choix des investissements permettent de classer et de comparer les différents projets en étude afin de sélectionner le ou les projets jugés acceptables.

Afin de choisir la meilleure solution pour un projet et justifier son engagement financier, la rentabilité de la solution retenue doit être avérée

III.4.1. Calcul du coût de jaugeage

Le coût de l'opération de jaugeage : 1.000.000, 00DA/op 7315.25 \$/op

Tableau III. 7 Coût des opérations de jaugeage par puits.

Les puits	Années	Nombres de jaugeage	coût en DA	coût en\$
ERAA1	2020	09	9.000.000,00	65837.27
	2021	08	8.000.000,00	51206.76
	2022	05	5.000.000,00	36576.26
	2023	03	3.000.000,00	21945.76
RDC20	2020	04	4.000.000,00	29261.01
	2021	04	4.000.000,00	29261.01
	2022	03	3.000.000,00	21945.76
	2023	02	2.000.000,00	14630.50
OMKZ15	2020	08	8.000.000,00	51206.76
	2021	08	8.000.000,00	51206.76
	2022	03	3.000.000,00	21945.76
	2023	01	1.000.000,00	7315.25
	2020	06	6.000.000,00	43891.51
OMJZ633	2021	04	4.000.000,00	29261.01

Chapitre III : Application de l'intelligence artificielle au niveau du puits

	2022	04	4.000.000,00	29261.01
	2023	02	2.000.000,00	14630.50
OMJZ65	2020	07	7.000.000,00	51206.76
	2021	04	4.000.000,00	29261.01
	2022	04	4.000.000,00	29261.01
	2023	01	1.000.000,00	7315.25

A- Calcul du coût de jaugeage après IA

Tableau III. 8 coût des opérations de jaugeage par puits après l'application d'IA.

Les puits	Années	Nombres de jaugeage	coût en DA	coût en\$
ERAA1	2020	07	7.000.000,00	51206.76
	2021	06	6.000.000,00	43891.51
	2022	03	3.000.000,00	21945.76
	2023	01	1.000.000,00	7315.25
RDC20	2020	02	2.000.000,00	14630.50
	2021	02	2.000.000,00	14630.50
	2022	01	1.000.000,00	7315.25
	2023	01	1.000.000,00	7315.25
OMKZ15	2020	06	6.000.000,00	43891.51
	2021	06	6.000.000,00	43891.51
	2022	01	1.000.000,00	7315.25
	2023	01	1.000.000,00	7315.25
OMJZ633	2020	04	4.000.000,00	29261.01

Chapitre III : Application de l'intelligence artificielle au niveau du puits

	2021	02	2.000.000,00	14630.50
	2022	02	2.000.000,00	14630.50
	2023	01	1.000.000,00	7315.25
OMJZ65	2020	05	5.000.000,00	36576.26
	2021	02	2.000.000,00	14630.50
	2022	02	2.000.000,00	14630.50
	2023	01	1.000.000,00	7315.25




Figure III. 34 Histogramme represente la régression des coûts après l'application de l'IA

Conclusion & Recommendation

Conclusion

Pour obtenir une bonne caractérisation des propriétés d'un réservoir pétrolière, il est essentiel d'avoir des données directes de jaugeage. Cependant, ces données ne sont pas toujours disponibles car l'équation de la duse est limitée par les changements des conditions thermodynamique de réservoir. L'augmentation de GOR dans les puits candidats qui peuvent survenir lors de l'opération de jaugeage. Pour combler cette lacune, le défi consiste à trouver un outil efficace et rapide pour estimer avec précision certains paramètres tels que le débit d'huile.

Au cours des deux dernières décennies, de nombreuses méthodes basées sur l'intelligence artificielle ont été proposées pour résoudre des problèmes complexes dans le domaine de l'ingénierie pétroliers.

L'objectif de cette étude se focalise sur les reconstitutions des data de jaugeage en utilisant plusieurs techniques de l'intelligence artificielle à l'aide de historique de jaugeage. Les puits (ERAA1, RDC20, OMJZK15, OMJZ65, OMJZ663,) ont été pris comme exemple d'application.

Les principaux résultats de cette étude peuvent se résumer comme suit :

1. La méthode régression linéaire simple donne un débit estimé plus ou moins grand que le débit mesuré par le jaugeage.
2. La méthode de régression linéaire multiple permet d'obtenir un débit estimé plus proche que le débit mesuré par le jaugeage.
3. La méthode du réseau de neurone artificielle simple et multiple dans des résultats moyennement fiable

Les résultats de cette étude confirment l'efficacité des outils de l'intelligence artificielle pour la prédiction des paramètres des réservoirs y compris ceux hétérogènes avec des performances notables ce qui permet un gain de temps d'une part et rentabilité économique d'autre part, car elle minimise les frais du jaugeage.

Recommandations

D'après les résultats obtenus les recommandations suivantes peuvent être proposées :

- L'application de la différente méthode de l'intelligence artificielle nécessite des scenarios complets ainsi que les profils de production des puits des zones d'étude.
- La précision de débit de gaz lift doit être déterminer pour les puits activées par gaz lift afin d'appliquer la méthode la plus convenable de IA.
- L'utilisation de la méthode RLM pour la détermination des données similaires aux données de jaugeage.
- L'équation de la duse est limitée pour les puits éruptifs.

REFERENCES

- A. J. (1991). *Outline for a theory of intelligence*. *IEEE Trans. Systems, Man and Cybernetics*, .
- Adibifard, M., Tabatabaei-Nejad., & S. A. R. . (2014). , . Artificial Neural Network (ANN) to estimate reservoir parameters in Naturally Fractured Reservoirs using well test data. *Journal of Petroleum Science and Engineering*.
- Ahmadi, M. C. (2018.). *Development of machine learning methods for estimating permeability and porosity of oil reservoirs via petro-physical logs*, *Petroleum*.
- Ameur-Zaimeche, O. Z. (2014). Modélisation et reconstitution des facies non carottés à l'aide des méthodes a base des Réseaux de Neurones Artificiels et Cluster Analysis, cas du réservoir Trias Argileux Gréseux inférie.
- Ameur-Zaimeche, O. Z. (2014). Use of Cluster Analysis method in log's data processing: prediction and rebuilding of lithologic facies. International Conference on Environmental Science and Geoscience .
- Bouchon-Meunier, B. (1995). La logique floue et applications.
- GAsmi. (2013). *Thèse de master « utilisation de Red-Eye MP en well testing par l mesure de water-cut et la comparaison avec le séparateur »*.
- Hamza., & Mr. MEDDI. (2017). *Thèse de l'institut algérien du pétrole Projet professionnel de fin de formation Pour l'obtention du diplôme d'ingénieur spécialisé en Production des hydrocarbures*.
- Haykin, S. (1999). *Neural Network: A Comprehensive Fondation*. (837 pp).
- M.T.HAMMOUDI, M. .: (2004). *Thèse de master « fracturation hydraulique »*.
- MORANDAT, F. (s.d.). *These de doctorat: Contribution à l'efficacité de la programmation par objets évaluation des implémentation de l'héritage multiple en typage statique*.
- RAFIK, B. (s.d.). *these THESE de DOCTORAT: Prédiction des Paramètres Physiques des Couches Pétrolifères par Analyse des Réseaux de Neurones et Analyse Faciologique*.
- Sahoune, M. (2019). *Thèse de master « ETUDE ET CHOIX DE CANDIDATURE FRACTURATION HYDRAULIQUE -*
- Sonatrach . (s.d.). *Documents de la département de production* .
- Sonatrach. (s.d.). *Documentation de la département d'exploration* .
- Widrow, B., & Hoff, M.E. (1960). Adaptive switching circuits. IRE WESCON Convention Record.
- Ziamech, A. (2021). *MODÉLISATION GÉOLOGIQUE DES RÉSERVOIRS PÉTROLIERS A L'AIDE DES MÉTHODES DE L'INTELLIGENCE ARTIFICIELLE, CAS DU BASSIN DE BERKINE, SUD-EST DE L'ALGÉRIE*. Ouargla.

