

## التنبؤ بقيم النفاذية في حقل عودة باستخدام أنظمة الذكاء الاصطناعي

د. علي العجي\*

### الملخص

هدفت هذه الدراسة إلى الحصول على قيم النفاذية من خلال تطبيق تقانة أنظمة الذكاء الاصطناعي على معطيات في آبار لم يتم اقتطاع عينات اللباب الصخري فيها، وكانت النتائج ذات دقة تقارب قيم النفاذية الناتجة عن تحاليل اللباب الصخري. حددت من خلال البحث بارامترات الدخل والخرج، وقسمت قاعدة البيانات إلى مجموعة بيانات التدريب، ومجموعة بيانات الاختبار، حيث دُرِبت المدخلات والمخرجات لمجموعة بيانات التدريب للحصول على أدق النتائج، كما تم التأكد من الأداء خلال مجموعة بيانات الاختبار، وتمت مقارنة المخرجات مع القياسات المنفذة على اللباب الصخري، وحسب الفارق بين القيمتين، الذي مثل قيم الخطأ في التنبؤ، فتم التعميم، وتم الحصول على نتائج عالية الدقة في بئر لم يقطع منها عينات اللباب، وليس هناك قياسات للنفاذية على هذه العينات. ساعد في ذلك تقانة أنظمة الشبكات العصبونية المتوفرة في برنامج الماتلاب (matlab)، وبرنامج تفسير القياسات البئرية IP-V3.5.

**الكلمات المفتاحية:** حقل عودة، القياسات البئرية، نفوذية، لباب صخري، الشبكات العصبونية، برنامج الماتلاب، برنامج التفسير البئر (IP3.5).

\* مدرس في قسم الجيولوجيا - كلية العلوم - جامعة دمشق.

## Estimation of permeability in Oudeh fields Using Artificial Intelligence Systems

Dr. Ali alaji\*

### Abstract

This study aimed to obtain the permeability by the application of Artificial Intelligence Systems technology in a well where no core samples have been taken with accuracy close to the values of permeability resulting from the core analysis.

The inputs and the targets outputs parameters have been determined, and the data base was splitted into the training data set and the testing data set; the orders of inputs and outputs of the training data set have been trained to obtain the most accurate results, and the results of the testing data set were tested to ensure the performance and the outputs have been compared with the results of the core analysis. The difference between the two values was calculated which presents the error values in the prediction, and finally generalized, and thus high-precision results in a well was obtained that doesn't have core analysis for the. The neural network technology was helpful which are available in the matlab software and Interactive Petrophysics -V3.5

**Keywords:** Oudehfields, well logging, permeability, Cores, Neural Network, matlab software, Interactive Petrophysics V3.5.

---

\* Doctor, Department of geology, Faculty of Sciences, Damascus University, Syria.

## 1- مقدمة:

تؤدي القياسات الجيوفيزيائية البئرية دوراً مهماً في تقدير الخصائص البتروفيزيائية للصخور الخازنة، وتقييم الخزانات الهيدروكربونية؛ مما جعل تطويراتها من الأدوات الأساسية في الحسابات الخزنية، ودقة حساباتها في الخزانات الهيدروكربونية؛ بالتالي تسهم في وضع استراتيجية لتطوير الحقول وتمييزها وإدارتها. وتسهم تسجيلات القياسات الجيوفيزيائية البئرية بفاعلية في مراحل تطوير نماذج الخزانات الهيدروكربونية؛ بهدف تحقيق كفاية عالية في الإنتاج وزيادة المردود الاقتصادي [1]. لذلك تركز العديد من الدراسات على تحديد الخصائص الخزنية كالنفذية، واهتمت الدراسات الحديثة في استنباط أساليب حديثة وذات موثوقية عالية وابتكارها؛ لتحديد هذه الخصائص الخزنية، ومنها أنظمة الذكاء الاصطناعي Artificial Intelligence Systems، حيث إن هذه التقانات لها القدرة على الربط بين المدخلات والمخرجات بعلاقات لا خطية [2].

**النفذية:** هي قدرة الصخر على تمرير الموائع عبر القنوات والمسامات المتصلة بين الفراغات، وتعتمد النفذية في الصخر بشكل كبير على المسامية الفاعلة؛ وبالتالي فهي تتأثر بحجم الحبات وشكلها، ونمط الفرز ونمط التعبئة، ودرجة التراص، ونمط الأسمنت، ونوع الغضار. ليس هناك قياس مباشر للنفذية؛ إنما يتم الحصول على قيمها من التحاليل المخبرية على اللباب الصخري، ويرمز للنفذية بـ  $(K)$  وتقاس بالميلي دارسي (mD) ضمن مجال [0.01-10000].

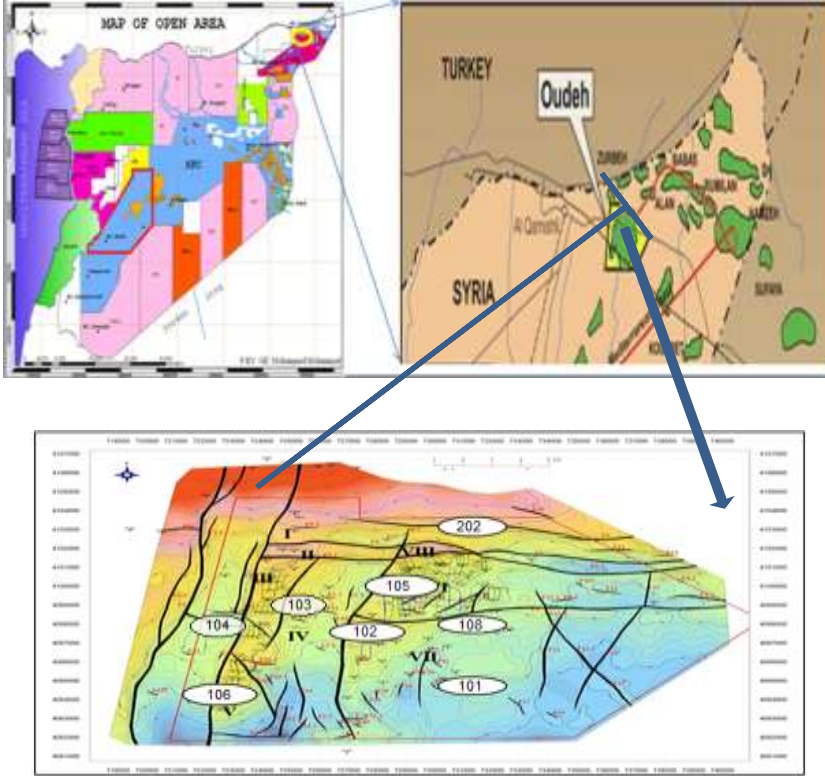
لا توجد علاقة مباشرة تربط بين المسامية والنفذية [3]. فيمكن أن يكون الصخر مسامياً، ولكن نفاذيته منخفضة أو العكس، كالغضار والصخور الكربونائية المشققة ذات نفاذية عالية ومسامية منخفضة. وتوجد عدة علاقات تجريبية لحساب النفذية، ومنها باستخدام معادلة كوتس، ولتقديرها يجب حساب الإشباع المائي؛ فضلاً عن تقديرها من علاقات تجريبية، وطرائق بئرية أخرى [4].

ليس بالضرورة أن تتطابق القيم المحسوبة مخبرياً مع القيم الناتجة من العلاقات الرياضية أو تكون قريبة من المحسوبة من القياسات الجيوفيزيائية البئرية؛ لأن عينة اللباب تبقى عينة نقطية من التشكيلة، والقياسات الجيوفيزيائية البئرية تتعامل مع حجم صخري كبير، وحدوده تبعاً لقدرة التمييز، وعمق الاختراق بالنسبة لسواير القياس [5].

## 2- منطقة الدراسة:

تمت الدراسة بالاعتماد على المعطيات المتوفرة في المؤسسة العامة للنفط، وشركة عودة مالكة الحقل، والذي يعود تكتونياً إلى منخفض شمال سنجار، وهو عبارة عن مرتفع بنيوي له اتجاه جنوب شرق - شمال غرب، وهو أحد التراكيب الرئيسة في هذا المنخفض [6].

