

تقدير قيم المسامية في حقل أبو رباح باستخدام الشبكات العصبونية الاصطناعية

د. علي العجي*

الملخص

اكتسبت تقنيات الذكاء الاصطناعي وخاصة الشبكات العصبونية في السنوات الأخيرة أهمية كبيرة في حل المسائل اللاخطية المعقدة. النفاذية والمسامية والإشباع المائي هي بارامترات أساسية في الأنظمة الخزنية، والتي تقسم نموذجياً إلى ساعات غير منتظمة وبطريقة لا خطية.

في هذا السياق، فإنه يمكن التنبؤ بالمسامية من البيانات البئرية باستخدام الشبكات العصبونية وتقنيات أخرى معتمدة على الحاسوب مناسب جداً.

تهدف الدراسة الحالية إلى التنبؤ بقيم المسامية الفعالة من المعطيات الرقمية للقياسات الجيوفيزيائية البئرية والقياسات المخبرية المنفذة على اللباب الصخري في حقل أبو رباح، باستخدام الشبكة العصبونية الاصطناعية، حيث استخدمت القياسات الجيوفيزيائية البئرية التالية كمدخلات للشبكة العصبونية الاصطناعية للتنبؤ بقيم المسامية (تسجيل أشعة غاما الطبيعي GR، وتسجيل قياس المقاومة العميقة Rt ، وتسجيل قياس الكثافة الصخري RHOB، وتسجيل قياس المسامية النترونية NPHI، وتسجيل قياس أزمنة الارتحال الصوتية DT)، كما استخدمت قياسات المسامية

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

المنفذة على اللباب الصخري كهدف لاختبار صحة التنبأ بالمعطيات، فتم اختبار دقة منهجية الشبكة العصبونية ANN في إيجاد قيم المسامية الفعالة، فكانت بدقة وسطية أعلى من 98%، ويعكس هذا التوافق الممتاز للبيانات الأساسية مع دقة القيم المتنبأ بها من خلال الدراسة، قدرة هذه التقنية على التنبؤ بالخواص الخزنية، مما يجعلها طريقة سريعة ودقيقة، وإحدى التقنيات الهامة في التقييم الخرنى.

الكلمات المفتاحية: حقل أبو رباح، قياسات بئرية، مسامية فعالة، لباب صخري، شبكة عصبونية، برنامج التفسير البئرى (IP 3.5)

Estimation of Porosity in Abu Rabah field using Artificial Neural Networks

Dr. Ali alaji*

Abstract

In recent years, artificial intelligence techniques and neural networks in particular, have gained popularity in solving complex nonlinear problems. Permeability, porosity and fluid saturation are three fundamental characteristics of reservoir systems that are typically distributed in a spatially non-uniform and non-linear manner.

In this context, porosity prediction from well log data is well-suited using neural networks and other computer-based techniques.

The present study aims to estimate formation porosity from digital well log data and experimental lab measurements on the core of Abu Rabah field using an artificial neural network (ANN) approach. Five well log data were used as inputs in the ANN to predict porosity responses: Gamma Ray Log (GR), Deep Resistivity (Rt), Formation Density (DEN), Neutron Porosity (PHIN) and Density Porosity (PHID). Core porosity were used as target data in the ANN to test the prediction. The accuracy of the ANN approach was tested by regression plots of predicted values of porosity with core porosity, and it was higher than 98%. This excellent matching of core data and predicted values reflects the accuracy of the ANN technique and its usability as a fast and accurate method for the prediction of reservoir properties and in reservoir modeling and characterization.

Keywords: Abu Rabah fields, well logging, Effective porosity, Cores, Neural Network, Interactive Petro physics V3.5

* Assistant Professor, Department of geology, Faculty of Sciences, Damascus University, Syria.

1- مقدمة:

تعد القياسات الجيوفيزيائية البئرية عبر تقنياتها، المتسارعة في التطور من خلال سوابر القياس، ومن خلال تقنيات السوابر المركبة والحديثة، إضافة لبرامج التفسير عبر الاصدارات المتتابة والمتطورة، العصب الرئيس في الصناعة النفطية، ويصب جميع ما تقدم في أهمية ذلك بالحصول على جودة المعلومة ودقتها العالية، وبأقل التكاليف في تقييم الخزانات الهيدروكربونية وبالتالي المساهمة في إدارتها على حد سواء. يعد علم البتروفيزياء جزءاً لا يتجزأ من علم تقييم التشكيلات، وتحديد الخواص الخزنية وفهم الخزانات، وإعطاء صورة واضحة عن هذه الخزانات، وتشكيلاتها بهدف معرفة كمية الاحتياطي، وفهم طبيعة الخزانات ومواصفاتها، وبالتالي فهم وتوجيه عمليات الإنتاج، وزيادة المردود الاقتصادي. لذلك ارتكزت الدراسات الحديثة في معظم تطورات علوم الجيوفيزياء، وبرامج تفسيرها على التقنيات الحديثة والمتطورة كالذكاء الاصطناعي (Artificial Intelligence (AI)، ومنها عمليات التنبؤ بالخصائص الخزنية وعمليات التقييم الخزني، حيث تتميز هذه التقنيات بقدرتها على الربط بين المدخلات والمخرجات بعلاقات لا خطية [1].

تعد المسامية إحدى الخصائص الخزنية الهامة، التي يسعى مهندسو المخزون إلى تحديدها، فهي تعبر عن حجم الفراغ الموجود في الهيكل الصخري بالنسبة لحجم الصخر الكلي متضمنة جميع أنواع الفراغات (مسامية كلية)، [2]. ويرمز للمسامية بالرمز Φ ويعبر عنها كنسبة مئوية % تأخذ المجال [0 - 1]، أما المسامية الفعالة فهي ذلك الجزء من المسامية الكلية الذي يعبر عن الفراغات المتصلة، والتي تسمح بمرور الموائع، وتحسب من القياسات الجيوفيزيائية البئرية بالمعادلة (1)، [3].