Annexe

Puits ERRA1

DATE	DUSE	Débit [m³/h]		GOR	Pression [bar]			TEMP [C°]	KPSI	EAU		GasLift			DENST	Unité
		Qh	GAS		PT	PP	PSEP			EAU _{rec}	EAU _{inj}	QGL	PGL _{inj}	PGL _{Res}		
16/4/2023	9	9.69	1791.94	185	87.7	18.3	--	31	.4721	0	0	-	-	-	.798	1440
18/3/2023	9	9.5	1861.39	196	102.5	15.3	16.85	27	.5634	0	0	-	-	-	.797	1440
21/1/2023	9	9.56	2079.09	218	83.5	15.2	15.36	24	.456	0	0	-	-	-	.8	1440
28/12/2022	9	8.25	1807.82	219	90.3	14.7	14.88	32	.571	0	0	-	-	-	.795	1440
21/7/2022	9	6.19	1174.22	190	73.8	25.1	25.38	40	.6218	0	0	-	-	-	.796	1440
14/5/2022	9	8.56	1249.26	146	91.8	32.7	32.63	36	.5598	0	0	-	-	-	.798	1440
13/3/2022	9	8.87	1468.94	166	98.4	29.2	29.31	30	.5789	0	0	-	-	-	.801	1440
23/2/2022	9	8.65	2291.76	265	101.3	26.1	5.74	33	.6112	0	0	-	-	-	.793	1440
23/12/2021	9	10.15	1650.35	163	113.8	24.6	24.84	24	.5854	0	0	-	-	-	.8	1440
21/11/2021	9	10.18	1603.08	157	118.1	31.4	31.97	30	.6056	0	0	-	-	-	.79	1440
30/10/2021	9	10.48	1578.19	151	122.2	33.6	34.21	30	.6083	0	0	-	-	-	.789	1440
9/10/2021	9	7.98	1343.31	168	93.2	25.9	25.49	36	.6099	0	0	-	-	-	.786	1440
8/10/2021	9	8.14	1371.00	168	94.9	26.4	--	--	.6085	0	0	-	-	-	.79	1440
3/8/2021	9	8.6	1938.45	226	110.1	23.9	3.95	40	.6683	0	0	-	-	-	.796	1440
21/4/2021	9	10.58	2241.85	212	104.5	23.7	--	31	.5154	0	0	-	-	-	.815	Vx40
16/2/2021	9	9.92	2087.00	210	109.5	23.2	--	15	.5759	0	0	-	-	-	.819	Vx40
8/12/2020	9	11.86	1878.00	158	130.4	24.5	--	--	.5742	0	0	-	-	-	-	1440
9/10/2020	9	12.08	1841.88	152	132.8	19.4	19.71	30	.574	0	0	-	-	-	.8	1440
5/10/2020	9	12.28	1818.58	148	133.9	22.4	22.8	31	.569	0	0	-	-	-	.794	1440
27/7/2020	9	11.9	1473.64	124	142.5	24.5	24.72	41	.6251	0	0	-	-	-	.79	1440
25/6/2020	9	12.49	1933.55	155	143.5	22.5	22.23	38	.5996	0	0	-	-	-	.79	1440
26/5/2020	9	12.04	1776.97	148	142.1	28.2	28.67	31	.6158	0	0	-	-	-	.796	1440
12/3/2020	9	11.04	1699.93	154	131.4	25	25.46	29	.6215	0	0	-	-	-	.792	1440
10/2/2020	9	11.68	1670.54	143	133.1	22	21.41	27	.5948	0	0	-	-	-	.793	1440
7/1/2020	9	11.98	2326.80	194	129.6	20.4	20.39	25	.5648	0	0	-	-	-	.798	1440
4/12/2019	9	14.1	1842.76	131	170.7	33.5	34.01	26	.6319	0	0	-	-	-	.796	1440
13/11/2019	9	10.87	1321.82	122	106.6	34.4	34.93	26	.5115	0	0	-	-	-	.804	1440
26/9/2019	9	12.47	1755.31	141	119.4	31.2	31.64	37	.4997	0	0	-	-	-	.792	1440

23/9/2019	9.53	16.31	2217.96	136	98.6	32.8	33.26	39	.3499	0	0	-	-	-	.792	1440
3/9/2019	9.53	13.22	1696.43	128	124.3	32.2	32.63	33	.5439	0	0	-	-	-	.796	1440
17/7/2019	9.53	13.75	1761.69	128	127.9	34.4	34.67	37	.5384	0	0	-	-	-	.792	1440
23/6/2019	9.53	13.57	1699.19	125	128.9	31.4	31.61	39	.5496	0	0	-	-	-	.79	1440
3/6/2019	9.53	13.32	1877.59	141	129.4	30.1	30.55	35	.5622	0	0	-	-	-	.792	1440
2/6/2019	9.53	13.59	1875.21	138	128.2	30.9	31.35	32	.546	0	0	-	-	-	.794	1440
7/5/2019	9.53	13.38	1933.66	144	103.9	29.1	29.5	27	.4491	0	0	-	-	-	.798	1440
14/4/2019	9.53	13.52	1895.83	140	133.1	31.8	32.02	33	.5695	0	0	-	-	-	.794	1440
13/4/2019	9.53	13.64	1838.43	135	132.2	30.8	31.2	32	.561	0	0	-	-	-	.794	1440
16/2/2019	9.53	14.53	1875.73	129	134.8	31.9	32.22	29	.5369	0	0	-	-	-	.796	1440
28/1/2019	9.53	14.65	1762.32	120	136.7	31	30.59	8	.5399	0	0	-	-	-	.798	1440
27/1/2019	9.53	14.77	1868.86	127	137	31.7	31.61	12	.5367	0	0	-	-	-	.788	1440
5/1/2019	9.53	14.52	1855.36	128	140.3	35	35.46	24	.5588	0	0	-	-	-	.796	1440
4/1/2019	9.53	14.2	2011.00	142	137.2	31.2	31.39	28	.5592	0	0	-	-	-	.798	1440
18/12/2018	9.53	14.47	2053.54	142	142.4	30.4	30.59	33	.5692	0	0	-	-	-	.792	1440
17/12/2018	9.53	14.81	2076.24	140	142.3	30.7	31.1	30	.556	0	0	-	-	-	.796	1440
26/11/2018	9.53	16.98	2029.67	120	141.2	28.8	28.55	30	.4812	23	0	-	-	-	.794	1440
25/11/2018	9.53	14.96	2032.74	136	143.5	28.4	28.55	30	.5549	0	0	-	-	-	.794	1440
6/11/2018	9.53	15.34	2099.75	137	143.9	29.3	29.58	30	.5426	0	0	-	-	-	.792	1440
5/11/2018	9.53	15.28	1999.78	131	143.4	31.2	30.95	29	.543	0	0	-	-	-	.794	1440
10/10/2018	9.53	14.95	1989.60	133	145.6	27.9	27.53	39	.5636	0	0	-	-	-	.79	1440
8/10/2018	9.53	15.13	1998.45	132	146.6	28.1	27.53	36	.5607	0	0	-	-	-	.794	1440
17/9/2018	9.53	14.86	2186.27	147	146.4	30.8	31.2	40	.5698	0	0	-	-	-	.792	1440
1/9/2018	9.53	14.92	2100.16	141	147.4	28.5	28.85	37	.5714	0	0	-	-	-	.792	1440
31/8/2018	9.53	14.93	2142.43	144	148.8	29.3	29.87	37	.5769	0	0	-	-	-	.794	1440
10/8/2018	9.53	15.76	2111.96	134	152.2	28.8	28.55	44	.5588	0	0	-	-	-	.788	1440
9/8/2018	9.53	15.41	2104.03	137	154.8	30	29.57	40	.5811	0	0	-	-	-	.792	1440
6/7/2018	9.53	15.9	2376.65	149	161	28	28.04	40	.5859	0	0	-	-	-	.792	1440
5/7/2018	9.53	16.47	2239.21	136	160.9	30.2	29.88	45	.5653	0	0	-	-	-	.788	1440