يبعد حقل عودة إلى الغرب من مدينة الرميلان بمسافة حوالي 55 كم، وحوالي 15 كم إلى جنوب الحدود السورية - التركية. ويظهر بشكل قبة صغيرة ذات إغلاقات تتراوح بين 25 و 50 م، وتنتشر في منطقة لا تزيد أبعادها على 8 x 12 كم، ويبدو أن هذه القبة الصغيرة يجمعها إغلاق واحد كبير، ويبدو أن مجموعة تراكيب عودة هي أعلى تركيبياً، وهذا الارتفاع أكسبها أهمية نفطية وغازية كبيرة، [7]. كما أن وجود عدد كبير من الفوالق يشير إلى إمكانية وجود تشققات؛ مما يؤدي إلى تحسين مواصفات الصخر الخزنية، الشكل (1).



الشكل (1) خارطة منطقة الدراسة شمال شرق سورية مواقع الآبار المرجعية ضمن حقل عودة  
[6]..(Sinopec, 2010)

### 3- بعض الدراسات المرجعية:

أجريت على الحقل والتشكيلات الخازنة مجموعة من الدراسات الأولية من قبل الشركة السورية للنفط والشركات الأجنبية [8]، واهتمت هذه الدراسات بالتراكيب البنوية للحقل والتشكيلات المتعاقبة، وبالخصائص الخزنوية لهذه التشكيلات وقدراتها الإنتاجية؛ فلقد خضعت مكونات التشكيلات لدراسات ومسوحات جيوفيزيائية سيزمية سطحية؛ فضلاً عن قياسات جيوفيزيائية بئرية، واقتطعت من عدة آبار مئات الأمتار

من اللباب الصخري، وأنجزت عليها قياسات مخبرية للنفاذية، والتي ساعدت في إنجاز هذه الدراسة، وتطبيق هذه التقانة.

إلى جانب ذلك، فقد أنجز العديد من الدراسات والبحوث العلمية حول العالم؛ باستخدام الشبكات العصبونية التي هي محور دراستنا، وقد تم استخدامها في مجال الصناعة النفطية في العديد من الدراسات؛ بهدف تحديد الصفات الخزنية للتشكيلات تحت السطحية؛ كالمسامية والنفاذية، والإشباع المائي، وتحديد المحتوى الكلي للكربون العضوي؛ فضلاً عن خواص أخرى.

ولعل تقدير الخواص البتروفيزيائية من العينات اللبابية، ومن تفسير استجابات القياسات البئرية هي عملية صعبة وغالباً ما تترافق مع أخطاء، إلا أن طرائق الذكاء الاصطناعي تعمل على تجاهل هذا الخطأ وتقليصه، وتستخدمه كعامل فاعل لزيادة دقة عملية التنبؤ [9].

(Castagna *et al* (1985) and Ikwuakor (1988)، Domenico (1984)، Tatham (1982))

قام Saputro، O.D. et al.، 2016، بالتنبؤ بمنحني المسامية الفاعلة بالاعتماد على شبكة عصبونية صناعية ذات الانتشار العكسي مكونة من 10 طبقات خفية، وتمت الدراسة في إندونيسيا لثلاث آبار؛ واعتمدت الدراسة على القياسات الجيوفيزيائية البئرية كعناصر دخل لتدريب الشبكة، وأعطت نتائج جيدة لقيم المسامية عند اختبارها؛ حيث بلغت قيمة الارتباط بين قيم مسامية اللباب الصخري والقيم المنتبأ بها  $R=0.90$  في بئر الاختبار الأول، و  $R=0.87$  في بئر الاختبار الثاني [10].

• قام Romero، S.، Patniyot، P.A.، 1998، بالتنبؤ بقيم المسامية والنفاذية؛ باستخدام الشبكة العصبونية ذات الانتشار العكسي، بالاعتماد على القياسات الجيوفيزيائية البئرية والقياسات المنفذة على اللباب الصخري، فكانت قيمة معامل الارتباط من أجل المسامية  $R^2=0.96$  ومن أجل النفاذية  $R^2=0.83$  [11].

- قام M.M. et al.,Salehi، 2016: بالتنبؤ بالقياسات المفقودة؛ باستخدام الشبكة العصبونية متعددة الطبقات في حقل نفطي جنوب غرب إيران؛ باستخدام بيانات لثلاث آبار للتنبؤ بقياس الصوتية  $\Delta T$  المفقود، وقياس المقاومة الضحلة والعميقة (LLD - LLS)؛ حيث استخدم الباحث 700 عينة لبيانات تدريب نموذج ANN، وتم استخدام 150 عينة من البيانات لاختبارها عشوائياً، وقد أثبتت هذه التقانية قدرتها، حيث بلغ معامل الارتباط  $R=0.99$  من أجل قياس المقاومة العميقة LLD،  $R=0.99$  من أجل قياس LLS و  $R=0.97$  من أجل قياس الصوتية [2].DT.
- قام M.Z.B.,Sultan، et al، 2013 بالتنبؤ بقيم النفاذية في حقل غاز هانبينغ شمال شرق بنغلادش؛ باستخدام الشبكة العصبونية ذات الانتشار العكسي؛ حيث قسمت البيانات المتوفرة بشكل عشوائي إلى مجموعتين، وتم استخدام المجموعة الأولى في عملية تدريب الشبكات التي تمثل 74.2% من مجموع نقاط العينة، والباقي 25.8% تم استخدامها لاختبار الشبكة. أثبتت الشبكة العصبونية المستخدمة قدرتها في إعطاء نتائج جيدة؛ وبلغت قيمة معامل الارتباط  $R=0.813$ [12].
- قام كل من Huang، Z، Shimeld، J، Williamson، M، Katsube، J، 1996 بالتنبؤ بقيم النفاذية في حقل غاز فينتور في شرق كندا؛ باستخدام خوارزمية الانتشار العكسي [13] ، حيث تم استخدام خمس آبار في حقل فينتور للتنبؤ بالنفاذية، واستخدمت أربع آبار كقاعدة بيانات لتدريب الشبكة العصبونية، وتم اختبار الشبكة بالبيتر الخامس، وتم التنبؤ بقيم النفاذية المطلوبة، وكانت قيمة معامل الارتباط الخطي  $R=0.8$ .
- اختبر Hsieh، B.-Z، Wang، B.-W، Lin، CH.-W، Z.-SH، 2009 نسبة معامل قص الصخر إلى انضغاطيته؛ باستخدام الشبكات العصبونية الاصطناعية؛ حيث تم تطبيق خوارزمية الانتشار العكسي للحصول على النتائج [14]، فكان معامل

الارتباط  $R=0.97$  بحيث تعبر القيمة 1 عن وجود تطابق كامل بين بيانات التحقق والنتائج عند اختبار أداء الشبكة.

- ومؤخراً قامت صونيا جلعة 2018 بدراسة حول تقييم التشكيلات؛ باستخدام أنظمة الذكاء الاصطناعي في حقول سارابا النفطية- سورية، [15]. فتم التنبؤ بقيم المسامية الفاعلة والنفاذية، وكذلك التنبؤ بمنحني القياسات الصوتية المفقودة في إحدى الآبار.

#### 4- الهدف من البحث:

تعد أنظمة الذكاء الصناعي إحدى التقانات الحديثة التي تفيد، وتدعم التفسير البتروفيزيائي، وتهدف الدراسة هذه إلى استخدام الشبكات العصبونية الصناعية للتنبؤ بمنحني النفاذية؛ بالاعتماد على القياسات الجيوفيزيائية البئرية (Well Logs) المنفذة في الآبار غير المكسية المتوفرة لدى المؤسسة العامة للنفط - شركة عودة مالكة حقل الدراسة، وكانت بصيغة ASCII، Las، والذي يتعامل معها برنامج التفسير البتروفيزيائي Interactive Petro physics V3.5؛ فضلاً عن معطيات قياس النفاذية المقاسة على العينات المقطعة من اللباب الصخري؛ بمعنى آخر سنقوم بالتنبؤ بقيم النفاذية للتشكيلات من دون أن نفسير التسجيلات البئرية المقاسة، ومن دون اقتطاع اللباب الصخري Core ومن دون أن نجري قياسات عليه.