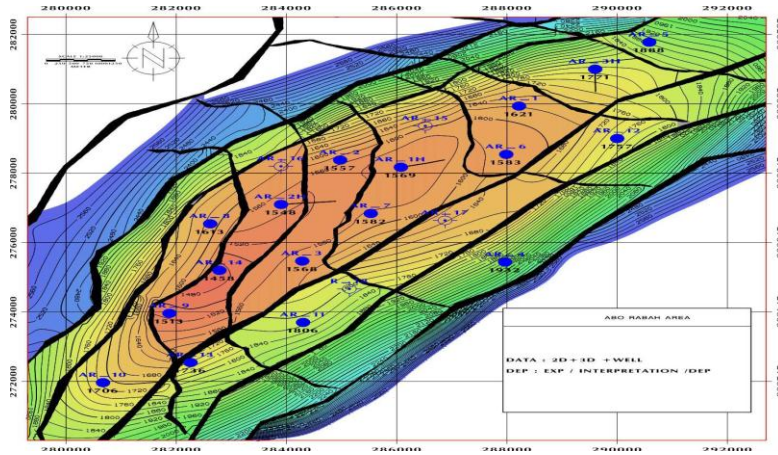
$$\phi_e = \phi_t (1 - V_{sh}) \quad (1)$$

حيث: \emptyset_e المسامية الفعالة، \emptyset_t المسامية الكلية، V_{sh} حجم الغضار
ليس بالضرورة أن تتطابق قيم المسامية 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 البئرية تتعامل مع الحيز
الصخري المقاس بحجم أكبر، تبعاً لقدرة تمييز السابرة وكذلك تبعاً إلى عمق
اختراقها، [4] .

2- منطقة الدراسة:

تم تنفيذ الدراسة في حقل أبو رياح قمنا بدراستنا هذه معتمدين على المعطيات
المأخوذة من آبار الحقل المذكور، والذي يُعد أحد أهم التراكيب الغازية في حوض
الدو، ولعل التعقيد التكتوني الكبير الذي تعرضت له المنطقة خلال التاريخ الجيولوجي،
والتي أنتجت عوامل ترسيبيه وتكتوينه أنتجت سماكات من المتبخرات، والذي أثر
بشكل مباشر على تشكيلة الكوراشينا دولوميت الخازنة والمشبعة بالغاز .

يقع حقل أبو رياح في وسط غربي سوريا (بلوك أبو رياح) ضمن حوض الدو الى
الجنوب الشرقي من مدينة حمص حوالي (74 كم) ويقع شمال شرق دمشق بـ 513
كم، في الجزء الأوسط من سورية الشكل (1). يقع حقل أبو رياح ضمن البلوك
الاستكشافي للشركة السورية للنفط، ويتوسط حقول شمال الفيض والفيض وقمم. وهو
من أهم الحقول الغازية في سوريا التي تنتج الغاز من خزان كوروشينا دولوميت،
ويمثل هذا التركيب بنية تحت سطحية، تتألف من طية محدبة متطاولة اتجاهها
شمال شرق - جنوب غرب [5] .



الشكل (1) الوضع البنيوي لمنطقة الدراسة ومواقع الابار (الشركة السورية للنفط (SPC) [5]

3- الدراسات السابقة:

أجريت على تشكيلة الهدف مجموعة من الدراسات الأولية من قبل الشركة السورية للنفط والشركات الأجنبية [6]، [7]، واهتمت تلك الدراسات بالتراكيب البنية للحقل والتشكيلات المتعاقبة وبالخصائص الخزنية لهذه التشكيلات وقدراتها الإنتاجية؛ حيث خضعت مكونات التشكيلة لدراسات وقياسات جيوفيزيائية بئرية، واقتطع منها مئات الأمتار من اللباب الصخري بالاتجاهين الأفقي والشاقولي، وانجزت عليها قياسات مخبرية متنوعة، والتي كانت مساعدة لنا في انجاز هذه الدراسة وتطبيق هذه التقنية. إضافة إلى ذلك فقد أنجزت 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 للطبقات تحت السطحية كالمسامية والنفاذية، وتحديد المحتوى الكلي للكربون العضوي إضافة الى خواص اخرى.

- استخدم Saputro *et al.* 2016، التنبؤ بمنحني المسامية الفعالة 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 اللباب الصخري والقيم المتنبأ بها $R=0.90$ في بئر الاختبار الأول و $R=0.87$ في بئر الاختبار الثاني [9].
- استخدم Patniyot and Romero، 1998، التنبؤ بقيم المسامية والنفاذية باستخدام الشبكة العصبونية ذات الانتشار الخلفي، بالاعتماد على القياسات الجيوفيزيائية البئرية والقياسات المنفذة على اللباب الصخري، فكانت قيمة معامل الارتباط من أجل المسامية $R=0.96$ ومن أجل النفاذية $R=0.83$ [10].
- قام Salehi *et al.*, 2016، التنبؤ بالقياسات المفقودة باستخدام الشبكة العصبونية متعددة الطبقات في حقل نفطي جنوب غرب إيران باستخدام بيانات لثلاث آبار للتنبؤ بقياس الصوتية ΔT 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 التقنية 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 DT [1].
- استخدم Sultan *et al.*, 2013، التنبؤ بقيم النفاذية في حقل غاز هاننينغ شمال شرق بنغلادش باستخدام الشبكة العصبونية ذات الانتشار الخلفي؛ 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 Huang *et al.*, 1996، التنبؤ بقيم النفاذية في حقل غاز فينتور في شرق كندا، باستخدام خوارزمية الانتشار الخلفي [13]؛ حيث تم استخدام خمس آبار في حقل فينتور للتنبؤ بالنفاذية، واستخدمت أربعة آبار كقاعدة بيانات لتدريب الشبكة العصبونية، وتم اختبار الشبكة بالبئر الخامس، وتم التنبؤ بقيم النفاذية المطلوبة وكانت قيمة معامل الارتباط الخطي $R=0.8$.
- اختبر Hsieh *et al.*, 2009، تقدير نسبة معامل قص الصخر إلى انضغاطيته باستخدام الشبكات العصبونية الاصطناعية؛ حيث تم تطبيق خوارزمية الانتشار الخلفي للحصول على النتائج [14]، فكان معامل الارتباط $R=0.97$ وتعتبر بيانات التحقق والنتائج عند اختبار أداء الشبكة.
- ومؤخراً قامت صونيا جلعة 2018 بدراسة حول تقييم التشكيلات باستخدام أنظمة الذكاء الاصطناعي في حقول سارابا النفطية-سوريا [15]. فتم التنبؤ بقيم المسامية الفعالة والنفاذية وكذلك التنبؤ بمنحني القياسات الصوتية المفقودة في أحد الآبار.