24/6/2018	9.53	15.95	2395.90	150	160.8	28.8	28.55	39	.5835	0	0	-	-	-	.792	1440
23/6/2018	9.53	16.31	2255.35	138	160.5	27.2	26.51	38	.5695	0	0	-	-	-	.792	1440
13/6/2018	9.53	16.17	2379.66	147	159.3	27.4	27.68	32	.5703	0	0	-	-	-	.798	1440
11/6/2018	9.53	16.16	2280.26	141	157.7	26	25.49	38	.5646	0	0	-	-	-	.792	1440
2/6/2018	9.53	15.3	2294.56	150	151.5	27.2	27.02	39	.5731	0	0	-	-	-	.792	1440
1/6/2018	9.53	15.41	2378.11	154	151	27.8	27.53	33	.5671	0	0	-	-	-	.794	1440
7/5/2018	9.53	14.16	2032.68	144	143.7	29.5	29.27	38		0	0	-	-	-	.794	1440
6/5/2018	9.53	14.15	2105.67	149	143.4	27.5	29.16	40	.5864	0	0	-	-	-	.794	1440
25/4/2018	9.53	14.58	2364.54	162	146.2	28.3	27.53	33	.5872	0	0	-	-	-	.8	1440
15/4/2018	9.53	16.56	2209.95	133	127.3	29	28.55	33	.4446	0	0	-	-	-	.8	1440
23/3/2018	8.73125	18.15	2628.24	145	126.5	34	33.65	29	.3444	0	0	-	-	-	.804	1440
6/3/2018	9.5	19.99	2785.64	139	111.6	28.8	29.28	32	.3211	0	0	-	-	-	.798	1440
4/3/2018	9.5	21.07	3147.58	149	112.8	26.8	26.51	35	.3079	0	0	-	-	-	.794	1440
26/2/2018	9.5	18.08	2876.55	159	134.1	24.5	24.47	37	.4267	0	0	-	-	-	.792	1440
144.8	23.9	15.35	2188.88	143			23.45	34	.5428	0	0	-	-	-	.792	1440
158.2	23.5	13.85	2119.82	153			23.45	32	.6571	0	0	-	-	-	.794	1440
18/2/2018	9.5	16.53	2189.10	132	134.9	23.9	23.45	34	.4695	0	0	-	-	-	.794	1440
1/2/2018	9.5	16.17	2328.87	144	143.4	30	30.67	30	.5102	0	0	-	-	-	.802	1440
31/1/2018	9	16.26	2260.24	139	142.6	27.9	29.19	33	.4578	0	0	-	-	-	.796	1440
9/1/2018	9.5	17.81	2710.57	152	132	28.3	28.81	32	.4265	0	0	-	-	-	.796	1440
25/12/2017	9.5	16.94	2353.87	139	136.6	28.1	27.53	36	.4639	0	0	-	-	-	.794	-
17/12/2017	9.5	18.51	2682.53	145	126.8	31.4	32.01	27	.3941	0	0	-	-	-	.804	-
16/12/2017	9.5	17.15	2391.60	139	137.7	28.1	28.04	32	.462	0	0	-	-	-	.8	-
3/12/2017	9.5	21.63	3066.53	142	125	30.6	30.96	31	.3325	0	0	-	-	-	.802	-
1/12/2017	9.5	14.62	646.72	44	185.4	34.4	34.99	31	.7299	0	0	-	-	-	.8	-
14/11/2017	9.5	20.67	3109.76	150	117.8	31	30.59	31	.328	0	0	-	-	-	.798	-
12/11/2017	9.5	20.93	3290.66	157	118.2	29	29.06	35	.325	0	0	-	-	-	.794	-
26/10/2017	9.5	19.06	2507.20	132	141.4	32.7	31.61	34	.4269	0	0	-	-	-	.794	-
10/10/2017	9.5	19.07	2725.15	143	153.5	30.8	31.16	36	.463	0	0	-	-	-	.794	-