#### 5- مواد البحث وطرائقه:

استخدمت في الدراسة تقانة الشبكات العصبونية التي تعد إحدى تقانات الذكاء الاصطناعي للتنبؤ في تقدير النفاذية لآبار حقل عودة. لن نتمكن في تقدير النفاذية من معرفة الخوارزمية التي تم العمل عليها لتحديد الخرج المطلوب؛ لذلك تمت الاستعانة باستخدام برنامج (Matlab 2015)، حيث تم تحديد بارامترات دخل الشبكة؛ وهي القياسات الجيوفيزيائية البئرية في الآبار غير المكسية، كما تم التوصل إلى اختيار خمسة مدخلات، والتي ضمت كلاً من قياسات تسجيل غاما الطبيعي (GR)،



وقياسات المقاومة العميقة (LLD)، وقياس تسجيل الكثافة الصخري (RHOB)، وقياس التسجيل النيوتروني (NPHI)، وتسجيل أزمنة الارتحال (DT)، فضلاً عن القياسات المخبرية المنفذة على اللباب الصخري المتوفرة في بئر عودة (103- Oudeh)، والتي استخدمت لتدريب الشبكة العصبونية، واكتساب خبرتها ضمن بنيات الشبكات التي يعتمد عليها برنامج التفسير البتروفيزيائي (IP V3.5)، [16]؛ فضلاً عن بئر عودة (105- Oudeh)، التي تم اعتمادها لاختبار الشبكة، والتحقق من دقتها؛ كونها تحتوي على قياسات للباب مع القياسات البئرية الخمسة التي تم اختيارها. بعد التأكد من دقة الشبكة، تم التعميم على ثلاثة آبار، عودة (101- Oudeh) وعودة (102- Oudeh) وعودة (104- Oudeh).

#### 6- المبدأ النظري:

ثمة علاقة منطقية بين المدخلات المحددة والنفاذية، فكل من قياسات (NPHI) و (DT) و (RHOB) هي قياسات مسامية [17]، فتمتلك العلاقة الأقوى مع النفاذية، فبتزايد النفاذية تزايد المسامية. ويستخدم تسجيل (GR) وهو مقياس للإشعاعية الطبيعية [18]، ويستخدم للتمييز بين التشكيلات النظيفة والمشوبة بالشيل والشيلية، وبطبيعة الحال فإن النطاقات النظيفة ذات (GR) المنخفضة تبدي نفاذية أعلى من تلك في النطاقات الشيلية [19]، عدا بعض التشكيلات. كما تعتمد قياسات المقاومة العميقة (LLD) في التشكيلات على عدة متغيرات تتضمن إشباع المائع، ونوعته الفراغ المسامي وهندسيته، وتتحكم هندسية الفراغ المسامي بالنفاذية [20].

#### 7- أنظمة الذكاء الاصطناعي:

توجّهت أنظار العلماء والباحثين إلى استنباط سبل جديدة للقيام بتطوير أنظمة لحل ومحاكاة الكثير من المسائل العلمية، ورفد الكثير من البرامج بخوارزميات متطورة لتطويرها، ولهذا السبب تم التفكير بأنظمة الذكاء الاصطناعي لحل هذه المهام، فكان منها عدة أنظمة نذكر منها: المنطق الترجيحي Fuzzy Logic System،

والخوارزميات الجينية Genetic Algorithms والشبكات العصبونية الصناعية Artificial Neural Network..... وغيرها. تعد الشبكات العصبونية الاصطناعية (ANN) واحدة من أهم تقانات الذكاء الاصطناعي المستخدمة في إيجاد حلول مختلفة للمشاكل الخطية، وغير الخطية.

#### 7-1- تعريف الشبكة العصبونية الصناعية:

هي إحدى تقانات الذكاء الاصطناعي مصممة لمحاكاة الطريقة التي يؤدي بها العقل البشري مهمة معينة، وهي عبارة عن معالج ضخم موزع على التوازي، ومكوّن من وحدات معالجة بسيطة، بحيث يقوم بتخزين المعرفة العملية؛ ليجعلها متاحة للمستخدم، وذلك عن طريق ضبط الأوزان. [21].

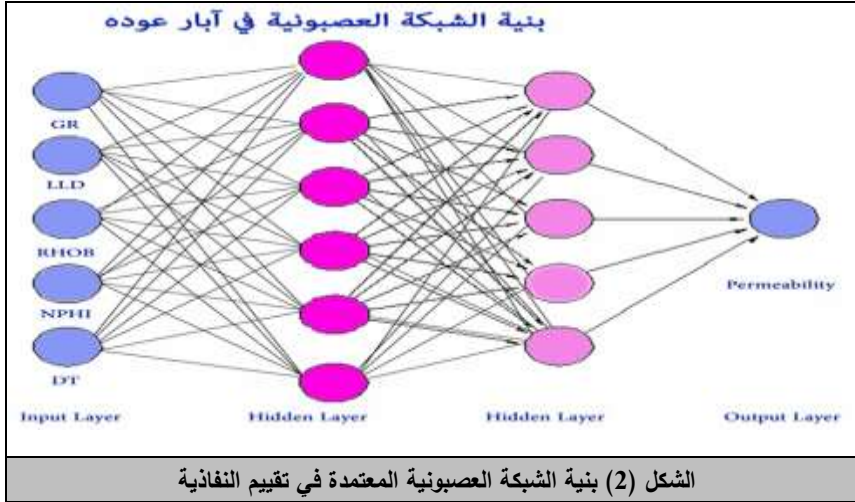
#### 7-2- مكونات الشبكة العصبونية الصناعية والمنهجية المستخدمة:

تطورت الشبكات العصبونية كأمتلة رياضية؛ معتمدة على طريقة التفكير البشري، وكيفية معالجة الأعصاب للمعلومات، فكما أن للإنسان وحدات إدخال توصله بالعالم الخارجي وهي حواسه الخمس، فكذلك تحتاج الشبكات العصبونية لوحدات إدخال ووحدات معالجة، تتم فيها عمليات حسابية تضبط بها الأوزان، ويتم الحصول من خلالها على الاستجابة المناسبة لكل مدخل من مدخلات الشبكة، وبذلك نستطيع القول إن مكونات الشبكة العصبونية، هي [21]:

1. طبقة المدخلات (Input Layer): تقوم باستلام إشارات الإدخال من خارج الشبكة.
2. طبقة المخرجات (Output Layer): وهي الطبقة الأخيرة التي تعطي الخرج الحقيقي بعد سلسلة من المعالجات التي تتم خلال الطبقات السابقة.
3. الطبقة الخفية وهي طبقة من الوصلات البينية التي تربط كل طبقة بالطبقة التي تليها والتي يتم فيها ضبط الأوزان الخاصة بكل وصلة بينية.

4. حد العتبة (Threshold): ويحدد مدى ونوع الخرج ليتسنى مقارنته مع الخرج المطلوب.

5. دالة التنشيط (Activation Function)، ويوجد عدة أنواع من هذه الدوال ومنها [22]:  
- دالة الخطوة (StepFunction): وهي الدالة التي يقع خرجها بين 0،1.



- دالة الإشارة (SignFunction): يكون فيها الخرج بين -1،0،1 وتستخدم في التصنيف والتعرف إلى الأنماط.  
- الدالة الخطية (LinerFunction): هي الدالة التي يكون فيها الخرج مشابه للدخل، وتعطي تصنيفات متعددة، وغير محدودة.  
- الدالة السيغماوية (Sigmoid Function): وهي دالة غير خطية يقع مداها بين 0،1 وتكون مستمرة قابلة للاشتقاق.

### 7-3- أساليب التعلم في الشبكات العصبونية:

يمكن استخدام طريقتين لتدريب الشبكات العصبونية كوسيلة للتعلم، وهي:

أ- التعلم بوجود مشرف Supervised:

تتم من خلال تجميع البيانات، وتقسيمها إلى بيانات داخلة إلى الشبكة وبيانات خارجة عن الشبكة، ويتم تشغيل البيانات الداخلة بهدف التنبؤ بالقيم المستقبلية ومن ثم تتم مقارنة النتائج عن طريق القيم الخارجة، ومن ثم يمكن تعديل الأوزان؛ وفق تلك الطريقة.

ب- التعليم مع عدم وجود مشرف Unsupervised:

يوجد تشابه كبير بين هذه الطريقة والطريقة السابقة للتدريب، إلا أنها تختلف عنها بأنه لا توجد قيم للمتغيرات الخارجة، حيث تقسم البيانات الداخلة إلى مجموعات، وتقوم الشبكة باكتشاف المميزات غير الظاهرة فيها، ثم يتم بعد ذلك تقسيم بيانات الدخل إلى مجموعات مختلفة ثم تتم المقارنة فيما بينها.