4- الهدف من البحث:

استخدام تقنية الشبكات العصبونية الاصطناعية من أجل التنبؤ بقيم المسامية الفعالة في بئر من آبار منطقة الدراسة، والذي لم يتم فيه اقتطاع عينات اسطوانية من اللباب الصخري (core)، انطلاقاً من تسجيل القياسات الجيوفيزيائية البئرية وقياسات المسامية المنفذة مخبرياً على عينات اللباب الصخري

5- مواد البحث وطرائقه:

تم الاستفادة من المعطيات المتوفرة في الشركة السورية للنفط لإنجاز البحث والتي تمثلت بـ:

- القياسات الجيوفيزيائية البئرية (Well Logs) المنفذة في الآبار غير المكسية، التي كانت متوفرة لدى الشركة السورية للنفط مالكة حقل الدراسة وكانت بصيغة . Las، ASCII

- معطيات اللباب الصخري وشملت القياسات المخبرية المنفذة على العينات الأسطوانية المقطعة من اللباب الصخري (core)، والتي تمثل قياسات المسامية، وقد تم الحصول عليها من مديرية المخابر التابعة للشركة السورية للنفت. استخدمنا في دراستنا تقنية الشبكات العصبونية الاصطناعية التي تعد إحدى تقنيات الذكاء الاصطناعي، في تقدير المسامية الفعالة في حقل أبو رياح الغازي. تم استخدام معطيات القياسات الجيوفيزيائية البئرية، وقمنا بتقسيم معطيات القياسات المخبرية المنفذة على اللباب الصخري المأخوذة من البئر (أبو رياح -3) إلى مجموعتين واحدة لتدريب الشبكة، وأخرى لاختبار أداءها هذه الشبكة، كونه لم يتوفر عينات لباب صخري سوى في هذا البئر.


6- المبدأ النظري لأنظمة الذكاء الاصطناعي:

لعل غزارة المعطيات المقاسة وكمية البيانات المتاحة في معظم العلوم التطبيقية، وعدم وجود علاقات رياضية أو طرق يتم من خلالها ربط القيم الناتجة خاصة في طرائق الاستكشاف الجيوفيزيائية ومنها القياسات الجيوفيزيائية البئرية، مع تلك التي تنفذ مخبرياً على عينات اللباب الصخري. سمح ذلك بأن تتوجه أنظار العلماء والباحثين إلى استنباط سبل جديدة للقيام بمثل هذه المهمة، ولهذا السبب تم التفكير بأنظمة الذكاء الاصطناعي لحل هذه المهام، فكان منها عدة أنظمة نذكر منها، المنطق الترجيحي Fuzzy Logic System، الخوارزميات الجينية Genetic Algorithms والشبكات العصبونية الصناعية Artificial Neural Network وغيرها. قام العلماء على مر السنوات بدراسة سلوك الإنسان وفهم آلية تفكيره، وقدرته على الإدراك والتنبؤ وحل المشاكل، خاصة بالمسائل الأكثر تعقيداً من نفسه، وظهرت ثمرة هذه البحوث والدراسات بعد الحرب العالمية الثانية، كعلم جديد عرف بالذكاء الاصطناعي (AI) Artificial Intelligence [17]، الجدير بالذكر أن الأنظمة

الذكية لا تنفي دقة الطرائق المستخدمة سابقاً، إنما تساعد الباحث في استنباط قرارات ونتائج لعلاقات لا خطية وبدقة عالية [18].

تعد الشبكات العصبونية الاصطناعية (ANN) Artificial neural network واحدة من أهم تقنيات الذكاء الاصطناعي المستخدمة في إيجاد حلول مختلفة للمشاكل الخطية وغير الخطية، والتي عجزت عن حلها بعض تقنيات الذكاء الاصطناعي، وتعد الشبكات العصبونية محاكاة حقيقية للدماغ البشري، التي تعتمد على منهجية رياضية للتعلم تتناسب مع المشكلة المطروحة [19].

7- المنهجية المستخدمة: توصف الشبكة العصبونية حسب بنيتها وطريقة تعلمها وتابع التنشيط activation function المستخدم بها، وتتألف الشبكات العصبونية من عدة طبقات: طبقة الدخل (Input Layer)، طبقات مخفية (Hidden Layer)، وطبقة الخرج (Output Layer) والوصلات البينية (الأوزان)، (Haykin, 1999)، [19]. يوضح الشكل (2) هندسة الشبكات العصبونية للدراسة الحالية.



الشكل (2) بنية الشبكة العصبونية المقترحة لتقدير المسامية الفعالة

7-1- طبقة المدخلات Input Layer: يتم عبرها تغذية الشبكة ببيانات الدخل، وتستقبل البيانات بواسطة وحدات المعالجة (العصبونات) التي تتألف منها الشبكة، ويمكن أن تكون واحدة أو أكثر تبعاً لتركيبة الشبكة. يمكن أن تكون مدخلات الشبكة

بيانات خام (Raw Data) أو قد تكون مخرجات من عناصر معالجة أخرى، وتكون البيانات المدخلة إلى الشبكة إما ثنائية (Binary) أو متصلة (Continuous) ويتوقف ذلك على نوع القيم العددية المستخدمة [18]. وحدات المعالجة في طبقة الإدخال لا يتم فيها معالجات حسابية بل تقوم بنقل البيانات المدخلة من هذه الطبقة عبر الوصلات البيئية (الأوزان) إلى وحدات المعالجة في الطبقة الخفية أو إلى وحدات المعالجة في طبقة المخرجات إذا كانت الشبكة لا تحتوي على طبقة خفية وأي شبكة عصبية تحتوي طبقة إدخال واحدة فقط.