7/10/2017	9.5	18.76	2675.76	143	131.6	31.6	31.82	40	.4035	0	0	-	-	-	.79	-
19/9/2017	9.5	17.83	2498.77	140	144	31.6	30.69	35	.4648	0	0	-	-	-	.796	-
18/9/2017	9.5	18.27	2660.64	146	139	32.3	31.1	35	.4376	0	0	-	-	-	.796	-
3/9/2017	9.5	17.03	1099.76	65	155.1	30.2	30.69	34	.524	0	0	-	-	-	.796	-
2/9/2017	9.5	17.19	2525.05	147	154.7	30.1	30.59	40	.5178	0	0	-	-	-	.792	-
16/8/2017	9.5	16.37	2467.18	151	167.5	30.9	31.63	36	.5886	0	0	-	-	-	.794	-
15/8/2017	9.5	16.69	2500.66	150	162.9	32	32.15	41	.5614	0	0	-	-	-	.792	-
14/8/2017	9.5	17.44	2501.57	143	162.2	29.4	30.89	37	.5352	0	0	-	-	-	.794	-
31/7/2017	9.5	18.65	2569.93	138	155.5	31.2	31.78	40	.4797	0	0	-	-	-	.792	-
30/7/2017	9.5	17.2	2486.64	145	177.9	32	32.57	39	.5949	0	0	-	-	-	.792	-
19/7/2017	9.53	17.18	2332.45	136	171.8	33.3	33.91	37	.5786	0	0	-	-	-	.798	-
29/6/2017	9.53	20.43	2890.45	141	148.3	36.4	36.99	41	.4201	0	0	-	-	-	.792	-
17/6/2017	9.53	17.66	2439.56	138	132.5	33.3	35.18	37	.4339	0	0	-	-	-	.792	-
16/6/2017	9.53	17.2	2501.11	145	135.3	34	35.96	40	.4552	0	0	-	-	-	.79	-
12/6/2017	12.7	16.23	2515.30	155	139	34.8	35.41	38	.8311	0	0	-	-	-	.79	-
11/6/2017	12.7	16.98	2524.53	149	136.2	34.5	35.07	39	.7782	0	0	-	-	-	.788	-
6/6/2017	12.7	17.96	2511.66	140	144.2	34.1	34.69	34	.7788	0	0	-	-	-	.8	-
4/6/2017	12.7	17.97	2546.43	142	145.2	34	34.54	35	.784	0	0	-	-	-	.79	-
30/5/2017	12.7	20.1	2816.68	140	131.6	32.2	34.17	34	.6352	0	0	-	-	-	.8	-
29/5/2017	12.7	19.84	2765.03	139	137.9	34	34.57	33	.6741	0	0	-	-	-	.8	-
17/5/2017	12.7	18.14	2381.64	131	152.4	36.4	37.08	32	.8153	0	0	-	-	-	.794	-
12/5/2017	12.7	16.7	2149.48	129	162.9	41.7	42.41	39	.9467	0	0	-	-	-	.794	-
2/5/2017	12.7	19.13	2563.11	134	136.4	40.6	41.32	28	.6917	0	0	-	-	-	.806	-
18/4/2017	12.7	11.6	1358.32	117	210	42.8	43.5	29	1.7566	0	0	-	-	-	.804	-
17/4/2017	12.7	12.02	1528.13	127	196.8	39.8	40.5	37	1.5881	0	0	-	-	-	.798	-
7/4/2017	12.7	20.74	2608.12	126	121.9	39.4	40.14	30	.5701	0	0	-	-	-	.802	-
2/4/2017	12.7	16.66	1945.39	117	150.7	38.7	38.75	29	.878	0	0	-	-	-	.798	-
29/3/2017	12.7	18.27	2316.02	127	128.2	38.5	37.73	32	.6807	0	0	-	-	-	.796	-
28/3/2017	12.7	16.61	1842.20	111	135.1	34	34.57	31	.7891	0	0	-	-	-	.8	-

18/3/2017	12.7	15.93	1946.93	122	106.1	39.8	40.55	28	.6462	0	0	-	-	-	.802	-
1/3/2017	12.7	22.43	3385.71	151	104	41.1	41.79	34	.4499	0	0	-	-	-	.79	-
3/2/2017	12.7	22.91	2078.33	91	118.6	38.1	37.73	26	.5022	0	0	-	-	-	.804	-
18/1/2017	12.7	24.33	3092.59	127	123.5	39.2	39.75	24	.4926	0	0	-	-	-	.806	1440
13/1/2017	12.7	24.92	3077.74	124	115.1	43.8	44.44	32	.4481	0	0	-	-	-	.802	1440
27/12/2016	12.7	20.87	2490.24	119	161.9	38.4	38.99	30	.7523	0	0	-	-	-	.8	1440
26/12/2016	12.7	21.3	2539.86	119	161.7	42	42.56	32	.7363	0	0	-	-	-	.798	1440
25/12/2016	12.7	21.01	2490.81	119	161	39.9	40.51	27	.7434	0	0	-	-	-	.8	1440
10/12/2016	12.7	21.93	2706.03	123	145	37.9	37.73	26	.6414	0	0	-	-	-	.804	1440
8/11/2016	12.7	24.06	3090.17	128	161.1	39.7	40.26	33	.6498	0	0	-	-	-	.8	1440
7/11/2016	12.7	23.85	3080.22	129	162.5	42.4	43.03	34	.661	0	0	-	-	-	.8	1440
6/11/2016	12.7	23.7	3072.68	130	160	44.1	44.78	40	.6549	0	0	-	-	-	.798	1440
20/10/2016	12.7	25.07	3175.29	127	162.8	42.9	45.48	36	.6299	0	0	-	-	-	.808	1440
9/10/2016	12.7	25.18	3585.44	142	168	45.1	--	36	.6472	0	0	-	-	-	.804	1440
10/9/2016	9.53	16.91	1998.44	118	221.3	43.1	43.72	34	.7572	0	0	-	-	-	.802	1440
9/9/2016	8.7	16.71	1929.89	115	215.9	44.7	45.28	35	.6343	0	0	-	-	-	.802	1440
2/9/2016	9.53	14.92	1778.68	119	231.9	42	42.53	31	.8995	0	0	-	-	-	.804	1440
1/9/2016	9.53	14.91	1762.45	118	232.5	40.9	41.53	32	.9022	0	0	-	-	-	.804	1440
24/8/2016	9.53	15.88	1823.06	115	233.5	42.5	42.32	29	.8508	0	0	-	-	-	.804	1440
23/8/2016	9.53	15.79	1872.08	119	232.5	42.3	41.5	29	.8518	0	0	-	-	-	.804	1440
22/8/2016	9.53	16.05	1922.30	120	232.5	42.5	42.11	31	.8379	0	0	-	-	-	.804	1440
14/8/2016	9.53	15.82	1945.29	123	237.8	42.9	42.93	30	.8695	0	0	-	-	-	.806	1440
13/8/2016	8.7	16.45	1917.22	117	238	41.6	41.81	30	.7105	0	0	-	-	-	.804	1440
12/8/2016	8.7	17.69	2002.96	113	230.2	41.5	41.81	28	.639	0	0	-	-	-	.806	1440
10/8/2016	8.7	18.1	2133.19	118	213.4	44.4	44.87	35	.5791	0	0	-	-	-	.804	1440