### 7-4- إنشاء الشبكة العصبونية Neural Network Creating:

إن أول خطوة في تدريب الشبكة العصبونية هي إنشاء الشبكة باستخدام عدة توابع، حيث يكون كل تابع مخصص لإنشاء أحد أنواع الشبكات ذات الصفات المتميزة. يتم استخدام تابع لإنشاء الشبكة، ويحتاج هذا التابع إلى عدة محددات دخل، وهي:

- مصفوفة تحتوي على القيم الصغرى والعظمى لكل عنصر من عناصر شعاع الدخل ويمكن أن يستعاض عنها ب (minmax(p)).

- مصفوفة تحتوي على عدد العصبونات في كل طبقة من طبقات الشبكة.

- مصفوفة تحتوي على أسماء توابع التفعيل لكل طبقة.

- اسم تابع التدريب المستخدم.

-

network=newff ( (minmax(p),[s1,s2,s3],{ logsig, logsig, logsig}, trainrp)

#### 7-5- الخوارزمية المستخدمة:

اعتمدت شبكة (BP-ANN) (Back-Propagation Neural Network) الانتشار العكسي للخطأ لتمثيل بيانات القياسات الجيوفيزيائية البترية، ومن ثم تم تهيئة أفضل الصيغ والطرق الرياضية التي تساعدنا في تقليل الخطأ الناتج في أثناء عملية التدريب، [23]، وهي:

- 1- عدد الطبقات الخفية (Hidden Layers) المستخدمة في بناء الشبكة العصبونية.
- 2- عدد العقد (Nodes) في الطبقة الخفية.
- 3- نوع دالة التنشيط (Activation Function) المستخدمة في الطبقة الخفية وطبقة الخرج.

4- نوع الخوارزمية المستخدمة في تدريب الخطأ.

تُعد شبكة الانتشار العكسي (BP-ANN) تقانة اختبار مميزة، حيث تُرسل القيم المدخلة خلال الشبكة، ومن ثم يتم حساب الاختلاف بين النتائج المحسوبة والنتائج المأخوذة من بيانات التدريب، [24]. فيما بعد يكون هذا الخطأ مُعدلاً ضمن الشبكة والأوزان في أثناء عدد من هذه التكرارات، ويتم التوقف عن الاختبار عندما تكون القيم الناتجة المحسوبة أفضل من القيم المطلوبة، حيث يتم في النهاية حساب مقياس كفاية تقانة الشبكات العصبونية (EFF) الذي يتناسب عكساً مع كل من الزمن (Time) ومعدل مربع الخطأ للنتائج (MSE)؛ وفقاً لما يأتي:

$$EFF = 1 / ( MSE * Time )$$

ويحدد تابع التدريب المستخدم (trainrp): بعدة بارامترات، وهي:  
 معدل التعلم: يعمل على تحديد سرعة تغير الميل والانحيازات، وكذلك الأمر لإظهار  
 حالة التدريب (Show) وبارامتر لإيقاف عملية التدريب (Epoch)، حيث تتوقف  
 الشبكة عن التدريب إذا بلغ عدد التكرارات العدد المحدد؛ فضلاً عن تحديد قيمة  
 الخطأ الأصغري (Goal) ، والميل الأصغري الذي يقف عنده التدريب (Min-grade)  
 .[25]

تعمل الشبكة العصبونية بصورة أفضل عندما تتغير كل مدخلاتها ومخرجاتها في  
 مدى يقع بين (1,0)؛ وبالتالي يجب تغيير كل البيانات قبل أن تستخدم في نموذج  
 الشبكة العصبونية، وتتم عملية تغيير البيانات بأساليب مختلفة، حيث يعتمد ذلك  
 على نوع البيانات (مستمرة، منقطعة، تصنيفية)، وبناء على نوع البيانات يمكننا أن  
 نقوم بتغيير البيانات بين قيمتين سابقتي التحديد (أقل قيمة وأكبر قيمة)، ويتم التحويل  
 أو التغيير إلى المدى (1,0) كما يأتي:

يتم استخدام توابع تحويل في الطبقة الخفية؛ لتحقيق التأرجح ثنائي الاتجاه، حيث  
 يصبح معدل التدريب أسرع عندما تكون الشبكة غير متناظرة، وتكون توابع التنشيط  
 المستخدمة من ناحية أخرى في طبقات الخرج غير متناظرة، لذلك يتم استخدام التابع  
 الأسّي (Log Sigmoid).

تقوم الطبقة الأولى بتطبيق تسوية للقيم (Normalization) على شعاع الدخل بحيث  
 يصبح لجميع المداخل الأولوية نفسها في أثناء التعلم؛ بمعنى أنه لا يوجد مداخل  
 ذات قيم كبيرة جداً، ومداخل ذات قيم صغيرة جداً؛ وبالتالي انزياح عملية التعلم نحو  
 القيم الكبيرة أو الصغيرة.


ويتم تسوية متغير الخرج (Normalization) ضمن مجال تابع تنشيط الخرج (Target) مع الحفاظ على بعض الإزاحة من القيمة المحددة لتابع التنشيط، وإلا فإن خوارزمية الانتشار العكسي سوف تميل إلى تشغيل بارامترات الشبكة إلى ما لا نهاية. وبذلك تصبح عملية التعلم بطيئة.

#### 6-7- دالة التنشيط:

تسمح دالة سيغمويد بتحويل المخرجات إلى قيم محصورة بين (0،1) وتسمى بهذه الحالة بدالة تنشيط سيغمويد الثنائي، أو يتم تحويل المخرجات إلى قيم بين (-1،+1) وتسمى بدالة تنشيط سيغمويد ثنائي القطبية . وتعد دالة السيغمويد من أكثر الدوال استخداماً في خوارزميات تدريب شبكات الانتشار العكسي وتأخذ هذه الدوال الصيغة الرياضية الآتية:

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

وتأخذ الشكل البياني الآتي (الشكل 4):



الشكل (3) شكل التابع الأسّي (sigmoid)

**8- حساب الخطأ والدقة في التنبؤ:**

تم حساب قيم الخطأ عند كل قيمة من القيم الناتجة عن ANN، وذلك بطرح قيمة النفاذية الناتجة عن قياسات اللباب الصخري من القيمة الناتجة عن الشبكة العصبونية الاصطناعية ANN، فيتم الحصول على منحني الخطأ  $err$  حسب المعادلة:

$$err(x) = \Phi_{core}(x) - \Phi_{predicted}(x) \dots \dots \dots (1)$$

كما تم حساب قيم دقة أداء الشبكة في الحصول على قيم النفاذية بدءاً من القياسات الجيوفيزيائية البئرية وقياسات اللباب الصخري، من خلال طرح قيمة الخطأ الناتجة من القيمة 100، فيتم الحصول على منحني الدقة ACC، [26] من العلاقة:

$$ACC(x) = 100 - err(x) \dots \dots \dots (2)$$

**9- النتائج والمناقشة:**

تم خلال الدراسة تحديد عناصر دخل الشبكة؛ حيث اعتمد في ذلك على العلاقة بين كل عنصر من عناصر دخل الشبكة مع قيمة النفاذية في طبقة الخرج؛ إذ يعد كل من تسجيل قياس الإشعاع الطبيعي، وقياس الكثافة الصخري، وقياس تسجيل أزمنة الارتحال الصوتية، وقياس تسجيل النترون وقياس تسجيل المقاومة العميقة، والكثير من القياسات الجيوفيزيائية البئرية، والتي ترتبط بعلاقة خفية مع الفراغ المسامي للصخر، وتعد مؤشر غير مباشر للنفاذية.

**9-1- تحضير البيانات للعمل على الشبكة العصبونية:**

تم استخدام برنامج ماتلاب MATLAB-2015 في هذه الدراسة؛ بهدف بناء نظام ذكي يعتمد على الشبكات العصبونية الصناعية، حيث تم تحضير قاعدة البيانات، وتحديد الشبكة العصبونية، ثم تم التدريب؛ باستخدام مجموعة بيانات التدريب، ثم تم اختبار أداء الشبكة؛ باستخدام مجموعة بيانات الاختبار وتقييم موثوقيتها. تلا ذلك



تعميم الشبكة على الآبار والتنبؤ بقيم النفاذية في الآبار التي لم يتم فيها أخذ لباب صخري وغير مفسرة قياساتها.