2-7- طبقة المخرجات: Output Layer : تتكون هذه الطبقة من وحدات المعالجة التي عبرها يتم إخراج الناتج النهائي للشبكة. وقد تحتوي هذه الطبقة على وحدة معالجة واحدة أو أكثر من وحدة وفقاً للبنية الهندسية للشبكة. تستقبل وحدات المعالجة في طبقة المخرجات الإشارات القادمة إليها من طبقة الإدخال مباشرة أو من الطبقة الخفية، وبعد إجراء المعالجات اللازمة قد ترسل إشارة بالمخرجات النهائية، أو قد تقوم بإعادة هذه 2-7- **الطبقة الخفية: Hidden Layer**: تقع هذه الطبقة بين طبقة المدخلات وطبقة المخرجات وقد لا تحتوي بنية بعض الشبكات على الطبقة الخفية وقد تحتوي على طبقة خفية واحدة أو أكثر. تستقبل الطبقة الخفية الإشارات القادمة إليها من طبقة المدخلات عبر الوصلات البيئية، فتقوم بمعالجتها وإجراء اللازم عليها ومن ثم إرسالها عبر الوصلات إلى طبقة المخرجات، [18].

4-7- الوصلات البيئية (الأوزان: Connections): تعمل كوصلات اتصال بين الطبقات المختلفة وتقوم بربط الطبقات مع بعضها أو الوحدات داخل كل طبقة عبر الأوزان، ومهمة هذه الوصلات نقل البيانات أو الإشارات الموزونة بين وحدات المعالجة أو الطبقات. يتميز العصبون بوزن ادخال وعتبة وعوامل تنشيط خطية أو لا خطية، فيرتبط العصبون في الطبقة الواحدة بالطبقات الأخرى بواسطة الوزن (Connecting

(Weights) [18]، لذلك فإن المخرجات هي عوامل لا خطية لجمع أوزان المدخلات واتجاهاتها.

7-5- وحدات المعالجات (العصبونات): - Processing Elements: وحدات المعالجة أو العصبونات هي الوحدات التي تقوم بعملية معالجة المعلومات في الشبكة العصبونية وتشكل المكونات الأساسية التي تتألف منها كل طبقات الشبكة العصبونية وتتصل هذه الوحدات بطرق مختلفة بواسطة الوصلات البينية لتعطي البنية الهندسية للشبكة العصبونية الاصطناعية. وتتألف أي وحدة معالجة أو عصبون من (معاملات الأوزان weighting Coefficients - دالة الجمع

الإخراج دالة Transfer Function التحويل - دالة Summation Function Output Function

إضافة لمعاملات الأوزان (weighting Coefficients) [18]، ويعد الوزن هو العنصر الرئيسي في الشبكات العصبونية الاصطناعية، فهي تمثل الروابط المختلفة التي يتم عبرها نقل البيانات من طبقة إلى أخرى، ويعبر الوزن عن القوة النسبية أو الأهمية النسبية لكل مدخل إلى عنصر المعالجة، [19]. وتمثل الأوزان الوسيلة الأساسية لذاكرة الشبكة العصبونية من خلال ضبط الأوزان ويرمز للوزن بين عنصري معالجة (i) و (j) بالرمز (Wij)، [20]. المعادلة (2).

$$S_j = \sum_{i=1}^n x_i w_{ij} \text{ --- --- --- --- (2)}$$

8- النتائج والمناقشة:

قمنا من خلال الدراسة بتحديد عناصر دخل الشبكة؛ حيث اعتمدنا في ذلك على العلاقة بين كل عنصر من عناصر دخل الشبكة مع قيمة المسامية في طبقة الخرج، حيث يعد كل من تسجيل قياس الكثافة الصخري، وقياس تسجيل ازمنا الارتحال

الصوتية، وقياس تسجيل النترون من القياسات التي تستخدم لحساب المسامية باستخدام القياسات الجيوفيزيائية البئرية، أما قياس تسجيل المقاومة العميقة فهو يشير إلى مقاومة المائع الذي يملأ الفراغ المسامي، وبالتالي فإن المقاومة العميقة المقاسة، ترتبط بعلاقة خفية مع الفراغ المسامي للصخر وهي مؤشر غير مباشر للمسامية، وعليه تم اتباع المراحل الآتية:

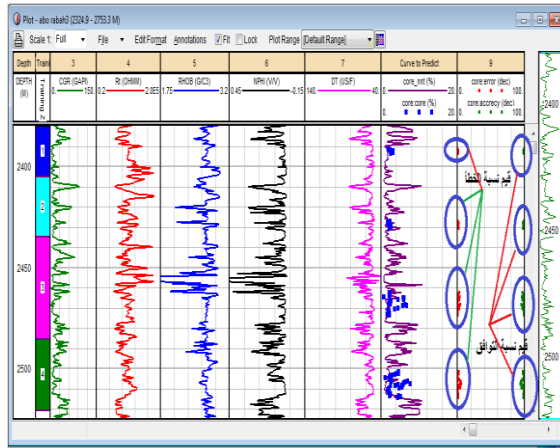
8-1-1- تحضير البيانات للعمل على الشبكة العصبونية: تم تقسيم قاعدة بيانات منطقة الدراسة إلى مجموعتين:

8-1-1- مجموعة بيانات التدريب: لقد تضمنت بيانات التدريب كل القياسات المتوفرة ضمن القياسات البئرية والتي تم تنفيذها من قبل شركة شلمبرجير لصالح الشركة السورية للنفط ، والتي كانت بصيغة (Las،Delis) ، والتي ضمت كل من قياسات تصحيح تسجيل غاما الطبيعي (CGR) وقياسات المقاومة العميقة (Rt) وقياس تسجيل الكثافة الصخري (RHOB) وقياس التسجيل النيوتروني (NPHI) وتسجيل ازمة الارتحال (DT) اضافة الى القياسات المخبرية المنفذة على اللباب الصخري المتوفرة في بئر (ابو رياح -3)، والتي استخدمناها لتدريب الشبكة العصبونية واكتساب خبرتها ضمن بنيات الشبكات التي يعتمدها برنامج التفسير البتروفيزيائي (IP V3.5) [16]. حيث قمنا بتنظيم مجموعة بيانات الهدف ضمن جدول، تضمن العمود الأول قيمة العمق يقابله قيمة المسامية المقاسة على اللباب الصخري، لمعرفة المجالات التي تم أخذ اللباب الصخري منها وعدد العينات المأخوذة ضمن كل مجال، وحفظت ضمن ملفات بصيغة txt، كملف منفرد وتم تحويلها الى صيغة ASCII. تم تقسيم العينات اللبابية من بئر أبو رياح-3 الى قسمين، فكان القسم الأول مؤلف من 4 عينات (87 نقطة قياس) والتي استخدمت لتدريب الشبكة الجدول رقم (1).

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

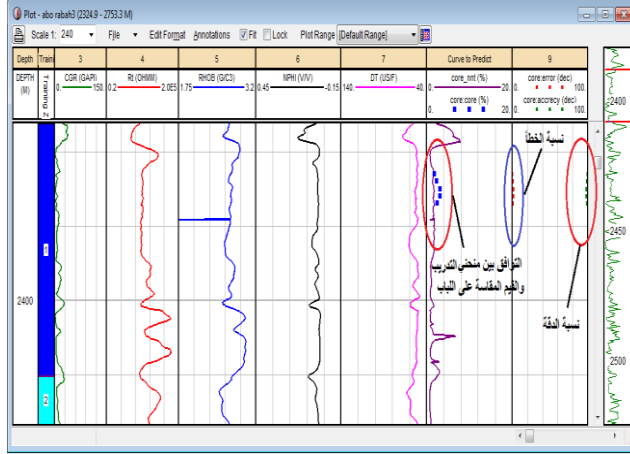
Well name	Depth interval (M)	Samples No.
أبو رياح -3	2395-2390	6
	2426-2431	10
	2460-2475	31
	2500-2515	40

يبين الشكل (3) نتائج بيانات التدريب للشبكة في بئر أبو رياح -3 للتنبؤ بقيم المسامية، ويظهر الشكل توافق منحنى تدريب الشبكة مع قيم المسامية المقاسة على عينات اللباب الصخري، وبأقل خطأ ممكن تبعاً للأعماق بين (2324.9 - 2753.3) والتي تم تجزئتها لاحقاً لأربعة مستويات عميقة، كما في الشكل (3). وتم حساب قيم نسبة الخطأ وقيم نسبة التوافق بين بيانات تدريب الشبكة والقيم المقاسة على اللباب تبعاً للمستويات الأربعة.



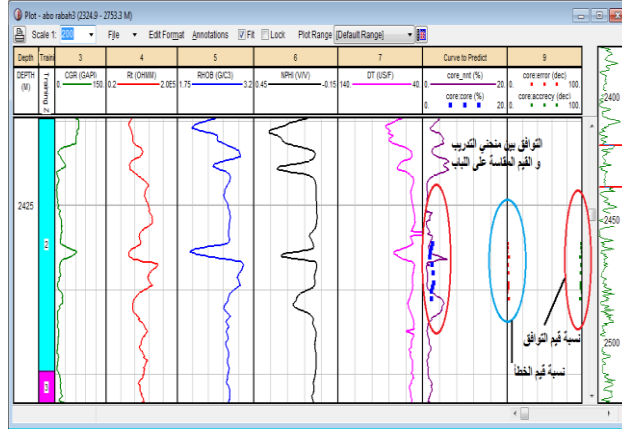
الشكل (3) يوضح بيانات التدريب للشبكة في بئر أبو رياح -3

بهدف التوضيح، تم إظهار منحنى تدريب الشبكة مع قيم المسامية المقاسة على عينات اللباب الصخري بمقياس أكبر للمستوى الاول في المجال العمقي (2390-2395) من بئر أبو رياح -3، شكل (4).

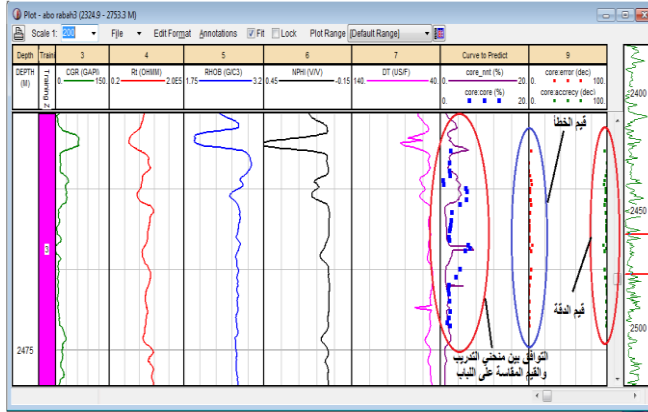


الشكل(4): يوضح بيانات التدريب للشبكة في المجال (2390-2395) من بئر ابو رياح -3

كذلك الامر بهدف التوضيح، تم إظهار منحنى تدريب الشبكة مع قيم المسامية المقاسة على عينات اللباب الصخري في بئر أبو رياح -3 بمقياس أكبر، للمستوى الثاني في المجال العمقي (2426-2431) شكل (5).