Puits OMJZ633

DATE	DUSE	Débit [m³/h]		GOR	Pression [bar]			TEMP [C°]	KPSI	EAU		GasLift		
		Qh	GAS		PT	PP	PSEP			EAU _{rec}	EAU _{inj}	QGL	PGL _{inj}	PGL _{Res}
11/02/2023	16	2.63	1844.01	701	16.5	9.4	--	13	.9229	848	0	-	-	-
31/01/2023	16	2.39	1120.64	468	13.8	10.5	10.31	19	.8338	540	0	15955	58	151
22/11/2022	16	2.98	1615.33	543	16.3	9.8	9.77	21.8	.8056	1010	0	20400	59	135
12/11/2022	16	1.98	1229.30	622	13.5	9.8	9.89	22.6	1.004	920	0	-	57	-
28/05/2022	16	2.87	1738.37	606	19	10.5	4.28	27	.9742	920	0	528	69	143
23/01/2022	16	3.1	3016.12	972	25.5	14.5	13.98	12	1.2092	879	0	24000	65	137
16/12/2021	16	2.58	1284.94	498	16.9	11	4.3	22	.9644	1800	0	3852	-	69
23/08/2021	15	2.76	1026.17	372	24.6	9.9	4.45	32	1.1685	320	0	-	-	-
04/05/2021	15	3.56	1450.46	407	24.9	9.5	9.53	26	.9162	470	0	18960	73	-
23/02/2021	13.5	2.6	1899.71	732	48	10.5	4.3	17	2.0029	0	0	-	-	-
12/12/2020	13.5	3.51	2161.77	616	36.1	12.1	12.08	22	1.1147	520	0	-	-	-
11/12/2020	13.5	3.7	1573.55	425	28.9	10.7	10.89	26	.8457	44	0	20631	-	-
01/09/2020	13.5	.99	1239.12	1250	14.7	10.7	--	34.5	1.6055	0	0	21917	1	-
08/05/2020	13.5	1.65	1639.43	992	16.7	9.2	9.15	27	1.0945	0	0	35904	81	-
17/03/2020	13.5	1.03	3390.19	3301	34.6	13.1	--	31	3.6482	34	0	67992	113	-
27/01/2020	13.5	3.89	1106.01	284	18.4	11	10.95	19	.5125	271.85	0	10282	75	159
05/12/2019	13.5	2.73	1740.17	637	27.2	11.1	--	26	1.0776	807	0	29510	80	-
02/10/2019	13.5	2.63	2117.48	806	32	12.9	12.94	31	1.3197	339	0	42048	92	-

01/10/2019	13.5	1.49	798.37	535	17	11.5	11.57	26	1.2343	0	0	18528	78	-
18/08/2019	13.5	2.66	2009.62	754	32.5	12.9	--	32	1.321	1095	0	27204	112	-
22/12/2018	13.5	2.01	1131.17	564	30.2	11.7	4.49	12	1.6307	0	0	-	-	-
13/09/2018	13.5	1.82	584.69	322	14.4	10.1	9.97	32	.8559	0	0	-	-	-
10/06/2018	13.5	3.02	752.68	249	21.4	11.2	10.71	27	.7675	108.44	0	-	-	-
25/03/2018	13.5	2.79	5506.07	1977	64.1	16.7	--	23	2.4924	0	0	-	-	-
06/11/2017	13.5	3.43	2790.52	815	56.8	12.9	--	7.7	1.7959	69	0	-	-	-
26/07/2017	13.5	2.94	1948.40	663	33	15.3	--	--	1.2159	768	0	-	-	-
19/05/2017	13.5	1.38	938.55	683	20.9	14.8	--	24.44	1.6461	111	0	-	-	-
07/03/2017	13.5	1.32	2149.74	1626	34.2	13.6	13.84	19	2.8046	0	0	-	-	-
27/11/2016	13.5	2.99	3595.39	1203	45	15	3.77	19	1.6304	70	0	-	-	-
24/08/2016	13.5	5.65	1432.70	254	41.2	16.1	15.84	27	.7887	130	0	-	-	-
02/06/2016	13.5	4.47	1677.60	375	37.6	14.7	14.86	31	.9105	500	0	-	-	-
02/02/2016	13.5	4.42	3400.24	769	50	13.5	5.61	10	1.225	470	0	-	-	-
27/01/2016	13.5	1.29	2596.24	2016	34.5	13.1	13.9	10	2.9015	0	0	-	-	-
06/12/2015	13.5	2.38	2210.56	927	33.9	13.5	--	11	1.5399	0	0	-	-	-
07/06/2015	13.5	4.37	2360.99	541	43.8	13.2	13	33	1.0858	510	0	-	-	-
18/03/2015	13.5	2.09	237.51	114	15	13	--	27	.6542	0	0	-	-	-
27/12/2014	13.5	4.01	975.80	244	26	12.9	--	--	.7027	136	0	-	-	-
26/11/2014	13.5	4.9	1092.00	223	28.4	12.3	--	--	.6277	0	0	-	-	-
30/06/2014	14	4.69	2579.40	550	29.1	23.5	--	15	.6766	1293	0	-	-	-
01/10/2013	14	4.48	2084.50	465	31.9	21.6	--	--	.8229	393	0	-	-	-

07/04/2013	14	5.14	2128.09	414	39	23.9	5.1	27	.8771	1800	0	-	-	-
14/10/2012	14	4.97	2841.78	572	30	22	22.43	32	.6986	0	0	-	-	-
25/07/2012	14	4.53	3012.52	665	42	21.1	4.69	32	1.0723	450	0	-	-	-
22/05/2012	14	1.99	2327.76	1171	31.4	27.4	4.69	21	1.5124	0	0	-	-	-
11/08/2011	14	4.91	1892.90	386	32.9	17.6	--	15	.7754	1757	0	-	-	-
17/05/2011	14	5.09	1584.38	311	38	18.7	--	--	.8637	54	0	-	-	-
17/11/2010	14	3.91	1906.57	488	41	17.2	4.69	13	1.2133	0	0	-	-	-
17/08/2010	14	2.46	763.10	310	28.5	14	4.49	31	1.3381	110	0	-	-	-
03/06/2010	14	1.44	544.03	378	34	17.2	3.47	34	2.7288	0	400	-	-	-
06/11/2009	14	2.01	1592.23	794	33	17.6	4.08	12	1.9024	0	0	-	-	-
28/05/2009	14	5.9	983.42	167	25	19	4.89	32	.4849	420	0	-	-	-
13/11/2008	14	2	2119.56	1060	26	18.4	4.28	15	1.5031	0	0	-	-	-
22/07/2008	13.06	4.15	476.32	115	36	19	5	29	.886	220	0	-	-	-
22/04/2008	13.06	1.8	99.81	55	19.8	16.2	5.1	14	1.0404	0	0	-	-	-
03/10/2007	13.06	4.74	112.69	24	19.8	17.5	3.87	27	.3411	250	230	-	-	-
12/05/2007	13.06	3.17	383.55	121	19	17	3.37	24	.4718	220	100	-	-	-
17/03/2007	13.06	2.4	70.38	29	20	16.5	3.77	15	.7805	85	570	-	-	-
28/09/2006	13.06	2.37	295.37	124	18.5	18.1	5	26	.3041	0	100	-	-	-
22/03/2005	12.7	2.4	281.42	117	22.9	17.6	3.77	16	.9113	0	0	-	-	-
27/11/2004	12.7	3.6	373.63	104	24	14	4.89	--	.6468	0	0	-	-	-
10/07/2004	12.7	2.98	372.34	125	33	13.3	6.53	22	1.0742	0	0	-	-	-
27/05/2004	12.7	6.72	898.17	112	28.1		3.4	42	.406	0	0	-	-	-