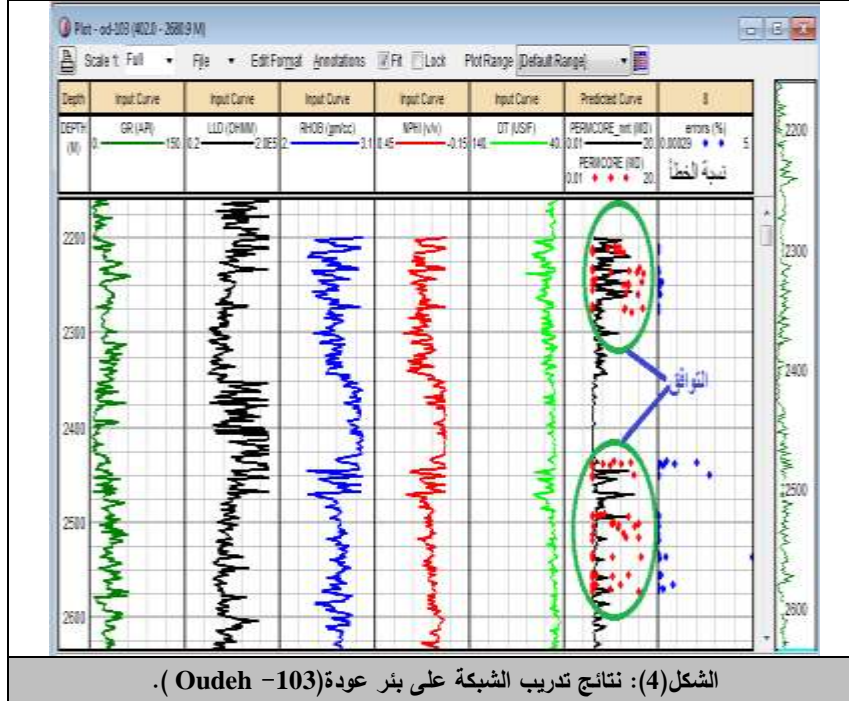
#### 9-1-1- مجموعة بيانات التدريب:

لقد تضمنت بيانات التدريب كل القياسات المتوفرة ضمن القياسات البئرية والتي تم تنفيذها من قبل شركة شلمبرجير لصالح المؤسسة العامة للنفط- شركة عودة ، والتي كانت بصيغة (Las,Delis) ، والتي ضمت كل من قياسات تصحيح تسجيل غاما الطبيعي (GR)، وقياسات المقاومة العميقة (LLD)، وقياس تسجيل الكثافة الصخري (RHOB)، وقياس التسجيل النيوتروني (NPHI)، وتسجيل أزمدة الارتحال (DT)؛ فضلاً عن القياسات المخبرية المنفذة على اللباب الصخري المتوفرة في بئر (103-Oudeh)، والتي استخدمناها لتدريب الشبكة العصبونية، واكتساب خبرتها ضمن بنيات الشبكات التي يعتمد عليها برنامج IP V3.5، حيث قمنا بتنظيم مجموعة بيانات الهدف ضمن جدول تضمن العمود الأول قيمة العمق وتقابله قيمة النفاذية المقاسة عند ذلك العمق؛ لمعرفة المجالات التي تم أخذ اللباب الصخري منها، وعدد العينات المأخوذة ضمن كل مجال، وحفظت ضمن ملفات بصيغة txt، كملف منفرد، وتم تحويلها إلى صيغة ASCII. نظمت العينات اللبابية من بئر عودة (103-Oudeh)، فكانت مكونة من (5) عينات، ومن (182) نقطة قياس والتي استخدمت لتدريب الشبكة، الجدول رقم (1).

الجدول (1) مجموعة بيانات الهدف المستخدمة في بناء الشبكة العصبونية، لتدريبها.

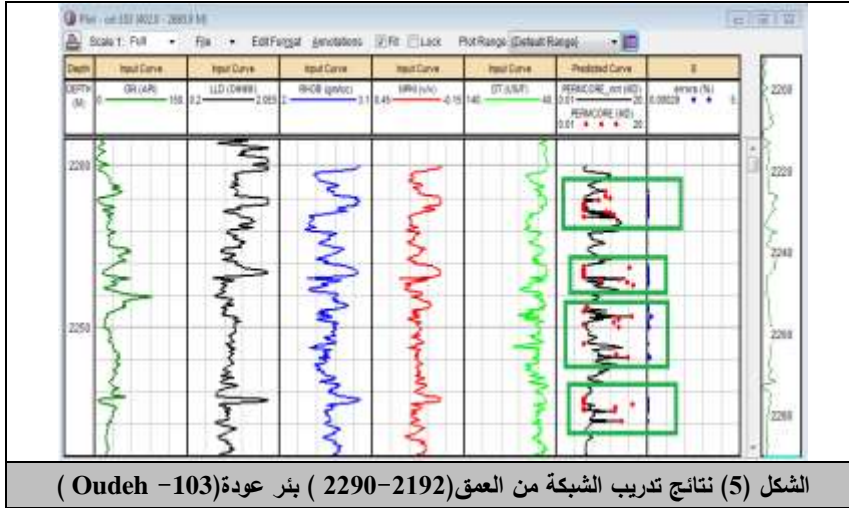
Well name	Depth interval (M)	Samples No.
Oudeh-103	1546-1554.9	27
	2208-2238.6	33
	2243.7-2262.4	22
	2279.8-2272.15	14
	2436.2-2573.5	84

يبين الشكل (4) نتائج بيانات التدريب للشبكة العصبونية، والتنبؤ بقيم النفاذية على بئر عودة (Oudeh -103)، كما يظهر في الشكل (4) توافق منحنى التنبؤ وبأقل خطأ ممكن بقيم النفاذية (المنحني المستمر) مع قيم النفاذية المقيسة على عينات اللباب الصخري (النقاط التي تتوضع حسب قيمها المقيسة وعمق العينة، وتم حساب قيم نسبة الخطأ وقيم نسبة التوافق بين بيانات تدريب الشبكة، والقيم المقيسة على اللباب؛ تبعاً للمستويات الخمسة، وسنعرض تبعاً مستويات التدريب تبعاً للأعماق (2175 - 2650).

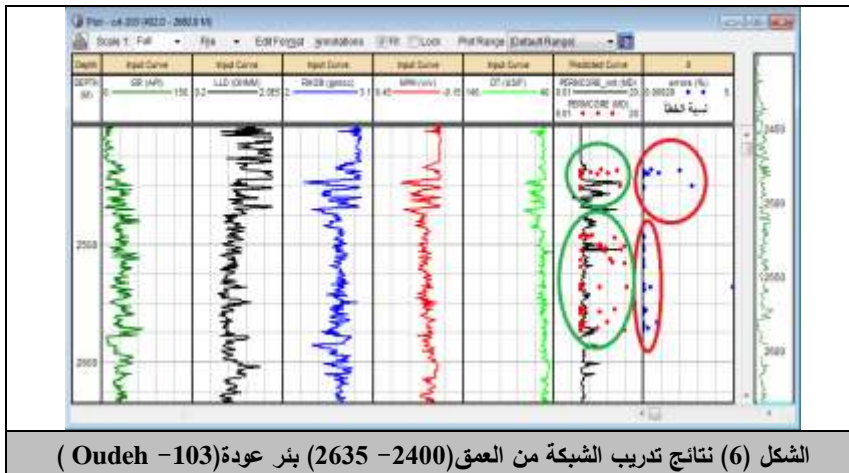


الشكل(4): نتائج تدريب الشبكة على بئر عودة (Oudeh -103).

بهدف التوضيح، وإظهار التوافق بين منحنى نتائج تدريب الشبكة للتنبؤ بمنحني قيم النفاذية مع قيم النفاذية المقيسة على عينات اللباب الصخري تبعاً لأعماقها بمقياس أكبر في المجال العمقي (2192-2290) في بئر (Oudeh -103) الشكل (5).



كذلك الأمر بهدف التوضيح، تم إظهار منحنى تدريب الشبكة للتنبؤ بمنحنى قيم النفاذية مع قيم النفاذية المقاسة على عينات اللباب الصخري في بئر (103- Oudeh) بمقياس أكبر في المجال العمقي (2400-2635) الشكل (6).