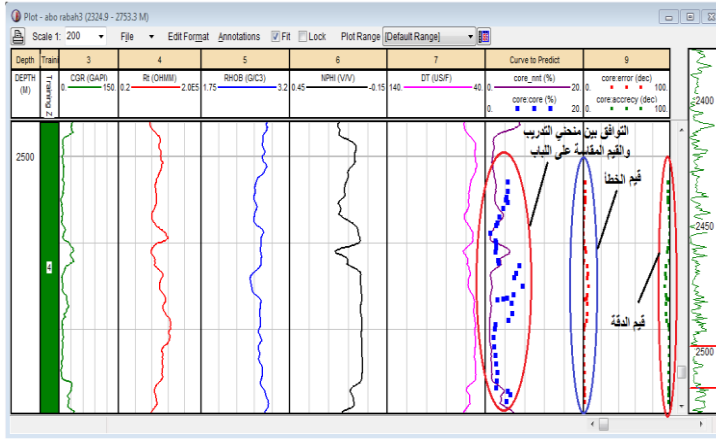


الشكل (5) يوضح بيانات التدريب للشبكة في المجال (2426-2431) من بئر أبو رياح -3 كذلك الامر بهدف التوضيح، تم إظهار منحنى تدريب الشبكة مع قيم المسامية المقاسة على عينات اللباب الصخري في بئر أبو رياح -3 بمقياس أكبر، للمستوى العميق الثالث في المجال (2460-2475)، شكل (6).



الشكل (6) يوضح بيانات التدريب للشبكة في المجال (2460-2475) من بئر أبو رياح -3

كذلك الامر بهدف التوضيح، تم إظهار منحنى تدريب الشبكة مع قيم المسامية المقاسة على عينات اللباب الصخري في بئر أبو رياح 3- بمقياس أكبر، للمستوى الرابع في المجال العمقي (2500-2515)، الشكل (7).



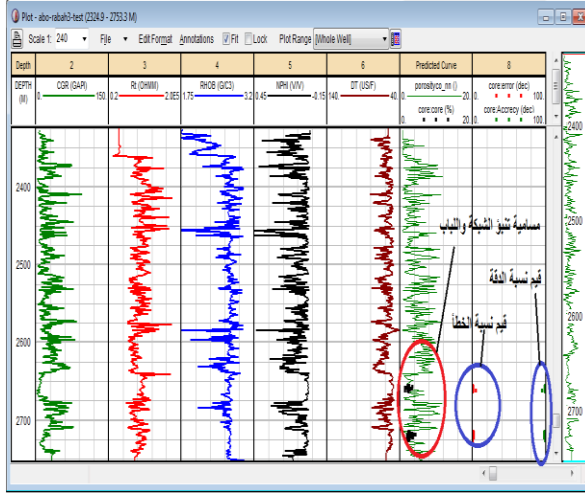
الشكل (7) يوضح بيانات التدريب للشبكة في المجال (2500-2515) من بئر أبو رياح 3-

8-1-2- مجموعة بيانات الاختبار: تضمنت مجموعة القياسات الجيوفيزيائية البئرية وقياسات المسامية المنفذة على اللباب الصخري في بئر (أبو رياح 3-)، والتي تم تحديدها للاختبار أداء الشبكة العصبونية في عملية التنبؤ بقيم المسامية، وكانت مؤلفة من عينتين للاختبار (56 نقطة قياس)، والتي يشترط أن تتوفر بمجالها العمقي، مدخلات تدريب الشبكة إضافة للقياسات المخبرية التي تم تنفيذها على اللباب الصخري أمام المجال العمقي للاختبار، ونظمت في الجدول رقم (2)

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

Well name	Depth interval (M)	Samples No.
أبو رياح 3-	2655-2663	22
أبو رياح 3-	2722-2715	34

قمنا باختبار الشبكة العصبونية المقترحة على الجزء الآخر لبئر أبو رياح -3، للتنبؤ بقيم المسامية، وتم تمثيل بيانات الاختبار مقابل المجال العمقي (2324.9- 2753.3) وبيانات المسامية المقاسة على اللباب الصخري، والتنبؤ بمنحي التنبؤ على المجالات التي تتوفر فيها منحنيات بقياسات التي تمثل مدخلات الشبكة المدربة، كما في الشكل (8).

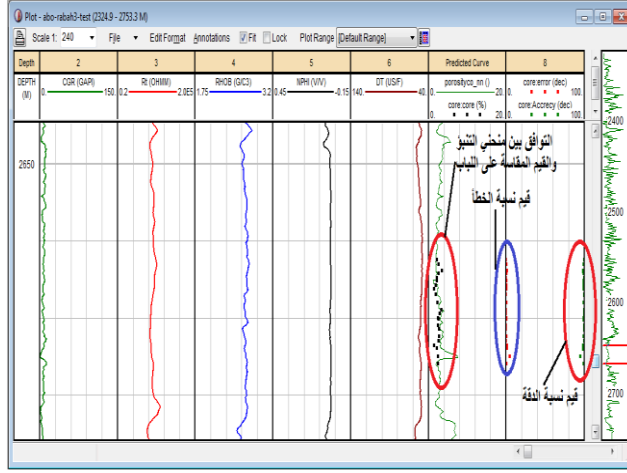


الشكل (8) يوضح بيانات الاختبار للشبكة العصبونية المقترحة للتنبؤ بقيم المسامية ببئر أبو رياح -3

نلاحظ أن قيم المسامية الناتجة عن اختبار الشبكة ANN في بئر أبو رياح -3 أقرب ما يمكن من قيم المسامية المقاسة على اللباب، وذات دقة عالية جداً حوالي 98% ونسبة خطأ صغيرة جداً، لا تزيد عن 2%.