Puits omjz65

DATE	DUSE	Débit [m³/h]		GOR	Pression [bar]			TEMP [C°]	KPSI	EAU		GasLift
		Qh	GAS		PT	PP	PSEP			EAU _{rec}	EAU _{inj}	QGL
13/05/2023	16	1.83	1238.17	675	15	11.3	11.43	27.4	1.1973	0	0	21036
31/12/2022	16	1.83	941.81	514	14.9	12.5	12.24	16	1.0718	0	0	21840
15/10/2022	16	.88	1040.04	1179	14.3	12.3	--	25	2.0402	0	0	20496
18/03/2022	16	1.52	1238.17	814	17.3	13.4	13.43	13	1.6392	0	0	24336
17/03/2022	16	1.65	867.19	527	15.6	12.7	12.76	20	1.3017	0	0	16464
27/12/2021	16	1.99	758.33	380	11.7	9.2	7.53	18	.8255	0	0	-
05/10/2021	14	2.71	1129.28	417	16.8	11.2	10.9	25	.7177	0	0	20640
08/06/2021	14	2.79	878.79	314	17.4	12.9	12.77	28	.7187	0	0	16435
12/05/2021	14	2.34	1606.53	686	20.9	10.5	10.54	23	1.0338	0	0	-
11/12/2020	14	2.56	1310.78	512	17.8	11.6	11.51	16	.8042	0	0	-
22/07/2020	14	2.46	712.28	289	13.1	9.7	9.54	33	.6143	0	0	13296
14/07/2020	14	2.38	1045.47	439	15.1	10.1	9.79	29	.7331	0	0	18384
18/05/2020	14	1.71	1900.03	1112	22.2	9.7	9.6	26	1.5008	0	0	40176
02/04/2020	14	2.58	1257.38	486	19.5	11.5	11.48	16	.8731	0	0	26112
06/02/2020	14	3.15	1626.00	516	22.5	14.1	13.97	9	.8259	0	0	30677
04/02/2020	14	2.88	1532.93	531	22.3	11.9	11.85	16	.8938	0	0	33120
12/12/2019	14	2.97	1877.48	633	24.1	13.2	12.75	21	.9395	0	0	32314
24/11/2019	14	2.72	1461.03	538	23.1	15.2	15.29	18	.983	0	0	-
28/08/2019	14	3.48	1293.77	372	22.1	16.5	16.32	33	.7343	0	0	24878
03/06/2019	14	3.18	1410.30	444	20.6	13.5	--	28.9	.7497	0	0	-
07/03/2019	14	3.37	1998.44	593	27.6	12.7	--	25	.9474	0	0	-
24/12/2018	14	3.2	2047.80	640	26.3	11.3	4.23	15	.9484	0	0	-
19/12/2018	14	3.52	1942.05	552	25.3	15	14.82	15.5	.8324	0	0	-
14/11/2018	14	3.52	1760.06	500	23.3	12.1	--	14	.7646	0	0	-
16/08/2018	14	3.88	1233.27	317	22.7	15.1	15.21	25	.6768	0	0	26400
15/08/2018	14	3.63	1807.07	498	26.3	18	17.94	29	.8393	0	0	34752
15/07/2018	14	3.22	1071.09	333	18.7	14.5	--	37	.6573	0	0	-
24/04/2017	9.53	4.78	582.32	122	42.8	5	7.34	29	.5184	0	0	-

Puits RDC 20

DATE	DUSE	Débit [m³/h]		GOR	Pression [bar]			TEMP [C°]	KPSI	EAU		GasLift
		Qh	GAS		PT	PP	PSEP			EAU _{rec}	EAU _{inj}	
11/05/2023	10	3.92	365.63	93	41.9	11.1	11.01	37.9	.6748	0	0	-
15/03/2023	10	4.29	653.47	152	43	11.3	11.16	26	.6317	0	0	-
28/11/2022	10	4.22	712.27	169	43.7	10.9	10.96	22	.6534	0	0	-
28/07/2022	10	4.03	891.15	221	44.8	10.9	9.59	37	.701	0	0	-
13/02/2022	10	4.38	569.05	130	41.4	9.4	26.51	20	.5968	0	0	-
25/11/2021	10	5.16	1132.07	219	55.1	10.7	4.21	23	.6737	0	0	-
04/09/2021	10	5.49	619.91	113	55.9	10.6	4.28	36	.6427	0	0	-
28/04/2021	10	4.74	308.65	65	57.4	10.2	4.3	29	.7642	0	0	-
23/01/2021	9	5.34	1085.31	203	54.2	10	4.28	26	.5289	0	0	-
28/09/2020	9	6.31	439.37	70	55	11.5	3.5	30	.4551	0	0	-
06/06/2020	9	6.68	1076.09	161	60	14	4.28	34	.4689	0	0	-
21/03/2020	9	6.48	1112.00	172	66	11.8	4.28	34	.5315	0	0	-
04/12/2019	9	7.38	1441.62	195	68.1	12.9	4.12	18	.4819	0	0	-
05/11/2019	9	7.53	1489.16	198	68.2	12.2	4.69	25	.4728	0	0	-
16/09/2019	9	7.57	1649.47	218	71	14	13.77	33	.4893	0	0	-
29/07/2019	9	8.11	1510.09	186	74.5	17	16.32	34	.4793	0	0	-
01/06/2019	9	8.93	1627.19	182	80.1	16.1	16.16	32	.4682	0	0	-
01/04/2019	9	8.17	1599.70	196	78.8	13.9	13.81	32	.5036	0	0	-
27/10/2018	9	8.03	1517.52	189	76.7	15.2	15.3	35	.4984	0	0	-
23/06/2018	9	10.35	2042.20	197	93.6	14.8	14.28	33	.472	0	0	-
11/02/2018	9	12.2	2354.85	193	109.6	13.4	13.01	52.78	.469	0	0	-
06/11/2017	9	9.88	1872.94	190	95.3	18.1	17.34	28	.5037	0	0	-
19/08/2017	9	9.48	1643.00	173	101.9	24.2	24.32	35	.5613	0	0	-
01/06/2017	9	9.88	1651.77	167	118.1	20.6	20.45	33	.6243	0	0	-
12/05/2017	9	10.88	1893.72	174	125.8	19.4	19.03	32	.6035	0	0	-
21/04/2017	9	11.58	2153.57	186	135.5	15.7	15.07	29	.6107	0	0	-
12/11/2016	9.53	13.87	4401.77	317	149	8	6.12	32	.6215	0	0	-
24/09/2016	9.53	5.13	383.18	75	40	10	6.32	29	.451	0	0	-