## 9-1-2- مجموعة بيانات الاختبار:

تضمنت كل من مجموعة القياسات الجيوفيزيائية البئرية وقياس النفاذية على اللباب الصخري (perm-core) في بئر (Oudeh -105) التي تم تحديدها لاختبار أداء الشبكة العصبونية في عملية التنبؤ بقيم النفاذية التي حصلنا عليها من مرحلة التدريب للشبكة. نشير هنا إلى أن قيم النفاذية المحسوبة من اللباب لم يتم إدخالها بالحسابات؛ وإنما تم الاعتماد عليها لمعايرة نتائج (خرج) الاختبار، وتكونت مجموعة بيانات اختبار الشبكة المستخدمة من 7 عينات، ومن (260) نقطة قياس، الجدول رقم (2).

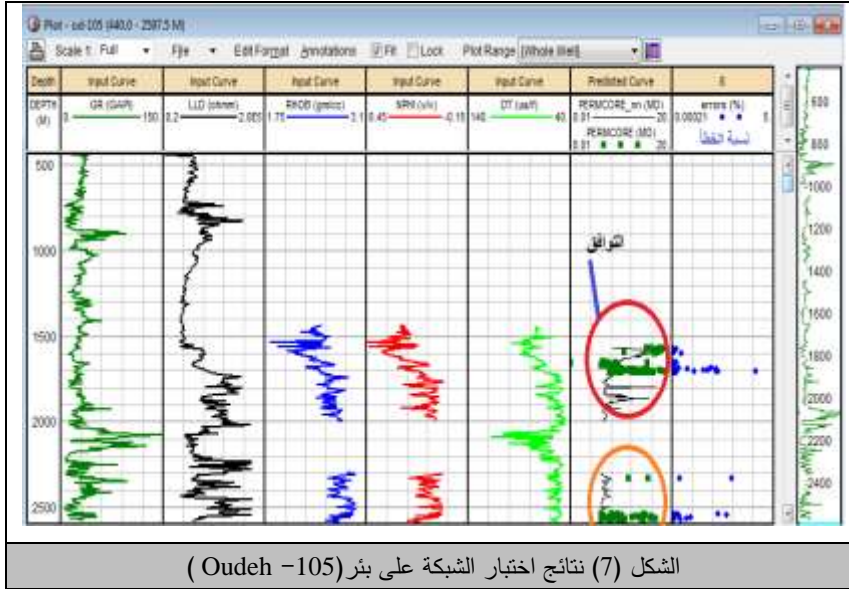
الجدول (2): مجموعة بيانات الهدف المستخدمة في اختبار الشبكة العصبونية

Well name	Depth interval (M)	Samples No.
Oudeh-105	1569-1587.9	52
	1591-1615.9	39
	1635.6-1657.9	18
	1666.3-1674.5	17
	1686.7-1713.9	56
	1681-2331	15
	2540.1-2574.2	63

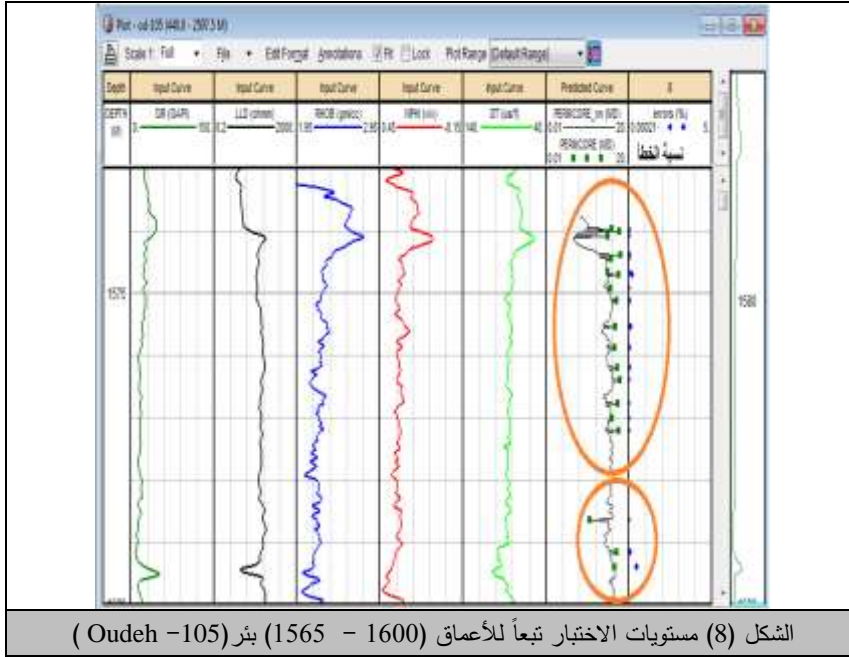
قمنا باختبار الشبكة العصبونية المقترحة على بئر (Oudeh -105)؛ للتنبؤ بقيم النفاذية، وتم تمثيل بيانات الاختبار مقابل المجال العمقي، وبيانات النفاذية المقيسة على اللباب الصخري، ومنحي التنبؤ بالنفاذية على المجالات التي تتوافر فيها منحنيات القياسات البئرية التي تمثل مدخلات الشبكة المدربة، كما في الشكل (7). وتم حساب نسبة الخطأ والدقة بين منحي التنبؤ بالنفاذية، والمحسوب بناء على اختبار الشبكة المقترحة، وبيانات النفاذية المقيسة على اللباب الصخري، وذلك تبعاً لمستويات المقارنة للشبكة. ولإظهار التوافق بشكل واضح على المنحنيات، قمنا

بإظهار ذلك من خلال الحقلين الأخيرين اللذين يمثلان نسبة الخطأ والدقة بين قيم التنبؤ والمقيسة.

لقد أظهرت نتائج اختبار الشبكة مدى نجاح تقانة الشبكات العصبونية في التنبؤ بقيم النفاذية من القياسات الجيوفيزيائية البئرية، حيث وصلت نسبة الخطأ أقل من 3%.

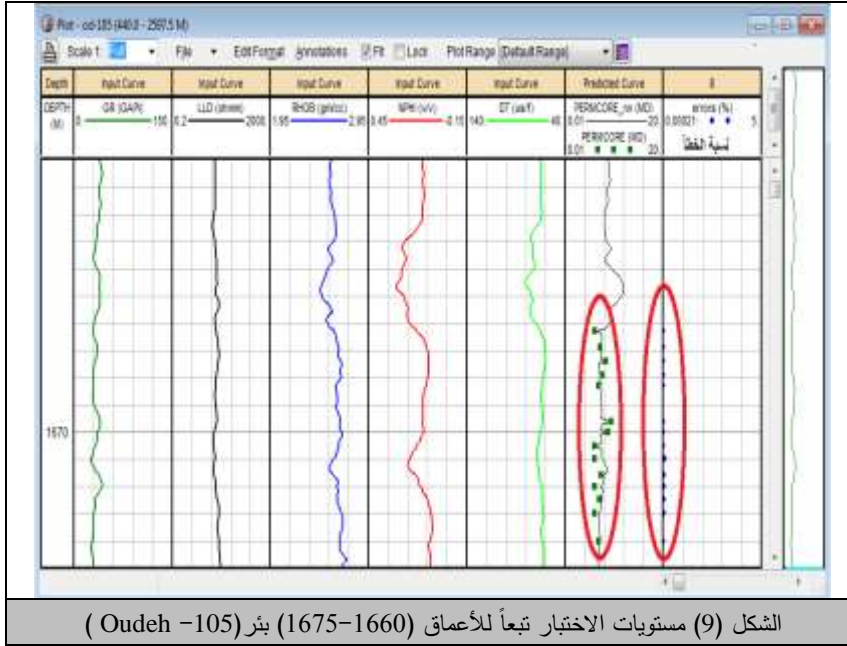


للتوضيح، تم إظهار نتائج منحنى اختبار الشبكة بناء على الشبكة المدربة ومقارنتها مع القيم المقيسة على اللباب الصخري في المجال العمقي (1565 - 1600) بمقياس أكبر من بئر (Oudeh - 105)، وكذلك إظهار نسبة الخطأ والتوافق، الشكل (8).