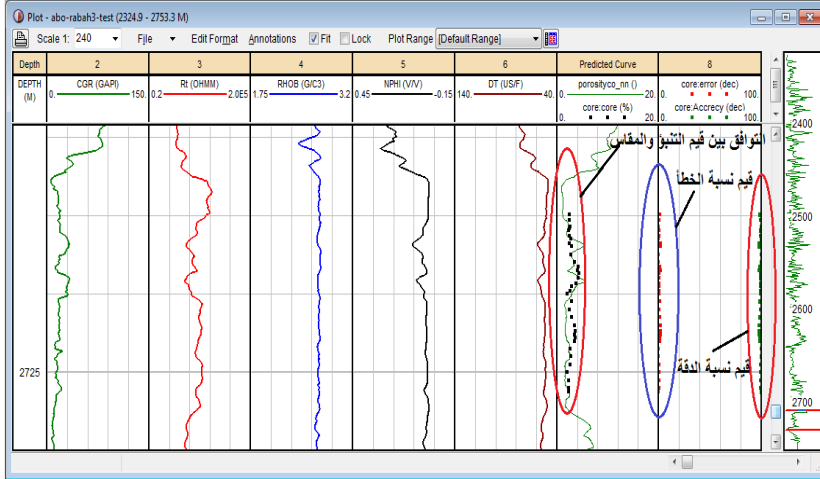
ولإظهار التوافق بشكل واضح على المنحنيات، قمنا بإظهار ذلك تبعاً لمستويات اختبار الشبكة، التي يتواجد فيها قيم للمسامية المقاسة على اللباب الصخري مخبرياً، وتم حسابها من خلال الحقلين الاخيرين والذين يمثلان نسبة الخطأ والتوافق بين قيم التنبؤ والقيم المقاسة.

يظهر الشكل (9) منحنى التنبؤ لمستويات الاختبار في المجال العمقي (2663-2655) من بئر أبو رياح -3، وإظهار نسبة الخطأ والتوافق بين قيم التنبؤ والمقاسة.



الشكل (9) يوضح بيانات الاختبار للشبكة في المجال (2655-2663) من بئر ابو رياح -3

كذلك للتوضيح، تم إظهار نتائج منحنى اختبار الشبكة، وكذلك إظهار نسبة الخطأ والتوافق بين قيم المسامية التي تم اختبارها بناء على الشبكة المدربة ومقارنتها مع القيم المقاسة على اللباب الصخري من بئر أبو رياح -3 في المجال العمقي (2715-2722) بمقياس أكبر، شكل (10).



الشكل (10) يوضح بيانات الاختبار للشبكة في المجال (2715-2722) من بئر أبو رباح 3-

8-1-3- حساب الخطأ والدقة في التنبؤ:

قمنا بحساب قيم الخطأ عند كل قيمة من القيم الناتجة عن ANN، وذلك بطرح قيمة المسامية الناتجة عن تحاليل اللباب من القيم التي تم التنبؤ بها من الشبكة العصبونية الاصطناعية ANN، [21]. فحصلنا على منحنى الخطأ err، حسب المعادلة:

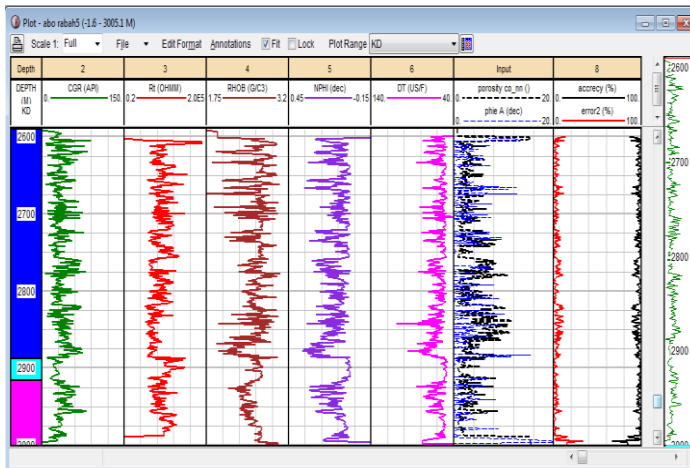
$$\text{err}(x) = \text{core Phi}(x) - \text{predicted Phi}(x) \dots \dots \dots (3)$$

كما قمنا بحساب قيم دقة أداء الشبكة في الحصول على قيم المسامية بدءاً من القياسات الجيوفيزيائية البئرية وتحاليل الأكوار، من خلال طرح قيمة الخطأ الناتجة من القيمة 100، [21]. فحصلنا على منحنى الدقة ACC من العلاقة:

$$\text{ACC}(x) = 100 - \text{err}(x) \dots \dots \dots (4)$$

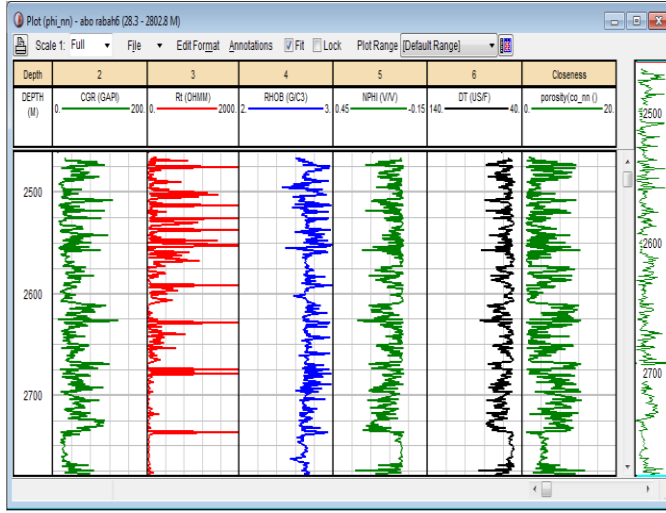
8-1-4- تعميم نتائج الشبكة على الآبار وتقييمها:

بعد اختبار الشبكة تبين أن قيمة الدقة في الحصول على مسامية أقرب ما يمكن من المسامية المقاسة على اللباب الصخري هي حوالي 98 %، قمنا بإجراء عملية تعميم الشبكة على بئر أبو رياح-5، وبناء على ذلك قمنا بإدخال بيانات القياسات الجيوفيزيائية البئر المنفذة في البئر، والتي تعد بالأساس مدخلات لتدريب الشبكة، وكذلك أخذنا من تفسيرنا البتروفيزيائي للبئر منحنى المسامية المحسوبة (phie A)، وقارناها مع نتائج مسامية الشبكة المقترحة، وتم التعميم هنا على بئر أبو رياح-5 من العمق 2590-3001 م، حيث تتوفر القياسات التي تعد مدخلات في الشبكة، ولا بد من الإشارة هنا إلى أن هذه البئر لم يقطع منها لباب، وحصلنا من تعميم نتائج الشبكة على هذه البئر، على منحنى التنبؤ بقيم المسامية وتمت مقارنتها مع منحنى قيم المسامية المفسرة والمحسوبة (phie A) وحساب الدقة في التفسير ومقارنته مع قيم الشبكة التي تعميمها عالية جداً، وكانت حوالي 98%، كما تم اظهار منحنى الخطأ error ومنحنى الدقة ACC لبئر التعميم أبو رياح-5 (بين منحنى التفسير والتنبؤ)، كما هو موضح في الشكل (11).



الشكل (11) يوضح بيانات التعميم للشبكة في بئر ابو رياح-5

كما قمنا بتعميم الشبكة على بئر أبو رياح -6 من العمق 2461 - 2780، حيث قمنا بإدخال بيانات القياسات الجيوفيزيائية البئر للبيتر، حيث تتوافر القياسات التي تعد مدخلات في الشبكة، ولا بد من الإشارة هنا إلى أن هذه البئر لم يقطع منها لباب، وحصلنا من تعميم نتائج الشبكة على هذه البئر، على منحنى التنبؤ بقيم المسامية الفعالة، الشكل (12).



الشكل (12) يوضح بيانات التعميم للشبكة العصبونية المقترحة للتنبؤ بقيم المسامية ببئر أبو رياح -6

9- النتائج:

لقد كان الهدف الرئيسي من هذا البحث هو التنبؤ بقيم المسامية الفعالة في آبار لم يتم فيه أخذ عينات اللباب الصخري ولم تنفذ قياسات مخبرية عليها، فقمنا بتطبيق الشبكات العصبونية الصناعية، واستفدنا من خمسة تسجيلات من القياسات الجيوفيزيائية البئر، وكانت كمجموعة عناصر الدخل -CGR-RD-NPHI-RHOB- (DT)، باستخدام برنامج التفسيرات البئر IP- V3.5 .

وعليه فإن مجموعة عناصر الدخل المتمثلة بالقياسات الجيوفيزيائية البئرية، ومجموعة عناصر الخرج المتمثلة بالقياسات المنفذة مخبرياً على عينات اللباب الصخري المقطع، هما العامل الأساسي في تحديد القيم المتنبئ بها. استخدمت الشبكات العصبونية الصناعية باستخدام برنامج IP-V3.5 للتنبؤ بمنحني المسامية الفعالة في آبار أبو رياح -5 وأبو رياح -6، التي لم يقطع منها عينات اللباب الصخري، ولم ينفذ عليها قياسات للمسامية مخبرياً. تمكنا من خلال هذه التقنية تحقيق هدف البحث والتنبؤ بالقيم المرغوبة، بحيث حققت دقة عالية جداً بلغت قيمتها الوسطية حوالي 98%، مما يعزز أهميتها في الصناعات النفطية والتقييم الخزني، وبالتالي يؤمن مخرجات ذات موثوقية عالية ويوفر الجهد والمال والزمن.

المراجع:

- [1] 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.
- [2] Schlumberger, 1989. Log Interpretation Principles/Applications, vol. 5, P241.
- [3] Ellis, D., Singer, J. (2008). Well logging for Earth scientists, second edition, P699. Rider. Malcolm, 2002,4.
- [4] The Geological Interpretation Of Well Logs 2nd Edition, Whittles Publishing, Scotland
- [5] الشركة السورية للنفط (2008) الخارطة العميقة لتشكيلة الكوراشينا دولوميت في تركيب أبو رياح - دراسة غير منشورة.
- [6] Ponikarov, V. (1966). Te geology of Syria, Explanatory notes on map of Syria, scale 1:200000, Damascus, Ministry Industry, Syrian Arab Republic.
- [7] Brew, G., Litak, R., Seber, D., Barazangi, M., Al-Imam, A., and Sawaf, T., (1997)- Basement depth and sedimentary velocity structure in the northern Arabian platform, eastern Syria. Geophys. Jour. International, 128, 617-631.
- [8] Chaimov, T., Barazangi, M., Al Saad, D., Sawaf, T. and Gebran, A., (1990)- Crustal shortening in the Palmyride fold belt, Syria, and implications for movement along the Dead Sea fault system. Tectonophysics, V.9, n.6, pp.1369-1386.
- [9] 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.
- [10] 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.
- [11] Sultan, M. Z. B. , Howladar, M. F. (2013). Permeability Modeling from well logs using artificial neural networks,

- Bangladesh, Mechanical Engineering Research Journal, Vol. 9, pp. 100-103
- [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 سارابا النفطية - أطروحة ماجستير - جامعة دمشق.
- [16] Help Interactive Petrophysics V3.5,1,2 Senergy, 2008
- [17] أ. بحبوح، (2009). توظيف الذكاء الصناعي في امثلة أداء نظم المعطيات الصناعية الموزعة، أطروحة دكتوراه، دمشق، الفصل 1، ص 22.
- [18] Russell, S.J., Norvig, P. (2013). Artificial Intelligence A Modern Approach, Third Edition, New Jersey, vol.1, p.1154.
- [19] Salehi, M.M. et al. (2016). Estimation of the non-records logs from existing logs using artificial neural networks, Egypt, Egyptian Journal of Petroleum.
- [20] Patniyot, S., Romero, P.A., APPLICATION OF CORE-LOG correlation and artificial neural networks to better define permeability porosity and lithology, sca-9836.
- [21] Karraz, G. (2006). Electrocardiogram signal automatic analysis, Doctoral Thesis, University of Pavia, Italy, vol.7, pp 75-83.