Puits omkz15

DATE	DUSE	Débit [m³/h]			GOR	Pression [bar]			TEMP [C°]	KPSI	EAU	
		Qh	GAS			PT	PP	PSEP			EAU _{rec}	EAU _{inj}
02/03/2023	16	3.43	1663.60	484	16.5	11	11.11	19.2	.7065	47	0	
04/11/2022	16	3.2	1098.92	343	14.7	11	--	23	.671	0	0	
23/05/2022	16	3.25	1006.88	310	14.5	10.7	11.15	35	.6563	400	0	
07/02/2022	16	3.17	1424.65	449	17.6	11.7	11.77	14	.8138	0	0	
18/12/2021	16	4	1314.40	329	15.8	10.7	5.2	16	.5817	0	0	
12/12/2021	16	1.19	1895.55	1589	14.4	9.7	9.79	30.1	1.7744	0	0	
02/09/2021	16	3.55	1273.96	358	16.3	10.9	10.73	36	.6729	139	0	
30/08/2021	16	3.47	1195.76	345	15.6	10.7	10.47	29	.6596	134	0	
14/05/2021	16	1.37	1300.93	952	12.5	8.6	--	26.4	1.3448	0	0	
24/03/2021	16	2.85	1268.01	444	15.5	11	10.9	20	.7989	0	0	
22/01/2021	16	2.84	1650.97	582	15.8	9.3	9.15	16	.8188	0	0	
21/01/2021	16	4.1	1361.36	332	14.9	9.6	9.45	20	.5343	0	0	
18/12/2020	16	4.08	1477.70	362	16.4	9.1	9.61	19	.5911	0	0	
20/11/2020	16	3.97	1315.59	331	15.5	10.5	10.56	21	.5743	0	0	
14/07/2020	16	2.96	1804.83	610	14.4	8.7	8.63	31	.7134	0	0	
24/06/2020	16	.74	1122.06	1513	11.8	9.1	--	34	2.2956	0	0	
29/04/2020	16	2.95	1766.45	598	17.7	11.9	--	31	.8809	0	0	
11/03/2020	16	3.71	1974.06	532	19.4	11.7	--	18	.7687	110	0	
24/02/2020	16	2.33	1327.46	570	16.2	11.6	11.75	20	1.0229	0	0	
14/02/2020	16	1.04	1341.88	1287	14.4	11.7	--	30	1.901	0	0	
01/12/2019	16	2.46	1602.02	651	18.5	11.6	11.17	14	1.1028	0	0	
28/09/2019	16	4.4	1985.89	451	22.1	11.3	11.15	29	.7382	0	0	
22/07/2019	16	2.88	1508.82	524	16.1	11.1	--	33	.8229	0	0	
03/06/2019	16	4.28	2026.52	474	21	11.3	--	26	.7215	0	0	
16/03/2019	16	3.09	1715.46	555	22.7	9.6	9.18	20	1.08	0	0	
11/03/2019	16	1.7	2746.95	1614	24.9	11.8	--	20	2.1513	0	0	
26/12/2018	16	3.43	2509.58	731	26.9	11.7	11.55	12	1.1506	0	0	
29/09/2018	16	4.75	1293.39	273	17.2	11.5	--	21	.5329	0	0	

02/09/2018	16	2.81	1152.51	410	16.2	11.7	11.6	26	.8461	0	0	
01/09/2018	16	3.99	2055.95	515	25.1	12.2	12.11	26	.9231	0	0	
04/07/2018	16	3.54	2454.06	693	28.8	14.1	13.77	26	1.1962	0	0	
04/04/2018	16	3.22	1682.83	523	21.4	13.2	12.75	26	.977	0	0	
17/11/2017	16	4.46	2303.30	516	25.8	11.8	--	--	.8506	0	0	
14/08/2017	16	4.2	3126.10	744	34.4	14.5	--	--	1.2043	0	0	
18/05/2017	16	3.19	4711.46	1477	46.5	17.9	17.97	23	2.1406	0	0	
12/03/2017	16	5.03	2179.23	433		29	14	14.17	20	.8475	0	0
30/01/2017	16	4.33	2334.42	539	25.8	13.4	--		14	.8757	0	0
29/12/2016	16		3222.08	3215	23.9	16.2	--		18	3.5061	0	0
29/10/2016	16	4.99	1999.40	401	24.4	14.4	--	25.6	.7191	0	0	
29/09/2016	16	3.56	3003.75	844	32.3	17.4	16.83		18	1.3345	60	0
19/09/2016	16	1.72	2111.21	1229	23.1		15	--	25	1.9777	0	0
12/05/2016	16	5.27	1410.69	268	22.4	15.3	--		34	.6256	0	0
15/03/2016	16	4.56	3074.09	675		32	16	5.1	25	1.0327	0	0
22/01/2016	16	5.8	2492.40	430	29.4	15.7	--	--	.7453	0	0	
12/10/2015	16	5.28	1840.59	349		29	16.2	16.52	30	.8075	0	0
04/09/2015	16	3.29	2231.46	679	25.5		15	--	32	1.1405	0	0
10/06/2015	16	5.16	2115.46	410		27	14	5.91	23	.7694	0	0
03/01/2015	16	6.56	2313.31	352	34.1	15.6	15.5		17	.7639	0	0
21/09/2014	16	6.56	1654.85	252	22.9	15.2	15.3		34	.5129	0	0
19/09/2014	16	6.14	1631.60	266	25.6	13.5	--	--	.6126	0	0	
29/06/2014	16	4.06	980.08	241	28.7	25.5	--		30	.82	0	0
18/02/2014	16	6.37	3490.64	548	40.3	18.6	--		26	.9308	0	0
28/11/2013	16	6.57	1827.40	278		24	14.3	4.28	19	.5367	0	0
01/09/2013	16	7.46	1814.43	243	30.6	17.9	17.54		32	.6035	0	0
05/06/2013	16	6.55	1493.30	228		25	16.8	--	--	.5611	0	0
31/03/2013	16	6.33	2204.57	348		33	22.5	4.18	26	.766	0	0
02/03/2013	16		1954.70	279	29.8		19	--	--	.6259	0	0
01/11/2012	16	7.91	3566.10	451	40.5	22.4	--		15	.7531	0	0

12/08/2012	16	7.29	1841.20	253	30.7	19.8	--	15	.6196	0	0	
25/03/2012	16	9.09	3248.81	357	45.6	19.8	5.1	27	.7373	0	0	
19/02/2012	16	9.51	3556.37	374	26.5	19.2	6.83	18	.4099	0	0	
25/08/2011	16	8.99	1923.35	214	36.8	17.9	19.41	31	.6019	0	0	
29/05/2011	16	9.58	1777.94	186	36.5	21.9	21.92	34	.5601	0	0	
12/02/2011	16	8.39	1880.76	224	32.2	16.6	--	--	.5642	0	0	
16/09/2010	16	8.11	1302.80	161	26.4		17	--	.4786	0	0	
03/08/2010	16	8.97	2017.70	225	33.7		19	--	.5522	0	0	
28/04/2010	16	11.18	3050.30	273	44.8	20.2	--	15	.5894	0	0	
16/12/2009	16	5.97	1195.98	200	21.8	18.6	4.89	21	.4672	0	0	
29/10/2009	16	11.46	2560.73	224	45.7	20.7	5.1	28	.5866	0	0	
22/09/2009	13	4.77	497.28	104	25.5		20	4.28	22	.5243	0	0
13/06/2009	13	5.14	486.58	95	26.5		21	4.28	28	.5013	0	0
25/04/2009	13	5.35	478.95	90		37	20	4.49	25	.6999	0	0
22/03/2009	13.89	5.55	450.73	81		39	16.8	4.28	24	.8008	0	0
29/11/2008	13.89	5.15	432.15	84	26.8	18.5	5.71	26	.5937	0	0	
30/08/2008	13.89	6.32	703.69	111	28.7		20	5.91	28	.5175	0	0
27/05/2008	13.89	3.18	197.96	62		26	19.8	2.86	23	.9234	0	0
04/02/2008	13.89	3	228.75	76	26.8	20.2	5.51	16	1.0142	0	0	
29/09/2007	13.89	2.78	160.27	58		26	18	3.26	23	1.0668	0	0
03/05/2007	13.89	3.61	397.38	110	27.4	15.1	4.69	13	.8659	0	0	
13/11/2006	13.89	4.98	405.64	81	30.2	17.8	2.45	19	.6911	0	0	
13/06/2006	13.89	4.37	524.89	120	36.1	16.8	4.28	22	.9415	0	0	
06/06/2006	13.89	2.78	214.03	77	35.2	17.4	4.89	23	1.444	0	0	
01/03/2006	13.89	4.41	371.19	84	56.1	15.5	2.65	13	1.4505	0	0	
23/01/2006	12.7	11.22	2065.29	184	58.7		1	4.28	32	.5077	0	0