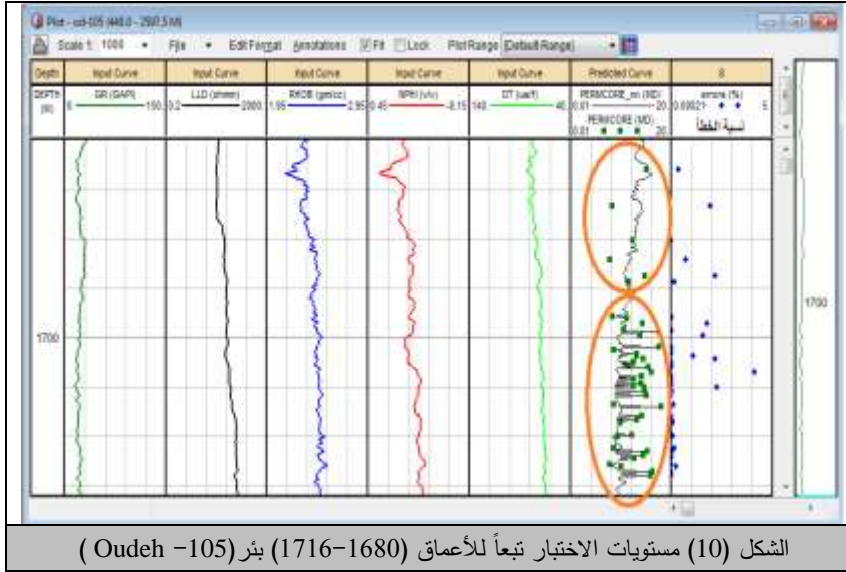


الشكل (8) مستويات الاختبار تبعاً للأعماق (1600 - 1565) بئر (Oudeh - 105)

كذلك للتوضيح، تم إظهار نتائج منحنى قيم النفاذية الناتجة من اختبار الشبكة بناء على الشبكة المدربة بمقياس أكبر، ومقارنتها مع قيم النفاذية المقيسة على اللباب الصخري في المجال العمقي (1660-1675) من بئر (Oudeh-105). وكذلك إظهار نسبة الخطأ بينها، الشكل (9) .



كذلك للتوضيح، تم إظهار نتائج منحنى قيم النفاذية الناتجة من اختبار الشبكة بناء على الشبكة المدربة بمقياس أكبر، ومقارنتها مع قيم النفاذية المقاسة على اللباب الصخري في المجال العمقي (1680-1716) في بئر (Oudeh-105) وكذلك إظهار نسبة الخطأ بينها، الشكل (10).



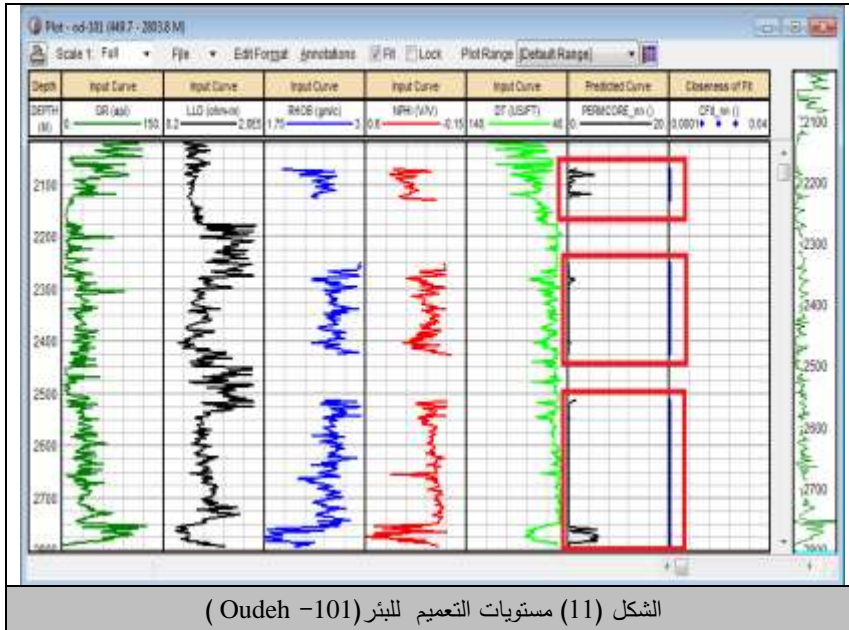
### 10- تعميم نتائج الشبكة على آبار عودة:

أخيراً اخترنا آبار التعميم التي تم تنفيذ القياسات الجيوفيزيائية البئرية فيها، لكن لم تؤخذ منها عينات اللباب الصخري، ولم تتفذ فيها قياسات مخبرية على اللباب الصخري، يعني أنه لم نقم حتى بعملية التفسير الكيفية والكمية، واستخدمنا هذه الآبار؛ لتعميم نتائج اختبار الشبكة؛ والتنبؤ بقيم النفاذية، حيث تضمنت القياسات كلاً من (NPHI-RHOB-DTLLD-GR) المنفذة في الآبار التي تعد عناصر الدخل. لا بد من الإشارة هنا إلى أنه لا بد من توفر نفس القياسات التي تم تدريب الشبكة عليها واختبارها في الآبار التي يتم التعميم عليها. تم التعميم على ثلاث آبار، هي: عودة (Oudeh- 101)، وعودة (Oudeh- 102)، وعودة (Oudeh- 104)، وراعينا أيضاً ظروف البئر، حتى لا يؤثر ذلك في استجابات كل من قياسات الكثافة والنيوترون.

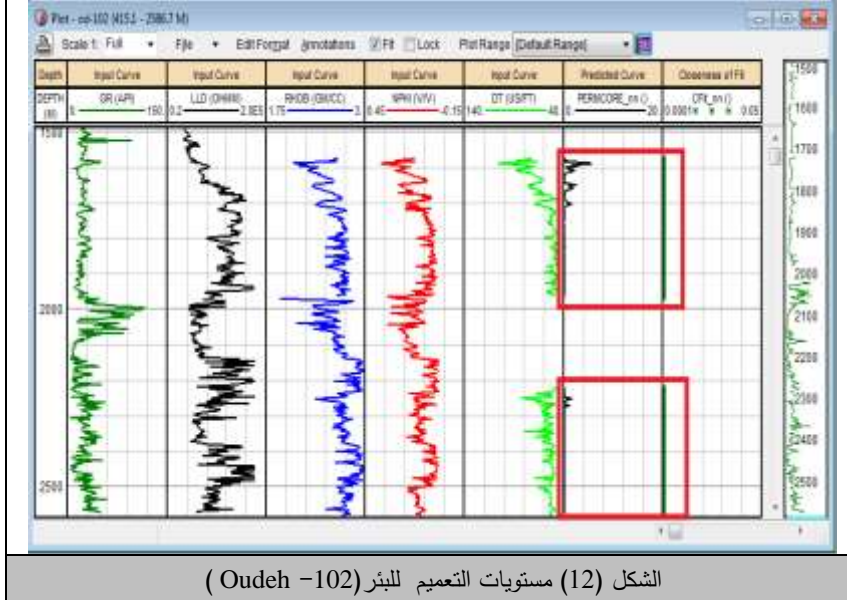


### 10-1- تعميم نتائج الشبكة على بئر عودة (101-Oudeh):

بعد اختبار الشبكة تبين أن قيمة الدقة في الحصول على نفاذية أقرب ما يمكن من النفاذية المقيسة على عينات اللباب الصخري ونسبة تجاوزت 97%. قمنا ببناء على ذلك بإدخال بيانات القياسات الجيوفيزيائية للبئر عودة (101-Oudeh) إلى الشبكة؛ متضمنة كامل المجال العمقي المقيس من قبل مدخلات الشبكة، لكن دون إدخال معطيات اللباب الصخري كهدف للتنبؤ بقيم النفاذية، وتم بالنتيجة التنبؤ بمنحني قيم النفاذية في بئر عودة (101-Oudeh) ، ويظهر مستويات التعميم، كما هو موضح في الشكل (11).

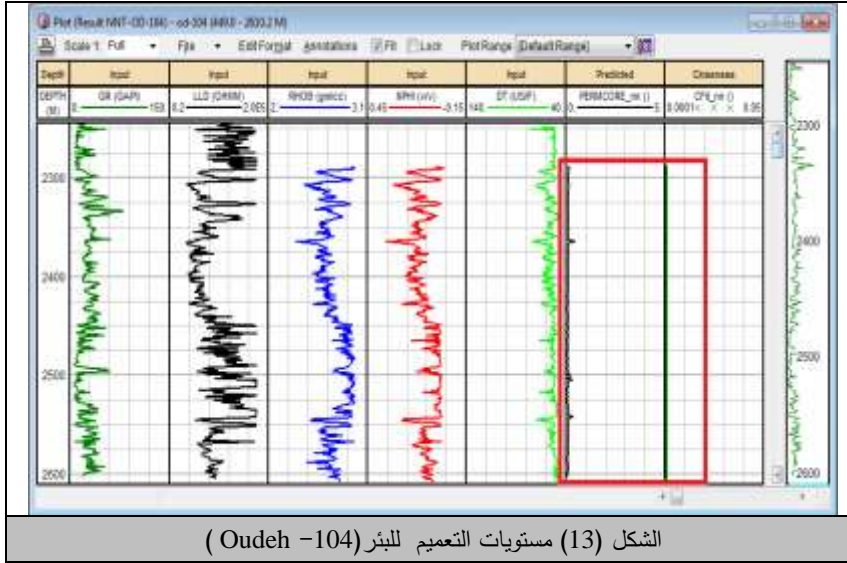


كما قمنا بتعميم الشبكة على بئر عودة (Oudeh-102) ، وتم التنبؤ بمنحني قيم النفاذية من خلال المستويات العميقة التي تتوفر فيها مدخلات الشبكة، كما هو موضح في الشكل (12).



الشكل (12) مستويات التعميم للبئر (Oudeh -102)

كما قمنا بتعميم الشبكة على بئر عودة (Oudeh-104)، وتم التنبؤ بمنحني قيم النفاذية من خلال المستويات العميقة التي تتوفر فيها مدخلات الشبكة، كما هو موضح في الشكل (13).



## 11- النتائج:

لقد كان الهدف الرئيس من هذا البحث هو التنبؤ بقيم النفاذية في آبار لم يتم فيها أخذ عينات لباب صخري ومقيسة النفاذية مخبرياً، والتي كانت مخرجاً عند استخدام الشبكة العصبونية ذات الانتشار العكسي للخطأ (BP-ANN) (Back-Propagation Neural Network)، واتسمت التقانة المستخدمة ببساطة العلاقات الرياضية المستخدمة، وسرعتها في المعالجة. قمنا بتطبيق الشبكات العصبونية الصناعية، واستفدنا من خمسة تسجيلات من القياسات الجيوفيزيائية البئرية، وكانت كمجموعة دخل (GR-LLD-RHO-NPHI-DT)؛ باستخدام برنامج التفسيرات البئرية (IP-V3.5) Interactive Petrophysics؛ فضلاً عن مجموعة عناصر الخرج المتمثلة بقياسات النفاذية المنفذة مخبرياً على عينات اللباب الصخري المقطع، فهما العامل الأساسي في تحديد القيم المتنبئ بها.

استخدمت الشبكات العصبونية الصناعية؛ باستخدام برنامج IP-V3.5 للتنبؤ بمنحني قيم النفاذية على ثلاث آبار، هي: عودة (101 - Oudeh)، وعودة (102 - Oudeh)، وعودة (104 - Oudeh)، وراعينا أيضاً ظروف البئر، حتى لا يؤثر ذلك في استجابات كل من قياسات الكثافة والنيترون.

تمكنا من خلال هذه التقانة من تحقيق هدف البحث والتنبؤ بـقيم النفاذية، وبدقة عالية تجاوزت 97%؛ مما يعزز أهميتها في الصناعة النفطية والتقييم البتروفيزيائي للخزانات.

إن تحقيق هذا الهدف يؤمن مخرجات ذات موثوقية عالية، كما يوفر الكثير من الجهد والمال والوقت، خاصة عندما نعلم أن تكلفة حفر اللباب الصخري يفوق بحوالي خمسة آلاف ضعف تكلفة تنفيذ القياسات الجيوفيزيائية البئرية.

المراجع:

- [1] Asquith, G., Gibson, Ch. (1982). **Basic well log analysis for earth geologists**, USA, 234P
- [2] Salehi, M.M. et al. (2016). Estimation of the non-records logs from existing logs using artificial neural networks, Egypt, Egyptian Journal of Petroleum, Pp5-9.
- [3] Krygowski, D.A. (2003). **Guide to Petrophysical Interpretation**, Austin Texas USA, 147p.
- [4] Bateman, R.M. (1991). **Well logging tools and techniques, GL402, Petroleum geology**, IHRDC publishers, Boston-USA, 279p.
- [5] Bateman, R.M. (2012). **Openhole Log Analysis and Formation evaluation**, Second Edition, Society of Petroleum Engineers, USA, 667p
- [6] Sinopec Company. (2010). Field Development Plan of Shiranish B in Oudeh Oilfield, Syria, unpublished study, Damascus –Syria.p: 207-250.
- [7] الشركة السورية للنفط، الوحدات الجيو نفطية في سورية، تقرير داخلي غير منشور .
- [8] Brew، G.، Litak، R.، Barazangi، M. (1999). Tectonic Evolution of Northeast Syria: Regional Implications and Hydrocarbon Prospects، Bahrain، GeoArabia، Vol. 4، No. 3، p290.
- [9] Saputro, O.D., Maulana, Z.L., Latief, F.D. (2016). Porosity log prediction using artificial neural network, IOP SCIENCE, Journal of Physics, 739 012092
- [10] Saputro, O.D., Maulana, Z.L., Latief, F.D. (2016). Porosity Log Prediction Using Artificial Neural Network, IOP SCIENCE, Journal of Physics, Vol. 29, Pp1-4.
- [11] Patniyot, S., Romero, P.A., (1998). Application of core-log correlation and artificial neural networks to better define permeability, porosity and lithology, PDVSA – INTEVEP, SCA-9836, Pp1-5.

- [12] Hsieh, B.-Z., Wang, CH.-W., Lin, Z.-SH. (2009). Estimation of formation strength index of aquifer from neural networks, Computers & Geosciences, vol. 35, 1933–1939.
- [13] Huang, Z., Shimeld, J., Williamson, M., Katsube, J. (1996). Permeability prediction with artificial neural network modeling in the Venture gas field offshore eastern Canada, research gate, article, Geophysics: vol. 61, no. 2, pp. 422-436.
- [14] Hsieh, B.-Z., Wang, CH.-W., Lin, Z.-SH. (2009). Estimation of formation strength index of aquifer from neural networks, Computers & Geosciences, vol. 35, 1933–1939.
- [15] صونيا جلغة، د. علي العجي، ا. د.م. جورج كراز-2018 تقييم التشكيلات باستخدام أنظمة الذكاء الصناعي في حقول ساربا النفطية - أطروحة ماجستير - جامعة دمشق.
- [16] Help Interactive Petrophysics V3.5,1,2 Senergy ,2008
- [17] Qadir, F.M. (1991). **Formation Evaluation of Reservoir**, Khabbaz Oil Field, NE Iraq, PHD thisis, Iraq, vol.4, p96-97.
- [18] Serra, O. (1984). **Fundamentals of well-log interpretation**, Elsevier Science Publishers B.V., 435p.
- [19] Schlumberger, **Introduction to Openhole Logging, Schlumberger Interpretation** Textbook, 96p.
- [20] Bateman, R.M. (1988). **Introduction to well logging**, GL401, Petroleum geology, IHRDC publishers, Boston-USA, 348p.
- [21] بحبوح، أ. (2009). **توظيف الذكاء الصناعي في أمثلة أداء نظم المعطيات الصناعية الموزعة، أطروحة دكتوراه، دمشق، الفصل 1، ص 22**
- [22] Haykin, S. S., 1999, **Neural Networks: A Comprehensive Foundation**. Prentice Hall.
- [23] Kalman, B. L., and Kwasny, S. C., 1992, **Why Tanh: choosing a sigmoidal function**, International Joint Conference on Neural Networks, 4, 578-581.

- [24] Garcia-Pedrajas, N., Hervas-Martinez, C., & Munoz-Perez, J. COVNET: , (2003), "A cooperative co-evolutionary model for evolving artificial neural networks." IEEE Transaction on Neural Networks, 14, 575–596.
- [25] Hornik, K., Stinchcombe, M., White, H., (1990), "Universal approximation of an unknown mapping and its derivatives using multilayer feed forward networks." Neural Networks, 3(5):551–60.
- [26] Karraz, G. (2006). **Electrocardiogram signal automatic analysis**, Doctoral Thesis, University of Pavia, Italy, vol.7, pp 75-83.