Exemple d'application d'IA au niveau de puits ERAA1 sur le logiciel Visual Studio Code et la langage Python Puits ERAA1

Basic regression: Predict Oil Rate

```
import matplotlib.pyplot as plt
import numpy as np
import pandas as pd
import seaborn as sns

# Make NumPy printouts easier to read.
np.set_printoptions(precision=3, suppress=True)
```

```
import tensorflow as tf
from tensorflow import keras
from tensorflow.keras import layers
```

2.12.0

Get the data

First download and import the dataset using pandas:

```
[182] path = 'Z://AI//ERAA1.csv'
raw_dataset = pd.read_csv(path, header=0, sep=';', na_values='--', names=['DUSE', 'QH', 'GAS', 'PT', 'PP', 'PSEP', 'TEMP'], skipinitialspace=True)
```

```
[329] dataset = raw_dataset.copy()
dataset.head()
```

...

Clean the data

The dataset contains a few unknown values:

```
dataset.isna().sum()
```

[184]

```
... DUSE    0
    QH     0
    GAS    0
    PT     0
    PP     0
    PSEP   6
    TEMP   2
    dtype: int64
```

Drop those rows to keep this initial tutorial simple:

```
dataset = dataset.dropna()
```

[185]

Inspect the data

Review the joint distribution of a few pairs of columns from the training set.

The top row suggests that the QH is a function of all the other parameters. The other rows indicate they are functions of each other.

```
sns.pairplot(train_dataset[['DUSE', 'QH', 'GAS', 'PT', 'PP', 'PSEP', 'TEMP']], diag_kind='kde')
```

[187]

Split features from labels

Separate the target value—the "label"—from the features. This label is the value that you will train the model to predict.

```
train_features = train_dataset.copy()
test_features = test_dataset.copy()

train_labels = train_features.pop('QH')
test_labels = test_features.pop('QH')
```

[189]

Python

Normalization

In the table of statistics it's easy to see how different the ranges of each feature are:

```
train_dataset.describe().transpose()[['mean', 'std']]
```

Python

It is good practice to normalize features that use different scales and ranges.

One reason this is important is because the features are multiplied by the model weights. So, the scale of the outputs and the scale of the gradients are affected by the scale of the inputs.

Although a model *might* converge without feature normalization, normalization makes training much more stable.

Note: There is no advantage to normalizing the one-hot features—it is done here for simplicity. For more details on how to use the preprocessing layers, refer to the [Working with preprocessing layers](#) guide and the [Classify structured data using Keras preprocessing layers](#) tutorial.

The Normalization layer

The `tf.keras.layers.Normalization` is a clean and simple way to add feature normalization into your model.

The first step is to create the layer:

```
normalizer = tf.keras.layers.Normalization(axis=-1)
```

Python

Then, fit the state of the preprocessing layer to the data by calling `Normalization.adapt`:

```
normalizer.adapt(np.array(train_features).astype('float32'))
```

Python

Calculate the mean and variance, and store them in the layer:

```
print(normalizer.mean.numpy())
```

Python

```
[[ 10.073 2182.125 144.121  31.741  31.597  33.047]]
```

When the layer is called, it returns the input data, with each feature independently normalized:

```
first = np.array(train_features[:1])

with np.printoptions(precision=2, suppress=True):
    print('First example:', first)
    print()
    print('Normalized:', normalizer(first).numpy())
```

Python

```
... First example: [[ 12.7 2515.3 139.  34.8  35.41  38.  ]]
```

```
Normalized: [[ 1.88  0.68 -0.16  0.49  0.52  0.88]]
```

Linear regression

Before building a deep neural network model, start with linear regression using one and several variables.

Linear regression with one variable

Begin with a single-variable linear regression to predict 'QH' from 'PT'.

Training a model with `tf.keras` typically starts by defining the model architecture. Use a `tf.keras.Sequential` model, which represents a sequence of steps.

There are two steps in your single-variable linear regression model:

- Normalize the 'PT' input features using the `tf.keras.layers.Normalization` preprocessing layer.
- Apply a linear transformation ($y = mx + b$) to produce 1 output using a linear layer (`tf.keras.layers.Dense`).

The number of *inputs* can either be set by the `input_shape` argument, or automatically when the model is run for the first time.

First, create a NumPy array made of the 'PT' features. Then, instantiate the `tf.keras.layers.Normalization` and fit its state to the PT data:

Build the Keras Sequential model:

```
PT_model = tf.keras.Sequential([
    PT_normalizer,
    layers.Dense(units=1)
])
PT_model.summary()
```

[259]

... Model: "sequential_12"

Layer (type)	Output Shape	Param #
normalization_9 (Normalization)	(None, 1)	3
dense_22 (Dense)	(None, 1)	2

=====
Total params: 5
Trainable params: 2
Non-trainable params: 3
=====

This model will predict 'QH' from 'PT'.

Run the untrained model on the first 10 'PT' values. The output won't be good, but notice that it has the expected shape of (10, 1):

```
PT_model.predict(PT[:10])
```

260]


```
.. 1/1 [=====] - 0s 61ms/step
```

```
array([[ -0.037],  
       [ -0.067],  
       [ -0.111],  
       [ -0.19  ],  
       [ -0.045],  
       [  0.011],  
       [ -0.237],  
       [  0.059],  
       [  0.017],  
       [ -0.15  ]], dtype=float32)
```

Activer W
Accédez au

```
plot_loss(history,10)
```

265]



Linear regression with multiple inputs

You can use an almost identical setup to make predictions based on multiple inputs. This model still does the same $y = mx + b$ except that m is a matrix and b is a vector.

Create a two-step Keras Sequential model again with the first layer being `normalizer` (`tf.keras.layers.Normalization(axis=-1)`) you defined earlier and adapted to the whole dataset:

```
linear_model = tf.keras.Sequential([
    normalizer,
    layers.Dense(units=1)
])
```

When you call `Model.predict` on a batch of inputs, it produces `units=1` outputs for each example:

```
plot_loss(history, 10)
```

